

# 基于深度残差定点网络的太赫兹 UM-MIMO 系统信道估计算法

于舒娟<sup>1</sup>, 魏玉尧<sup>1</sup>, 蔡良隆<sup>1</sup>, 卢宏宇<sup>1</sup>, 张昀<sup>1</sup>, 赵生妹<sup>2</sup>

(1. 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;

2. 南京邮电大学通信与信息工程学院, 江苏南京 210003)

**摘要:** 针对 THz 超大规模 MIMO 系统中的混合场和波束偏移效应带来的信道估计难题, 提出了基于深度学习的不动点正交近似消息传递残差自注意 (FPN-OAMP-SRLG) 算法。利用坐标注意力与部分通道移位提出深度残差块 (BSRB) 和门控线性自注意力 (SARG), 构建了特征提取网络 SRLG, 并结合 FPN-OAMP 框架, 将信道估计问题建模为图像恢复问题。以最小二乘算法估计后的导频信息作为输入特征, 通过 FPN-OAMP-SRLG 中线性估计器和非线性估计器迭代来恢复信道状态信息。仿真表明, 所提算法不仅能高精度地估计 THz 信道, 且具有较快的收敛速度和良好的鲁棒性。

**关键词:** 信道估计; THz 超大规模 MIMO 系统; 深度残差块; 注意力机制

**中图分类号:** TN92

**文献标志码:** A

**DOI:** 10.11959/j.issn.1000-436x.2025093

## THz UM-MIMO system channel estimation algorithm based on deep residual block fixed-point network

YU Shujuan<sup>1</sup>, WEI Yuyao<sup>1</sup>, CAI Lianglong<sup>1</sup>, LU Hongyu<sup>1</sup>, ZHANG Yun<sup>1</sup>, ZHAO Shengmei<sup>2</sup>

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

2. School of Communications and Information Engineering, Nanjing University of Posts and Telecommunications, Nanjing 210003, China

**Abstract:** To mitigate the channel estimation challenges induced by hybrid near-far field and beam squint effects in THz ultra-massive MIMO systems, a deep learning-based FPN-OAMP-SRLG algorithm was proposed. A feature extraction network SRLG was constructed by developing a deep residual block (BSRB) with coordinate attention and partial channel shift, along with a gated linear self-attention module (SARG). The channel estimation problem was formulated as an image restoration task through integration with the FPN-OAMP framework. The algorithm utilized pilot information, estimated via the least squares method, as input features and recovered channel state information through iterative linear and nonlinear estimators. Simulation results demonstrate that the proposed algorithm achieves high-precision THz channel estimation, exhibiting fast convergence and robust performance.

**Keywords:** channel estimation, THz ultra-massive MIMO system, deep residual block, attention mechanism

### 0 引言

在通信技术持续演进的背景下, 太赫兹 (THz, terahertz) 频段通信凭借其巨大可用带宽, 成为 6G 及未来通信发展的关键技术<sup>[1]</sup>。根据弗里

斯传输公式, 天线接收功率与传输信号频率的平方成反比, 这导致高频的 THz 信号在传输中存在严重损耗, 极大地制约了太赫兹通信技术的实际应用与推广。超大规模多输入多输出 (UM-MIMO, ul-

收稿日期: 2025-03-28; 修回日期: 2025-05-14

通信作者: 魏玉尧, 2681709197@qq.com

基金项目: 国家自然科学基金资助项目 (No.62375140)

**Foundation Item:** The National Natural Science Foundation of China (No.62375140)

tra massive multiple input multiple output) 系统通过在小区内密集封装大量天线, 形成尖锐波束以补偿传播损失<sup>[2]</sup>, 是一种能有效应对信号路径损耗的方案。

在 THz 系统中, 大量天线单元 (AE, antenna element) 被集成在几平方毫米的空间, 且天线间距与波长相当, 这增加了天线阵列控制的复杂性<sup>[3]</sup>, 限制 UM-MIMO 系统的波束形成和复用增益。因此, 文献[4]提出了将大型天线阵划分为多个小尺寸子阵列 (SA, subarray) 的平面子阵列 (AOSA, array-of-subarray) 架构。SA 间的距离远大于波长, 且集成多个 AE, 降低了每个 AE 的发射功率。

在 AOSA 架构中, 天线单元间距大且分布不均, 阵列孔径大且工作波长短, 导致混合场信道问题凸显<sup>[5]</sup>。根据电磁传播理论, 通信距离超过瑞利距离时, 信道遵循球面波模型; 小于瑞利距离时, 遵循平面波模型。当前多数信道估计算法基于近场或远场均匀阵列的理想假设设计, 难以高效、准确地估计 AOSA 平面中 THz UM-MIMO 系统的复杂混合场信道, 无法满足实际应用需求。但是, 对于无线通信系统而言, 获取精确的信道状态信息是后续预编码等相关工作的关键。此外, 在 AOSA 架构下, 由于基站 (BS, base station) 配备数量庞大的天线, 若采用最小二乘 (LS, least square) 法、最小均方误差 (MMSE, minimum mean square error) 等标准方法进行信道估计, 则需要巨大的开销。

文献[6-7]基于压缩感知技术来降低信道估计开销, 然而其分别假设在均匀的近场和远场信道环境下。在实际 THz UM-MIMO 系统的混合场信道中, 上述基于单一类型均匀场假设的算法会面临信道特征不匹配、准确率大幅下降的问题。为解决上述问题, 文献[8]提出了混合场正交匹配追踪 (HF-OMP, hybrid-field orthogonal matching pursuit) 算法, 然而该算法精度不足, 不能有效解决混合场问题。其他基于贝叶斯的算法虽然能够接近贝叶斯最佳性能, 但存在难以承受的迭代收敛时延<sup>[9]</sup>。

在 UM-MIMO 系统中, 不同子载波波束的物理方向发生偏移, 产生不同的到达角和出发角, 即波束斜视现象。而现有算法 (如文献[6-7,10]) 都基于到达角和出发角相同的假设, 且仅考虑了相位差, 忽略了不同天线接收信号之间的时延差, 因此

在 UM-MIMO 系统中性能大幅降低。文献[11]基于真时延器来抑制波束斜视, 带来了额外的硬件成本。文献[12]虽然降低了器件的硬件缺陷, 但仅侧重于入射角估计, 忽略了时延等参数。

深度学习 (DL, deep learning) 被认为是通信系统各种应用的关键技术<sup>[13]</sup>。通过使用 DL 训练具有预定义目标函数的神经网络模型, 可以学习适应真实世界数据的特征, 并且训练后的模型可以实时执行预测, 复杂度较低<sup>[9]</sup>。在相关研究中, 采用模型驱动<sup>[14]</sup>的方法将深度学习与传统估计方法相结合, 能够充分利用测量矩阵, 提高算法的可解释性。文献[15]将 LS 算法对信道初步估计的结果作为图像信息输入卷积神经网络, 以提取信道特征。文献[16]创新性地将信道时频响应看作二维图像, 开创了利用 DL 的超分辨率和图像恢复技术进行信道估计的新思路。文献[17]提出了一种基于深度学习的宽带混合预编码网络来解决波束斜视问题。文献[9]提出了一种基于知识和数据双驱动的深度学习方法, 在具有混合信道和严重波束斜视的 UM-MIMO 系统中取得良好的性能。针对 THz UM-MIMO 系统, 文献[18]提出了一种由线性估计器和深度学习非线性估计器构成的不动点网络结构, 并用理论证明了该网络结构的高速收敛性、稳定性和低复杂度。

相比于现有方法, 采用 DL 处理混合场信道和波束偏移问题的显著优势主要体现在非线性建模能力、动态自适应机制以及低复杂度的快速收敛能力。混合场信道中信号的传播路径模型为球面模型和平面模型混合, 传统基于稀疏贝叶斯学习的算法具有很高的复杂度, 迭代收敛需要的时间是实际无法承受的。通过使用 DL 训练具有预定义目标函数的神经网络模型, 可以学习适应真实世界数据的特征, 并且训练后的模型可以实时执行预测, 复杂度较低<sup>[9]</sup>。DL 是一种端到端方法, 不需要任何模型假设, 通过使用残差神经网络<sup>[19]</sup>和自注意力机制<sup>[20]</sup>, 能够从高维数据中自适应捕捉混合场信道的非均匀特性, 得到更精确的估计结果。针对波束斜视问题, 传统基于真时延器或混合预编码的方法无法同时关注入射角、时延、相位差等全部参数, 并且受到器件灵敏度和硬件成本的限制。深度学习神经网络可自适应地学习信道的特性, 从时变信道状态中实时预测波束偏移

