

噪声感知不动点网络的太赫兹超大规模MIMO信道估计

张华卫 牛亚宁* 蒋占军 刘英挺

(兰州交通大学 兰州 730070)

摘要: 针对太赫兹超大规模MIMO系统在混合场传播与AoSA架构下, 现有压缩感知与深度展开方法在低信噪比(SNR)及噪声统计失配条件下易出现性能饱和与泛化性较差问题。为此, 该文提出一种噪声条件化不动点展开网络(FPN-NCAS)。该方法在保持不动点理论框架的同时, 将由重复导频差分获得的粗噪声功率估计值作为条件控制量耦合至非线性恢复过程, 从而实现随噪声水平自适应调节的估计策略。在此基础上, 设计噪声条件化的块稀疏近端恢复模块Block Shrink, 通过噪声感知阈值与平滑切换机制增强混合场稀疏结构恢复能力; 构造Token-Gate模块对子阵级特征进行轻量可靠性校准, 并构建门控混合多尺度细化(G-HMTD)模块对主恢复后的残余误差进行全局—局部协同细化。仿真结果表明, 所提方法在不同SNR条件下均取得更优的归一化均方误差(NMSE)性能; 此外, 在多种非理想信道与噪声条件下, 所提方法仍表现出良好的鲁棒性。

关键词: 太赫兹通信; 超大规模MIMO; 信道估计; 不动点网络; 噪声条件化

中图分类号: TN911.7

文献标识码: A

文章编号: 1009-5896(2026)12-0001-12

DOI: 10.11999/JEIT260420

CSTR: 32379.14.JEIT260420

1 引言

太赫兹(TeraHertz, THz)通信频段由于大带宽、短波长等特征有望支持数据量的爆炸性需求, 满足卫星通信、近空间通信等6G应用发展^[1]。为补偿由于其短波特性的严重分子吸收损耗, 超大规模多输入多输出(UltraMassive Multiple-Input Multiple-Output, UM-MIMO)系统被广泛应用以获取足够的波束增益^[2]。随着阵列孔径不断增大, 近场球面波及近远场并存的混合场传播特性^[3]逐渐成为THz UM-MIMO系统中的典型特征。而阵列子阵(Array-of-SubArray, AoSA)结构^[4]通过子阵共享射频(Radio-Frequency, RF)链的方式降低了射频开销, 但可能造成部分信道状态信息(Channel State Information, CSI)的损失^[5], 进一步提高了信道观测与恢复的难度。因此, 有必要针对THz AoSA系统研究更为高效且精确的信道估计方法。

近年来, 针对THz UM-MIMO及复杂传播环境下无线信道的高维稀疏结构, 相关研究主要沿压缩感知(Compressed Sensing, CS)与贝叶斯学习(Bayesian Learning, BL)推断两条路线展开。文献^[6]针对THz UM-MIMO系统中的近场、远场及过渡场并存问题, 提出跨场信道估计策略; 文献^[7]针对

THz宽间距多子阵列系统, 提出多种稀疏恢复理论的估计框架。文献^[8]针对全息MIMO复杂电磁传播场景, 建立了参数化信道建模与贝叶斯估计框架; 文献^[9]则面向混合场THz UM-MIMO, 提出稀疏化矩阵学习辅助的BL估计方法。然而, 上述方法大多仍依赖迭代式稀疏恢复或后验更新, 在大规模阵列和实时应用场景下仍面临较高的计算复杂度与时延开销。

深度学习(Deep Learning, DL)已成为提升无线物理层性能的重要工具, 并在信道估计与CSI反馈等任务中展现出良好的应用潜力。信道估计也逐步由纯数据驱动转向模型驱动, 后者更强调将迭代求解机制与可学习模块结合, 从而兼顾可解释性与跨场景泛化能力^[10]。文献^[11]针对宽带混合毫米波大规模MIMO信道估计问题, 结合稀疏BL提出宽带THz近场信道的深度展开估计方法; 文献^[12]面向混合场波束偏斜下的超大规模MIMO场景, 提出知识与数据双驱动的信道估计与反馈框架。文献^[13]将Turbo译码消息传递机制与深度降噪学习相结合, 实现可重构智能超表面辅助大规模MIMO系统的级联信道估计。而针对THz UM-MIMO混合场信道估计问题, 文献^[14]提出了不动点网络(Fixed Point Network, FPN)框架, 兼顾可解释性、低单次迭代复杂度与收敛保证的同时具备较强的分布偏移鲁棒性。此外, 近期利用生成式人工智能扩散模型^[15]提升THz UM-MIMO近场信道重建质量, 表明高维近场信道估计正在从单一稀疏恢复走向多先验、多任务融合的新阶段。

然而, 现有方法大多仍围绕预设阵列结构、既

收稿日期: 2026-04-09; 改回日期: 2026-07-04; 网络出版: 2026-07-19

*通信作者: 牛亚宁 12241981@stu.lzjtu.edu.cn

基金项目: 国家自然科学基金(62561037), 甘肃省自然科学基金(26JRRA053)

Foundation Items: The National Natural Science Foundation of China(62561037), The Natural Science Foundation of Gansu Province (26JRRA053)

定观测模型或固定统计条件。对于AoSA架构下受限RF链观测、噪声水平波动以及统计失配并存的实际场景，如何兼顾估计精度与跨信噪比(Signal-to-Noise Ratio, SNR)泛化能力，仍然值得深入研究。基于此，本文提出一种噪声条件化不动点网络(FPN Noise-Conditioned AoSA-aligned Shrinkage, FPN-NCAS)。其核心是将重复导频差分得到的粗噪声功率估计值作为条件控制量注入非线性恢复过程，使网络能够根据噪声水平自适应调节恢复强度与阈值策略。在具体结构上，设计Block Shrink作为主恢复模块，通过噪声感知阈值生成与平滑切换机制，对AoSA对齐特征中的块稀疏结构进行自适应约束，从而抑制低SNR下的噪声伪激活并保留中高SNR下的有效结构信息；提出Token-Gate进行子阵级可靠性预校准，以减弱结构扰动和子阵响应不一致带来的误差传播；构建门控混合多尺度细化(Gated Hybrid Multi-scale Transformer Denoiser, G-HMTD)模块提升全局上下文建模能力与局部细节恢复能力。仿真结果表明，所提方法在不同SNR条件下均取得更优的归一化均方误差(Normalized Mean Square Error, NMSE)性能；并在噪声功率估计失配与结构扰动场景下，所提方法仍表现出良好的鲁棒性。

