

超大规模太赫兹系统深度学习信道估计算法

于舒娟¹, 赵阳¹, 魏玉尧¹, 张昀¹, 高贵¹, 赵生妹²

(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: 为了进一步提升 THz 超大规模 MIMO 系统混合场信道估计性能, 基于不动点网络 (FPN) 引入了一种基于跨通道信息交互的 Transformer 注意力机制模块与快速傅里叶变换卷积网络 (FCN), 提出了一种基于图像恢复网络的信道估计算法 FPN-OTFN, 将信道估计问题建模为图像恢复问题。在导频处采用最小二乘算法获得初始信道信息, 并将其作为所提 FPN-OTFN 算法的输入, 通过训练学习低精度信道图像和高精度图像间的映射关系, 恢复出真实的信道状态信息。仿真实验结果表明, 所提算法不仅继承了 FPN 框架的高效性、自适应性, 同时对 THz 信道拥有较高的估计精度和良好的鲁棒性。

关键词: 信道估计; THz 超大规模 MIMO 系统; 深度学习; 图像恢复; 注意力机制

中图分类号: TN92

文献标志码: A

DOI: 10.11959/j.issn.1000-436x.2025018

Deep learning channel estimation algorithm for ultra-massive terahertz systems

YU Shujuan¹, ZHAO Yang¹, WEI Yuyao¹, ZHANG Yun¹, GAO Gui¹, ZHAO Shengmei²

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: In order to further improve the hybrid-field channel estimation performance in terahertz ultra-massive multiple-input multiple-output systems, an efficient cross channel Transformer module for image restoration and a fast Fourier transform convolutional network were introduced based on the fixed point network, and a scalable and efficient deep learning model FPN-OTFN was proposed, which models the channel estimation problem as an image restoration problem. Firstly, the least squares algorithm was used to obtain the channel information at the pilot location, and then the channel information was input into the proposed FPN-OTFN algorithm. By training and learning the mapping relationship between low precision channel images and high-precision images, the true channel state information was restored. The simulation results show that the proposed scheme not only inherits the high efficiency and adaptivity of the FPN framework, but also possesses high estimation accuracy and good robustness for THz channels.

Keywords: channel estimation, THz ultra-massive MIMO system, deep learning, image restoration, attention mechanism

0 引言

无线应用的快速发展所带来的新需求, 激发了

人们对于 6G 极大的研究兴趣。太赫兹 (THz, terahertz) 超大规模多输入多输出 (UM-MIMO, ultra

收稿日期: 2024-09-12; 修回日期: 2025-01-10

通信作者: 赵阳, zy3132412@163.com

基金项目: 国家自然科学基金资助项目 (No.62375140); 江苏省研究生科研与实践创新计划基金资助项目 (No.KYCX23_0994)

Foundation Items: The National Natural Science Foundation of China (No.62375140), Postgraduate Research & Practice Innovation Program of Jiangsu Province (No.KYCX23_0994)

massive multiple input multiple output) 技术由于其巨大的带宽和丰富的空间自由度, 能够支持高达 Tbit/s 级别的超高数据速率, 被认为是未来 6G 极具潜力的核心技术之一^[1]。基于 THz 频段波长短的特点, UM-MIMO 技术可以通过密集部署大量天线所获得的增益来补偿太赫兹通信中的高路径损耗^[2]。但同时, 这种密集设计会导致空间采样不足, 牺牲系统本身的波束成形和复用增益^[3]。

作为上述问题的一种解决方案, 阵列子阵列 (AoSA, array-of-subarray) 结构^[4]通过将大规模天线分成多个子阵列, 在子阵列中部署多个天线, 可以有效降低每个元件所需的传输功率, 不同阵列相互协作, 有效地提高了复用增益^[3], 对于解决距离问题至关重要, 因此被广泛应用于 THz UM-MIMO 系统中。

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。然而, THz UM-MIMO 系统的巨大的天线数、有限数量的射频链, 以及不可忽略的近场球面波阵面特性等因素, 将给其信道估计带来严峻的挑战。

在 THz UM-MIMO 系统中, 通过利用波束空间信道的稀疏性, 可以将信道估计转化为稀疏信号恢复的问题, 使用基于压缩感知的算法进行估计, 文献[5]基于正交匹配追踪 (OMP, orthogonal matching pursuit) 算法, 引入了宽带字典并且假设不同的子载波共享非零信号的位置集合, 提出了广义同步正交匹配追踪 (GSOMP, generalized simultaneous OMP) 算法。文献[6]针对 THz 系统中的近场区域的波束斜视 (NB, near-field beam-squint) 问题, 基于 OMP 算法, 设计了一个 NB 感知字典, 考虑了 NB 引起的角度和范围偏差, 有效地减轻了 NB 的影响。文献[7]针对 UM-MIMO 系统中近场球面波阵列中角度域通道并不稀疏的问题, 引入了一种极域表示, 通过这种表示使近场区域中的信道也表现出稀疏性, 进而提出了极域同步正交匹配追踪 (P-SOMP, polar domain simultaneous OMP) 算法, 有效地估计了近场信道状态。然而, 如果 THz 大规模 MIMO 信道的稀疏特性得不到适当处理, 基于压缩感知的信道估计算法的性能将严重下降。这些算法大多采用结构化稀疏特性对无线信道进行估计, 利用迭代优化策略求解欠定最优化问题^[8]。这些重构算法的弱点是收敛速度慢, 在更实际的信道模型中

性能会有所降低, 并且具有较高的复杂度。

相比之下, 基于深度学习 (DL, deep learning) 的信道估计方法可以凭借其强大的学习能力利用大量的训练数据提取和处理隐藏特征, 以更低的复杂度更准确地估计信道。针对 THz UM-MIMO 系统中球面波信道的高复杂性和传播特性, 文献[9]提出了一个 15 层的深度卷积神经网络 (DCNN, deep convolutional neural network) 结构。在此结构中, 方位角、仰角、相移矩阵等众多信道参数均被处理为训练标签进行训练, 但该方案仅预测信道路径的关键参数, 如角度、距离、增益等。文献[10]提出了一种基于多尺度融合深度核卷积神经网络 (MF-DKCNN, multi-fusion based deep kernel convolutional neural network) 的联合方案来从精确的信道参数中估计无噪声的接收信号。然而上述 2 种方案均是基于数据驱动的方法, 往往不能充分利用观测矩阵中包含的信息。而基于模型驱动的方法结合了传统迭代算法和数据驱动的优点, 利用 DL 模型替换算法中的一些复杂模块, 将整个算法展开成固定层数的模型。文献[11]将迭代算法酉近似消息传递-稀疏贝叶斯学习 (UAMP-SBL, unitary approximate message passing-sparse Bayesian learning) 与深度神经网络 (DNN, deep neural network) 相结合, 在每次迭代中, 通过 DNN 来学习参数更新规则, 有效地提高了算法的收敛速度和性能。基于模型驱动的算法相较于基于纯数据驱动的方法能够利用观测矩阵中的信息, 可解释性也更强, 但同样存在可扩展性差、计算复杂度高等缺点。文献[12]针对 THz UM-MIMO 系统中复杂的远近混合场信道以及现有基于深度展开的 DL 算法的缺点, 提出了一种基于不动点迭代 (FPI, fix point iteration) 的信道估计框架——不动点网络 (FPN, fix point network)。基于该框架, 作者引入了正交近似消息传递 (OAMP, orthogonal approximate message passing) 算法, 并将其中的非线性估计部分用神经网络代替, 提出了 FPN-OAMP 算法。该算法利用神经网络强大的学习能力, 有效地利用了数据中的先验知识, 在取得不错性能的同时还具有低复杂度、强自适应性和强鲁棒性等众多优点。