角度, 提取角域和时域中固有的非线性特征<sup>[21]</sup>。DL 对硬件没有灵敏度要求, 也不需要模型中增加硬件成本。此外, 深度学习通过将简单估计方法 (如 LS) 的结果作为输入, 约束神经网络训练, 形成数据-模型驱动优化范式。这种范式既能减少对标注数据的依赖, 又能解决纯数据驱动方法的可解释性缺陷<sup>[14]</sup>。

受上述文献启发, 为了进一步增强神经网络捕获传播场景的高维特征, 自适应捕捉混合场信道非均匀特性的能力, 本文提出了提取残差特征能力更强的残差块, 以及注意力机制; 为了保证算法的高速收敛性和稳定性, 引入了不动点框架。最终, 基于深度学习的方法, 本文将信道估计转换为图像超分辨率问题, 并基于不动点结构构建了改进的 THz UM-MIMO 信道估计系统, 如图 1 所示。本文主要贡献总结如下。

1) 提出基于深度蒸馏特征的具有双向通道转移的残差块网络 (BSRB, bi-directional shifting residual block), 出于模块轻量级设计考量, BSRB 舍弃批归一化层, 降低模型复杂度与计算量, 使网络结构更精简; 为缓解神经元死亡问题, 采用 Leaky ReLU 函数作为激活函数以缓解; 为增强特征提取能力, 融入坐标注意力机制, 提升捕获跨通道信息的水平; 在不增加复杂度的情况下, 对输入特征进行部分信道移位处理, 促进数据泛化, 增强模块抗过拟合能力, 提升模型在不同数据分布下的稳定性和泛化性能。

2) 本文构建了 SARG (self-attention with ReLU gated linear unit) 注意力机制模块, 并结合 BSRB 残差块, 创新地提出可与传统估计方法结合的特征

提取网络 SRLG。作为深度神经网络, SRLG 在特征提取上优势显著, 能有效解决 AOSA 中的混合信道估计问题; 通过数据驱动训练, SRLG 不依赖信道先验结构, 可应对复杂信道特性, 包括波束斜视问题; 深度学习的低复杂性使 SRLG 能降低计算资源消耗和系统总体开销, 提升信道估计的准确性与稳定性。

3) 在 THz 信道估计系统中引入将 SRLG 网络, 并基于正交近似消息传递 (OAMP, orthogonal approximate message passing)<sup>[22]</sup>和 FPN-OAMP (fix point network OAMP)<sup>[18]</sup>2 种框架, 分别提出了 OAMP-SRLG 和 FPN-OAMP-SRLG 这 2 种模型驱动的信道估计模型。2 种模型以系统模型的信道矩阵初步估计的结果作为输入, 依次经过线性估计器 (LE, linear estimator) 和非线性估计器 (NLE, non-linear estimator), 通过 LE 和 NLE 交替迭代优化, 直至算法收敛, 最终得到高精度的估计结果。

## 1 系统模型

本文考虑文献[18]中采用平面 AOSA 架构的 THz UM-MIMO 系统的上行链路, 每个 BS 配备了  $\sqrt{M} \times \sqrt{M}$  个 SA, 每个 SA 为  $\sqrt{N} \times \sqrt{N}$  个 AE 组成的均匀平面阵列 (UPA, uniform planar array)。如图 2 所示, AOSA 中第  $m$  行、第  $n$  列的 SA 中第  $\bar{m}$  行、第  $\bar{n}$  列的 AE 的坐标  $p_{m,n,\bar{m},\bar{n}}$  可建模为

$$p_{m,n,\bar{m},\bar{n}} = \begin{pmatrix} (m-1) \left[ (\sqrt{N}-1)d_a + d_{sub} \right] + (\bar{m}-1)d_a \\ (n-1) \left[ (\sqrt{N}-1)d_a + d_{sub} \right] + (\bar{n}-1)d_a \\ 0 \end{pmatrix} \quad (1)$$

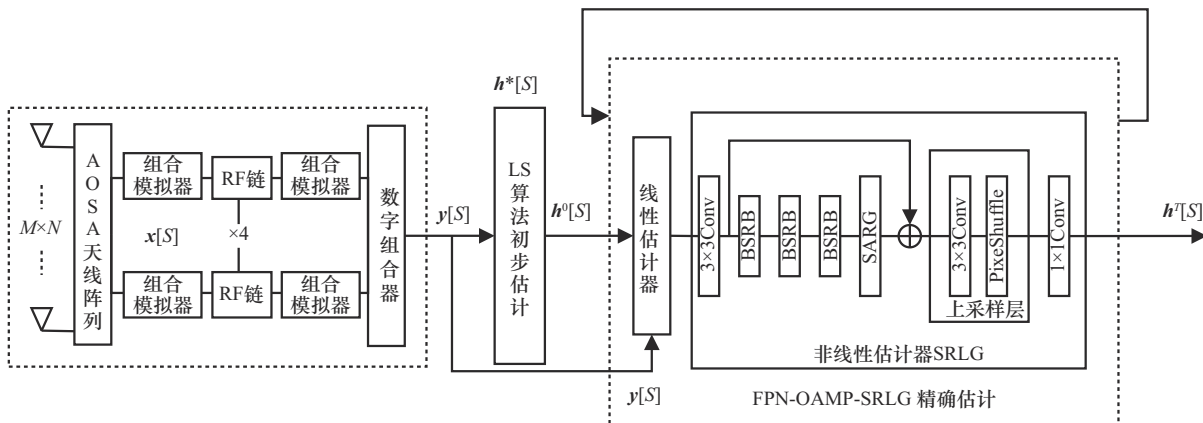


图 1 改进的 THz UM-MIMO 信道估计系统

其中,  $d_a$  为相邻 AE 的间距,  $d_{\text{sub}}$  为相邻 SA 的间距。




图2 平面AoSA结构

为了降低硬件开销和功耗, 本文采用了部分连接的混合模数结构, 每个 SA 中的 AE 通过移相器共享一个射频 (RF, radio frequency) 链, 共有  $M$  个 RF 链被用来接收来自多个单天线用户的数据流。

本文考虑一个中心频率为  $f_c$ 、带宽为  $B$ 、子载波数为  $S$  的 THz UM-MIMO 系统, 第  $s$  个子载波的基带频率  $f_s$  为

$$f_s = f_c + \left( s - 1 - \frac{S-1}{2} \right) \frac{B}{S}, s = 1, 2, \dots, S \quad (2)$$

对于 BS 和第  $k$  个用户 ( $k = 1, 2, \dots, K$ ) 间的第  $s$  个子载波, 由于 THz 波的有限散射, BS 和用户之间的空间频率信道响应  $\mathbf{h}_{k,s}$  可用一个视距 (LoS, line of sight) 信号和  $L-1$  个非视距 (NLoS, non line of sight) 信号叠加表示<sup>[7]</sup>, 表达式为

$$\mathbf{h}_{k,s} = \sum_{l=1}^L \beta_{k,l}(f_s) \mathbf{a}_{k,l}(\phi_{k,l}, \theta_{k,l}, r_{k,l}, \tau_{k,l,s}) e^{-j2\pi f_s \tau_{k,l,s}} \quad (3)$$

其中,  $f_s$ 、 $\phi_{k,l}$ 、 $\theta_{k,l}$ 、 $r_{k,l}$ 、 $\tau_{k,l,s}$  分别表示子载波的频率、第  $l$  条路径的方位角、仰角、用户与天线的距离、时延,  $\beta_{k,l}(f_s)$  和  $\mathbf{a}_{k,l}(\phi_{k,l}, \theta_{k,l}, r_{k,l}, f_s)$  分别表示第  $l$  条路径的路径衰退函数和第  $l$  条路径的阵列响应矢量。

$$\beta_{k,l}(f_s) = \Gamma_{k,l} \frac{c}{4\pi(f_s)r_{k,l}} e^{-\frac{1}{2}k_{\text{abs}}(f_s)r_{k,l}} \quad (4)$$

