

基于 DFMN-TWF 的高速无人机太赫兹时变混合场信道估计

张昀, 孙洋, 卢宏宇, 蔡良隆, 管腾飞, 于舒娟, 黄丽亚¹

(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)

摘要: 针对高速无人机 THz 超大规模 MIMO 系统中混合远近场、宽带波束斜视、多普勒扩展与姿态变化共同作用下的信道估计问题, 构建宽带时变混合场信道模型, 并提出基于 FPN-OAMP 的 FPN-OAMP-DFMN-TWF 信道估计方法。TWF 利用相邻时隙信道的相关性, 通过可学习权重对连续多个时隙的观测信号进行加权融合。DFMN 作为 FPN-OAMP 的非线性估计器, 由自适应多尺度融合模块和跨块注意力模块组成, 分别提取多尺度角域特征并加强不同特征块之间的信息交互。仿真结果表明, 所提方法较 FPN-OAMP 具有更低的 NMSE 和更快的收敛速度, 并在不同无人机速度、路径数和欠采样率下保持稳定的估计性能。

关键词: 太赫兹通信; 超大规模 MIMO; 信道估计; 无人机通信; 混合远近场; 注意力机制

中图分类号: TN92

文献标志码: A

DFMN-TWF-Based Time-Varying Hybrid-Field Channel Estimation for High-Speed UAV Terahertz Communications

ZHANG Yun, SUN Yang, LU Hongyu, CAI Lianglong, GUAN Tengfei, YU Shujuan, HUANG Liya¹

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

Abstract: The channel estimation problem in high-speed UAV THz UM-MIMO systems under hybrid near-/far-field propagation, wideband beam squint, Doppler spread, and attitude variations was investigated. A wideband time-varying hybrid-field channel model was established, and an FPN-OAMP-DFMN-TWF method was proposed. Adjacent-slot correlation was exploited by TWF, and multi-slot observations were fused using learnable weights. DFMN, the nonlinear estimator in FPN-OAMP, was composed of adaptive multi-scale fusion and cross-block attention modules; multi-scale angular-domain features were extracted and inter-block information interaction was enhanced. Lower NMSE and faster convergence than FPN-OAMP were demonstrated by simulations, and stable performance was maintained under different UAV speeds, path numbers, and undersampling ratios. The proposed method achieves robust channel estimation for high-speed UAV THz UM-MIMO systems.

Key words: Terahertz Communications, Ultra-massive MIMO, Channel Estimation, UAV Communications, Hybrid Near-far Field, Attention Mechanism

0 引言

随着 6G 空天地一体化网络的发展, 无人机(Unmanned Aerial Vehicle, UAV) 凭借部署灵活、机动性强等特点, 逐渐应用于应急通信^[1]、数据回

传^[2]等场景。太赫兹(Terahertz, THz) 频段具有超宽频谱资源, 为无人机高速通信提供了新的技术路径^[3]。然而, 当无人机以百公里级速度飞行并与地面基站建立太赫兹链路时, 通信信道面临一系列严

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)

峻挑战。THz 超大规模多输入多输出 (Ultra-Massive MIMO, UM-MIMO) 系统由于阵列孔径大、波长短, 且通信距离常跨越瑞利距离, 使得信道同时呈现近场球面波与远场平面波混合场效应^[4]。UAV 高速运动带来显著的多普勒频移, 使信道相干时间缩短至微秒级^[5], 此外, UAV 平台在气流扰动下的姿态漂移进一步加剧了信道的非平稳性^[6]。

针对超大规模阵列中的混合场传播与空间非平稳特性, 已有研究从信道建模、特征表征和估计方法等方面进行了深入研究。随着 THz UM-MIMO 阵列孔径不断增加, 传统远场平面波模型难以准确刻画超大规模阵列中不同天线位置对应的幅度衰减与相位变化近, 场球面波传播逐渐成为 XL-MIMO 系统的重要特征。文献[4]系统分析了 XL-MIMO 系统中远场、近场及混合场传播模型的适用条件, 指出随着阵列孔径增大, 信道可能同时呈现球面波与平面波传播特征。在此基础上, 空间非平稳 (Spatially Non-Stationary, SnS) 特性进一步受到关注。由于超大规模阵列中不同子阵的散射环境和可见区域存在差异, 路径功率分布、阵列响应以及有效散射区域均呈现明显的空间变化。针对近场 SnS 信道估计问题, 已有研究利用空间结构差异辅助信道恢复, 通过自适应子阵列划分和分层估计策略提升估计性能并降低计算复杂度^[7-8]。随着实际阵列架构的引入, 文献^[9]进一步研究了混合合并架构下的非平稳近场信道估计问题。此外, 模型驱动与数据驱动融合方式逐渐应用于近场 XL-MIMO SnS 信道估计, 通过结合物理先验与深度学习网络提升复杂场景下的估计能力^[10]。然而, 上述工作主要聚焦于空间域中的近场传播特性和非平稳散射建模, 通常假设信道在观测时间内保持准静态, 尚未考虑高速移动平台下信道随时间变化的动态特性。

除空间域的非平稳特性外, 高速 UAV 运动导致的传播路径长度、到达方向及多普勒频移随时间变化, 使信道呈现明显的时变特性。传统移动通信场景中, 文献[11]采用一阶 AR(1)过程近似 Jakes 模型的时间相关特性以表征时间相关性, 适用于 sub-6 GHz 地面远场低速移动场景。UAV 信道因平台高机动性呈现更强的非平稳性, 文献[12]基于几何信道模型, 理论推导 THz 频段 UAV 信道的时自相关函数与多普勒功率谱密度随姿态、速度等参数的变化规律。文献[13]结合无人机大规模 MIMO 实测

数据, 提出平稳角作为平稳距离在时域上的补充度量, 并分析了信道在空域与频域的平稳性特征。另一方面, THz 系统的大带宽和超大规模阵列特性使阵列响应应具有明显的频率依赖性, 从而产生波束斜视效应。由于近场传播中阵列响应同时依赖传播距离和入射方向, 波束斜视会进一步与近场球面波传播产生耦合, 使不同频率分量对应的空间响应出现差异。针对上述问题, 已有研究开始关注波束斜视与近场传播共同作用下的信道建模与估计问题。文献^[14]针对 THz XL-MIMO 系统中的混合场波束分裂问题, 提出基于波束斜视模式检测的信道估计方法, 实现了远近场传播条件下的波束分裂识别。文献^[15]进一步研究了波束斜视与近场效应共同影响下的分布式信道估计问题, 分析了宽带条件下频率相关阵列响应对近场信道恢复的影响。文献^[16]从远近场统一角度分析了 THz 系统中的波束斜视形成机制, 并讨论了相应的补偿策略。现有研究或聚焦于近场与波束斜视的频域耦合, 或单独分析高速运动引起的时变特性, 尚未将高速运动导致的传播参数动态变化与频率相关阵列响应的耦合纳入统一框架。因此, 上述耦合效应使基于准静态假设的传统信道估计方法难以直接适用。