超分辨率 (SR, super-resolution) 网络是一种用于图像重建的 DL 技术, 也已被广泛运用于无线通信系统信道估计中。文献[13]将信道中导频位置

的时频响应视为一个低分辨率图像，引入了超分辨率网络和图像恢复网络来提高图像的分辨率；文献[14]在正交频分复用（OFDM）系统中，先通过最小二乘（LS, least square）算法获得粗略的信道矩阵，接着使用基于 CNN 的 SR 网络来学习信道矩阵中的细微连接；文献[15]同样先通过 LS 算法获得信道矩阵，并将其视为低分辨率矩阵，然后进行插值操作并送入 SR 网络中以提高估计精度。受文献[13-15]启发，为了进一步发挥图像恢复网络在信道估计中的优势，本文将超分辨率网络引入 THz 信道估计系统中，基于 FPN 框架并结合一种高效的可用于图像恢复的 Transformer 模块^[16]和快速傅里叶变换卷积网络（FCN, fast Fourier transform convolution network），提出了用于 THz 信道估计的深度学习算法 FPN-OTFN。具体地，在 FPN 框架非线性估计器中引入 Transformer-FCN 深度神经网络，将线性估计器输出的初始信道估计值展开为图像形式，将信道估计问题转换为图像恢复问题。通过 Transformer^[16]中的自注意力机制隐式地建模不同通道图像间的全局关系，扩大图像的感受野，控制有效信息的输出。之后，通过构建的 FCN 有效地提取特征图信息，捕获信道特征，充分发挥卷积神经网络解决非线性问题的优势，从而改善信道估计的性能。该算法不仅继承了 FPN 框架的高效性、自适应性，同时拥有较高的信道估计精度以及较强的鲁棒性等优点。

1 系统模型

本节将介绍 THz UM-MIMO 系统，并将信道估计问题转换为信号恢复问题。本文考虑基于平面 AoSA 架构的 THz UM-MIMO 系统上行链路，系统框架如图 1 所示。

在该系统中，基站（BS, base station）配备有 $\sqrt{M} \times \sqrt{M}$ 个子阵列（SA, subarray），每个 SA 均为

由 $\sqrt{N} \times \sqrt{N}$ 个天线元件（AE, antenna element）组成的均匀平面阵列，平面 AoSA 结构如图 2 所示。为了减少硬件开销和功耗，采用了部分连接的混合模数结构^[17]，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。




图 2 平面 AoSA 结构

由于 THz 波的有限散射，BS 和用户之间的空间频率信道响应 $\mathbf{h} \in \mathbb{C}^{MN \times 1}$ 可以由一条 LoS（line of sight）路径和 $L - 1$ 条 NLoS（non line of sight）路径叠加来表示，表达式^[5]为

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

其中， $\beta_l(f)$ 为第 l 条路径的损耗函数； $\mathbf{a}(\phi_l, \theta_l, r_l, f)$ 为基站的阵列响应； f 为工作频率； ϕ_l 、 θ_l 、 r_l 和 τ_l 分别为第 l 条路径的方位角、仰角、距离和时延。

对于 THz 信道来说，信号在传播过程中的分子吸收损耗无法被忽略^[5]，对于 LoS 路径，其路径损耗可以表示为^[18]

$$\beta_1(f) = \alpha(f) = \frac{c}{4\pi(f)r} e^{-\frac{1}{2}k_{\text{abs}}(f)r} \quad (2)$$




图 1 THz UM-MIMO 系统框架

其中, k_{abs} 为分子吸收系数, 由传播介质决定; r 为传播路径距离。

对于 NLoS 路径而言, 除了分子吸收损耗外, 还需要考虑反射、散射和衍射带来的损耗。但由于 THz 频段的散射和衍射穿透严重, 因此可以忽略, 本文只考虑单次反射带来的影响, 可以通过反射系数 Γ_l 来表示。反射系数 Γ_l 可以由式(3)给出^[19]

$$\Gamma_l = \frac{\cos \varphi_{i,l} - \eta_t \cos \varphi_{o,l}}{\cos \varphi_{i,l} + \eta_t \cos \varphi_{o,l}} e^{-\left(\frac{8\pi^2 f^2 \sigma_{\text{rough}}^2 \cos^2 \varphi_{i,l}}{c^2}\right)} \quad (3)$$

其中, $\varphi_{i,l}$ 与 $\varphi_{o,l}$ 分别为第 l 条路径的入射角和反射角, η_t 与 σ_{rough} 分别为反射面材料的折射率和粗糙度系数, c 为光速。

那么, NLoS 路径的损耗公式可以表示为

$$\beta_l(f) = \Gamma_l \alpha(f), l = 1, 2, \dots, L \quad (4)$$

根据 r_l 和瑞利距离 D 之间的关系, 可以将整个区域划分为近场区域和远场区域。当 $r_l < D$ 时为近场区域, 反之为远场区域。瑞利距离 D 可以由式(5)得出^[12]

$$D = [\sqrt{M}(\sqrt{N} - 1) + (\sqrt{M} - 1)w]^2 \lambda \quad (5)$$

其中, $w = \frac{d_{\text{sub}}}{d_a}$, 如图2所示, d_{sub} 为相邻 SA 之间的距离, d_a 为相邻 AE 之间的距离, λ 为载波波长。

对于近场区域球面波阵面, 阵列响应向量 $\mathbf{a}(\phi_l, \theta_l, r_l, f)$ 中的元素取决于每个 AE 和 RF 链之间的精确距离。对于第 l 条路径, RF 链的位置为 $r_l \mathbf{t}_l$, \mathbf{t}_l 为信号到达角方向上的单位长度矢量, 可以由 $\mathbf{t}_l = (\sin \theta_l \cos \phi_l, \sin \theta_l \sin \phi_l, \cos \theta_l)^T$ 得出。而对于远场区域平面波阵面, 每个 AE 和 RF 链之间的距离可以通过线性函数来近似。

因此, 本文与文献[12]一致, 对平面 AoSA 进行建模以获得阵列中元素的精确坐标。如图2所示, 假设整个 AoSA 位于 x - y 平面上, 以第一个 SA 中的第一个 AE 作为原点构建笛卡儿坐标系, AoSA 中第 m 行第 n 列的 SA 的索引 s_{sub} 以及任意 SA 中的第 \bar{m} 行和第 \bar{n} 列的 AE 的索引 s_a 由式(6)给出

$$\begin{aligned} s_{\text{sub}} &= \left\{ (m-1)\sqrt{M} + n, 1 \leq m, n \leq \sqrt{M} \right\} \\ s_a &= \left\{ (\bar{m}-1)\sqrt{N} + \bar{n}, 1 \leq \bar{m}, \bar{n} \leq \sqrt{N} \right\} \end{aligned} \quad (6)$$