其中,  $\Gamma_{k,l}$  为反射系数<sup>[18]</sup>, 对于 LoS 信号为 1;  $k_{\text{abs}}$  为分子吸收系数<sup>[7]</sup>;  $c$  为光速。

$$\mathbf{a}_{k,l}(\phi_{k,l}, \theta_{k,l}, r_{k,l}, f_s) = \begin{cases} e^{-j2\pi \frac{f_s}{c} \|\mathbf{p}_{m,n,\bar{m},\bar{n}} - r_{k,l} \mathbf{t}_l\|_2}, r_{k,l} < D \\ e^{-j2\pi \frac{f_s}{c} (\mathbf{p}_{m,n,\bar{m},\bar{n}}^\top - \mathbf{t}_l)}, r_{k,l} \geq D \end{cases} \quad (5)$$

$$\mathbf{t}_{k,l} = \left( \sin \theta_{k,l} \cos \phi_{k,l}, \sin \theta_{k,l} \sin \phi_{k,l}, \cos \theta_{k,l} \right)^\top \quad (6)$$

其中,  $D$  为瑞利距离,  $\mathbf{t}_{k,l}$  为路径方向上的单位长度矢量,  $\|\mathbf{p}_{m,n,\bar{m},\bar{n}} - r_{k,l} \mathbf{t}_l\|_2$  为 AE 和 RF 链之间的精确距离,  $\mathbf{p}_{m,n,\bar{m},\bar{n}}^\top - \mathbf{t}_l$  为前者的一阶泰勒展开式。

图 1 展示了相邻  $S$  个子载波的信道估计过程, 对于任意的用户, 用  $\mathbf{x}_p[S]$  表示时隙  $p$  处的发射导频信号,  $\mathbf{y}_p[S] \in \mathbb{C}^{M \times 1}$  表示 BS 在时隙  $p$  处的接收导频信号<sup>[18]</sup>, 即

$$\mathbf{y}_p[S] = \mathbf{W}_p^H (\tilde{\mathbf{h}}[S] \mathbf{x}_p[S] + \mathbf{n}_p[S]) = \mathbf{W}_p^H \mathbf{F} \bar{\mathbf{h}}[S] \mathbf{x}_p[S] + \mathbf{W}_p^H \mathbf{n}_p[S] \quad (7)$$

其中,  $\mathbf{W}_p^H$  为图 1 中模拟与数字组合器的混合的共轭矩阵,  $\tilde{\mathbf{h}}$  为 BS 和用户之间的空间频率信道响应,  $\mathbf{n}_p[S]$  为加性白高斯噪声,  $\mathbf{F}$  为信道的字典学习矩阵, 用于将信道转换为其稀疏表示。平面 AoSA 中的每个 SA 均为几何结构相同的 UPA, 可采用逐子阵列的方式设计整体字典矩阵。在远场路径中, 阵列响应是 AE 索引的线性函数, 可采用基于离散傅里叶变换 (DFT, discrete Fourier transform) 的字典。不同于传统压缩感知方法显示依赖稀疏表示, DL 方法通过神经网络隐式学习信道结构, 对字典选择的敏感性更低。因此, 本文直接采用基于 DFT 的学习字典作为混合场字典<sup>[18]</sup>。

经过  $P$  个时隙后, 接收到的导频信号可表示为

$$\mathbf{y} = \mathbf{A} \mathbf{h} + \mathbf{n} \quad (8)$$

其中,  $\mathbf{y} = [\mathbf{y}_1^\top[S], \dots, \mathbf{y}_P^\top[S]]^\top \in \mathbb{C}^{MP \times 1}$  为  $P$  个时隙后的接收导频信号,  $\mathbf{A} = [(\mathbf{W}_1^H \mathbf{F})^\top, \dots, (\mathbf{W}_P^H \mathbf{F})^\top]^\top \in \mathbb{C}^{MP \times MN}$  为信道观测矩阵,  $\mathbf{n} = [(\mathbf{W}_1^H \mathbf{n}_1[S])^\top, \dots, (\mathbf{W}_P^H \mathbf{n}_P[S])^\top]^\top \in \mathbb{C}^{MP \times 1}$  为噪声矩阵。

## 2 基于 SRLG 网络的信道估计

针对上述的系统模型, 本文提出了模型驱动的 FPN-OAMP-SRLG 算法。1) 初步估计部分的主要目标是生成便于神经网络快速收敛的初始值。为降低初始估计的复杂度, 并考虑到信道先验信息 (如噪声分布) 未知的情况, 本文采用 LS 估计进行初步信道估计, 以 LS 估计的结果作为 SRLG 测量矩阵的初始值。2) 精确估计部分是基于 SRLG 网络, 结合 OAMP 和 FPN-OAMP 提出了 2 个基于 SRLG 的模型用于信道估计。

系统的流程是: 首先以 LS 作为初步估计器,

估计系统模型输出的载波导频信号  $y[S]$ , 得到信道的初步估计值  $h^0[S]$ ; 然后将  $y[S]$  和  $h^0[S]$  作为 SRLG 模型的初始输入, 经多次迭代后得到最终信道估计值  $h^T[S]$ 。

### 2.1 SRLG 网络结构

本文利用提出的 BSRB 残差块和 SARG 注意力机制模块, 结合上采样层构建全新的 SRLG 网络, 如图 3 所示。




图 3 SRLG 网络结构

SRLG 的第一部分由特征提取卷积、深度特征残差块 BSRB 和 SARG 注意力模块组成。首先采用  $3 \times 3$  的二维卷积核, 通过卷积层将输入图像的特征通道数扩展至 64, 然后用 BSRB 对拓展后的特征向量进行深度特征提取, 最后引入 SARG 注意力模块为不同特征信息动态分配权重, 使学习更高效。

第二部分将拓展通道数后的特征向量和 SARG 动态分配权重后的信息输入上采样层。上采样层通过  $3 \times 3$  的卷积将特征的通道数增大到 128, 再通过上采样因子为 2 的反卷积压缩通道以获得更精确的通道特征, 最后采用  $1 \times 1$  的卷积核将特征映射为输出特征的形状, 得到输出特征图。

### 2.2 BSRB 残差块

在视觉任务中, 残差块通常使用批归一化层 (BN, batch normalization) 标准化每层输入的均值和方差, 以此缓解梯度消失/爆炸问题, 加速网络收敛。因为图像语义主要依赖幅度特征, 对相位信息不敏感, BN 对输入数据的线性变换不会破坏关键特征, 分布偏移对性能影响较小。太赫兹信道数据是相位敏感的, BN 基于小批量数据的局部统计量估计会与信道真实分布产生显著偏差, 进而引入归一化误差, 破坏信道矩阵。而且 BN 层的引入会产生与卷积层参数量相当的额外参数, 故本文在设计 BSRB 残差块时去除了 BN 层。为应对缺失 BN 可能引发的“神经元死亡”(ReLU 函数在  $x < 0$  时梯度为 0, 神经元参数无法更新), BSRB 采用激活函数 Leaky ReLU (在负区间保留微小梯度) 替代

ReLU, 防止信道中部分神经元永久失活, 同时避免对相位信息进行截断式非线性变换。图 4 展示了 BSRB 网络结构。




图 4 BSRB 网络结构

BSRB 引入坐标注意力 (CA, coordinate attention) [23], 通过方向感知与跨通道优化适配太赫兹信道。CA 的轻量化结构 (坐标分解、零参数量) 高效支持超大规模天线的高维数据处理, 满足低复杂度提取信道特征的要求。CA 结构如图 5 所示。

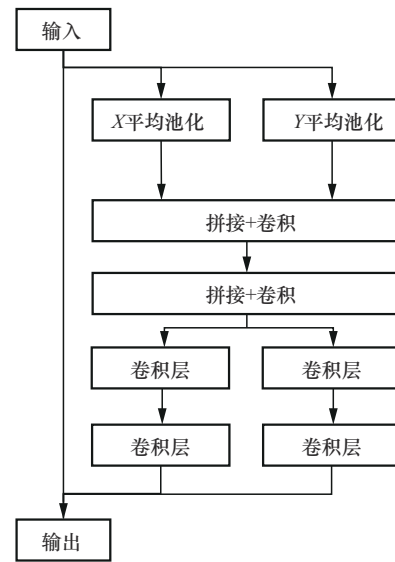


图 5 CA 结构

BSRB 模块的部分信道移位 (PSC, partial channel shifting) [24] 技术通过双向通道位移, 直接建模信道收发过程可能出现信道信息错位, 零填充则保持信道矩阵的完整性。PSC 通过特征错位增强信道中多径成分的多样性, 抑制模型对固定阵列模式的过拟合, 增强了网络的泛化能力, 同时避免传统数据增强所带来的计算开销。图 6 为 PSC 双向偏移示意, PSC 丢弃了位移后凸出于特征网格的部分, 同时对产生的空白区域进行零填充, 以保持整体结构的完整性。