在 THz 混合场信道估计方面, 传统 LS、MMSE 及压缩感知类方法存在估计精度不足、先验依赖较强或计算复杂度较高等问题, 难以适应近场球面波与远场平面波并存的信道结构^[17]。文献[18]将固定点网络用于 THz 混合场信道估计, 实现了混合场信道的统一估计。文献[19]进一步提出基于固定点网络的 FPN-OAMP, 将 OAMP 线性估计与神经网络非线性估计相结合, 并依据迭代残差自适应调整迭代次数, 在满足收缩条件时可保证固定点迭代收敛。现有 THz 深度学习信道估计方法主要通过网络结构和物理先验融合提升估计性能。基于残差网络的固定点框架采用轻量化非线性估计器, 通过迭代结构降低网络深度依赖^[19]。引入 LSTM、注意力机制或多尺度特征提取模块的方法虽增强了网络的时空特征交互能力, 但增加了网络参数数量和计算开销^[20-21]。从先验利用角度看, 现有方法可分为隐式先验学习和显式模型约束两类。隐式先验学习依靠神经网络从训练数据中学习信道分布特征^[19], 显式模型约束则通过算法展开、稀疏约束或概率模型将信道先验嵌入网络结构^[21-23], 本文采用模型约

束与隐式先验学习相结合的方式,在FPN-OAMP框架下保留线性观测模型与OAMP迭代结构,并通过DFMN和TWF从训练数据中学习混合场结构特征与时序相关信息。自适应迭代网络根据输入状态调整推理深度,避免固定层数带来的计算冗余^[19];注意力结构和概率推断模型虽能提升特征表达能力,但会引入额外计算负担^{[20-21][23]}。现有方法主要围绕单时刻信道特征恢复展开,对高速运动场景下相邻时隙信道之间存在的时间相关性利用不足。

为此,本文面向高速UAV THz UM-MIMO宽带时变混合场信道估计,提出一种时序加权融合(TWF)前端的改进型FPN-OAMP框架,在利用相邻帧时间相关性的同时增强网络对宽带混合场特征的表征能力,并在非线性估计器满足收缩条件时保持固定点迭代的收敛性。本文主要贡献如下:

1) 区别于现有UAV信道研究仅关注姿态对信道统计特性的影响,深度学习估计方法通常针对单时刻信道特征恢复,本文利用相邻时隙信道相关性,创新地提出时序加权融合前端,综合考虑波束斜视与UAV信道进行结合。该模块通过可学习权重对连续 T 个时隙的观测信号进行加权融合,仅引入 T 个可学习参数,无需采用循环网络即可利用相邻时隙的相关信息。

2) 提出了DFMN非线性估计器。通过AMSF匹配不同散射距离下的角域弥散尺度,以CBA实现跨子阵全局特征交互,联合完成角域多尺度覆盖与空域非平稳建模。解决了通用卷积或注意力机制难以同时表征近场角域弥散与空域非平稳散射的难题。

3) 创新性构建了FPN-OAMP-DFMN-TWF联合固定点信道估计框架。TWF在迭代前对连续时隙观测进行自适应加权融合,DFMN作为非线性估计器参与固定点迭代,并通过收缩因子约束网络映射。该框架将相邻时隙相关信息与混合场多尺度角域特征、跨子阵特征共同引入信道估计过程,解决了现有FPN-OAMP主要依赖单时刻观测、难以同时利用高速UAV信道时序相关性与混合场空间结构信息的问题。

1 系统模型

考虑一个高速无人机THz上行链路通信场景:

无人机作为移动终端向地面基站(Base Station, BS)发送信号。UAV飞行高度为数十米,运动速度超过100km/h,引入数十千赫兹量级的多普勒频移,使信道相干时间降至微秒级,呈现强时变非平稳特性。




图1 高速UAV太赫兹混合场动态信道系统模型

基站采用AoSA硬件架构,如图1所示^[11],该架构由 N_s 个子阵列(Subarray, SA)组成,每个子阵内部集成 M 个天线单元,并共享一条射频链,通过移相器实现模拟波束成形;子阵间则进行数字信号处理。采用模拟波束成形(RE),子阵间进行数字处理。子阵列间距 d_{sub} ,子阵内部元间距 $d_a = \lambda_c/2$ 。子阵内部天线间距决定单个子阵的局部阵列响应,而子阵间距用于描述不同子阵之间的空间布局差异。由于THz波长极短且阵列孔径较大,收发距离常跨越瑞利距离,

$$D_F = \frac{2D^2 A}{\lambda_c} \quad (1)$$

其中 D_A 为最大物理孔径, λ_c 为载波波长,当散射体到阵列原点的距离 $r_l(t) \leq D_F$ 时,信道呈现近场球面波(Spherical Wavefront, SW)特性;当 $r_l(t) \geq D_F$ 时,则退化为远场平面波(Plane Wavefront, PW)特性。

系统采用宽带OFDM,总带宽为 B ,子载波数为 K ,第 k 个子载波频率为

$$f_k = f_c + \left(k - \frac{K}{2}\right) \Delta f, \quad k = 1, \dots, K \quad (2)$$

其中 $\Delta f = B/K$ 为子载波间隔。由于空间频率 $\sin \theta / \lambda_k$ 随 f_k 变化,不同子载波的等效波束方向产生偏移,即波束斜视(Beam Squint)效应,导致角度-时延耦合失真。设信道包含 L 条传播路径,考虑UAV高速运动引起路径传播距离和到达方向均随时间变

化^[12], 分别为 $r_l(t)$ 和 $(\theta_l(t), \phi_l(t))$ 。其中, $r_l(t)$ 由无人机位置与散射点位置之间的相对距离确定。对于第 t 个时隙, 无人机位置表示为:

$$\mathbf{p}_u(t) = \mathbf{p}_u(0) + \mathbf{v}t, \quad (3)$$

对于第 l 条传播路径, 设对应散射点位置为 $\mathbf{s}_l$, 则传播距离为

$$r_l(t) = \|\mathbf{s}_l - \mathbf{p}(t)\| \quad (4)$$

由时变传播距离进一步确定路径到达方向:

$$\mathbf{u}_l(t) = \frac{p_l - p_u(t)}{\|p_l - p_u(t)\|} \quad (5)$$

由此得到 $(\theta_l(t), \phi_l(t))$ 。其中, $(\theta_l(t), \phi_l(t))$ 分别表示由时变方向向量 $\mathbf{u}_l(t)$ 转换得到的俯仰角和方位角。由式(5)可得到第 l 条路径的时变传播方向及其对应的俯仰角和方位角。进一步考虑 UAV 高速运动引起的其多普勒频移为

$$[\mathbf{a}(\theta_l, \phi_l, f_k)]_m = \begin{cases} \frac{1}{\sqrt{N}} \exp\left(-j \frac{2\pi f_k}{c} D_{m,l}\right), & r_l \leq Z_R \\ [8pt] \frac{1}{\sqrt{N}} \exp\left(j \frac{2\pi f_k}{c} (p_{x,m} \sin \theta_l \cos \phi_l + p_{y,m} \sin \theta_l \sin \phi_l)\right), & r_l > Z_R \end{cases} \quad (7)$$