2 系统模型

如图1所示，本文考虑THz UM-MIMO上行导频阶段的混合场信道估计场景。基站(Base Station, BS)采用AoSA架构，由 $M \times M$ 个子阵(图1浅蓝色)组成，每个子阵由 $N \times N$ 个天线单元(图1浅黄色)组成的均匀平面阵列表示。为保持阵列建模一致性，本文沿用文献[14]中的平面坐标构造方式。

记天线单元间距为 $d_{ae} = \lambda/2$ ，子阵间距为 $d_{sub} = 56\lambda$ ， λ 为载波波长。由于THz超大孔径阵列

中近场球面波与远场平面波可能同时存在，本文采用瑞利距离作为近远场分界，定义为 $d_R = 2D^2/\lambda$ ，其中 D 表示AoSA阵列孔径，可写为

$$D = \sqrt{2}[M(N-1)d_{ae} + (M-1)d_{sub}] \quad (1)$$

在混合场传播条件下，THz信道由少数直射路径(Line of Sight, LoS)与若干非直射路径(Non Line of Sight, NLoS)构成。记空间域信道响应向量 $\tilde{\mathbf{h}} \in \mathbb{C}^{M^2N^2 \times 1}$ ，可表示为

$$\tilde{\mathbf{h}} = \sum_{l=1}^L \beta_l(f) \mathbf{a}(\varphi_l, \theta_l, r_l; f) e^{-j2\pi f \tau_l} \quad (2)$$

其中， L 为路径数， f 为载波频率， φ_l ， θ_l ， r_l 和 τ_l 分别表示第 l 条路径的方位角、仰角、距离与时延， $\beta_l(f)$ ， $\mathbf{a}(\cdot)$ 表示路径损耗与阵列响应向量。当 $r_l < d_R$ 时，采用近场球面波响应，而当 $r_l \geq d_R$ 时采用远场平面波响应。自由空间扩散损耗、分子吸收损耗、Fresnel反射系数以及基于瑞利距离的近远场阵列响应已有成熟建模，具体可参考文献[16]，此处不再展开。

为利用信道在角域的稀疏性，引入基于DFT的角域字典矩阵 $\mathbf{F} \in \mathbb{C}^{M^2N^2 \times M^2N^2}$ ，并记角域稀疏系数为 $\mathbf{h}^* \in \mathbb{C}^{M^2N^2}$ ，则空间域信道可近似表示为 $\tilde{\mathbf{h}} \approx \mathbf{F}\mathbf{h}^*$ 。

假设用户在 Q 个导频时隙向BS发送相互正交、单位模的导频符号，第 q 个导频时隙RF链上的复接收向量可写成

$$\mathbf{y}_q = \mathbf{W}_{BB,q}^H \mathbf{W}_{RF,q}^H (\mathbf{F}\mathbf{h}^* + \mathbf{z}_q) \quad (3)$$

其中， $\mathbf{W}_{BB,q}$ ， $\mathbf{W}_{RF,q}$ 分别表示数字、模拟合并矩阵， $\mathbf{z}_q \sim \mathcal{CN}(\mathbf{0}, \sigma_n^2 \mathbf{I})$ 为加性高斯白噪声。将 Q 个导频时隙的接收向量堆叠表示，再按实部与虚部进行等价实数化处理，得到实数观测模型

$$\mathbf{y} = \mathbf{A}\mathbf{h} + \mathbf{z} \quad (4)$$

上述实数化后的向量将作为后续网络框架的输入以进行信道估计。

3 噪声感知的FPN-NCAS信道估计算法

为缓解传统方法在低SNR条件下的性能退化及噪声失配问题，本文提出了一种噪声感知的不动点网络FPN-NCAS。该方法以实数观测向量 $\mathbf{y}$ 、测量矩阵 $\mathbf{A}$ 以及由重复导频差分获得的粗噪声功率估计值 σ^2 为输入，在不动点迭代结构中引入噪声条件化非线性恢复机制，从而实现跨SNR条件下的自适应收缩与稳定恢复。

整体算法框架如图2所示，分为线性更新与非线性恢复两部分。其中 $\mathbf{h}^{(t)}$ 表示第 t 个阶段的信道估




图1 系统模型




图2 整体算法框架

计结果，正文中为简化记号统一写作 $\mathbf{h}^t$ 。首先初始化利用 $\mathbf{A}$ 的伪逆得到初始信道估计 $\mathbf{h}^0 = \mathbf{A}^\dagger \mathbf{y}$ ，再将噪声估计功率 σ^2 输入网络，随后网络展开为 T 个阶段的迭代结构，即每个阶段以当前估计 $\mathbf{h}^t$ 为输入，经过线性残差更新并将向量域估计重排为AoSA对齐的特征图张量，再通过引入噪声的非线性恢复网络进行先验约束与整体增强，输出下一阶段估计 $\mathbf{h}^{t+1}$ ，最终经过迭代得到信道估计结果 $\mathbf{h}^T$ 。

3.1 导频差分噪声估计

在第 t 个阶段中，网络首先对当前信道估计 $\mathbf{h}^t$ 执行线性更新。由测量矩阵 $\mathbf{A}$ 得到预测观测 $\hat{\mathbf{y}}^t = \mathbf{A}\mathbf{h}^t$ ，并将其与真实观测 $\mathbf{y}$ 构造残差 $\tilde{\mathbf{y}}^t = \mathbf{y} - \mathbf{A}\mathbf{h}^t$ ，再通过阶段步长 ρ_t 加权，得到

$$\mathbf{h}_{\text{LE}}^t = \mathbf{h}^t + \rho_t \mathbf{A}^\dagger \tilde{\mathbf{y}}^t = \mathbf{h}^t + \rho_t \mathbf{A}^\dagger (\mathbf{y} - \mathbf{A}\mathbf{h}^t) \quad (5)$$

为利用AoSA结构先验，将线性更新后的输出结果 $\mathbf{h}_{\text{LE}}^t$ 按实部、虚部及子阵索引进行重排得到AoSA对齐的特征图 $\mathbf{G}^t = \mathcal{R}(\mathbf{h}_{\text{LE}}^t) \in \mathbb{R}^{2M^2 \times N \times N}$ ，其中 $\mathcal{R}(\cdot)$ 表示可逆重排算子。在完成非线性恢复后，可通过逆变换将特征图张量重新映射回向量表示，得到下一阶段输入。