图6 PSC双向偏移示意

### 2.3 SARG 注意力模块

SARG 注意力模块专为超大规模太赫兹 UM-MIMO 系统的信道估计需求设计，其核心在于通过领域优化的自注意力机制与门控单元协同工作，实现对信道方向性及复数特性的高效建模，结构如图 7 所示。

SARG 左半部分采用自注意力机制<sup>[25]</sup>，利用  $1 \times 1$  卷积将输入特征通道拓展至 3 倍，并分割为 Query ( $Q$ )、Key ( $K$ ) 和 Value ( $V$ ) 矩阵，Attn 的输出结果可以表示为

$$\text{Attn}(Q, K, V) = \text{softmax}\left(\frac{QK^T}{\sqrt{d}}\right)V \quad (9)$$

其中， $Q$  矩阵表征接收端对空间方向或路径的主动搜索，如聚焦视距路径的到达角； $K$  矩阵则映射发送端天线的空间响应特性，通过  $QK^T$  计算接收与发送方向的空间匹配程度，从而捕捉多径信号的能量相关性； $V$  矩阵携带信道响应的复数幅相信息，通过注意力权重加权，强化有效路径增益并抑制噪声干扰。 $\text{softmax}$  的稀疏权重分配仅对少数主导路径分配显著权重，适配信道低秩特性。

SARG 右半部分为改进过的门控线性单元 Re-

GLU<sup>[26]</sup>，通过双全连接层分别提取信道特征，其中一路经 ReLU 激活后与另一路进行点乘。

$$\text{ReGLU}(x, w_1, b_1, w_2, b_2) = \text{ReLU}(w_1x + b_1) \otimes (w_2x + b_2) \quad (10)$$

其中， $x$  为输入向量， $w_1, w_2$  和  $b_1, b_2$  分别为 2 个全连接层的权重和偏置， $\text{ReLU}(\cdot)$  为激活函数 ReLU。

这一设计动态调节特征的非线性表达能力，抑制混合场（近场/远场）信道畸变引发的冗余特征，同时增强对波束斜视效应下到达角不同于出发角，以及相位差变化的拟合能力。

SARG 模块输出通过残差连接与层归一化实现稳定训练

$$\begin{aligned} y_1 &= y_{in} + \text{Attn}(y_{in}) \\ y_2 &= \text{ReGLU}(\text{LN}(y_1)) \\ \text{SARG}(y_{in}) &= \text{LN}(y_2 + \text{LN}(y_1)) \end{aligned} \quad (11)$$

其中， $y_{in}$  为输入特征， $\text{Attn}(\cdot)$  为 Attn 模块， $\text{ReGLU}(\cdot)$  为 ReGLU 模块， $\text{LN}(\cdot)$  为层归一化。

### 2.4 SRLG 模型

本文采用模型驱动算法，将 SRLG 引入 THz 信道估计系统中。第一阶段，以 LS 为初步估计器，通过输入导频信道  $y[S]$  获得信道的初步估计  $h^0(S)$ 。第二阶段，嵌入了 SRLG 网络的 OAMP-SRLG 或 FPN-OAMP-SRLG 框架以  $h^0(S)$  和  $y[S]$  为输入，进行数次迭代后得到信道信息  $h^T(S)$ 。

OAMP 是一种解决信道估计问题的高效压缩感知算法，由去相关线性估计 (LE) 和无散度非线性估计 (NLE) 组成，结构如图 8 所示。

LE 部分采用原 OAMP 中 LE 区相关矩阵的伪逆形式，因为其仅需计算一次，且在每次迭代过程不变，具有较低的计算成本，形式为

$$u^{T+1}(S) = f(h^T(S), y(S)) = h^T(S) + W^T(y(S) - Ah^T(S)) \quad (12)$$

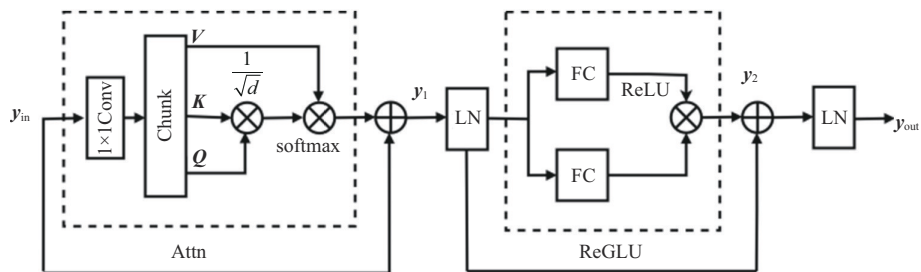


图7 SARG注意力模块结构

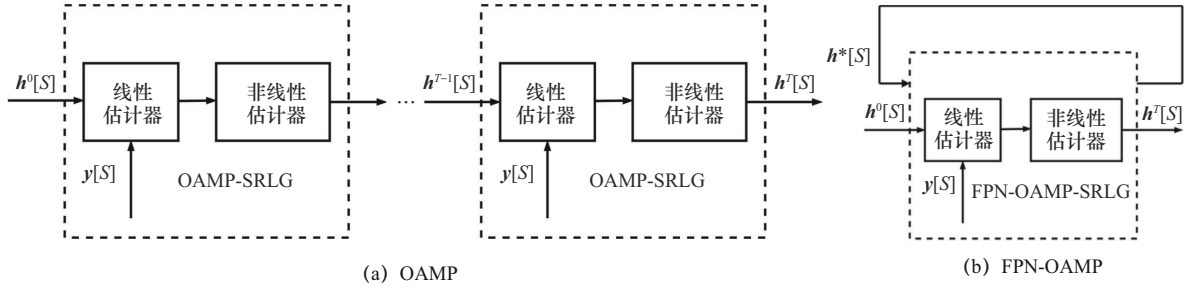


图 8 OAMP 和 FPN-OAMP 流程

其中,  $\mathbf{u}^{T+1}(S)$  为第  $T+1$  层 LE 的输出结果,  $\mathbf{h}^T$  为第  $T$  层 NLE 输出的信道状态,  $\mathbf{y}(S)$  为导频信号,  $\mathbf{A}$  为信道观测矩阵,  $\mathbf{W}^T$  为 LE 去相关矩阵<sup>[7]</sup>, 形式为

$$\mathbf{W}^T = \mu \mathbf{A}^\dagger = \frac{2MN}{\text{tr}(\mathbf{A}^\dagger \mathbf{A})} \mathbf{A}^\dagger \quad (13)$$

其中,  $\mathbf{A}^\dagger$  为信道观测矩阵  $\mathbf{A}$  的伪逆变化,  $\text{tr}(\cdot)$  表示求矩阵的迹,  $\mu$  为保证  $\text{tr}(\mathbf{I} - \mathbf{W}\mathbf{A}) = 0$  去相关条件成立的步长。

本文将 NLE 部分转换为图像超分辨率问题来处理<sup>[16]</sup>, 将信道响应数据的实部和虚部按照  $\begin{bmatrix} \text{Re} & -\text{Im} \\ \text{Im} & \text{Re} \end{bmatrix}$  形式拼接为  $\sqrt{N} \times \sqrt{N}$  的张量, 通道数为  $2M$ 。以如此处理过的数据为输入特征图, 输入如图 8 所示的 NLE 结构中训练, 形式为

$$\mathbf{h}^{T+1}(S) = f_{\text{NLE}}(\mathbf{u}^{T+1}(S)) \quad (14)$$

其中,  $f_{\text{NLE}}(\cdot)$  为 SRLG 神经网络。

以上为 OAMP-SRLG 模型, 同理, 本文依照 FPN-OAMP 的结构构造了 FPN-OAMP-SRLG 模型。2 种算法的主要区别在于 OAMP-SRLG 基于固定层数的 LE 和 NLE 组合进行迭代, 而 FPN-OAMP-SRLG 则基于同一组 LE 和 NLE 进行迭代。后续的实验结果证明, FPN-OAMP-SRLG 继承了 FPN 框架的稳定性以及收敛性, 详细理论证明可参考文献<sup>[18]</sup>。