进一步考虑无人机在飞行中受风场扰动影响, 机体产生随机横滚角 $\alpha(t)$ 、俯仰角 $\beta(t)$ 与偏航角 $\gamma(t)$ 抖动, 各分量独立服从一阶自回归 (AR(1)) 过程为:

$$\phi(t) = \rho\phi(t-1) + \sqrt{1-\rho^2} \sigma \varepsilon(t), \varepsilon(t) \sim \mathcal{N}(0,1) \quad (8)$$

其中 $\rho = \exp(-\Delta t/\tau_c)$ 为时间相关系数, $\tau_c = 50\text{ms}$ 为姿态相关时间, σ 为抖动标准差。三个欧拉角构成旋转矩阵:

$$f_{d,l} = \frac{v f_c}{c} \cos \psi_l \quad (6)$$

其中 v 是无人机速度, c 为光速, f_c 是载波频率, ψ_l 为 UAV 运动方向与第 l 条路径入射方向之间的夹角。受混合场信道建模工作的启发^[20], 本文采用基于传播距离的分段导向矢量模型, 对第 k 个子载波, 第 m 个天线单元对第 l 条路径的空间导向响应如式(7), 其中 $D_{m,l}$ 为第 m 个天线到第 l 个散射体的实际距离, $(p_{x,m}, p_{y,m})$ 为第 m 个天线的平面坐标。式(7)以 r_l 与 Z_R 的大小关系为判据, 自适应切换球面波与平面波模型, 统一刻画混合场特性。由于实际传播环境中的波前演化具有连续性, 本文采用基于瑞利距离的区域划分方法选择相应波前近似模型, 以在保证建模准确性的同时降低混合场信道分析复杂度。

$$\mathbf{R}(t) = \mathbf{R}_z(\gamma) \mathbf{R}_y(\beta) \mathbf{R}_x(\alpha) \quad (9)$$

其中 $\mathbf{R}_x(\alpha)$ 、 $\mathbf{R}_y(\beta)$ 、 $\mathbf{R}_z(\gamma)$ 分别为绕 x 、 y 、 z 轴的基本旋转矩阵。此外, 考虑无人机姿态扰动导致阵列坐标系变化, 将无人机运动产生的时变入射方向 $\hat{\mathbf{k}}l(t)$ 变换至机体坐标系: $\hat{\mathbf{k}}_{\text{loc}} = \mathbf{R}(t)^\top \hat{\mathbf{k}}l(t)$, 以此修正式(7)中的有效导向角。由本文系统参数可知, 阵列孔径约 122λ , 半功率波束宽度 (Half-Power Beam Width, HPBW) 仅约 0.42° ; 当 $\sigma = 0.5^\circ$ 时指向误差已超 HPBW, 导致角域信道能量峰值偏移, 破坏稀疏结构。综合时变多普勒相位与姿态漂移修




图2 基于 FPN-OAMP-DFMN-TWF 的无人机 THz UM-MIMO 信道估计架构

正,第 t 时隙第 k 子载波的完整导向响应为:

$$\tilde{a}_m(\theta_l, \varphi_l, f_k, t) = [\mathbf{a}(\hat{\mathbf{k}}_{\text{loc}}(t), f_k)]_m \cdot \exp(j2\pi f_{D,l} t \Delta t) \quad (10)$$

将空间几何响应、频率色散与时域动态特性统一建模,描述高速UAV场景下的时变非平稳宽带混合场信道行为。第 t 时隙第 k 子载波的基带接收信号为

$$\mathbf{y}_{k,t} = \mathbf{W}_{\text{RF}}^H (\mathbf{A}_k \mathbf{h}_{k,t} + \mathbf{n}_t) \quad (11)$$

其中 $\mathbf{W}_{\text{RF}}$ 为模拟组合矩阵, $\mathbf{A}_k = \mathbf{W}_{\text{RF}}^H \mathbf{F}_k \in \mathbb{C}^{M \times N}$ 为频率相关压缩量测矩阵,其中 M 表示信道估计中有效观测维度, N 为基站天线数量。 $\mathbf{h}_{k,t} \in \mathbb{C}^N$ 为角域信道向量, $\mathbf{n}_t$ 为加性高斯白噪声。将复数量测转化为实数形式:

$$\tilde{\mathbf{y}}_{k,t} = \begin{bmatrix} \text{Re}(\mathbf{y}_{k,t}) \\ \text{Im}(\mathbf{y}_{k,t}) \end{bmatrix} \in \mathbb{R}^{2M} \quad (12)$$

由于无人机高速移动,信道随时间快速变化,但相邻时隙的信道状态仍保留一定时间相关性。由Jakes模型计算, $v = 120\text{km/h}$ 、 $\Delta t = 2\mu\text{s}$ 时相邻帧相关系数0.957,具有显著时序利用价值。为此,收集连续 T 个时隙的量测值构成输入窗口:

$$\mathbf{Y} = [\tilde{\mathbf{y}}_{k,t-T+1}, \dots, \tilde{\mathbf{y}}_{k,t}]^T \in \mathbb{R}^{T \times 2M} \quad (13)$$

本文设计了时序加权融合(TWF)前端,对窗口内 T 帧量测进行自适应加权融合:

$$\hat{\mathbf{y}} = \sum_{\tau=1}^T w_{\tau} \tilde{\mathbf{y}}_{k,t-T+\tau}, \quad w_{\tau} = \frac{\exp(s_{\tau})}{\sum_{j=1}^T \exp(s_j)} \quad (14)$$

TWF以仅 $T = 8$ 个参数实现时序信息的有效聚合,融合量测 $\hat{\mathbf{y}} \in \mathbb{R}^{2M}$ 作为后续DFMN网络的输入,在利用帧间时间强相关性的同时保持极低参数开销。基于上述宽带时变混合场模型,本文进一步构建FPN-OAMP-DFMN-TWF信道估计模型,以充分利用相邻时隙的观测信息,并增强对复杂信道特征的提取能力。

2 基于DFMN-TWF模型的信道估计

FPN-OAMP框架将信道估计转化为不动点求解,NLE的特征表达能力决定了其性能上限。高速UAV THz混合场信道的三重物理特性使NLE面临专门挑战:近场球面波角域能量扩散宽度随散射体距离变化,需多尺度感受野覆盖;大孔径AoSA各子阵可见散射体不同,空域非平稳性要求跨子阵特