在线性更新之后，本文由重复观测对构造得到粗噪声功率估计值，其作用是调节恢复强度与阈值水平。考虑到本文采用单载波压缩观测模型，默认一个导频采集块内信道近似保持不变。设第 m 个重复观测对满足 $y_m^{(1)} = \mathbf{a}_m^T \mathbf{h} + z_m^{(1)}$ ， $y_m^{(2)} = \mathbf{a}_m^T \mathbf{h} + z_m^{(2)}$ 。其中， $\mathbf{a}_m^T$ 表示矩阵 $\mathbf{A}$ 的第 m 行。两次观测采用相同的测量行与导频配置，则两式作差可得 $\Delta y_m = y_m^{(1)} - y_m^{(2)} = z_m^{(1)} - z_m^{(2)}$ 。从而消除了共享信道分量对噪声估计的直接影响，可进一步构造粗噪声功率估计值

$$\sigma^2 = \frac{1}{2Q_1} \sum_{m=1}^{Q_1} |\Delta y_m|^2 \quad (6)$$

其中， Q_1 表示重复导频对数。随后将 σ^2 作为噪声条件量输入非线性恢复模块，用于自适应调节阈值水平与恢复强度。进一步考虑AoSA接收结构中每个导频时隙对应 N_{RF} 条RF链观测，可将其扩展为

$$\sigma^2 = \frac{1}{2Q_1 N_{\text{RF}}} \sum_{m=1}^{Q_1} \sum_{r=1}^{N_{\text{RF}}} |\Delta y_{m,r}|^2 \quad (7)$$

其中， $\Delta y_{m,r}$ 表示第 m 个重复导频对在第 r 条RF链上的差分观测。若接收噪声满足 $z_{m,r}^{(1)}, z_{m,r}^{(2)} \sim \mathcal{CN}(0, \sigma_n^2)$ ，则 $\Delta y_{m,r} \sim \mathcal{CN}(0, 2\sigma_n^2)$ 。因此， σ^2 是 σ_n^2 的无偏估计。其相对标准差为

$$\text{RSD}(\sigma^2) = \frac{1}{\sqrt{Q_1 N_{\text{RF}}}} \quad (8)$$

本文 $N_{\text{RF}} = 4$ ，若要求粗噪声功率估计的相对标准差不超过25%时，则有 $Q_1 \geq 4$ 。采用额外重复导频方式，即原有 $Q = 128$ 个压缩观测导频保持不变，额外加入 Q_1 个重复导频对用于构造噪声条件量，则总导频开销为 $Q_{\text{tot}} = Q + Q_1$ ，相对于原始导频数的额外导频开销为 $\Delta_{\text{pilot}} = Q_1/Q$ 。当 $Q_1 = 4$ 时， $\Delta_{\text{pilot}} = 3.13\%$ 。此时重复导频不会占用原有压缩观测导频，因此不会降低原始观测维度。若系统严格限制总导频长度，则需要从原始导频中划分出导频用于重复观测，此时会引入噪声估计精度与有效观测维度之间的进一步折中。

3.2 噪声条件化非线性恢复

在线性更新与AoSA对齐后，本文构建噪声条件化非线性恢复链。该恢复链由Token-Gate, Block Shrink和G-HMTD 3部分组成，分别用于子阵级可靠性预校准、噪声条件化块稀疏主恢复以及全局—局部残差细化。其中，粗噪声功率估计以 $\lg \sigma^2$ 的形式注入网络，用于调节门控权重、阈值水平与恢复强度。

3.2.1 子阵预校准

如图3所示，Token-Gate由特征编码、特征交互和门控生成3部分组成，用于在主恢复前对子阵级特征进行可靠性预校准。

首先，在特征编码中，将AoSA对齐特征图 $\mathbf{G}^t$ 划分为 M^2 个子阵特征块，经过特征提取得到每个子阵的统计特征；随后，将统计特征、坐标编码与噪声条件 $\lg \sigma^2$ 拼接，再通过线性嵌入得到第 s 个子阵的初始特征token $\mathbf{x}_s^t$ 。在特征交互中，所有子阵特征经多头注意力(Multi-Head Attention,

MHA)和前馈网络(Feed-Forward Network, FFN)进行跨子阵交互,得到更新后的特征 $\bar{\mathbf{x}}_s^t$,其表示第 s 个子阵在融合阵列上下文和噪声条件后的可靠性特征。最后,在门控生成中,通过平均池化(Average Pooling, AvgPool)与门控权重生成子阵门控向量

$$\mathbf{g}_{\text{sub}}^t = \text{GateHead}(\text{TokenAvgPool}([\bar{\mathbf{x}}_1^t, \bar{\mathbf{x}}_2^t, \dots, \bar{\mathbf{x}}_{M^2}^t])) \quad (9)$$

并对输入特征图张量 $\mathbf{G}^t$ 进行乘性重标定,得到预校准输出

$$\mathbf{G}_{\text{tg}}^t = \mathbf{g}_{\text{sub}}^t \odot \mathbf{G}^t \quad (10)$$

其中 $\odot$ 表示按子阵分组的逐元素加权。Token-Gate更适合作为一种轻量的前置校准机制,其作用是抑制低SNR下可靠性较低子阵响应,并为后续Block Shrink提供更稳定的输入。

3.2.2 噪声条件化稀疏近端

如图4所示,Block Shrink是本文非线性恢复链中的核心模块,以预校准后的 $\mathbf{G}_{\text{tg}}^t$ 为输入,在AoSA子阵局部特征图上执行噪声条件化块级近端收缩。该模块由阈值生成和块稀疏收缩两部分组成:前者根据噪声条件生成阶段阈值,后者基于块级范数执行稀疏收缩。

在阈值生成中,首先由平滑切换根据 $\lg\sigma^2$ 生成低SNR与高SNR阈值策略之间的切换权重 $\omega(\sigma^2)$,随后多层感知机(Multi-Layer Perceptron, MLP)分别生成低SNR和高SNR条件下的阈值调节因子,得到

$$\left\{ \begin{aligned} \zeta_t^{\text{lo}} &= b_t^{\text{lo}} \alpha_{\text{lo}}(\ell_\sigma) \sqrt{\sigma^2} \\ \zeta_t^{\text{hi}} &= b_t^{\text{hi}} \alpha_{\text{hi}}(\ell_\sigma) \sqrt{\sigma^2} \end{aligned} \right\} \quad (11)$$