则第 s_{sub} 个 SA 中的第 s_a 个 AE 的坐标 $\mathbf{p}_{s_{\text{sub}}, s_a}$ 可以表示为

$$\mathbf{p}_{s_{\text{sub}}, s_a} = \begin{pmatrix} (m-1)\left[(\sqrt{N}-1)d_a + d_{\text{sub}}\right] + (\bar{m}-1)d_a \\ (n-1)\left[(\sqrt{N}-1)d_a + d_{\text{sub}}\right] + (\bar{n}-1)d_a \\ 0 \end{pmatrix} \quad (7)$$

其中, d_{sub} 为相邻 SA 之间的距离, d_a 为相邻 AE 之间的距离。

此时, 第 s_{sub} 个 SA 中的第 s_a 个 AE 的阵列响应可以由式(8)给出^[12]

$$\mathbf{A}(\phi_l, \theta_l, r_l, f) = \begin{cases} e^{-j2\pi \frac{f}{c} \|\mathbf{p}_{s_{\text{sub}}, s_a} - r_l \mathbf{t}_l\|}, r_l < D \\ e^{-j2\pi \frac{f}{c} \mathbf{p}_{s_{\text{sub}}, s_a}^T \mathbf{t}_l}, r_l \geq D \end{cases} \quad (8)$$

其中, $\mathbf{p}_{s_{\text{sub}}, s_a}$ 为第 s_{sub} 个子阵列中第 s_a 个天线的坐标, 可以由式(7)得到。阵列响应向量 $\mathbf{a}(\phi_l, \theta_l, r_l, f) = \text{vec}(\mathbf{A}(\phi_l, \theta_l, r_l, f))$ 。

对于上行信道估计, 假设 U 个单天线用户向 BS 发送相互正交的导频序列, 即每个用户的信道估计是独立的, 因此在不失一般性的前提下, 可以考虑任意一个用户^[20]。将 \mathbf{x}_p 表示为用户在时隙 p 处的发射导频, 为了方便起见, 将其模值设为 1。那么 BS 在时隙 p 接收到的导频信号 $\mathbf{y}_p \in \mathbb{C}^{M \times 1}$ 可以表示为

$$\mathbf{y}_p = \mathbf{W}_p^H \tilde{\mathbf{h}} \mathbf{x}_p + \mathbf{W}_p^H \mathbf{n}_p = \mathbf{W}_p^H \mathbf{F} \bar{\mathbf{h}} + \mathbf{W}_p^H \mathbf{n}_p \quad (9)$$

其中, $\mathbf{W}_p^H = \mathbf{W}_{\text{BB}, p}^H \times \mathbf{W}_{\text{RF}, p}^H$ 表示接收机混合组合器, 由模拟组合器 $\mathbf{W}_{\text{RF}} \in \mathbb{C}^{MN \times M}$ 和数字组合器 $\mathbf{W}_{\text{BB}} \in \mathbb{C}^{M \times M}$ 组成, \mathbf{H} 表示取矩阵的自共轭运算。在未知信道情况下考虑任意场景, 将 $\mathbf{W}_{\text{BB}, p}$ 取单位矩阵 \mathbf{I} 。 $\mathbf{W}_{\text{RF}, p} = \text{blkdiag}(\mathbf{w}_{1,p}, \mathbf{w}_{2,p}, \dots, \mathbf{w}_{M,p})$ 中每个分量 $\mathbf{w}_{i,p} \in \mathbb{C}^{N \times 1}$ 中的元素满足恒模约束, 模值为 $\frac{1}{\sqrt{N}}$ 。为了减少能量损耗, $\mathbf{W}_{\text{RF}, p}$ 中的模拟相移采用

1 bit 量化角度, 那么最终 $\mathbf{w}_{i,p}$ 中的每个元素的取值从集合 $\left\{ -\frac{1}{\sqrt{N}}, \frac{1}{\sqrt{N}} \right\}$ 中等概率随机选取^[7]。 $\tilde{\mathbf{h}}$ 为

BS 和用户之间的空频信道响应。 \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。由于基于深度学习的方法并不依赖于信道的稀疏性, 本文

采用基于 DFT 的学习字典^[12]。 \mathbf{n}_p 为加性白高斯噪声 (AWGN, additive white Gaussian noise)。 \mathbf{W}^H 为矩阵 \mathbf{W} 的自共轭矩阵。

那么, 经过 P 个时隙后, 导频信号可以表示为

$$\bar{\mathbf{y}} = \bar{\mathbf{A}}\bar{\mathbf{h}} + \bar{\mathbf{n}} \quad (10)$$

其中, $\bar{\mathbf{y}} = [\mathbf{y}_1^T, \mathbf{y}_2^T, \dots, \mathbf{y}_{P-1}^T, \mathbf{y}_P^T]^T \in \mathbb{C}^{MP \times 1}$ 为 P 个时隙后接收到的导频信号, $\bar{\mathbf{A}} = [(\mathbf{W}_1^H \mathbf{F})^T, (\mathbf{W}_2^H \mathbf{F})^T, \dots, (\mathbf{W}_{P-1}^H \mathbf{F})^T, (\mathbf{W}_P^H \mathbf{F})^T]^T \in \mathbb{C}^{MP \times MN}$ 为信道观测矩阵, $\bar{\mathbf{n}} = [(\mathbf{W}_1^H \mathbf{n}_1)^T, (\mathbf{W}_2^H \mathbf{n}_2)^T, \dots, (\mathbf{W}_{P-1}^H \mathbf{n}_{P-1})^T, (\mathbf{W}_P^H \mathbf{n}_P)^T]^T \in \mathbb{C}^{MP \times 1}$ 为噪声矩阵。

值得注意的是, 对于深度学习框架, 复数域的信号难以处理, 因此本文将式(10)表示的复数模型转化为等价的实数模型, 可以表示为

$$\mathbf{y} = \begin{bmatrix} \Re(\bar{\mathbf{y}}) \\ \Im(\bar{\mathbf{y}}) \end{bmatrix}, \mathbf{h} = \begin{bmatrix} \Re(\bar{\mathbf{h}}) \\ \Im(\bar{\mathbf{h}}) \end{bmatrix}, \mathbf{n} = \begin{bmatrix} \Re(\bar{\mathbf{n}}) \\ \Im(\bar{\mathbf{n}}) \end{bmatrix}, \quad \mathbf{A} = \begin{bmatrix} \Re(\bar{\mathbf{A}}) & -\Im(\bar{\mathbf{A}}) \\ \Im(\bar{\mathbf{A}}) & \Re(\bar{\mathbf{A}}) \end{bmatrix} \quad (11)$$

其中, $\mathbf{y} \in \mathbb{C}^{2MP \times 1}$, $\mathbf{h} \in \mathbb{C}^{2MN \times 1}$, $\mathbf{n} \in \mathbb{C}^{2MP \times 1}$, $\mathbf{A} \in \mathbb{R}^{2MP \times 2MN}$, $\Re(\cdot)$ 和 $\Im(\cdot)$ 分别表示复变量的实部和虚部。

于是, 最终的系统模型可以表示为

$$\mathbf{y} = \mathbf{A}\mathbf{h} + \mathbf{n} \quad (12)$$

接着, 将导频信号 \mathbf{y} 作为 LS 算法的输入, 得到信道的粗略估计值 \mathbf{h}^0 。最后, 将导频信号 \mathbf{y} 、估计值 \mathbf{h}^0 以及信道观测矩阵 \mathbf{A} 作为 FPN-OTFN 的输入, 通过训练恢复出真实的信道状态信息。FPN-OTFN 中每一次迭代过程可以表示为

$$\mathbf{h}^{(J+1)} = f_{\text{NLE}, \delta}(f_{\text{LE}}(\mathbf{h}^{(J)}; \mathbf{y})) \quad (13)$$