征交互;相邻时隙信道高度相关,时序观测窗口包含冗余信息,无法充分利用单时隙独立估计。因此,本文在FPN-OAMP框架中加入TWF和DFMN,其中TWF用于融合连续时隙的观测信息,DFMN作为非线性估计器提取多尺度特征,整体架构如图2所示。

2.1 FPN-OAMP框架与特征图构造

本文在FPN-OAMP不动点迭代框架基础上^[19],针对宽带时变信道对两处关键设计进行了改进。迭代终止条件改为相对残差:

$$\frac{\|\mathbf{h}^{(i)} - \mathbf{h}^{(i-1)}\|}{\|\mathbf{h}^{(i)}\| + \varepsilon} \leq \varepsilon \quad (15)$$

相比原框架的绝对残差,相对残差使迭代深度自适应于信道能量大小,对宽带时变信道具有更强的鲁棒性。特征图构造严格遵循AoSA物理排布,将NLE输入向量 $\mathbf{h} \in \mathbb{R}^{2N}$ 重排为:

$$H_{\text{feat}} = \text{reshape}(\mathbf{h}) \in \mathbb{R}^{C \times H \times W} \quad (16)$$

其中 $C = N_{\text{RF}} \times 2 = 8$, $H = W = 16$ 满足 $C \times H \times W = 2048 = 2N$ 。每个特征图通道对应一个子阵的实部或虚部角域响应,为后续卷积操作感知子阵间空间结构差异提供物理基础。

2.2 时序加权融合(TWF)前端

在时变信道估计中,单时隙观测容易受到噪声影响,而相邻时隙信道之间仍具有较强的相关性。由Jakes模型^[11]可知,本文场景下相邻时隙信道相关系数约为0.957,时序观测窗口内的历史测量携带与当前时隙高度相关的信道信息,单帧独立估计难以利用这部分相关信息。

基于此,本文设计的TWF前端,以式(15)所示的Softmax加权方式对时序观测窗口 $\mathbf{Y}$ 中 T 帧量测进行自适应融合。各时隙权重通过训练自适应学习,从而充分利用跨时隙相关信息,并减小单时隙噪声对估计结果的影响。TWF在时序维度构造一个自适应匹配滤波器,在不引入循环结构的前提下,以 $T = 8$ 个参数实现对时序相关信息的自适应线性利用,所得融合量测 $\hat{\mathbf{y}} \in \mathbb{R}^{2M}$ 作为后续所有迭代步的固定观测基础。

2.3 DFMN网络结构

由于混合场信道的角域能量分布具有不同尺度,且单个卷积块难以充分利用不同层次的特征信息,本文设计DFMN作为FPN-OAMP的非线性估计器。如图3所示,DFMN由自适应多尺度融合与




图3 DFMN网络结构

跨块注意力两部分串联构成^[24]。AMSF采用不同膨胀率的并行卷积提取多尺度角域特征，并通过可学习系数对各分支输出进行加权融合。CBAD对前序块特征进行加权聚合，并利用注意力图对当前块特征进行加权调整，建立不同特征块之间的关联。输出卷积将特征图映射为信道向量，并通过收缩因子 $\gamma = 0.99$ 对网络输出进行缩放，保证满足不动点压缩映射条件。

2.3.1 自适应多尺度融合模块 AMSF




图4 AMSF结构

由于混合场信道中不同传播分量的角域能量扩散尺度存在明显差异，固定感受野卷积难以同时刻画大范围扩散与局部集中两类特征，因此本文采用 AMSF 模块，通过不同膨胀率的并行卷积分支提取多尺度角域特征，并利用可学习系数对各分支输出进行加权融合。

参考空洞卷积在 Massive MIMO 信道特征提取中的多尺度设置^[25]，AMSF 采用膨胀率为 1、2、3 的三路并行膨胀卷积，分别对应窄、中、宽三种角域感受野，如图 4 所示。三路特征以可学习权重经 Softmax 归一化后自适应融合：

$$w_i = \frac{\exp(z_i)}{\sum_{j=1}^S \exp(z_j)}, \quad i = 1, 2, \dots, S \quad (17)$$

其中 z_i 为第 i 个尺度分支的可学习得分， $S = 3$ ，Softmax 归一化保证 $\sum_{i=1}^S w_i = 1$ 。权重 $\{w_i\}$ 由网络根据输入特征自适应学习：近场分量丰富时宽感受野

权重增大，远场为主时窄感受野权重增大。加权融合得到多尺度特征图：

$$\mathbf{F}_{\text{fuse}} = \sum_{i=1}^S w_i \cdot \mathbf{F}_i \quad (18)$$

其中 $\mathbf{F}_{\text{fuse}} \in \mathbb{R}^{C \times H \times W}$ 为融合后的多尺度特征图，保持与输入相同的空间维度，同时融合了三种尺度的角域散射信息。

2.3.2 跨块注意力模块 CBAD

大孔径 AoSA 阵列中不同子阵的散射体可见域随空间位置变化，信道呈现空域非平稳散射特性。单个卷积块主要提取局部信息，难以充分刻画不同子阵之间的特征差异，同时不同层次的特征信息也未得到充分利用。为此，本文提出 CBAD 模块，其整体结构如图 5 所示，由特征提取主干与跨块注意力（CBA）两部分串联构成，CBA 的内部结构如图 6 所示。




图5 CBAD结构

CBAD 的特征提取主干依次经过 GroupNorm 归一化、自适应多尺度融合（AMSF）、SimpleGate 门控激活与 SCA 简单通道注意力，提取当前层的多尺度角域特征。第一个残差连接将原始输入 h 直接与 SCA 输出相加，减少主干处理过程中的特征信息损失：

$$F_1 = \text{SCA}(\text{AMSF}(\text{GroupNorm}(F))) + F \quad (19)$$

所得 h_1 随后送入 FFN 进行通道维度的非线性变换，第二个残差连接将 h_1 与 FFN 输出相加，缓解深层变换造成的特征偏移：

$$F_2 = \text{FFN}(\text{GroupNorm}(F_1)) + F_1 \quad (20)$$

两个残差连接有助于保留原始信息并稳定网络训练。考虑到单个特征块难以充分刻画不同子阵之间的可见域差异，CBAD 通过融合前序块特征加强跨块信息交互。

如图 6，CBA 以当前块特征 F_{curr} 和前序块特征 F_{prev} 作为双输入： F_{curr} 经全局平均池化和轻量卷积动态生成聚合系数 λ_i ，用于对 F_{prev} 进行加权聚合； F_{curr} 同时直接参与最终的门控调制输出，形成两条




图6 CBA注意力机制

并行路径。CBA对前序块特征进行加权聚合，聚合系数 λ_i 由当前特征图的全局统计量动态生成：

$$\mathbf{F}_{\text{agg}} = \sum_{i=1}^K \lambda_i \mathbf{F}_i^{(\text{prev})} \quad (21)$$