其中, b_t^{lo} 与 b_t^{hi} 分别表示第 t 次迭代对应的低SNR和高SNR基础阈值, $\alpha_{\text{lo}}(\cdot)$ 与 $\alpha_{\text{hi}}(\cdot)$ 为噪声条件调节因子。随后,在阈值融合中,两分支经平滑融合得到阶段阈值

$$\xi_t = \omega(\sigma^2) \zeta_t^{\text{lo}} + (1 - \omega(\sigma^2)) \zeta_t^{\text{hi}} \quad (12)$$

通过上述设计使阈值策略能够在不同噪声区间之间平滑切换,从而同时兼顾低SNR下的强抑噪需求与高SNR下的细节保持需求。在块稀疏收缩中,先通过子阵拆分将 $\mathbf{G}_{\text{tg}}^t$ 按子阵对应的通道组拆分,再将每个子阵特征块划分为若干patch,记第 s 个子阵中第 c 个块向量为 $\mathbf{b}_{s,c}^t$,计算其范数

$$\nu_{s,c}^t = \sqrt{\|\mathbf{b}_{s,c}^t\|_2^2 + \epsilon_{\text{bn}}} \quad (13)$$

其中, $\epsilon_{\text{bn}} > 0$ 用于避免范数接近零时出现数值不稳定。随后在收缩因子中基于阶段阈值 ξ_t 构造收缩系数

$$\zeta_{s,c}^t = \max\left(1 - \frac{\xi_t}{\nu_{s,c}^t}, 0\right) \quad (14)$$

并对块向量做幅度收缩 $\hat{\mathbf{b}}_{s,c}^t = \zeta_{s,c}^t \mathbf{b}_{s,c}^t$,最后将收缩后的块patch折叠恢复至子阵网格,并通过子阵合并得到输出 $\mathbf{G}_{\text{bs}}^t$ 。

由此,Block Shrink可视为在AoSA对齐特征图张量上的噪声条件化块级近端算子。与固定阈值或逐元素收缩不同,该模块一方面利用估计的噪声




图3 Token-Gate




图4 Block Shrink

条件与迭代阶段信息实现阈值的自适应调节，另一方面借助块级范数约束更好地匹配混合场信道在子阵局部区域内的团簇化稀疏特性。在低SNR条件下，它能够有效地抑制噪声诱发的伪激活；在中高SNR条件下，又可尽量保留稳定的有效结构，因此构成了本文非线性恢复中的核心单元。

3.2.3 全局—局部协同增强

经过Block Shrink后，输入特征中的主要噪声伪激活已被抑制，然而由压缩观测不充分、模型失配以及残余噪声共同造成的细粒度偏差仍可能存在，表现为跨子阵依赖刻画不足以及局部多尺度细节恢复不充分。为此，本文进一步设计G-HMTD模块，对特征进行全局—局部协同增强。

如图5所示，G-HMTD输入为 $\mathbf{G}_{bs}^t$ 。首先输入特征经过前置FFN变换后与恒等分支相加，得到共享特征 $\mathbf{G}_0^t = \mathbf{G}_{bs}^t + \text{FFN}(\mathbf{G}_{bs}^t)$ ，同时分支门控根据当前输入内容生成自适应权重 w_1^t 与 w_2^t ，用于动态平衡局部增强与全局增强在当前阶段中的贡献。

在局部多尺度增强中，模块以 $\mathbf{G}_0^t$ 为输入，模块通过3条不同空洞率的深度可分离卷积(Depth-Wise Convolution, DWConv)以及一条全局平均池化(Global Average Pooling, GAP)提取不同感受野下的局部响应特征。并在通道维进行融合。随后，利用通道注意力(Channel Attention, CA)与空间注意力(Spatial Attention, SA)对融合后的局部多尺度表示进行重标定，从而突出与局部结构恢复更相关的响应区域，得到局部增强结果 $\mathbf{G}_{loc}^t = \mathcal{H}_{loc}(\mathbf{G}_0^t)$ ，该分支主要关注相邻局部区域的多尺度细节连续性，对残留的局部纹理偏差与边缘失真更为有效。

在全局上下文路径中，同样以 $\mathbf{G}_0^t$ 为输入，

依次经过QKV注意力、门控FFN与轻量频域增强进行跨子阵上下文建模，得到全局增强结果 $\mathbf{G}_{glb}^t = \mathcal{H}_{glb}(\mathbf{G}_0^t)$ 。该路径采用轻量化Restormer风格模块^[17]，更侧重于捕获跨子阵的长程相关性，用于弥补仅依赖局部块结构时可能忽略的全局耦合关系。最终，两路增强结果通过分支权重进行内容自适应融合，得到G-HMTD的输出

$$\bar{\mathbf{G}}^t = w_1^t \mathbf{G}_{loc}^t + w_2^t \mathbf{G}_{glb}^t \quad (15)$$

由此，G-HMTD实现了局部多尺度细化与全局上下文补偿的协同建模。

3.3 层间稳定性

为提升FPN-NCAS的层间稳定性，本文在阶段更新中引入桥接松弛和非线性残差缩放机制。由3.1节可知，在第 t 层中线性更新结果为 $\mathbf{h}_{LE}^t$ 。为避免线性修正过强导致层间震荡，引入桥接系数 ψ_t ，得到

$$\begin{aligned} \mathbf{h}_B^t &= (1 - \psi_t) \mathbf{h}_{LE}^t + \psi_t \mathbf{h}^t \\ &= \mathbf{h}^t + (1 - \psi_t) \rho_t \mathbf{A}^\dagger (\mathbf{y} - \mathbf{A} \mathbf{h}^t), 0 \leq \psi_t < 1 \end{aligned} \quad (16)$$

随后 $\mathbf{h}_B^t$ 被送入噪声条件化非线性恢复分支。记原始非线性恢复算子为 $\mathcal{F}_t(\cdot; \sigma^2)$ ，并引入残差缩放系数 ϖ_t ，则非线性输出定义为

$$\mathbf{h}_{NLE}^t = \mathbf{h}_B^t + \varpi_t (\mathcal{F}_t(\mathbf{h}_B^t; \sigma^2) - \mathbf{h}_B^t), 0 < \varpi_t \leq 1 \quad (17)$$

其中， ϖ_t 为残差缩放系数。当非线性分支的局部响应过强时，减小 ϖ_t 有助于抑制扰动放大，从而提升层间更新的稳定性。于是，第 t 层整体更新可统一表示为

$$\mathbf{h}^{t+1} = (1 - \gamma) \mathbf{h}_B^t + \gamma \mathbf{h}_{NLE}^t, 0 < \gamma \leq 1 \quad (18)$$