其中, $\mathbf{h}^{(J)}$ 为第 J 次迭代过程中的信道状态; $\mathbf{h}^{(J+1)}$ 为第 J 次迭代过程的估计结果; δ 为 NLE 的参数集, 在每次迭代过程中是一致的; $f_{\text{LE}}(\cdot)$ 和 $f_{\text{NLE}, \delta}(\cdot)$ 分别为线性估计器和非线性估计器。

2 基于 FPN-OTFN 的信道估计

近年来, 超分辨率图像恢复网络被广泛应用于传统通信系统的信道估计。本节基于 FPN-OAMP

算法引入了一种图像恢复 Transformer 模块和快速傅里叶变换卷积网络, 提出了基于图像恢复网络的深度学习算法 FPN-OTFN。

2.1 网络结构

FPN-OTFN 算法基于 FPN 框架^[12]设计, 如图 3 所示, 该框架分为线性估计器 (LE, linear estimator) 和非线性估计器 (NLE, non-linear estimator) 两部分, 其中, δ 表示 NLE 的参数集, 在每次迭代过程中是相同的。该结构既保留了传统算法的优点, 也补充了神经网络模型强大的学习能力, 显著地降低了模型复杂度。

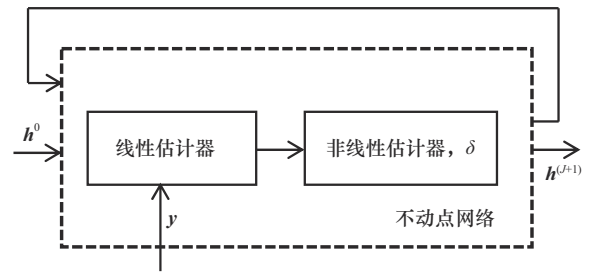


图 3 FPN 框架

FPN-OTFN 的 LE 部分采用 OAMP 算法^[21]中去相关线性估计的伪逆形式, 因为其去相关估计矩阵仅需计算一次, 在每次迭代中都是相同的, 对于 UM-MIMO 系统来说具有较低的计算成本, 同时其性能具有出色的竞争力。其线性表达式为

$$f(\mathbf{h}^{(J)}; \mathbf{y}) = \mathbf{h}^{(J)} + \mathbf{W}(\mathbf{y} - \mathbf{A}\mathbf{h}^{(J)}) \quad (14)$$

其中, $\mathbf{h}^{(J)}$ 为第 J 次迭代过程中的信道状态; \mathbf{A} 为信道观测矩阵; \mathbf{W} 为去相关线性矩阵的伪逆形式, 可以表示为

$$\mathbf{W} = \mu \mathbf{A}^\dagger = \frac{2MN}{\text{tr}(\mathbf{A}^\dagger \mathbf{A})} \mathbf{A}^\dagger \quad (15)$$

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, μ 为保证 $\text{tr}(\mathbf{I} - \mathbf{W}\mathbf{A}) = 0$ 去相关条件成立的步长。

在经过 OAMP 部分的线性估计后, 将非线性估计部分转换成图像恢复的问题来进行信道估计, 将信道响应的数据分为实部和虚部两部分, 每个部分展开成通道数为 M 、信道矩阵大小为 $\sqrt{N} \times \sqrt{N}$ 的图像张量形式, 最终将通道数为 $2M$ 、信道矩阵大小为 $\sqrt{N} \times \sqrt{N}$ 的图像张量作为

非线性估计器输入。通过训练,学习恢复出正确的信道响应。

如图 4 所示, NLE 部分首先是输入通道数为 $2M=8$ 、输出通道数为 64、卷积核大小为 3×3 的输入卷积块,用于提升图像的特征图个数,以便神经网络能更好地提取信道特征。接着是 Leaky ReLU 激活函数和 Layer Norm 层,用于缓解过拟合以及提升模型的稳定性。接着将所得特征图送入 Transformer 模块,有效地增强特征图之间的信息交互,控制有效信息流的进出。之后,经过 FCN 充分地学习特征图中的全局信息,弥补 Transformer 模块提取特征图信息不足的缺点。

最后,经过输入通道数为 64、输出通道数为 8、卷积核大小为 1×1 的输出卷积块实现通道匹配,以便转换为和输入形式相同的信道状态。

2.2 跨通道 Transformer 注意力机制模块

相较于传统的卷积架构,每一个卷积层获得的是局部信息,要想获得更大的感受野,则需要堆叠多层。而 Transformer^[22]中的自注意力机制能够有效地获得全局信息,建模所有像素之间的关系,并且已经在图像处理领域中取得了优异表现。

受此启发,本文在 NLE 部分引入了一种低复杂度的用于图像恢复的 Transformer 模块^[17],该模块由跨通道自注意力(MDTA, multi-dconv head transposed attention)机制和门控前馈网络(GDFN, gated-dconv feed-forward network)两部分组成。

传统的用于图像处理的自注意力机制的计

算开销往往是无法承受的,因为对于高为 H 、宽为 W 的特征图来说其复杂度为 $O(W^2H^2)$,是呈二次增长的。而 MDTA 注重学习特征图通道之间的关系,通过计算特征图通道之间的交叉协方差以生成权重矩阵,在这个过程中其复杂度是呈线性增长的,既满足了计算效率的要求,又为特征图带来了全局信息,其结构如图 5 所示。

图 5 中,首先通过由 1×1 卷积层和 3×3 深度卷积层组成的卷积块生成自注意力机制所需的 Query 矩阵(Q)、Key 矩阵(K)和 Value 矩阵(V),在此过程中能够隐式地建模特征图全局特征。之后是自注意力机制,其计算过程可以抽象为

$$\text{Attention}(Q, K, V) = \text{softmax}\left(\frac{QK^T}{\sqrt{d_k}}\right)V \quad (16)$$

其中, $Q \in \mathbb{C}^{HW \times C}$ 、 $K \in \mathbb{C}^{C \times HW}$ 、 $V \in \mathbb{C}^{HW \times C}$ 分别为查询矩阵、键矩阵、值矩阵,分别由特征图线性映射所得; d_k 是一个可学习参数,用于控制 Q 与 K 点积的大小; C 、 H 和 W 分别为特征图的数量、高和宽。

MDTA 模块丰富了不同通道间的全局信息后,引入 GDFN 模块来控制信息流的输出,使每个层次都能专注于与其他层次互补的细节,其结构如图 6 所示。首先由 1×1 卷积层来扩展通道数;之后通过 3×3 深度卷积层和 GLUE 激活函数来生成门控机制的 2 个特征图,再进行点积操作得到门控信息流输出;最后经过 1×1 卷积层来恢复通道数。




图 4 NLE 结构




图 5 MDTA 结构




图6 GDFN结构

2.3 快速傅里叶变换卷积网络

通过 Transformer 模块可以有效地增强不同通道间的信息关联，得到有效的信息流输出。但考虑到其提取特征图信息的能力是欠缺的，因为MDTA更侧重于通道间的信息交互，而快速傅里叶卷积层具有更宽的图像感受野，拥有较强的提取特征图信息的能力^[23]。如图4所示，本文在NLE部分提出了FCN，其结构如图7所示。