其中 λ_i 为第 i 个前序块的聚合系数，由 $\mathbf{F}_{\text{curr}}$ 经全局平均池化和轻量卷积动态生成并经Softmax归一化， K 为前序块数量。聚合特征 $\mathbf{F}_{\text{agg}}$ 经LCN处理后送入Sigmoid激活，生成逐元素注意力图 $\mathbf{A} \in \mathbb{R}^{C \times H \times W}$ ，对当前特征进行门控调制^[26]：

$$\mathbf{F}_{\text{out}} = \mathbf{F}_{\text{cur}} \odot (1 + \mathbf{A}) \quad (22)$$

其中 $\odot$ 表示逐元素相乘， $\mathbf{A}$ 取值范围为(0,1)，保证调制系数在1附近波动，维持特征稳定性。式(21)的聚合系数 λ_i 为对前序块特征加权的标量，式(22)的注意力图 $\mathbf{A}$ 则对当前特征逐元素加权，使CBAD能够融合前序块信息并突出当前特征中的重要区域。

2.4 FPN-OAMP-DFMN-TWF 信道估计流程

FPN-OAMP-DFMN-TWF的完整估计流程如图2所示。TWF前端融合时序观测窗口 $\mathbf{Y}$ 得到时序融合量测 $\hat{\mathbf{y}}$ ，以最小二乘解初始化后，LE与DFMN交替迭代直至满足相对残差终止条件或达到最大迭代深度15次。在每次迭代中，DFMN依次完成特征图构造、AMSF多尺度提取、CBAD跨块注意力精炼以及输出卷积与 λ 压缩，最终输出当前迭代的信道估计结果。整个框架在继承FPN-OAMP可证明线性收敛与自适应迭代深度理论保证的同时，通过FPN-OAMP-DFMN-TWF在时域、角域与空域三个维度实现联合特征提取，针对性应对高速UAV THz混合场信道的三重物理挑战。

3 实验及结果分析

3.1 评估标准

为了客观评估本文提出的FPN-OAMP-DFMN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：

$$\text{NMSE} = 10 \lg \left\{ \mathcal{E} \left[\frac{\|\hat{\mathbf{H}} - \mathbf{H}\|_2^2}{\|\mathbf{H}\|_2^2} \right] \right\} \quad (23)$$

其中， $\hat{\mathbf{H}}$ 和 $\mathbf{H}$ 分别表示估计信道和真实信道。

3.2 实验设置

实验采用的THz UM-MIMO系统主要参数见表1，散射体距离设置为均匀分布的随机变量，同时涵盖近场与远场区域。信道数据集按高速UAV场景生成：无人机运动速度 $v = 120\text{km/h}$ ，时隙持续时间 $\Delta t = 2\mu\text{s}$ ，每个样本包含 $T = 8$ 个连续时隙，相邻时隙信道相关系数约为0.957；欧拉角姿态漂移标准差 $\sigma = 0.5$ ，姿态相关时间 $\tau_c = 50\text{ms}$ 。本文构建了低信噪比(0 - 10dB)与高信噪比(10 - 20dB)两种仿真场景，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

参数名称	参数取值
载波频率/GHz	300
基站总天线数	1024
子阵列数	4
单个子阵列天线数	256
天线间距/m	0.0005
子阵列间距/m	0.056
移动速度/(km/h)	120
时隙持续时间/ μs	2
单个样本的时隙数T	8
姿态漂移标准差/(°)	0.5
参数名称	参数取值
欠采样率	0.5
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	[10,25]
分子吸收系数/ m^{-1}	0.0033
折射率	2.24-j0.025
粗糙度系数/m	8.8×10^{-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 20dB 之间随机抽取, 具体训练参数设置见表 2。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

参数名称	参数取值
训练集样本	80000
测试集样本	5000
验证集样本	5000
低信噪比/SNR	0-10
高信噪比/SNR	10-20
周期数	150
学习率	0.001
学习率衰退周期	30
学习率衰减的乘法因子	0.5

3.3 仿真分析

3.3.1 基于不同模块的 DFMN 性能对比




图 7 不同 SNR 下各模型 NMSE 性能对比

为系统评估 FPN-OAMP-DFMN-TWF 各组成模块的独立贡献, 本文以时序建模能力与网络后端结构为两个消融维度, 构建四个对比变体: 以原始 ResNet 为后端且不含时序前端的 FPN-OAMP 作为基线; 在 ResNet 后端基础上引入 TWF 前端的 FPN-OAMP+TWF; 采用 DFMN 后端但不含时序前端的 DFMN; 以及本文完整提出的 FPN-OAMP-DFMN-TWF。四种方法在宽带时变 THz UAV 信道上的

NMSE 性能如图 7 所示, FPN-OAMP-DFMN-TWF 在本文实验范围内取得较优性能, 相比基线 FPN-OAMP 平均降低 1.87dB。TWF 前端在 ResNet 后端不变的条件下带来 1.45dB 平均改善, 低 SNR 下改善幅度达 3.39dB, 验证了时序降噪在噪声主导环境下的显著作用; DFMN 结构在单帧条件下较 FPN-OAMP 改善 1.37dB, 且在 TWF 配置相同的条件下仍带来 0.42dB 额外增益, 表明两者具有一定互补性。上述结果表明, TWF、AMSF 与 CBAD 跨块注意力机制共同增强了网络对高速 UAV THz 混合场信道的建模能力。

为分析不同膨胀率组合对 AMSF 特征提取能力的影响, 本文分别设置三种膨胀率配置, 即单尺度组合 [1|1|1]、多尺度组合 [1|2|3] 和 [1|2|4], 结果如表 3 所示。相比于单尺度膨胀率组合 [1|1|1], 引入多尺度膨胀卷积后, 模型在不同信噪比条件下均取得更优的性能。但多尺度组合 [1|2|4] 在各信噪比条件下比 [1|2|3] 性能略低, 虽然增大了膨胀率扩大卷积感受野, 但扩大的膨胀率增加了特征采样间隔, 使局部相关信息提取能力下降。因此, [1|2|3] 能够充分利用不同感受野范围的信息, 增强模型对混合场信道角域结构的表征能力。

表 3 不同膨胀率下的 NMSE 性能

膨胀率	0dB	5dB	10dB	15dB	20dB
[1,1,1]	-11.07	-14.27	-16.93	-20.12	-22.65
[1-3]	-11.42	-14.63	-17.62	-20.86	-23.44
[1-2,4]	-11.32	-14.57	-17.51	-20.64	-23.35

表 4 给出了四种方法的参数量与训练时间对比。TWF 模块仅引入 8 个可学习标量权重, 对参数量与训练时间几乎无影响。DFMN 系列参数量约 10.8 万, 仅为 FPN-OAMP 系列 36.2 万的 30%, 得益于深度可分离卷积与轻量注意力机制的高效设计; 训练时间约 60s/epoch, 略高于 FPN-OAMP 系列的 33s/epoch, 增量来自多分支膨胀卷积与跨块注意力的额外计算。综合来看, FPN-OAMP-DFMN-TWF 在参数量显著减少的同时, 以可接受的计算开销换取了更高的信道估计精度, 具有良好的参数效率。