其中， γ 为非线性校正的松弛系数。由式(18)可见，FPN-NCAS的层间稳定性主要来自受控步长




图5 G-HMTD

的线性一致性校正、桥接松弛机制以及非线性残差缩放。若线性映射与非线性恢复在目标解邻域内满足局部Lipschitz收缩条件,则整体阶段映射可视为局部收缩映射,从而保证迭代过程具有稳定趋势。

实际推理时,本文根据相邻两层信道估计结果的相对变化幅度判断是否停止迭代;当该变化低于预设阈值或达到最大迭代层数时终止。

4 实验仿真与结果分析

4.1 评估指标

为定量评估各方法对信道的重构精度,本文采用NMSE作为核心评价指标。对每个测试样本计算其估计信道与真实信道之间的误差能量,并以真实信道能量进行归一化;随后,在给定SNR条件下,对全部测试样本的归一化误差取平均,作为该SNR点的统计结果。

4.2 仿真参数

对于本文所提算法FPN-NCAS的部分信道仿真参数如表1所示。

对于本文的数据集,同样依据文献[14]的方式,对每个样本根据混合场建模生成空间AoS信道矩阵,随后将信道利用DFT字典矩阵按子阵逐块变换到角域,再用生成的压缩测量矩阵对角域信道进行线性观测,并叠加复高斯噪声得到观测向量。不同的是在导频采集块内额外选取少量重复观测对,并依据重复导频差分构造粗噪声功率估计值 σ^2 ,作为网络的噪声条件输入。最后分别生成训练、验证及测试的信道样本数为80 000, 5 000及5 000。

本实验的训练配置为NVIDIA GeForce RTX

4060 Laptop,所用环境为python 3.8.20, pytorch 1.13.0, cuda 11.6。训练周期为150轮,批大小为64,采用AdamW优化器,主干网络参数的初始学习率设为0.002,噪声条件相关参数组的初始学习率设为0.004,以加快条件分支的学习与收敛。

4.3 实验结果与分析

本节通过仿真结果来评估所提FPN-NCAS方法在THz UM-MIMO混合场窄带系统中的性能。对比算法分别有LS、OAMP^[18]、ISTA-Net+^[19]、FPN-OAMP^[14]以及FPN-OTFN^[20]。其中除了LS与OAMP为传统算法外,ISTA-Net+为深度展开模型算法,而FPN-OAMP与FPN-OTFN均为基于不动点框架的算法。

4.3.1 性能分析

由图6(a)可见,FPN-NCAS在所有测试SNR点上均取得最低NMSE,说明噪声条件化恢复机制能够提升不同噪声水平下的信道恢复精度。具体而言,在SNR=0 dB时,FPN-NCAS相比FPN-OAMP和FPN-OTFN分别获得约3.0 dB和1.9 dB的NMSE增益;在SNR=20 dB时,增益进一步扩大至约4.5 dB和2.6 dB。图6(b)与图6(c)表明,FPN-NCAS在SNR=5 dB时约3层达到稳定平台,在SNR=15 dB时约5层趋于稳定,层间波动较小。相比之下,FPN-OAMP和FPN-OTFN的最终精度略低,ISTA-Net+的迭代波动更明显。该结果说明所提方法在提升估计精度的同时,也具有较好的工程收敛稳定性。

4.3.2 鲁棒性分析

为验证所提方法在非理想条件下的稳定性,本文从重复导频开销、噪声功率估计失配、噪声分布失配、信道统计变化以及结构扰动等方面进行测

表1 部分信道仿真参数

参数	载波频率 f (GHz)	子阵数量 M^2	天线单元数量 N^2	天线间距 d_{ae} (m)	子阵间距 d_{sub} (m)	导频长度 Q	总路径数 L
取值	300	4	256	2×10^{-4}	0.056	128	5




图6 不同算法NMSE及算法收敛对比

试。为验证重复导频数量对粗噪声估计精度和最终信道估计性能的影响,本文进一步测试不同 Q_1 下的NMSE结果。本文默认选取 $Q_1 = 4$,额外导频开销按 Q_1/Q 计算, σ_2 相对标准差由 $1/\sqrt{Q_1 N_{\text{RF}}}$ 计算。表2给出了不同 Q_1 下的额外导频开销、噪声估计相对标准差以及对应的NMSE结果。

由表2可见,当 $Q_1 = 1$ 时,额外导频开销仅为0.78%,说明所提网络对噪声条件误差具有一定鲁棒性,但此时粗噪声功率估计的相对标准差达到50.00%,说明输入网络的噪声条件量仍存在较大的随机波动。随着 Q_1 增大, σ_2 的相对标准差逐渐降低,NMSE结果也逐步趋于稳定。当 $Q_1 = 4$ 时,额外导频开销为3.13%,粗噪声功率估计的相对标准差降低至25.00%,同时在0~20 dB范围内已经取得稳定的NMSE结果。继续将 Q_1 增大至8或16时,NMSE改善幅度较小,说明重复导频数量继续增加后的边际收益有限。因此,本文选择满足相对标准差约束的最小重复导频对数 $Q_1 = 4$ 作为默认设置,以在导频开销、噪声估计可靠性和最终NMSE性能之间取得更稳健的折中。

为评估算法对噪声统计不确定性的鲁棒性,在推理阶段对输入网络的噪声功率估计值施加失配扰动:将基准噪声条件量 σ^2 替换为失配值 $\delta^2 = \iota \sigma^2$,其中 $\iota \in \{0.5, 0.8, 1.0, 1.25, 1.5, 2.0\}$,模型权重固定。如图7(a)所示,在轻中度失配区间 $\iota \in [0.8, 1.5]$ 范

围,各SNR下NMSE变化较小,退化幅度普遍不超过0.3 dB;当出现极端失配时才观察到较明显性能下降。说明模型对实际噪声功率估计误差具有良好的适应性。


为验证噪声分布失配下的鲁棒性,本文以加性高斯白噪声为基准,并引入相关有色噪声和脉冲噪声进行测试。其中,有色噪声的相关系数设为0.8,脉冲噪声的脉冲概率设为0.05,混合分量数设为25。图7(b)给出了3种噪声分布下的NMSE-SNR曲线,图7(c)给出了SNR=10 dB时的逐样本NMSE-CDF。结果表明,尽管两者均会导致性能退化,但FPN-NCAS在3种噪声条件下仍整体优于FPN-OAMP,说明其在噪声分布失配下具有更稳定的逐样本误差表现。