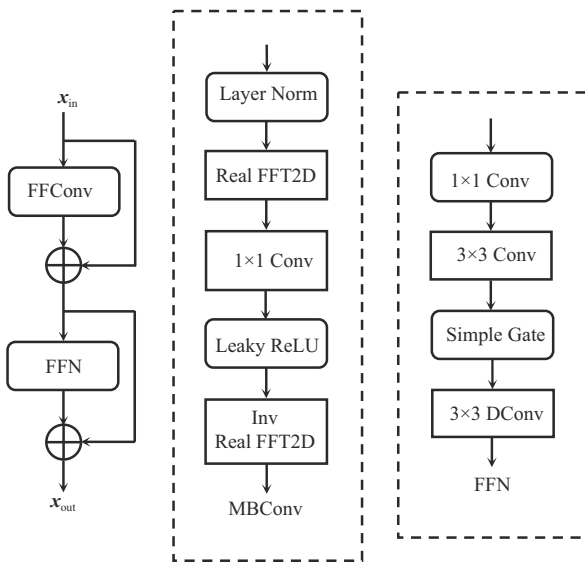


图7 FCN结构

本文构建的FCN由两部分组成，分别为快速傅里叶卷积（FFConv，fast Fourier convolution）模块和前馈神经网络（FFN，feed-forward network）模块。整个过程可以表示为

$$\begin{aligned} \mathbf{x} &= \text{FFConv}(\mathbf{x}_{\text{in}}) \\ \mathbf{x}_{\text{out}} &= \text{FFN}(\mathbf{x}) + \mathbf{x}_{\text{in}} \end{aligned} \quad (17)$$

FCN使用 SimpleGate 单元^[24]代替非线性激活函数。FFConv 模块首先是 Layer Norm 层，可以加快收敛速度；其次是快速傅里叶卷积模块，由二维快速傅里叶变化层、1×1 卷积层、Leaky ReLU 激活函数、反二维快速傅里叶变化层组成，用于提取特征图信息。

FFN 模块首先是 1×1 卷积层和 3×3 卷积层组成的卷积模块，用于提升特征图个数，有效地提取特征。接着是 SimpleGate 单元，该单元既能够代替非线性激活函数的作用，同时能够降低通道数。最后是 3×3 深度卷积层，进一步提高模型的表示能力。整个模块采用残差连接，可以很好地防止信息丢失。

3 仿真与实验结果分析

针对 THz UM-MIMO 系统上行链路系统，本节将通过仿真分析验证所提出的基于 FPN-OTFN 的信道估计算法的性能。

3.1 评估标准

为了进一步客观评估所提 FPN-OTFN 深度学习信道估计算法和其他算法的性能，本文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 用来衡量估计值与真实值之间的差距。NMSE 越小，说明估计性能越好。NMSE 的表达式为

$$\text{NMSE} = 10 \lg \left\{ \mathbb{E} \left[\frac{\|\hat{\mathbf{H}} - \mathbf{H}\|_2^2}{\|\mathbf{H}\|_2^2} \right] \right\} \quad (18)$$

其中， $\hat{\mathbf{H}}$ 为算法的预测值， \mathbf{H} 为真实值。

3.2 训练参数配置及细节

所有的实验是在一台配置 GPU（NVIDIA GeForce RTX3080）的计算机上进行的。所提 FPN-OTFN 基于 Pytorch 框架实现，并使用 Adam 优化器进行训练。训练的批大小为 128，初始学习率为 0.001，训练过程总共 150 个周期，每过 30 个周期，学习率降低一半。训练时，算法的迭代层数设置为 15，训练所用的损失函数为 NMSE，可以表示为

$$\text{loss} = \mathbb{E} \left\{ \frac{\|\hat{\mathbf{H}} - \mathbf{H}\|_2^2}{\|\mathbf{H}\|_2^2} \right\} \quad (19)$$

对于 FPN-OTFN，训练了两组参数，一组用于低信噪比（SNR）场景（0~10 dB），一组用于高 SNR 场景（10~20 dB）。对于每个场景，分别生成 80 000、5 000 和 5 000 个信道样本用于训练、验证和测试。

信道仿真参数如表 1 所示。

表 1 信道仿真参数

参数名称	参数取值
载波频率/GHz	300
基站总天线数/条	1 024
子阵列数	4
单个子阵列天线数/条	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/ns	100
NLoS 路径时延/ns	$\tau_l \sim \mathcal{U}(100, 110)$
分子吸收系数/m ⁻¹	0.003 3
折射率	2.24-j0.025
粗糙度系数/m	8.8×10^{-5}

3.3 仿真实验及结果分析

本节通过仿真实验验证了 FPN-OTFN 信道估计方案在混合场 THz UM-MIMO 窄带系统中的性能, 并与传统信道估计方案和其他基于深度学习的信道估计方案进行了比较。对比算法分别为 LS、ISTA-Net+[25] 和 FPN-OAMP[12]。ISTA-Net+ 是基于软阈值迭代算法的最先进的深度展开模型。FPN-OAMP 的线性部分与 FPN-OTFN 一致, 非线性部分采用了三层残差卷积结构。单层残差块结构如图 8 所示。




图 8 单层残差块结构

3.3.1 有效性分析

在信噪比为 0~20 dB 的情况下, LS、ISTA-Net+、FPN-OAMP 和 FPN-OTFN 的 NMSE 性能如图 9 表示。其中, FPN-OAMP、FPN-OTFN 的迭代

层数均为 15 层, 而 ISTA-Net+ 的层数为 10 层, 实验发现层数的过度叠加将导致其性能变差。实验结果表明, 在一定条件下, 基于深度学习的信道估计算法 FPN-OTFN 及 FPN-OAMP 等均优于传统检测算法 LS。在不同的 SNR 水平下, FPN-OTFN 相比于 FPN-OAMP 和 ISTA-Net+ 的 NMSE 性能均有不同程度的提高。其中, 在 SNR 为 0 时, FPN-OTFN 的 NMSE 性能相比于 ISTA-Net+ 算法提高了 2.3 dB 左右, 相比于 FPN-OAMP 估计算法提升了 1.1 dB 左右。在 SNR 为 20 dB 时, 相比于 ISTA-Net+ 估计算法, FPN-OTFN 有 4.6 dB 左右的性能增益; 相比于 FPN-OAMP 估计算法, FPN-OTFN 有 1.8 dB 左右的性能增益。这说明相较于 FPN-OAMP 中的三层残差卷积结构, 所提 Transformer-FCN 结构具有更强的信息提取能力。




图 9 不同信噪比下, 不同算法的 NMSE 性能比较

图 10 和图 11 分别给出了 ISTA-Net+、FPN-OAMP 和 FPN-OTFN 算法在信噪比为 5 dB 和 15 dB 时在不同迭代层数下的 NMSE 性能对比。由于 LS 并不会产生中间结果, 因此没有绘制。实验结果表明, 当信噪比为 5 dB 时, 在迭代层数为 1 时, FPN-OAMP 性能优于其他算法; 在迭代层数大于 1 时, FPN-OTFN 性能最优。此外, FPN-OAMP 与 FPN-OTFN 均在迭代层数为 4 左右时收敛。而当信噪比为 15 dB 时, FPN-OTFN 性能一直处于最优且在迭代层数为 5 时收敛, 同时比 FPN-OAMP 拥有更快的收敛速度。由此说明, 所提模型既继承了 FPN 框架的动态收敛特性, 同时拥有更高的估计精度。而从图 10 和图 11 可以看出, ISTA-Net+ 的性能随着迭代层数的变化起伏较大, 这是因为