### 3 实验及结果分析

#### 3.1 实验设置

实验采用的 THz UN-MIMO 系统主要参数如表 1 所示, 其中,  $r_{k,l}$  设置为均匀分布的随机变量, 涵盖远场和近场区域。本文生成了低信噪比 (SNR) 场景 (0~10 dB) 和高 SNR 场景 (10~20 dB), 每个场景的训练集、测试集和验证集分别包含 80 000、5 000 和 5 000 个样本。

表 1 信道仿真参数

参数名	取值
载波频率/GHz	300
子载波数	32
基站总天线数	1 024
子阵列数	4
单个子阵列天线数	256
天线间距/m	0.000 5
子阵列间距/m	0.056
导频长度	128
欠采样率	0.5
路径方位角	$\phi_l \sim \mathcal{U}\left(-\frac{\pi}{2}, \frac{\pi}{2}\right)$
路径仰角	$\theta_l \sim \mathcal{U}(-\pi, \pi)$
入射角	$\varphi_{i,l} \sim \mathcal{U}\left(0, \frac{\pi}{2}\right)$
总路径数	5
瑞利距离/m	20
LoS 路径长度/m	30
NLoS 散射体距离/m	$r_l \sim \mathcal{U}(10, 25)$
LoS 路径时延/nsec	100
NLoS 路径时延/nsec	$\tau_l \sim \mathcal{U}(100, 110)$
分子吸收系数/ $\text{m}^{-1}$	0.003 3
折射率	2.24-j0.025
粗糙度系数/m	$8.8 \times 10^{-5}$

本节所有与 DL 相关的算法均基于 Pytorch 框架实现, 并采用 Adam 优化器进行了 150 次的训练, 训练和验证样本的信噪比水平在 0 到 20 dB 之间随

机抽取，模型训练参数如表 2 所示。所有实验在配备 NVIDIA GeForce RTX 3080 的 GPU 计算机上完成。

表 2 模型训练参数

参数名	取值
训练集样本/个	80 000
测试集样本/个	5 000
验证集样本/个	5 000
低信噪比/dB	0~10
高信噪比/dB	10~20
周期数	150
学习率	0.001
学习率衰退周期	0.056
学习率衰退的乘法因子	0.5
优化器	Adam

### 3.2 评估标准

为了客观评估本文提出的 OAMP-SRLG 和 FPN-OAMP-SRLG 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

$$NMSE = 10 \lg \left\{ E \left\{ \frac{\|\hat{\mathbf{H}} - \mathbf{H}\|_2^2}{\|\mathbf{H}\|_2^2} \right\} \right\} \quad (15)$$

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

### 3.3 仿真分析

#### 3.3.1 基于不同残差块的 SRLG 的性能对比

在 SRLG 网络中分别嵌入 SRResNet<sup>[27]</sup>、ResNet<sup>[28]</sup>、EDSR<sup>[29]</sup>、RLF<sup>[30]</sup>、RFDB<sup>[30]</sup>，与 BSRB 对比得到的 NMSE 性能如图 9 所示。从图 9 中可以看出，在 0 到 20 dB 的所有信噪比条件下，BSRB 残差块均取得了最好的 NMSE 性能。在所有信噪比条件下，BSRB 的 NMSE 性能相比 SRResNet、ResNet、EDSR、RFDB 和 RLF 分别平均提升了 1.47 dB、1.53 dB、1.25 dB、0.84 dB 和 0.73 dB，且随着信噪比的降低，性能优势进一步扩大。图 9 表明，BSRB 残差块在高噪声干扰环境下具备更为出色的适应性与稳定性，拥有更为显

著的鲁棒性，确保在复杂噪声环境下仍能维持较为优异的网络性能表现。

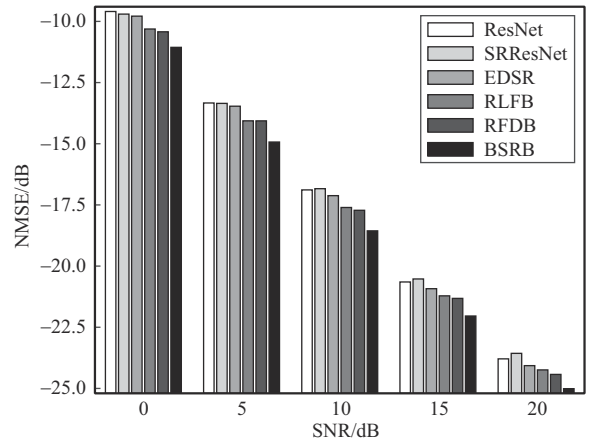


图 9 不同信噪比水平下各残差块的 NMSE 性能

不同残差块的时空复杂度如表 3 所示。从图 9 和表 3 可以看出，BSRB 的参数量和浮点运算数与 SRResNet、ResNet、EDSR 大致相同，测试时间略微增加，而 BSRB 却取得了明显的性能提升。对比 RLF 和 RFDB，BSRB 在参数量和浮点运算数减少的条件下仍取得了巨大的性能优势。综合性能与复杂度，BSRB 具有卓越的性能，在 THz 环境中更具有竞争力。

表 3 不同残差块的时空复杂度

残差块	参数量/个	每轮训练时间/s	测试时间/s	浮点运算数/GB
SRResNet	78 792	68	0.18	2.26
ResNet	74 112	69	0.19	2.26
EDSR	73 856	65	0.18	2.25
RLF	164 352	99	0.36	2.97
RFDB	230 080	120	0.45	4.96
BSRB	78 792	80	0.21	2.38

#### 3.3.2 基于不同注意力模块的 SRLG 的性能对比

不加注意力，以及分别嵌入 CA<sup>[23]</sup>、Galerkin<sup>[31]</sup>、Self-Attention<sup>[25]</sup>、SARG 注意力的 SRLG 网络的 NMSE 性能比较如图 10 所示。由图 10 可得，在所有信噪比条件下，SARG 的 NMSE 性能相比不加注意力、CA、Galerkin、Self-Attention 分别平均提升了 0.98 dB、0.92 dB、0.43 dB 和 0.34 dB。相比不加任何注意力，加入注意力机制的网络均得到

性能提升,且采用SARG注意力在所有信噪比条件下均取得最佳NMSE性能。

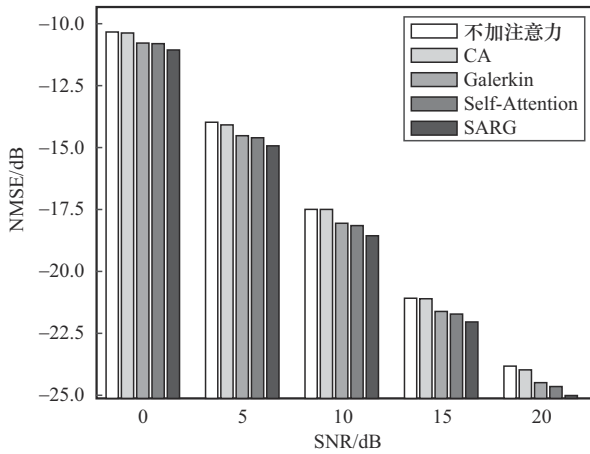


图10 不同信噪比水平下不同注意力NMSE性能

由图10和表4可知, SARG具有和Galerkin、Self-Attention相同的参数量和浮点运算数,却取得了更好的NMSE性能; CA虽具有最低的参数量和浮点运算数,但性能提升较小。因此,综合时间、空间复杂度和浮点运算数, SARG性能更优异,在THz环境更具有竞争力。

表4 不同注意力的时空复杂度

注意力	参数量/个	每轮训练时间/s	测试时间/s	浮点运算数/MB
CA	776	75	0.21	6.25
Galerkin	21 056	79	0.23	640
Self-attention	21 056	80	0.24	640
SARG	21 056	80	0.21	640

### 3.3.3 不同算法性能对比

图11比较了LS、OMP<sup>[6]</sup>、OAMP<sup>[22]</sup>、OAMP-SRLG、ISTA-NET<sup>[32]</sup>、FPN-OAMP和FPN-OAMP-SRLG在不同信噪比水平下的NMSE性能。当SNR=0时, FPN-OAMP-SRLG相比ISTA-NET和FPN-OAMP分别增加了3.72 dB和1.11 dB; 当SNR=20 dB时, FPN-OAMP-SRLG相比ISTA-NET和FPN-OAMP分别增加了7.55 dB和2.30 dB。FPN-OAMP-SRLG性能显著优于所有对比算法,在所有信噪比条件下均取得了最佳的NMSE表现。本文提出的基于模型驱动的DL信道估计算法性能明显优于传统的基于压缩感知和信道稀疏性的算法。