表3给出了不同信道统计条件下的鲁棒性结果。相较混合场分布内基准,测试分布切换至近场和远场时,NMSE仅分别退化0.15 dB和0.08 dB;当主路径数由基线 $L=5$ 偏移至 $L=3 \sim 4$ 时,由于信道更稀疏,NMSE进一步下降;当 $L=6 \sim 7$ 时,散射分量增加导致NMSE有限抬升。结果表明FPN-NCAS对场区域分布和主路径数变化均具有一定鲁棒性,能够有效抑制统计失配带来的影响。


如图8所示展示了Token-Gate在结构扰动下的泛化效果,其中,图8(a)对应AoSA子阵顺序随机重排,分别比较基准、重排+无Gate和重排+

表 2 不同重复导频对下的噪声估计敏感性


Q_1	导频开销(%)	相对标准差(%)	0 dB	5 dB	10 dB	15 dB	20 dB
1	0.78	50.00	-12.94	-17.57	-21.32	-24.42	-26.58
2	1.56	35.36	-13.02	-17.64	-21.36	-24.45	-26.63
4	3.13	25.00	-13.07	-17.68	-21.38	-24.47	-26.66
8	6.25	17.68	-13.09	-17.69	-21.39	-24.48	-26.67
16	12.50	12.50	-13.10	-17.70	-21.40	-24.48	-26.67



(a) 噪声功率失配NMSE对比



(b) 噪声分布失配下NMSE对比



(c) 不同噪声分布下逐样本NMSE的CDF

图 7 噪声功率与噪声分布失配

Gate三种设置, 图8(b)对应RF链幅度/相位失配, 分别比较基准、RF失配+无Gate和RF失配+Gate三种设置。

结果表明, 在AoSA子阵顺序打乱条件下, Token-Gate在SNR=0, 5, 10 dB时相对no-Gate的净改善分别为3.38, 5.86和9.41 dB; 在RF振幅/相位失配条件下, 相应改善分别为4.14, 5.43和7.02 dB。该结果说明, 尽管Token-Gate不是整体性能提升的主导来源, 但在结构扰动场景下能够显著减弱误差传播。

为细化Token-Gate在RF链幅度与相位随机扰动下的泛化验证, 本文补充多次随机扰动统计实验。设第 i 条RF链的复数失配因子为 $g_i = \alpha_i e^{j\phi_i}$, 其中, α_i 表示RF链幅度扰动因子, ϕ_i 表示RF链相位扰动。本文采用如下随机扰动模型: $\alpha_i = \exp(u_i)$, $u_i \sim \mathcal{N}(0, 0.10^2)$, $\phi_i \sim \mathcal{N}(0, 0.20^2)$ 。因此, RF链幅度扰动因子 α_i 的均值和标准差分别约为1.005和0.101; 相位扰动 ϕ_i 的均值和标准差分别为

0 rad和0.20 rad。在该扰动模型下, 本文独立生成20组RF链幅相随机扰动, 并分别测试“RF失配+Gate”与“RF失配+no-Gate”两种设置下的NMSE均值和标准。

由表4可见, 启用Token-Gate后, 0, 5和10 dB下的平均NMSE分别由-7.665, -8.931与-8.856 dB改善至-10.794, -13.001与-13.510 dB, 对应的平均改善量分别为3.130, 4.071与4.654 dB。结果说明, Token-Gate在多次随机RF链幅相扰动下仍能保持稳定的性能优势, 验证了其对子阵/RF链级可靠性校准和误差传播抑制的作用, 能够模拟RF链硬件不一致带来的随机扰动。

4.3.3 消融对比

为验证所提方法中关键模块的作用差异与必要性, 本文对Token-Gate, Block Shrink与G-HMTD进行消融对比。由图9(a)可见, 去除Block Shrink的双阈值分支策略后, 模型在全SNR范围内均出现最显著性能退化, 说明噪声条件化块稀疏近端恢复




图8 AoSA子阵顺序重排与RF振幅相位失配

表3 不同分布与主路径数条件下的 NMSE 对比

测试项	分布/条件变化	NMSE(dB)	相对变化(dB)
区域分布外推	混合场→近场	-20.57	+0.15
区域分布外推	混合场→远场	-20.64	+0.08
主路径数偏移	$L=3\sim 4$	平均 -21.84	-1.22
主路径数基线	$L=5$	平均 -20.62	0
主路径数偏移	$L=6\sim 7$	平均 -19.22	+1.40

表4 RF链幅度相位随机扰动下的Token-Gate统计验证

项目	统计对象/方法	均值	标准差	0 dB	5 dB	10 dB
幅度扰动	α_i	1.005	0.101	-	-	-
相位扰动	ϕ_i	0 rad	0.20 rad	-	-	-
NMSE	RF失配+no-Gate	-	-	-7.665 ± 0.523	-8.931 ± 0.765	-8.856 ± 0.883
NMSE	RF失配+Gate	-	-	-10.794 ± 1.083	-13.001 ± 1.892	-13.510 ± 2.501
改善量	no-Gate-Gate	-	-	3.130 ± 0.563	4.071 ± 1.145	4.654 ± 1.657




图9 消融对比与噪声条件化可视化验证

是整体增益的主要来源；去除G-HMTD后性能次之，说明该模块在主恢复后能够持续提供残差细化和结构补偿；去除Token-Gate虽然带来的退化相对较小，但在整个SNR范围内较稳定，表明该模块主要承前端结构预校准作用。

为验证噪声条件信息在消融中的决定性贡献，本文构造基准配对、随机错配与固定条件三种噪声条件策略。其中，基准配对表示对每个样本输入与其观测噪声水平一致的粗噪声功率估计值 σ^2 ；随机错配表示仅对噪声条件量 σ^2 在样本维度进行随机置换；固定条件表示对所有样本采用同一固定噪声条件量 σ_0^2 ，从而移除逐样本噪声条件化。图9(b)用于说明不同噪声条件策略对整体误差分布的影响，图9(c)则用于说明性能退化是否由少数极端样本造成。结果表明，与基线相比，随机错配与固定条件两种设置的CDF均整体右移，而 Δ NMSE主要集中在正区间，说明性能下降不是由少量异常样本引起，而是普遍存在于多数样本中。因此，噪声条件输入是实现跨噪声水平自适应恢复的重要因素。