ISTA-Net+是基于深度展开的，它只保证训练时设置的层数的性能，而无法保证中间层数的性能，可扩展性较差，这也再次体现出 FPN 框架的优越性。

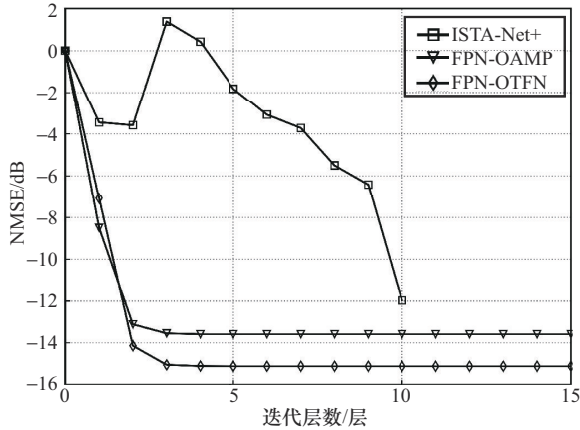


图 10 在信噪比为 5 dB 时,不同迭代层数下不同算法的 NMSE 性能对比

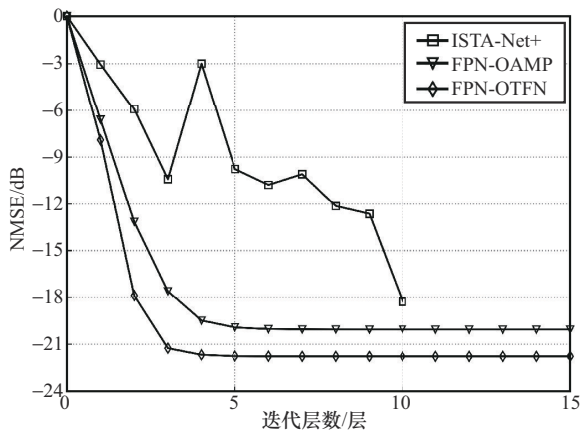


图 11 在信噪比为 15 dB 时,不同迭代层数下不同算法的 NMSE 性能对比

不动点残差和迭代层之间的关系如图 12 所示。不动点残差 Residual norm 由式(20)得出

$$\text{Residual norm} = E \left(\frac{\| \mathbf{h}^{(J)} - \mathbf{h}^* \|_1}{\| \mathbf{h}^* \|_1} \right) \quad (20)$$

其中, $\mathbf{h}^{(J)}$ 为在迭代层为 J 时的预测值, 不动点 \mathbf{h}^* 是通过运行 FPN-OTFN 50 次迭代获得的, 远远超过了训练期间设置的 15 次。

从图 12 可以看出, 曲线在收敛之前均是线性递减的, 在迭代层数为 15 时趋于饱和, 这同样与 FPN 框架的理论是一致的, 表明 Transformer-FCN 的引入并没有对 FPN 框架的特性造成影响。




图 12 不动点残差和迭代层数之间的关系

3.3.2 鲁棒性分析

在实际场景中, 分布偏移(即训练和测试数据的分布不同的情况)在实际部署中普遍存在, 并可能导致基于 DL 的信道估计方法的性能严重下降。本文根据不同的主路径数生成了信道样本, 在路径数 $L = 5$ 的数据集上进行训练, 然后用训练好的模型分别在 $L = 3, 4, 5, 6, 7$ 的测试集上进行测试, 结果如图 13 所示。由于模型在 $L = 5$ 时训练阶段与测试阶段使用了相同分布数据集, 因此作为基线。




图 13 在不同主路径下的 FPN-OTFN 性能比较

从图 13 可以看出, 当 $L = 3, 4$ 时, FPN-OTFN 的 NMSE 性能优于基线, 这是因为在其余环境参数相同的情况下, $L = 3, 4$ 时的信道结构相比于基线较为简单, 因此基于 $L = 5$ 信道数据集训练的模型拥有更为优异的性能。同理, 在信道环境更为复杂的 $L = 6, 7$ 信道时, FPN-OTFN 的 NMSE 性能略有下降, 但仍取得了具有竞争力的 NMSE 性能。

根据 r_l 和瑞利距离 D 之间的关系, 可以将整个

区域划分为近场区域和远场区域。由表1可知,实验仿真设置 $D=20$ m。通过将 r_i 分别设置成 $r_i \sim \mathcal{U}(10,20)$ 和 $r_i \sim \mathcal{U}(20,35)$,可以仅分别对近场区域和远场区域生成对应数据集。

表2验证了信道环境失配对算法性能的影响。本文使用基于混合场数据集训练好的FPN-OTFN模型分别在近场区域数据集和远场区域数据集上进行测试。从表2可以看出,FPN-OTFN单独在近场区域和远场区域的NMSE性能与混合场区域基本一致。其中,在近场区域中NMSE性能稍有下降,而在远场区域中,除了SNR为0外NMSE性能均稍有提升,表明相比于远场区域,近场区域中球面波特性和模型性能的影响是存在的,但同时本文提出的FPN-OTFN算法在环境失配问题中时具有较强的鲁棒性。

表3给出了不同阵列间距对FPN-OTFN的性能影响。根据式(5)可知,阵列间距的变化会导致瑞利距离的变化,进而导致信道环境失配。本文使用阵列间距为 56λ 的数据集进行训练,作为基线,之

后使用训练好的模型分别在阵列间距为 36λ 、 56λ 、 76λ 的数据集上进行测试。结果表明,所训练的网络在阵列间距为 36λ 、 76λ 的条件下相比于基线性能变化与表2是一致的,仍有不错的性能,对于不同的阵列间距NMSE性能较为稳定。

表4验证了阵列中天线间距变化对算法性能的影响。使用基于间距为 $\frac{\lambda}{2}$ 的数据集进行训练的FPN-OTFN模型分别在间距为 $\frac{\lambda}{3}$ 、 $\frac{\lambda}{4}$ 、 $\frac{\lambda}{5}$ 的数据集上进行测试。从表4可以看出,随着天线间距减小,FPN-OTFN的NMSE性能下降,但整体变化不大,表明算法性能对于天线间距的变化同样较为稳定。

表5验证了LoS路径长度对算法性能的影响。使用基于LoS路径长度为30的数据集进行训练的FPN-OTFN模型分别在LoS路径长度为10 m、50 m的数据集上进行测试。从表5可以看出,当LoS路径长度减小时,模型的NMSE性能下降较多,平均下降了0.35 dB。而当LoS路径长度增加时,模型

表2 FPN-OTFN在不同区域的NMSE性能

区域	NMSE/dB				
	SNR=0 dB	SNR=5 dB	SNR=10 dB	SNR=15 dB	SNR=20 dB
近场区域	-11.04	-14.89	-18.24	-21.49	-23.94
远场区域	-11.26	-15.37	-18.59	-21.89	-24.43
混合场区域	-11.29	-15.11	-18.49	-21.77	-24.28