3.3.2 TWF 时间窗口参数分析

由于 TWF 利用相邻时隙之间的相关信息进行

表4 消融实验各变体参数量与训练复杂度对比		
模块	参数量	训练时间/(s·epoch ⁻¹)
FPN-OAMP	361,992	33
FPN-OAMP+TWF	362,000	30
DFMN	108,347	60
FPN-OAMP-DFMN-TWF	108,355	61

观测融合，其性能依赖于信道短时间尺度相关性。为分析高速 UAV 运动对时间相关性的影响，基于 Jakes 模型计算不同飞行速度下的相邻时隙相关系数^[11]，结果如表 5 所示。

表5 不同 UAV 速度下的相邻时隙相关系数		
UAV 速度/(km/h)	多普勒频移/kHz	相关系数 ρ
60	16.67	0.9896
90	25.00	0.9765
120	33.33	0.9566
150	41.67	0.9326
180	50.00	0.9047

由表 5 可知，随着 UAV 速度增加，多普勒频移逐渐增大，相邻时隙相关系数呈下降趋势。然而，在本文考虑的微秒级时隙间隔下，即使高速运动条件下，相邻观测之间仍保持较强的时间相关性。




图8 不同SNR下各模型NMSE性能对比

为进一步分析时间窗口长度对 TWF 性能的影响，同时为避免窗口长度分析受数据长度限制，本文额外生成包含 16 个连续时隙的数据样本，分别设置 T=1、4、8、12 和 16 五种窗口长度进行测试。不同窗口长度下的 NMSE 性能及 SNR=5 dB 时的迭代收敛结果分别如表 6 和图 8 所示。

由图 8 和表 6 可知，当 T 由 1 增加至 8 时，NMSE 在各 SNR 条件下均得到改善，增加历史观测数据能够提供更多的相关信息。但当 T 继续增加至 12 和 16 时，估计性能未继续提升，并出现小幅波动。不同窗口长度下模型均能在较少迭代次数内趋于稳定，收敛速度差异较小。综合估计性能与时间窗口规模，本文验证了 T=8 在所测试窗口范围内具有较好的估计性能，因此保留原实验设置中的 T=8 作为时间窗口长度。

表6 不同时间窗口下 TWF 的 NMSE 性能					
T	0dB	5dB	10dB	15dB	20dB
1	-10.02	-13.72	-16.89	-20.24	-22.80
4	-11.31	-14.59	-17.20	-20.40	-22.94
8	-11.44	-14.70	-17.70	-20.70	-23.30
12	-11.23	-14.45	-17.19	-20.35	-22.89
16	-11.30	-14.55	-17.23	-20.43	-22.95

3.3.3 不同算法性能对比

表 7 比较了 LS，OMP^[27]，OAMP^[23]，Cross-field RD-SOMP^[28]，FPN-OAMP，FPN-OAMP-DFMN-TWF 在不同信噪比水平下各算法的 NMSE 性能。LS、OMP 与 OAMP 三种传统方法在本文宽带时变混合场 THz 信道上估计性能明显受限，平均 NMSE 不超过 -2dB。其中，LS 和 OAMP 主要依赖线性观测模型进行信号恢复，在欠采样条件下难以有效挖掘混合场信道中的复杂结构信息。OMP 算法依赖固定角域字典的稀疏假设，而宽带波束斜视与姿态漂移共同破坏了角域稀疏结构，使其先验假设失效。

相比传统方法，Cross-field RD-SOMP 通过联合考虑近场距离域与远场角域特征，能够更充分地利用混合场传播结构，因此相比 LS、OMP 和 OAMP 取得了明显性能提升。然而，该方法主要依赖基于字典的稀疏搜索过程，难以进一步利用高速

表7 不同信噪比水平下各算法的NMSE性能

方法	0dB	5dB	10dB	15dB	20dB
LS	0.19	-1.72	-2.55	-2.85	-2.95
OMP	-1.44	-1.59	-1.63	-1.64	-1.64
OAMP	0.19	-1.72	-2.55	-2.85	-2.95
Cross-field	-5.00	-9.70	-14.10	-17.63	-19.45
FPN-OAMP	-7.83	-12.48	-16.39	-19.72	-22.16
DFMN+ TWF	-11.42	-14.63	-17.62	-20.86	-23.44

UAV 场景中的时序相关信息以及复杂非线性特征。FPN-OAMP 深度展开方式引入可学习的非线性估计器,能够隐式学习信道特征,表明深度学习非线性估计器在复杂信道场景下能够有效提升估计性能。所提 FPN-OAMP-DFMN-TWF 平均 NMSE 为 -17.59dB ,较 FPN-OAMP 进一步改善 1.87dB ,充分体现了 DFMN 多尺度角域特征提取与 TWF 时序信息利用的协同优势,在高速 UAV THz 混合场信道估计中具有更优的性能表现。

3.3.4 收敛速度对比

图9和图10分别展示了在信噪比为5dB与15dB条件下,FPN-OAMP、FPN-OAMP+TWF、FPN-OAMP+DFMN及FPN-OAMP+DFMN+TWF四种方法随迭代层数增加时的NMSE变化情况,四种方法均在6次迭代内达到收敛。




图9 不同迭代层数下各算法NMSE性能

根据图9与图10所示的收敛曲线,在收敛精度方面,FPN-OAMP+DFMN+TWF在两个SNR条件下均取得最低收敛NMSE,FPN-OAMP收敛精度最差。在收敛速度方面,引入TWF前端后融合量测 $\hat{\mathbf{y}}$ 的信噪比得到提升,使LS初始解更接近真实




图10 不同迭代层数下各算法NMSE性能

信道, FPN-OAMP+TWF 与 FPN-OAMP+DFMN+TWF 均比 FPN-OAMP 更快达到稳定; DFMN 后端凭借更强的非线性特征提取能力,使每次迭代的更新效果更为显著。在 $\text{SNR}=5\text{dB}$ 低信噪比条件下,各方法收敛后的 NMSE 差距更为明显, FPN-OAMP+DFMN+TWF 的优势最为突出; 在 $\text{SNR}=15\text{dB}$ 高信噪比条件下,各方法收敛所需迭代次数相近,但收敛精度差异仍存在一定差异, FPN-OAMP+DFMN+TWF 仍保持最低的收敛 NMSE。上述结果表明,所提方法在继承 FPN-OAMP 框架收敛性保证的同时,进一步提升了单次迭代性能。

3.3.5 收缩因子敏感性分析

为分析收缩因子 γ 对固定点迭代过程的影响,本文测试了不同 γ 取值下的信道估计性能。除 γ 外,其余网络结构和实验参数均保持不变,分别设置 $\gamma=0.90$ 、 0.95 、 0.99 和 1.00 ,实验结果如表8所示。