4.3.4 宽带扩展分析

为验证FPN-NCAS的宽带扩展能力，本文进一步构建宽带场景测试验证。系统中心频率设为 $f_c = 300$ Hz，总带宽为 $B = 15$ GHz，子载波数为 $K = 32$ ，各子载波共享相同的模拟组合器和压缩观测矩阵，第 k 个子载波上的压缩观测模型可写为 $\mathbf{y}[k] = \mathbf{A}\mathbf{h}[k] + \mathbf{z}[k], k = 1, 2, \dots, K$ 。由于本文主体模型基于窄带压缩观测框架设计，宽带实验采用窄带预训练权重初始化，并在32个子载波构成的宽带数据集上进行微调，得到FPN-NCAS-WB。图10表明，FPN-NCAS-WB在宽带场景下整体优于FPN-OTFN-WB, FPN-OAMP-WB和ISTA-Net+

-WB，说明所提方法经过少量宽带数据适配后仍具有较好的迁移能力。需要指出的是，完整的宽带频率选择性建模、子载波联合估计和波束斜视效应补偿仍需在后续工作中进一步研究。

4.3.5 复杂度分析

为了评估FPN-NCAS的复杂度开销，本文在统一实验环境下，对OAMP, ISTA-Net+, FPN-OAMP, FPN-OTFN以及FPN-NCAS的单样本前向推理复杂度进行统计。

由表5可以看出，FPN-NCAS的参数量、计算量和平均推理时间分别为0.523 M, 1.764 G和251.33 ms，高于其他对比方法。与FPN-OAMP相比，FPN-NCAS的参数量由0.362 M增加至0.523 M，计算量由0.888 G增加至1.764 G，平均推理时间由64.89 ms增加至251.33 ms，该开销主要来源于噪声条件化非线性恢复过程。因此，FPN-NCAS在提升估计精度和鲁棒性的同时引入了更高的推理复杂度。后续工作将进一步研究轻量化结构和高效实现，以降低实际部署开销。




图10 宽带场景下NMSE对比

表 5 不同模型的复杂度对比

模型	固定迭代层数	可训练参数量(M)	计算量(G)	平均推理时间(ms)
OAMP	-	-	0.065	7.71
ISTA-Net+	15	0.454	0.181	31.76
FPN-OAMP	15	0.362	0.888	64.89
FPN-OTFN	15	0.179	0.701	150.47
FPN-NCAS	15	0.523	1.764	251.33

5 结束语

本文针对THz超大规模MIMO混合场信道估计问题,提出了一种噪声条件化不动点网络FPN-NCAS。该方法将重复导频差分获得的粗噪声功率估计值注入非线性恢复过程,并结合Token-Gate,Block Shrink和G-HMTD,实现子阵结构校准、噪声条件化块稀疏恢复和残余细化增强。仿真结果表明,FPN-NCAS在0~20 dB SNR范围内取得了较优的NMSE,并在噪声功率估计失配、噪声分布偏离、信道统计变化和结构扰动等条件下保持了较好的鲁棒性与迭代稳定性。但所提方法带来了更高的推理复杂度。后续将进一步开展轻量化设计,并面向宽带、多用户和硬件非理想场景扩展该框架。

参 考 文 献

- [1] HE Yuanzhi, MA Chensheng, ZHU Zhongbo, *et al.* Terahertz communication payload architecture for space information networks: Challenges, key technologies, and trends[J]. *IEEE Network*, 2026, 40(1): 107–114.
- [2] JIANG Wei, ZHOU Qiheng, HE Jiguang, *et al.* Terahertz communications and sensing for 6G and beyond: A comprehensive review[J]. *IEEE Communications Surveys & Tutorials*, 2024, 26(4): 2326–2381. doi: [10.1109/COMST.2024.3385908](https://doi.org/10.1109/COMST.2024.3385908).
- [3] HAN Chong, CHEN Yuhang, YAN Longfei, *et al.* Cross far- and near-field wireless communications in terahertz ultra-large antenna array systems[J]. *IEEE Wireless Communications*, 2024, 31(3): 148–154.
- [4] LIN Cen and LI G Y L. Terahertz communications: An array-of-subarrays solution[J]. *IEEE Communications Magazine*, 2016, 54(12): 124–131.
- [5] SHA Ziyuan and WANG Zhaocheng. Channel estimation and equalization for terahertz receiver with RF impairments[J]. *IEEE Journal on Selected Areas in Communications*, 2021, 39(6): 1621–1635.
- [6] TARBOUSH S, ALI A, and AL-NAFFOURI T Y, *et al.* Cross-field channel estimation for ultra massive-MIMO THz systems[J]. *IEEE Transactions on Wireless Communications*, 2024, 23(8): 8619–8635.
- [7] YANG Songjie, PENG Yizhou, LYU Wanting, *et al.* Near-field channel estimation for extremely large-scale terahertz communications[J]. *Science China Information Sciences*, 2024, 67(9): 192302.
- [8] 袁正道, 郭亚博, 高大伟, 等. 参数化全息MIMO信道建模及其贝叶斯估计[J]. 电子与信息学报, 2025, 47(11): 4176–4187. doi: [10.11999/JEIT250436](https://doi.org/10.11999/JEIT250436).
YUAN Zhengdao, GUO Yabo, GAO Dawei, *et al.* Parametric holographic MIMO channel modeling and its Bayesian estimation[J]. *Journal of Electronics & Information Technology*, 2025, 47(11): 4176–4187. doi: [10.11999/JEIT250436](https://doi.org/10.11999/JEIT250436).
- [9] LI Yuanjian and 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.
- [10] 蒲旭敏, 刘雁翔, 宋米雪, 等. 基于模型驱动深度学习的OTFS信道估计[J]. 电子与信息学报, 2024, 46(2): 680–687. doi: [10.11999/JEIT230072](https://doi.org/10.11999/JEIT230072).
PU Xumin, LIU Yanxiang, SONG Mixue, *et al.* Orthogonal time frequency space channel estimation based on model-driven deep learning[J]. *Journal of Electronics & Information Technology*, 2024, 46(2): 680–687. doi: [10.11999/JEIT230072](https://doi.org/10.11999/JEIT230072).
- [11] GAO Jiabao, CHEN Xiaoming, and LI G Y. Deep unfolding based channel estimation for wideband terahertz near-field massive MIMO systems[J]. *Frontiers of Information Technology & Electronic Engineering*, 2024, 25(8): 1162–1172.
- [12] WANG Kuiyu, GAO Zhen, CHEN Sheng, *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.
- [13] 刘婷, 王媛, 辛元雪. 可重构智能超表面辅助的大规模机器类通信深度学习大规模MIMO信道估计[J]. 电子与信息学报, 2024, 46(10): 4002–4008. doi: [10.11999/JEIT240584](https://doi.org/10.11999/JEIT240584).
LIU Ting, WANG Yuan, XIN Yuanxue. Deep learning-enhanced massive channel estimation for reconfigurable intelligent surface-aided massive machine-type communication[J]. *Journal of Electronics & Information*