表3 FPN-OTFN在不同阵列间距下NMSE性能

间距	NMSE/dB				
	SNR=0 dB	SNR=5 dB	SNR=10 dB	SNR=15 dB	SNR=20 dB
36λ	-11.32	-15.24	-18.56	-21.87	-24.41
56λ	-11.29	-15.11	-18.49	-21.77	-24.28
76λ	-11.02	-14.83	-18.30	-21.60	-24.04

表4 FPN-OTFN在不同天线间距下NMSE性能

间距	NMSE/dB				
	SNR=0 dB	SNR=5 dB	SNR=10 dB	SNR=15 dB	SNR=20 dB
$\frac{\lambda}{2}$	-11.29	-15.11	-18.49	-21.77	-24.28
$\frac{\lambda}{3}$	-10.99	-14.79	-18.16	-21.42	-23.90
$\frac{\lambda}{4}$	-10.83	-14.44	-17.87	-21.11	-23.60
$\frac{\lambda}{5}$	-10.70	-14.20	-17.86	-21.08	-23.62

表5 FPN-OTFN 在不同LoS路径长度下NMSE性能

LoS路径长度	NMSE/dB				
	SNR=0 dB	SNR=5 dB	SNR=10 dB	SNR=15 dB	SNR=20 dB
10	-10.92	-14.84	-18.21	-21.44	-23.82
30	-11.29	-15.11	-18.49	-21.77	-24.28
50	-11.15	-15.23	-18.51	-21.81	-24.33

的NMSE性能较为稳定，至多只有0.14 dB的变化。

表6验证了欠采样率对算法性能的影响。欠采样率的大小受到导频长度的影响。使用基于欠采样率为0.50的数据集进行训练的FPN-OTFN模型分别在欠采样率为0.25、0.75的数据集上进行测试。从表6可以看出，当欠采样率为0.25时即导频长度减小时，对模型的NMSE性能影响非常大，平均下降了3 dB。而当欠采样率为0.75时，模型的NMSE性能不受影响。

3.3.3 宽带系统仿真分析

3.3.1节与3.3.2节利用窄带系统对所提出的算法进行了仿真分析，通过与其他算法进行对比，验证了所提出算法的性能。但在实际中，为了能够利用巨大的带宽，宽带系统往往更有价值。而对于宽带系统来说，由于不同子载波的频率相差很大，即使对于相同的多径分量，波束功率在不同的子载波上仍然会有很大的变化，这会导致波束斜视效应的产生^[12]。

本节考虑了拥有与图2相同天线阵列的THz UM-MIMO OFDM宽带系统，其中心频率 f_c 为300 GHz，带宽 B 为15 GHz，子载波数目 K 为32，所有子载波共享相同的模拟组合器，其余环境参数均与窄带系统一致，那么最终的系统模型可以建模为

$$y[k] = Ah[k] + n[k] \quad (21)$$

其中， $k = 1, 2, \dots, K$ 为各个子载波的索引，第 k 个子载波的频率为 $f_k = f_c + \left(k - 1 - \frac{K - 1}{2}\right)BK^{-1}$ ， $A \in \mathbb{R}^{2MP \times 2MN}$ 为信道观测矩阵。

同窄带系统一样，对于低信噪比和高信噪比2个场景，分别生成覆盖了32个子载波频率的80 000、

5 000和5 000个宽带信道样本用于训练、验证和测试，其余细节均与窄带系统训练过程一致。

不同算法在宽带系统中的性能对比如图14所示。从图14可以看出，在宽带系统中，FPN-OTFN的性能依然优于基于深度学习的算法FPN-OAMP、ISTA-Net+。

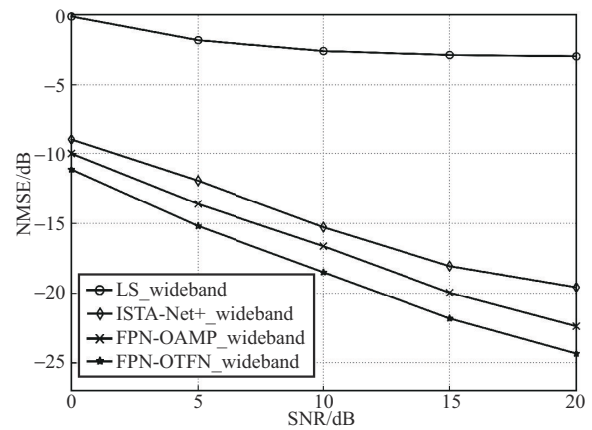


图14 不同算法在宽带系统中的性能对比

图15给出了在宽带系统中，FPN-OTFN、FPN-OAMP、ISTA-Net+这3种基于深度学习的算法在信噪比为15 dB时不同迭代层数下的NMSE性能对比。可以看出，与图11一致，ISTA-Net+的NMSE性能变化起伏巨大，因为其是基于深度展开模型训练的。而基于FPN框架的FPN-OAMP与FPN-OTFN同样随着迭代层数的增加逐渐收敛。其中，FPN-OTFN的NMSE性能一直优于FPN-OAMP，并且在迭代层数为4时收敛，而FPN-OAMP在迭代层数为5时收敛。这表明在宽带系统下，FPN-OTFN相比于FPN-OAMP在测试时动态收敛速度更快。

表6 FPN-OTFN 在不同欠采样率下NMSE性能

欠采样率	NMSE/dB				
	SNR=0 dB	SNR=5 dB	SNR=10 dB	SNR=15 dB	SNR=20 dB
0.25	-7.74	-12.65	-15.82	-19.39	-20.90
0.50	-11.29	-15.11	-18.49	-21.77	-24.28
0.75	-12.82	-16.48	-19.89	-23.02	-25.43

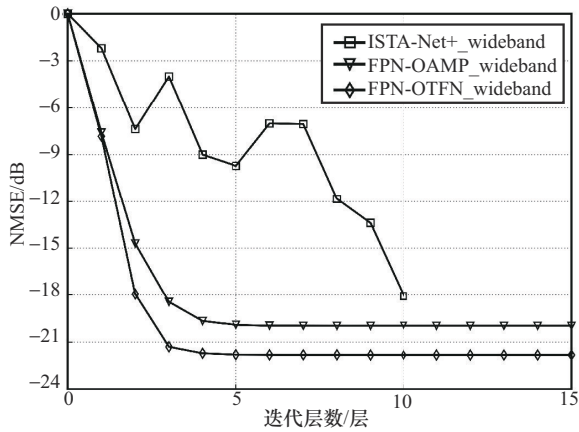


图15 宽带系统信噪比为15 dB时,不同迭代层数下不同算法的NMSE性能比较

3.4 算法复杂度分析

表7对上述所使用的几种深度学习信道估计算法进行了复杂度比较,主要比较了模型的时间复杂度和空间复杂度。为了直观展示,时间复杂度直接使用了模型的每轮训练时间和测试时间进行衡量。而空间复杂度描述了算法在运行过程中临时占用存储空间大小,用参数量进行度量,这里提供了单层模型的参数量。

表7 不同算法的复杂度

算法	参数量	每轮训练时间/s	测试时间/s
ISTA-Net+	313.348×10^3	约60	0.869 7
FPN-OAMP	361.992×10^3	约53	0.133 1
FPN-OTFN	184.009×10^3	约62	0.182 2