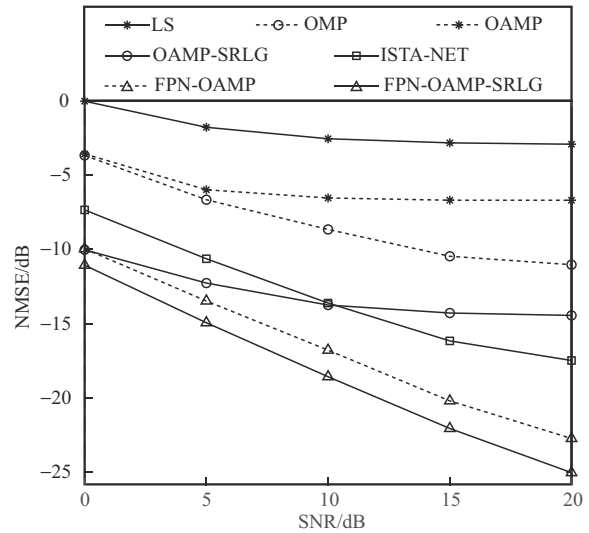


图11 不同信噪比水平下各算法的NMSE性能

使用SRLG模块前后NMSE性能对比如图12所示。从图12可以看出, SRLG模块的引入为OAMP算法带来了显著的性能提升,当SNR=0时,性能增益达到6.4 dB; 当SNR=20 dB时,增益为3.4 dB,并且随着信噪比的降低, SRLG模块对OAMP算法的性能增益逐渐增强。对于FPN-OAMP算法, SRLG模块的加入也在所有信噪比下带来了1.1~2.2 dB的性能提升。这些结果表明, SRLG模块能够有效提取和利用THz UM-MIMO系统的信道结构,并与现有的模型驱动算法具备良好的兼容性,能显著提升模型性能。

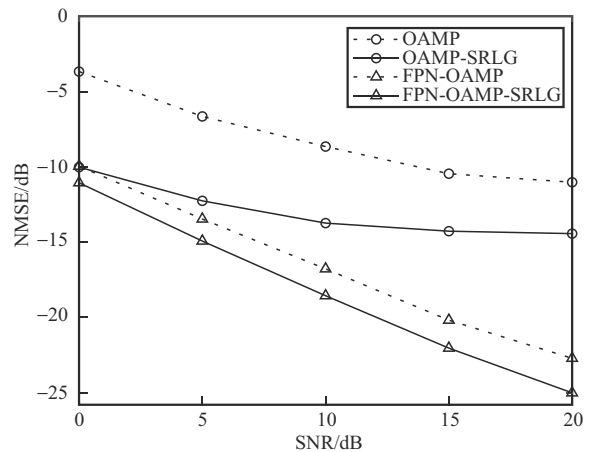


图12 使用SRLG模块前后NMSE性能对比

### 3.3.4 收敛速度对比

当信噪比分别为5 dB和15 dB时,各算法在不同迭代层数时的NMSE如图13和图14所示。LS和OMP为直接计算,不存在迭代过程和中间结果;

ISTA-NET 只保证固定迭代层数后的性能, 无法保证中间层数的性能, 因此没有绘制以上算法的曲线。

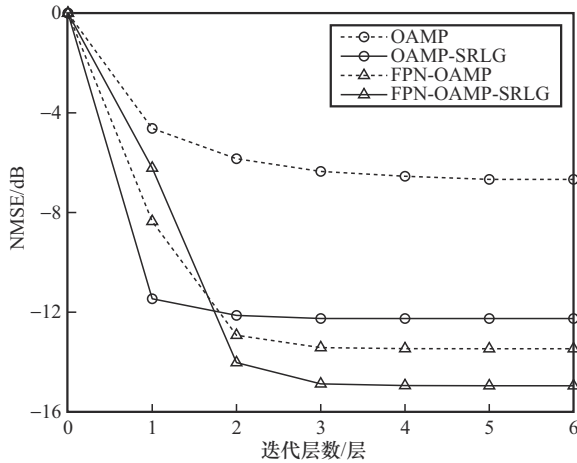


图 13 信噪比为 5 dB 时各算法在不同迭代层数时的 NMSE




图 14 信噪比为 15 dB 时各算法在不同迭代层数时的 NMSE

从图 13 和图 14 中可以看出, 在 2 种信噪比下, OAMP-SRLG 在层数为 1 时就超越了 OAMP 算法收敛后的性能, 并且在层数为 2 后基本达到收敛状态。当信噪比分别为 5 dB 和 15dB 时, FPN-OAMP-SRLG 分别在第二层和第三层迭代后表现出优于所有其他算法的性能, 并依次在第三层和第四层迭代后基本收敛。由图 13 和图 14 可以看出, 4 种算法的性能均随着迭代层数的增加趋于稳定, 最终都稳定收敛, 可见本文提出的算法在加速收敛的同时并未以牺牲稳定性为代价。表 5 显示了各算法单次迭代额外增加的参数量和计算量。基于 OAMP 框架的算法每次迭代均基于不同的 NLE, 故增加迭代层数时也会增加算法的参数量和计算量; 基于 FPN 不动点的算法不需要额外参数, 只会增加计算量; 采用了

SARG 网络的算法会增加更多的参数量和计算量。综合性能和复杂度可得出结论: SRLG 网络不仅带来了性能提升, 同时显著加快了模型的收敛速度, 使算法在更少的迭代层数内即可达到更佳的性能, 但这是以增加每次迭代的浮点运算数为代价的。

表 5 各算法单次迭代增加的参数量与计算量

算法	参数量/个	浮点运算数/GB
OAMP	361 992	7.583
OAMP-SRLG	373 152	9.604
FPN-OAMP	0	7.583
FPN-OAMP-SRLG	0	9.604

### 3.3.5 宽带频域信道的泛化性分析

在实际应用中, 训练和测试数据集的分布可能存在偏移, 这可能会显著影响模型的性能。因此, 本节设置了噪声等级偏移、不同主路径数、LoS 路径阻塞、信号发射阵列和路径损耗模型参数偏移等不同的信道与环境偏移情况。本文通过以上泛化情况验证模型的强大泛化能力 (取 3.3.4 节中 NMSE 性能最优的 FPN-OAMP-SRLG 模型)。

本文重点研究了噪声等级偏移以及信道偏移对模型性能的影响, 在信噪比为 0~10 dB 和 10~20 dB 的训练集上进行训练, 并在信噪比为 -5 dB 和 25 dB 的测试集上评估模型效果。FPN-OAMP-SRLG 在不同场景下的 NMSE 性能如表 6 所示, 以训练集包含测试集信噪比的分组作为基线, 对于低于训练配置的噪声水平, 算法的 NMSE 性能只减少了 0.18 dB, 对于高于训练配置的噪声水平, 算法性能虽降低了 0.38 dB, 但仍具有较高的性能。总体来说, 在噪声水平偏移的情况下, 模型的 NMSE 性能与基线性能整体接近。这表明所提出的算法在面对不同噪声电平变化时表现出良好的鲁棒性。

表 6 FPN-OAMP-SRLG 在不同场景下的 NMSE 性能

训练数据集信噪比/dB	测试数据集信噪比/dB	NMSE/dB
0~10	-5	-6.42
-5~10	-5	-6.60
10~20	25	-27.05
10~25	25	-27.43

此外, 通过扩大训练中的信噪比范围, 模型能够进一步降低性能损失, 适应更广泛的实际应用需求。这些结果显示了 FPN-OAMP-SRLG 模型在复

杂环境下的适应能力和稳定性。

本文根据不同的主路径数生成了多种信道样本,在主路径数  $L = 5$  的数据集上进行训练后,分别在  $L = 3,4,5,6,7$  的测试集上评估效果,可知  $L = 5$  与训练数据集相同,故以  $L = 5$  为基线。如图 15 所示,当  $L = 3,4$  时, NMSE 性能平均优于基线 0.76 dB 和 1.53 dB, 这表明  $L = 3,4$  的情况下信道结构比较简单,更有利于去噪;在  $L = 6,7$  信道结构更加复杂的情况下,基于  $L = 5$  训练的模型性能虽略微下降了 0.41 dB 和 1.05 dB,但仍表现出了优异的性能,具有较好的鲁棒性。