- Technology*, 2024, 46(10): 4002-4008. doi: [10.11999/JEIT.240584](https://doi.org/10.11999/JEIT.240584).
- [14] YU Wentao, SHEN Yifei, HE Hengtao, *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.
- [15] HU Zhengdong, HAN Chong, GERSTACKER W, *et al.* DiffPace: Diffusion-based plug-and-play augmented channel estimation in mmWave and terahertz ultra-massive MIMO systems[J]. *IEEE Journal on Selected Areas in Communications*, 2026, 44: 2559-2573.
- [16] 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.
- [17] ZAMIR S W, ARORA A, KHAN S, *et al.* Restormer: Efficient transformer for high-resolution image restoration[C]. The 2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition, New Orleans, USA, 2022: 5718-5729.
- [18] MA Junjie and LI Ping. Orthogonal AMP[J]. *IEEE Access*, 2017, 5: 2020-2033.
- [19] ZHANG Jian and GHANEM B. ISTA-Net: Interpretable optimization-inspired deep network for image compressive sensing[C]. The 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, Salt Lake City, USA, 2018: 1828-1837.
- [20] 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.
- YU Shujuan, ZHAO Yang, WEI Yuyao, *et al.* Deep learning channel estimation algorithm for ultra-massive terahertz systems[J]. *Journal on Communications*, 2025, 46(1): 144-156.
- 张华卫：男，高级工程师，研究方向为无线通信、深度学习等。
- 牛亚宁：男，硕士生，研究方向为无线通信、信道估计、深度学习等。
- 蒋占军：男，教授，研究方向为移动通信、信道估计、正交时空等。
- 刘英挺：男，副教授，研究方向为无线通信、非正交多址通信、反向散射通信等。
- 责任编辑：余 蓉

THz Ultra-Massive MIMO Channel Estimation via a Noise-Conditioned Fixed-Point Network

ZHANG Huawei NIU Yaning JIANG Zhanjun LIU Yingting

(School of Electronic and Information Engineering, Lanzhou Jiaotong University, Lanzhou 730070, China)

Abstract:

Objective Terahertz (THz) Ultra-Massive Multiple-Input Multiple-Output (UM-MIMO) systems are expected to support future high-capacity wireless communications. However, accurate channel estimation remains challenging under hybrid near-/far-field propagation and Array-of-SubArrays (AoSA) architectures, where limited Radio-Frequency (RF) chains, low Signal-to-Noise Ratio (SNR), noise uncertainty, and structural perturbations degrade compressed observations. Existing compressed sensing, Bayesian inference, and deep unfolding methods generally rely on fixed statistical assumptions, which limit their cross-SNR generalization under varying noise conditions and statistical mismatches. To address these limitations, this paper proposes a Noise-Conditioned Fixed-Point Network (FPN-NCAS) for robust THz UM-MIMO channel estimation. The proposed method aims to improve estimation accuracy, cross-SNR generalization, robustness, and iterative stability by incorporating noise-aware nonlinear recovery.

Methods FPN-NCAS is developed within an Orthogonal Approximate Message Passing (OAMP)-based fixed-point unfolding framework. A coarse noise power estimate is obtained from repeated pilot differences and injected into the nonlinear recovery module as an explicit conditioning variable. After each linear update, the vector-domain estimate is reshaped into an AoSA-aligned tensor to exploit subarray-level structural priors. The nonlinear recovery chain consists of three components. Token-Gate performs lightweight subarray-level reliability pre-calibration to suppress unreliable responses under low-SNR and structurally inconsistent conditions. Block Shrink serves as the core noise-conditioned block-sparse proximal operator, in which a smooth dual-threshold mechanism balances strong denoising at low SNR with structural preservation at medium-to-high SNR. G-HMTD(Gated Hybrid Multi-scale Transformer Denoiser) further refines residual errors by

combining Local Multi-scale Enhancement and Global Context Modeling. Bridge relaxation and nonlinear residual scaling are also incorporated to improve inter-stage stability.

Results and Discussions Simulation results demonstrate that FPN-NCAS consistently outperforms LS, OAMP, ISTA-Net+, FPN-OAMP, and FPN-OTFN over the 0~20 dB SNR range (Fig. 6). At SNR = 0 dB, FPN-NCAS achieves Normalized Mean Square Error (NMSE) gains of approximately 3.0 dB and 1.9 dB over FPN-OAMP and FPN-OTFN, respectively. At SNR = 20 dB, the gains increase to approximately 4.5 dB and 2.6 dB (Fig. 6(a)). The convergence curves show that FPN-NCAS reaches a stable plateau after approximately three layers at SNR = 5 dB and five layers at SNR = 15 dB, demonstrating stable fixed-point iterative behavior (Fig. 6(b) and Fig. 6(c)). Analysis of repeated pilots shows that four repeated pilot pairs introduce only 3.13% additional pilot overhead while reducing the relative standard deviation of the coarse noise power estimate to 25.00%. Under moderate noise power mismatch, NMSE degradation remains within 0.3 dB. The proposed method also maintains strong robustness under colored Gaussian noise, impulsive noise, near-/far-field distribution shifts, variation in the number of propagation paths, AoSA subarray shuffling, and RF amplitude/phase mismatch (Fig. 7 and Fig. 8). Ablation studies indicate that Block Shrink provides the largest performance gain, whereas Token-Gate and G-HMTD further improve performance through structural calibration and residual refinement (Fig. 9).

Conclusions This paper proposes FPN-NCAS for noise-conditioned fixed-point channel estimation in THz UM-MIMO systems. By integrating repeated-pilot-based noise conditioning, AoSA-aware feature reshaping, Token-Gate calibration, Block Shrink recovery, and G-HMTD refinement, the proposed method improves NMSE performance, robustness, and iterative stability under different SNR conditions and non-ideal scenarios. The improved performance is achieved at the cost of higher inference complexity. Future work will focus on lightweight implementations and extensions to wideband, multi-user, and hardware-impaired THz communication systems.

Key words: THz communications; Ultra-Massive MIMO; Channel estimation; Fixed-Point Network(FPN); Noise conditioning