表8 不同收缩因子 γ 的NMSE性能

收缩因子 γ	0dB	5dB	10dB	15dB	20dB
0.90	-10.88	-13.64	-15.61	-17.25	-17.90
0.95	-11.27	-14.10	-17.10	-19.80	-21.50
0.99	-11.42	-14.63	-17.62	-20.86	-23.44
1.00	-11.39	-14.61	-17.56	-20.77	-23.30

由表8可知,随着 γ 增加,模型的估计性能逐渐提升,在 γ 从0.90增加到0.99时,NMSE性能得到明显改善。然而,当 γ 进一步增加到1时,性能趋于饱和,略低于0.99。因此, γ 在0.99时取得最佳估计性能,并在估计精度和迭代稳定性之间获得较好的平衡。

3.3.6 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。为评估 FPN-OAMP-DFMN 在训练域之外的泛化能力,本节在保持模型参数不变的条件下,分别改变信道路径数、无人机速度、传播场景及欠采样率,并比较不同测试条件下的 NMSE 性能。




图 11 不同主路径数下的 FPN-OAMP-DFMN 性能

图 11 展示了所提算法在不同路径数条件下的归一化均方误差性能,随路径数 L 增大, NMSE 整体呈上升趋势。从信息论角度分析,路径数增加使信道角域支撑集扩展、有效稀疏度降低,在固定压缩比条件下估计难度增加。 $L=2$ 时稀疏度最高, AMSF 多尺度卷积核能以最小的角域特征混叠精确定位各路径能量分布,因而在本文实验范围内取得较优性能; $L=5$ 为训练配置,其曲线处于中间位置而非最低,表明 DFMN 学习到的是对信道统计特性的通用表征而非对特定路径数的过拟合。 $L=3$ 在低 SNR 下性能出现局部波动,与其路径间角域间隔小、多径分量在噪声主导条件下难以有效分辨有关,随 SNR 升高后性能恢复正常。 $L=7$ 与 $L=10$ 的 NMSE 差距不超过 2 dB,说明所提方法对超出训练配置的高复杂度信道仍具有一定适应能力,验证了对路径数变化的良好泛化性。

图 12 展示了所提算法在不同多普勒频移(速度)下的归一化均方误差性能。从多普勒效应的角度分析,无人机速度决定了信道的时变速率,速度越高多普勒频移越大、相邻时隙间的信道相位旋转越快。然而, TWF 通过可学习的 Softmax 加权系数自适应调整各历史时隙的融合权重,无需预设固定




图 12 不同无人机速度(多普勒频移)下所提算法的 NMSE 性能

的多普勒模型,因而对速度变化具有内在的自适应能力。即使在训练速度 120km/h 之外的 30 至 150km/h 范围内, TWF 仍能有效利用帧间时间相关性提升量测质量,减弱速度变化对 DFMN 特征提取的影响。上述结果表明,所提方法对无人机速度变化具有较好的鲁棒性,在实际飞行速度波动场景下无需重新训练即可保持稳定性能。




图 13 FPN-OAMP-DFMN 在不同场景下 NMSE 性能

为评估 FPN-OAMP-DFMN 算法对传播场景的适应性,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。由图 13 可知,近场、混合场与远场三种传播场景下的 NMSE 曲线高度重合,各 SNR 点差值均不超过 0.6dB。

近场球面波因波前曲率引起相位非线性,角域能量跨多个 DFT 频点扩散;远场平面波波前近似

线性, 角域能量高度集中。两种传播机制在角域特征上存在本质差异, 然而 AMSF 模块通过膨胀率为 1、2、3 的三路并行深度可分离卷积, 分别覆盖不同尺度的角域感受野, 在统一框架内同时捕获近场多频点扩散与远场集中分量的空间特征; CBAD 模块通过跨块注意力机制建模大孔径 AoSA 阵列各子阵可见域差异引起的空域非平稳散射, 对近远场场景均具有有效的自适应能力。因此, 所提方法在训练分布之外, 纯近场与纯远场条件下仍能维持稳定的估计性能, 表明 DFMN 结构在不同场景有较好的泛化能力。

图 14 揭示了欠采样率 M/N 对估计性能的影响, 随 M/N 从 0.500 降低至 0.125, NMSE 呈现明显的退化。在 $M/N=0.500$ 为训练配置条件下具有较好性能; $M/N=0.375$ 时 NMSE 仍随 SNR 持续改善, 说明适度压缩条件下不动点迭代仍能从有限观测中提取有效信道信息; M/N 降至 0.250 以下时曲线趋于水平, SNR 的提升无法弥补测量维度不足带来的信息损失, 系统进入观测信息受限区域。上述结果表明, 所提方法在 $M/N \geq 0.375$ 范围内具有可接受的泛化能力, 为实际部署中 RF 链数配置提供了参考依据。




图 14 FPN-OAMP-DFMN 不同欠采样率下 NMSE 性能

进一步验证所提方法在复杂动态环境下的泛化性能, 本文设计多因素联合变化场景进行测试。不同于单因素变化实验, 该实验同时考虑 UAV 速度、传播路径数以及姿态扰动强度的联合变化。具体场景参数如表 9 所示, 其中 Default 表示训练与测试条件一致的默认场景, Case 1 - Case 3 表示逐渐增强的联合扰动场景。由表 10 可知, 随着联合扰动程

度增加, 模型估计性能逐渐下降。尽管高速运动、多径数量增加以及姿态扰动增强共同提高了信道建模复杂度, 所提方法仍能够保持有效的估计性能, 表明其具备较好的复杂动态场景适应能力。

表 9 多因素联合变化场景参数

场景	速度(km/h)	路径数	姿态标准差
Default	120	5	0.5°
Case1	150	7	1.0°
Case2	180	9	1.5°
Case3	210	10	2.0°

表 10 多因素联合变化场景下的 NMSE 性能比较

场景	0dB	5dB	10dB	15dB	20dB
Default	-11.42	-14.63	-17.62	-20.86	-23.44
Case1	-9.93	-13.12	-16.32	-19.47	-21.90
Case2	-8.57	-11.48	-15.18	-18.16	-20.30
Case3	-7.95	-10.65	-14.63	-17.51	-19.51

3.3.7 算法时空复杂度分析

各算法的参数量与时空复杂度对比如表 11 所示。LS、OAMP 与 OMP 均无可训练参数, 推理速度最快, 但性能受限于欠采样条件下的信息理论下界。深度学习方法中, 所提 FPN-OAMP-DFMN-TWF 参数量仅为 FPN-OAMP 的 30%, 在参数量显著减少的同时取得了更高的估计精度。测试时间的小幅增加来自 TWF 时序融合与 DFMN 多分支注意力机制的额外计算, 该方法在资源受限的场景中具有部署的可行性。