从表7中可以看出,3种基于深度学习的方案中,FPN-OTFN的参数量最少,只有FPN-OAMP的约一半。而ISTA-Net+的每轮训练时间约为60 s, FPN-OAMP的每轮训练时间最少,只需要约53 s,而FPN-OTFN的每轮训练时间约为62 s,相较于FPN-OAMP多了9 s。但在GPU上的测试时间中,FPN-OTFN、FPN-OAMP两者相当,分别约为0.182 2 s、0.133 1 s, ISTA-Net+的测试时间最多,约为0.869 7 s。综合来看,FPN-OTFN算法在拥有最优异性能的同时,参数量大幅度减少,虽相较于其他2种算法训练时间有所增多,但在测试时间上仍拥有不错的竞争力。同时,由图10和图11可知,在测试时,FPN-OTFN在5层时NMSE性能就已经收敛,因此在测试时可以调整模型的层数来调整测试时实际花费的时间。

4 结束语

本文针对THz UM-MIMO系统混合场信道估计问题提出了一种基于FPN的深度学习算法FPN-OTFN。首先在导频处采用最小二乘算法获得初始信道信息,之后将其作为去相关的线性估计OAMP和Transformer-FCN深度神经网络组成的基于不动点迭代的估计器的输入,将每次迭代过程中的非线性估计部分视为图像恢复问题,通过引入跨通道Transformer注意力机制模块和FCN有效地提升了THz信道估计的精度。仿真结果表明,本文提出的FPN-OTFN算法相较于FPN-OAMP等算法,拥有更高的估计性能、更低的空间复杂度,同时在一些失配的信道环境中具有良好的鲁棒性。未来工作计划将深度学习领域的迁移学习技术引入THz系统信道估计,旨在解决信道标注数据稀缺问题。具体而言,将利用预训练模型提取特征,并在新信道环境估计任务上微调模型,以提升其在新环境中的性能。

参考文献:

- [1] WAN Z W, GAO Z, GAO F F, et al. Terahertz massive MIMO with holographic reconfigurable intelligent surfaces[J]. IEEE Transactions on Communications, 2021, 69(7): 4732-4750.
- [2] ELBIR A M, MISHRA K V, CHATZINOTAS S. Terahertz-band joint ultra-massive MIMO radar-communications: model-based and model-free hybrid beamforming[J]. IEEE Journal of Selected Topics in Signal Processing, 2021, 15(6): 1468-1483.
- [3] FAISAL A, SARIEDDEEN H, DAHROUJ H, et al. Ultramassive MIMO systems at terahertz bands: prospects and challenges[J]. IEEE Vehicular Technology Magazine, 2020, 15(4): 33-42.
- [4] LIN C, LI G Y L. Terahertz communications: an array-of-subarrays solution[J]. IEEE Communications Magazine, 2016, 54(12): 124-131.
- [5] 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.
- [6] ELBIR A M, SHI W, PAPAFAEIROPOULOS A K, et al. Near-field terahertz communications: model-based and model-free channel estimation[J]. IEEE Access, 2023, 11: 36409-36420.
- [7] CUI M Y, DAI L L. Channel estimation for extremely large-scale MIMO: far-field or near-field?[J]. IEEE Transactions on Communications, 2022, 70(4): 2663-2677.
- [8] 黄源, 何怡刚, 吴裕庭, 等. 基于深度学习的压缩感知FDD大规模MIMO系统稀疏信道估计算法[J]. 通信学报, 2021, 42(8): 61-69.
- HUANG Y, HE Y G, WU Y T, et al. Deep learning for compressed sensing based sparse channel estimation in FDD massive MIMO systems[J]. Journal on Communications, 2021, 42(8): 61-69.

- [9] CHEN Y H, HAN C. Deep CNN-based spherical-wave channel estimation for terahertz ultra-massive MIMO systems[C]//Proceedings of the GLOBECOM 2020 - 2020 IEEE Global Communications Conference. Piscataway: IEEE Press, 2020: 1-6.
- [10] RANJITH S, JESU J P, CHANDRA S 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.
- [11] GAO J B, CHENG X M, LI G Y. Deep unfolding-based channel estimation for wideband TeraHertz near-field massive MIMO systems[J]. arXiv Preprint, arXiv: 2308.13381, 2023.
- [12] YU W T, SHEN Y F, HE H T, et al. An adaptive and robust deep learning framework for THz ultra-massive MIMO channel estimation[J]. arXiv Preprint, arXiv: 2211.15939, 2022.
- [13] SOLTANI M, POURAHMADI V, MIRZAEI A, et al. Deep learning-based channel estimation[J]. IEEE Communications Letters, 2019, 23 (4): 652-655.
- [14] RU X, WEI L, XU Y Y. Model-driven channel estimation for OFDM systems based on image super-resolution network[C]//Proceedings of the 2020 IEEE 5th International Conference on Signal and Image Processing (ICSIP). Piscataway: IEEE Press, 2020: 804-808.
- [15] WANG Y Z, LU H C, SUN H. Channel estimation in IRS-enhanced mmWave system with super-resolution network[J]. IEEE Communications Letters, 2021, 25(8): 2599-2603.
- [16] ZAMIR S W, ARORA A, KHAN S, et al. Restormer: efficient transformer for high-resolution image restoration[C]//Proceedings of the 2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway: IEEE Press, 2022: 5718-5729.
- [17] SARIEDDEEN H, ALOUINI M S, AL-NAFFOURI T Y. An overview of signal processing techniques for terahertz communications[J]. Proceedings of the IEEE, 2021, 109(10): 1628-1665.
- [18] BOULOGGEORGOS A A, PAPANOTIRIOU E N, ALEXIOU A. Analytical performance assessment of THz wireless systems[J]. IEEE Access, 2019, 7: 11436-11453.
- [19] PIESIEWICZ R, JANSEN C, MITTLEMAN D, et al. Scattering analysis for the modeling of THz communication systems[J]. IEEE Transactions on Antennas and Propagation, 2007, 55(11): 3002-3009.
- [20] TSE D, VISWANATH P. Fundamentals of wireless communication[M]. Cambridge: Cambridge University Press, 2005.
- [21] MA J J, PING L. Orthogonal amp[J]. IEEE Access, 2017, 5: 2020-2033.
- [22] VASWANI A, SHAZEER N, PARMAR N, et al. Attention is all you need[C]//Proceedings of the 31st International Conference on Neural Information Processing Systems. Massachusetts: MIT Press, 2017: 6000-6010.
- [23] ZHANG D F, HUANG F Y, LIU S Z, et al. SwinFIR: revisiting the SwinIR with fast Fourier convolution and improved training for image super-resolution[J]. arxiv Preprint, arxiv:2208.11247, 2022.
- [24] CHEN L Y, CHU X J, ZHANG X Y, et al. Simple baselines for image restoration[C]//Proceedings of European Conference on Computer Vision. Cham: Springer Nature Switzerland, 2022: 17-33.
- [25] ZHANG J, GHANEM B. ISTA-net: interpretable optimization-

inspired deep network for image compressive sensing[C]//Proceedings of the 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. 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。



赵阳 (2000-), 男, 江苏淮安人, 南京邮电大学硕士生, 主要研究方向为深度学习与信号处理。



魏玉尧 (2001-), 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。



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。



高贵 (2000-), 男, 安徽阜阳人, 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。



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。