图 15 不同主路径数下的 FPN-OAMP-SRLG 性能

表 7 给出了 FPN-OAMP-SRLG 在 LoS 阻塞时的 NMSE 性能。本文考虑了 LoS 阻塞的影响,由于高穿透损耗, LoS 阻塞的情况经常出现在 UM-MIMO 系统中。模型训练集的信道由一个 LoS 和 4 个 NLoS 路径组成,测试集的信道仅由 4 个 NLoS 路径组成,其中 NLoS 的散射体距离为  $r_{k,l} \sim \mathcal{U}(10,25)$ 。表 7 结果表明, NMSE 性能最高下降 0.15 dB, 平均下降 0.10 dB, FPN-OAMP-SRLG 对于 LoS 阻塞有较强泛化性。

为了验证在远近场不匹配的情况下 FPN-OAMP-SRLG 依然具有良好的性能,本节将表 1 中的散射体距离  $r_{k,l} \sim \mathcal{U}(10,25)$  分别设置为  $r_{k,l} \sim \mathcal{U}(10,20)$  的近场区域和  $r_{k,l} \sim \mathcal{U}(20,35)$  的远场区域,使用基于混合场数据训练的模型在远场和近场数据集上进行测试,结果如表 8 所示。从表 8 中可以看出,在远场和近场条件下, NMSE 性能平均提高了 0.06 dB 和 0.11 dB, 模型取得了比在混合场更好的 NMSE 性能。可见,算法对于场不匹配的信道偏移情况具有强大的泛化能力,且能在近场或远场的均匀场中表现出比混合场更好的性能。

表 9 展示了 FPN-OAMP-SRLG 在不同阵列间距下的 NMSE 性能。在训练集上,将 SA 间距设置为  $56\lambda$ ; 在测试集上,分别设为  $36\lambda$  和  $76\lambda$ 。SA 间距的变化会影响瑞利距离,从而引起场不匹配的副作用

表 7 FPN-OAMP-SRLG 在 LoS 阻塞时的 NMSE 性能

路径状态	NMSE/dB				
	SNR=0 dB	SNR=5 dB	SNR=10 dB	SNR=15 dB	SNR=20 dB
LoS 阻塞	-10.98	-14.89	-18.43	-21.91	-24.86
LoS 非阻塞	-11.06	-14.93	-18.56	-22.04	-25.01

表 8 FPN-OAMP-SRLG 在不同场景下的 NMSE 性能

区域	NMSE/dB				
	SNR=0 dB	SNR=5 dB	SNR=10 dB	SNR=15 dB	SNR=20 dB
近场	-11.15	-14.96	-18.60	-22.11	-25.09
远场	-11.19	-15.03	-18.66	-22.13	-25.14
混合场	-11.06	-14.93	-18.56	-22.04	-25.01

表 9 FPN-OAMP-SRLG 在不同阵列间距下的 NMSE 性能

SA 间距	NMSE/dB				
	SNR=0 dB	SNR=5 dB	SNR=10 dB	SNR=15 dB	SNR=20 dB
$36\lambda$	-11.12	-14.98	-18.62	-22.15	-25.07
$56\lambda$	-11.06	-14.93	-18.56	-22.04	-25.01
$76\lambda$	-10.98	-14.81	-18.44	-21.98	-24.93

(相应的瑞利距离变为 10.40 m 和 33.12 m)。结果显示, SA 间距越小, 瑞利距离减小, 远场范围增大而近场范围减小, NMSE 性能小幅提升。然而, 整体上 NMSE 性能变化仍较为细微, 在如此复杂的场不匹配情况下, 算法依然展现出了较强的泛化性。

表 10 展示了 FPN-OAMP-SRLG 在不同天线间距下的 NMSE 性能。训练集的 AE 间距为  $\frac{\lambda}{2}$ , 测试集的 AE 间距分别为  $\lambda$ 、 $\frac{\lambda}{3}$  和  $\frac{\lambda}{4}$ 。从表 10 中可以看出, 随着天线间距的变化, 虽然模型 NMSE 性能逐渐降低, 但整体变化较为细微 (最高只减少了 0.48 dB), 算法对于阵列天线间距偏移具有较强鲁棒性。

表 11 展示了 FPN-OAMP-SRLG 在不同分子吸收系数下的 NMSE 性能。训练集分子吸收系数为 0.003 3, 测试集则分别为 0.002 3、0.004 3 和 0.005 3。从表 11 中可以看出, 在分子吸收系数不同的情况下, 算法 NMSE 性能几乎没有改变 (最高只减少

了 0.7 dB), 可见算法对不同分子吸收系数造成的不同路径损耗情况具有较强的泛化性。

表 12 展示了 FPN-OAMP-SRLG 在不同 LoS 路径长度下的 NMSE 性能。训练集的 LoS 路径长度为 30 m, 测试集则分别为 10 m 和 50 m。从表 12 中可以看出, 随着 LoS 路径长度的变化, 模型 NMSE 性能整体只产生了细微的变化, 算法对于 LoS 路径长度具有较强的泛化能力。

表 13 展示了 FPN-OAMP-SRLG 在不同欠采样率 (导频长度) 下的 NMSE 性能。训练集的欠采样率为 0.500, 测试集的欠采样率分别为 0.250、0.375、0.625、0.750。由表 13 可知, 当欠采样率增加时, 模型取得了更好的 NMSE 性能, 且性能提升幅度与欠采样率的增加程度呈正相关, 最高提升了 1.70 dB; 当欠采样率为 0.375 和 0.250 时, 模型性能受到了较大影响, 最高下降了 3.01 dB。这些结果表明, FPN-OAMP-SRLG 可以处理更多的接收导频, 但直接推广到比预期少的导频发送的情况会有一定的性能损失。

表 10 FPN-OAMP-SRLG 在不同天线间距下的 NMSE 性能

间距	NMSE/dB				
	SNR=0 dB	SNR=5 dB	SNR=10 dB	SNR=15 dB	SNR=20 dB
$\lambda$	-10.92	-14.78	-18.33	-21.68	-24.75
$\frac{\lambda}{2}$	-11.06	-14.93	-18.56	-22.04	-25.01
$\frac{\lambda}{3}$	-10.97	-14.77	-18.45	-21.86	-24.79
$\frac{\lambda}{4}$	-10.82	-14.61	-18.26	-21.57	-24.53

表 11 FPN-OAMP-SRLG 在不同分子吸收系数下的 NMSE 性能

$K_{abs}$	NMSE/dB				
	SNR=0 dB	SNR=5 dB	SNR=10 dB	SNR=15 dB	SNR=20 dB
0.002 3	-11.13	-14.92	-18.56	-22.05	-25.01
0.003 3	-11.06	-14.93	-18.56	-22.04	-25.01
0.004 3	-11.07	-14.94	-18.56	-22.06	-25.04
0.005 3	-11.02	-14.89	-18.53	-22.04	-24.98

表 12 FPN-OAMP-SRLG 在不同 LoS 路径长度下的 NMSE 性能

LoS 路径长度/m	NMSE/dB				
	SNR=0 dB	SNR=5 dB	SNR=10 dB	SNR=15 dB	SNR=20 dB
10	-11.01	-14.81	-18.54	-22.02	-24.95
30	-11.06	-14.93	-18.56	-22.04	-25.01
50	-11.05	-14.95	-18.57	-22.07	-24.97

表13 FPN-OAMP-SRLG在不同欠采样率(导频长度)下的NMSE性能

欠采样率	NMSE/dB				
	SNR=0 dB	SNR=5 dB	SNR=10 dB	SNR=15 dB	SNR=20 dB
0.250	-8.05	-12.58	-16.21	-19.78	-22.87
0.375	-9.94	-14.01	-17.50	-21.07	-24.05
0.500	-11.06	-14.93	-18.56	-22.04	-25.01
0.625	-12.01	-15.68	-19.41	-22.86	-25.82
0.750	-12.76	-16.25	-20.05	-23.46	-26.36