4 结束语

本文面向高速无人机 THz 超大规模 MIMO 系统中混合场传播、宽带波束斜视、多普勒扩展及气流扰动下姿态变化共同作用所带来的信道估计问题, 提出一种基于 FPN-OAMP 的 FPN-OAMP-DFMN-TWF 信道估计方法。其中, TWF 用于融合连续时隙观测, DFMN 作为非线性估计器完成多尺度特征提取与跨块信息交互。仿真结果表明, 与基线 FPN-OAMP 相比, 所提算法的平均 NMSE 改善 1.87dB, 参数量为其 30%, 并在不同无人机速度、传播场景、路径数和欠采样率条件下保持了较稳定的估计性能。

张昀 (1975-), 女, 江苏南京人, 博士, 南京邮电大

表 11 不同算法的时空复杂度

算法模型	可训练参数量	训练时间/(s·epoch ⁻¹)	测试时间/(ms·sample ⁻¹)
LS	0	-	0.034
OMP	0	-	0.901
OAMP	0	-	0.034
FPN-OAMP	361,992	33	0.350
FPN-OAMP-DFMN-TWF	108,355	61	0.623



学副教授，主要研究方向为智能化算法与通信信号处理。
孙洋（2001-），女，内蒙古呼和浩特人，南京邮电大



数据处理。
黄丽亚（1972-），女，江苏南京人，博士，南京邮电



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。
蔡良隆（2001-），男，浙江温州人，南京邮电大学硕



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。



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。
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

参考文献：

[1] Giordani M, Polese M, Mezzavilla M, et al. Toward 6G networks: Use cases and technologies[J]. IEEE communications magazine, 2020, 58 (3): 55-61.

[2] SAAD W, BENNIS M, CHEN M. A vision of 6G wireless systems: Applications, trends, technologies, and open research problems[J]. IEEE network, 2019, 34(3): 134-142.

[3] ZHANG R, WU W, CHEN X, et al. Terahertz integrated sensing and communication-empowered UAVs in 6G: A transceiver design perspective[J]. IEEE Vehicular Technology Magazine, 2025.

[4] WEI X, DAI L. Channel estimation for extremely large-scale massive MIMO: Far-field, near-field, or hybrid-field?[J]. IEEE Communications Letters, 2021, 26(1): 177-181.

- [5] WANG R, REN H, PAN C, et al. Channel Estimation for mmWave High-Mobility Systems with 5G New Radio OFDM[J]. IEEE Transactions on Communications, 2025.
- [6] Wang W, Zhang W. Jittering effects analysis and beam training design for UAV millimeter wave communications[J]. IEEE Transactions on Wireless Communications, 2021, 21(5): 3131-3146.
- [7] Yang S, An P, Yang P, et al. Adaptive subarray segmentation: A new paradigm of spatial non-stationary near-field channel estimation for XL-MIMO systems[J]. IEEE Transactions on Communications, 2025, 74: 2220-2234.
- [8] Wang H, Wen F, Wang X, et al. Hierarchical channel estimation for near-field spatial non-stationary channels: A pre-selection and multi-level dynamic threshold strategy[J]. IEEE Transactions on Cognitive Communications and Networking, 2025, 12: 4174-4185.
- [9] Zhang X, Zheng J. Non-stationary near-field channel estimation for XL-MIMO systems with hybrid combining[J]. IEEE Wireless Communications Letters, 2024, 13(10): 2727-2731.
- [10] Lei H, Zhang J, Liu Z, et al. Mixed model-and data-driven spatial non-stationary channel estimation for near-field XL-MIMO systems[C]// 2025 IEEE 26th International Workshop on Signal Processing and Artificial Intelligence for Wireless Communications (SPAWC). IEEE, 2025: 1-5.
- [11] Truong K T, Heath R W. Effects of channel aging in massive MIMO systems[J]. Journal of Communications and Networks, 2013, 15(4): 338-351.
- [12] Jiang H, Zhang Z, Gui G. Three-dimensional non-stationary wideband geometry-based UAV channel model for A2G communication environments[J]. IEEE Access, 2019, 7: 26116-26122.
- [13] Colpaert A, Cui Z, Vinogradov E, et al. 3D non-stationary channel measurement and analysis for MaMIMO-UAV communications[J]. IEEE Transactions on Vehicular Technology, 2023, 73(5): 6061-6072.
- [14] Lu J, Zhang J, Lei H, et al. Hybrid-field beam-split pattern detection-based channel estimation for THz XL-MIMO systems[J]. IEEE Transactions on Vehicular Technology, 2024, 73(9): 13944-13949.
- [15] Lu Z, Han Y, Li X, et al. Distributed near-field channel estimation for U6G XL-MIMO systems under beam squint[J]. IEEE Transactions on Communications, 2025, 74: 1146-1161.
- [16] Hao W, You X, Zhou F, et al. The far-/near-field beam squint and solutions for THz intelligent reflecting surface communications[J]. IEEE Transactions on Vehicular Technology, 2023, 72(8): 10107-10118.
- [17] Alkhateeb A, El Ayach O, Leus G, et al. Channel estimation and hybrid precoding for millimeter wave cellular systems[J]. IEEE journal of selected topics in signal processing, 2014, 8(5): 831-846.
- [18] Yu W, Shen Y, He H, et al. Hybrid far-and near-field channel estimation for THz ultra-massive MIMO via fixed point networks[C]// GLOBECOM 2022-2022 IEEE Global Communications Conference. IEEE, 2022: 5384-5389.
- [19] 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.
- [20] Kim J, Ahn Y, Kim S, et al. Deep learning-aided parametric sparse channel estimation for terahertz massive mimo systems[J]. IEEE Transactions on Cognitive Communications and Networking, 2024, 10(6): 2136-2148.
- [21] 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, 2024.
- [22] Gao J, Chen X, 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.
- [23] MA J, PING L. Orthogonal amp[J]. IEEE Access, 2017, 5: 2020-2033.
- [24] Feijoo D, Benito J C, Garcia A, et al. Darkir: Robust low-light image restoration[C]//Proceedings of the Computer Vision and Pattern Recognition Conference. 2025: 10879-10889.
- [25] Tang S, Xia J, Fan L, et al. Dilated convolution based CSI feedback compression for massive MIMO systems[J]. IEEE Transactions on Vehicular Technology, 2022, 71(10): 11216-11221.
- [26] Chen L, Chu X, Zhang X, et al. Simple baselines for image restoration [C]//European conference on computer vision. Cham: Springer Nature Switzerland, 2022: 17-33.
- [27] LEE J, GIL G T, KIM S J, et al. Channel estimation via orthogonal matching pursuit for hybrid MIMO systems in millimeter wave communications[J]. IEEE Transactions on Communications, 2016, 64(6): 2370 - 2386.
- [28] Tarboush S, Ali A, Al-Naffouri T Y. Cross-field channel estimation for ultra massive-MIMO THz systems[J]. IEEE Transactions on Wireless Communications, 2024, 23(8): 8619-8635.