### 3.3.6 算法时空复杂度分析

表14比较了3种算法的时空复杂度。时间复杂度通过模型每层训练时间和测试时间,以及浮点运算数评估,空间复杂度则通过模型的参数量评估。结果显示,FPN-OAMP-SRLG的参数量与FPN-OAMP接近,而浮点运算数有少量增加;参数量最小的ISTA+在训练时间上却较长。综合来看,FPN-OAMP-SRLG在时间复杂度和空间复杂度上与前代算法相差不大,虽然增加了一定程度的浮点运算数,但实现了显著的性能提升,是一种极具竞争力的方案。

表14 3种算法的时空复杂度

算法模型	参数量/个	每层训练时间/s	测试时间/s	浮点运算数/GB
ISTA+	313 348	73	1.02	103.646
FPN-OAMP	361 992	65	0.16	45.499
FPN-OAMP-SRLG	373 152	80	0.21	57.625

## 4 结束语

本文提出了用于深度学习的残差块网络BSRB和SARG注意力机制,并基于以上模块提出了一种名为SRLG的深度学习特征提取网络。针对THz UM-MIMO系统中的混合场信道估计问题,提出了OAMP-SRLG和FPN-OAMP-SRLG信道估计算法。仿真实验表明,BSRB残差块和SARG注意力机制不仅具有优秀特征提取能力,还能加速模型的收敛;BSRB残差块具有强大的数据泛化能力和抗过拟合能力。SRLG网络能够有效解决AOSA中的波束斜视和混合信道估计问题,通过数据驱动训练,避免了对信道先验结构的依赖,因此在面对复杂的信道特性(如波束斜视)时,能够提供较强的适应性。后续的仿真进一步证明,FPN-OAMP-SRLG取得了优异性能,同时展现出强大的鲁棒性和泛化性。未来工作计划在网络结构设计时进一步考虑THz信道的频率选择性、

空间稀疏性及其他特性,以充分利用信道特性。此外,对NLE部分的转换可能对OAMP的误差正交性条件有所破坏,致使模型未能发挥全部性能,下一步也将基于NLE部分的无发散问题进行优化。

### 参考文献:

- [1] RAPPAPORT T S, XING Y C, KANHERE O, et al. Wireless communications and applications above 100 GHz: opportunities and challenges for 6G and beyond[J]. IEEE Access, 2019, 7: 78729-78757.
- [2] ZHANG J Y, BJÖRNSSON E, MATTHAIIOU M, et al. Prospective multiple antenna technologies for beyond 5G[J]. IEEE Journal on Selected Areas in Communications, 2020, 38(8): 1637-1660.
- [3] SARIEDDEEN H, ALOUINI M S, AL-NAFFOURI T Y. Terahertz-band ultra-massive spatial modulation MIMO[J]. IEEE Journal on Selected Areas in Communications, 2019, 37(9): 2040-2052.
- [4] LIN C, LI G Y L. Terahertz communications: an array-of-subarrays solution[J]. IEEE Communications Magazine, 2016, 54(12): 124-131.
- [5] TARBOUSH S, SARIEDDEEN H, CHEN H, et al. TeraMIMO: a channel simulator for wideband ultra-massive MIMO terahertz communications[J]. IEEE Transactions on Vehicular Technology, 2021, 70(12): 12325-12341.
- [6] LEE J, GIL G T, LEE Y H. Channel estimation via orthogonal matching pursuit for hybrid MIMO systems in millimeter wave communications[J]. IEEE Transactions on Communications, 2016, 64(6): 2370-2386.
- [7] DOVELOS K, MATTHAIIOU M, NGO H Q, et al. Channel estimation and hybrid combining for wideband terahertz massive MIMO systems[J]. IEEE Journal on Selected Areas in Communications, 2021, 39(6): 1604-1620.
- [8] WEI X H, DAI L L. Channel estimation for extremely large-scale massive MIMO: far-field, near-field, or hybrid-field?[J]. IEEE Communications Letters, 2022, 26(1): 177-181.
- [9] WANG K Y, GAO Z, CHEN S, et al. Knowledge and data dual-driven channel estimation and feedback for ultra-massive MIMO systems under hybrid field beam squint effect[J]. IEEE Transactions on Wireless Communications, 2024, 23(9): 11240-11259.
- [10] WANG B L, GAO F F, JIN S, et al. Spatial- and frequency-wideband effects in millimeter-wave massive MIMO systems[J]. IEEE Transactions on Signal Processing, 2018, 66(13): 3393-3406.
- [11] DAI L L, TAN J B, CHEN Z, et al. Delay-phase precoding for wideband THz massive MIMO[J]. IEEE Transactions on Wireless Communications, 2022, 21(9): 7271-7286.
- [12] SHI B H, CHEN N, ZHU X C, et al. Impact of low-resolution ADC on DOA estimation performance for massive MIMO receive array[J]. IEEE Systems Journal, 2022, 16(2): 2635-2638.

- [13] ELDAR Y, GOLDSMITH A, GÜNDÜZ D, et al. Machine learning and wireless communications[M]. Cambridge: Cambridge University Press, 2022.
- [14] HE H, JIN S, WEN C K, et al. Model-driven deep learning for physical layer communications[J]. IEEE Wireless Communications, 2019, 26(5): 77-83.
- [15] 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.
- [16] SOLTANI M, POURAHMADI V, MIRZAEI A, et al. Deep learning-based channel estimation[J]. IEEE Communications Letters, 2019, 23(4): 652-655.
- [17] YUAN Q, LIU H, XU M, et al. Deep learning-based hybrid precoding for terahertz massive MIMO communication with beam squint[J]. IEEE Communications Letters, 2023, 27(1): 175-179.
- [18] 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 on Selected Topics in Signal Processing, 2023, 17(4): 761-776.
- [19] WEI Y, ZHAO M-M, ZHAO M, et al. An AMP-based network with deep residual learning for mmWave beamspace channel estimation[J]. IEEE Wireless Communications Letters, 2019, 8(4): 1289-1292.
- [20] GAO J, HU M, ZHONG C, et al. An attention-aided deep learning framework for massive MIMO channel estimation[J]. IEEE Transactions on Wireless Communications, 2021, 20(8): 5123-5136.
- [21] MA K, WANG Z, TIAN W, et al. Deep learning for mmwave beam-management: state-of-the-art, opportunities and challenges[J]. IEEE Wireless Communications, 2023, 30(4): 108-114.
- [22] MA J, PING L. Orthogonal amp[J]. IEEE Access, 2017, 5: 2020-2033.
- [23] HOU Q, ZHOU D, FENG J, et al. Coordinate attention for efficient mobile network design[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway: IEEE Press, 2021: 10-25.
- [24] ZHANG X, LI T, ZHAO X. Boosting single image super-resolution via partial channel shifting[C]// Proceedings of the IEEE/CVF International Conference on Computer Vision (ICCV). Piscataway: IEEE Press, 2023: 13223-13232.
- [25] VASWANI A, SHAZEER N, PARMAR N, et al. Attention is all you need[C]//Proceedings of the 31st Conference on Neural Information Processing Systems. Piscataway: IEEE Press, 2017: 4-9.
- [26] SHAZEER N. GLU variants improve Transformer [J]. arXiv Preprint, arXiv: 2002.05202, 2020.
- [27] LIU J, ZHANG W J, TANG Y T, et al. Residual feature aggregation network for image super-resolution[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE Press, 2020: 2359-2368.
- [28] HE K, ZHANG X, REN S, SUN J. Deep residual learning for image recognition[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway: IEEE Press, 2016: 27-30.
- [29] LIM B, SON S, KIM H, et al. Enhanced deep residual networks for single image super-resolution[C]//Proceedings of 2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops (CVPRW). Piscataway: IEEE Press, 2017: 136-144.
- [30] KONG F, LI M, LIU S, et al. Residual local feature network for efficient super-resolution[C]//Proceedings of 2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops (CVPRW). Piscataway: IEEE Press, 2023: 766-776.
- [31] CAO S. Choose a transformer: Fourier or Galerkin[C]//Proceedings of the 35th International Conference on Neural Information Processing Systems. Piscataway: IEEE Press, 2021: 6-14.
- [32] ZHANG J, GHAEM B. ISTA-Net: interpretable optimization-inspired deep network for image compressive sensing[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway: IEEE Press, 2018: 1828-1837.

## [作者简介]



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。



魏玉尧 (2004-), 男, 湖南邵阳人, 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。



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。



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。



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。



赵生妹 (1968-), 女, 江苏丹徒人, 博士, 南京邮电大学教授, 主要研究方向为量子通信与信息处理、无线通信与信号处理。