

基于条件先验的非平稳信道估计使用加速扩散模型

穆罕默德·阿赫梅德·穆辛¹, 阿桑·比拉尔², 穆罕默德·乌迈尔¹, 阿萨德·阿里³,
穆罕默德·阿里·贾姆谢德⁴, 迪恩·F·休根², 约翰·M·奇奥菲¹

¹ Dept. of Electrical Engineering, Stanford University, Stanford, CA, USA

² School of Computer Science, University of Oklahoma, Norman, OK, USA

³ Dept. of Radiology, Stanford University, Stanford, CA, USA

⁴ College of Science and Engineering, University of Glasgow, Glasgow, UK

ABSTRACT

在充满运动的城区微小区 (UMi) 环境中, 无线信道是非平稳的; 移动性和散射体的动力学随时间改变分布, 恶化了经典和深度估计器的表现。本工作提出了条件先验扩散用于信道估计, 该方法学习了一个基于历史条件的分数以去除嘈杂的信道快照中的噪声。一个带有跨时间注意力机制的时间编码器将短观测窗口压缩为上下文向量, 捕捉到信道瞬时的一致性, 并通过特征调制引导去噪过程。在推理阶段, 信噪比匹配初始化选择边缘与测量输入信噪比对齐的扩散步骤, 并且该过程遵循一个缩短的、几何间隔的时间表, 用远少得多的迭代次数保留了信号噪声轨迹。利用前一信道估计进行时间自条件处理, 并在训练期间仅施加平滑性惩罚以进一步稳定演变, 而不偏置测试阶段的估计算法。在一个 3GPP 基准上的评估显示, 在所有信噪比下 NMSE 均低于 LMMSE、GMM、LSTM 和 LDAMP 基线, 表明了稳定的性能和强大的高信噪比保真度。

Index Terms— 信道估计, 扩散模型, 非平稳信道, MIMO 系统

1. 介绍

精确的信道状态信息 (CSI) 是现代无线系统的一级要求。在宽带多输入多输出 (MIMO) 部署中, 可靠的信道估计对于实现空间复用增益至关重要 [1]。然而, 在城市微蜂窝 (UMi) 中, 用户加速通过时变的

多普勒效应压缩了时间相干性, 这会降低基于导频的插值性能并导致 CSI 过时 [2, 3, 4, 5]。如非平稳性, 其特点是时变抽头统计和相关长度, 打破了平稳性假设, 并恶化了基于固定分布训练的模型。

最近的研究探索了序列模型, 如循环编码器, 用于时变 MIMO 信道 [6]。然而, 这些方法隐含地假设统计变化缓慢 (分段平稳), 并且往往会将测量噪声与信道动态纠缠在一起, 通常需要在相干性减小时频繁重新训练。相比之下, 扩散模型通过控制的时间表和得分匹配分离信号和噪声, 提供了一种原则性的替代方案, 在快速变化的条件下实现了校准去噪 [7, 8]。然而, 标准的基于扩散的去噪器通常是 无条件的, 因此忽略了由诸如用户速度变化等动态引起的依赖历史结构 [9]。

本文解决了通过从因果窗口的信道观测中学习一个条件先验分布来进行非平稳信道估计的问题。先验信息被注入逆扩散过程中, 以使去噪更新与信道当前相干长度对齐。时间上下文使用轻量级循环编码器和跨时注意力进行编码, 并且一个高斯-马尔可夫自条件化机制将之前的干净估计反馈到先验中, 以保持物理上合理的演变。该方法通过特征式线性调制 (FiLM) 融合扩散时间、序列索引和时间上下文来引导特征而不会导致架构膨胀。为了减少采样成本, 在边际分布最符合测量信噪比的扩散步骤开始逆过程, 接着遍历一个子采样的几何间隔扩散阶梯, 其中使用了信噪比匹配初始化 [10]。

贡献。主要贡献如下。

1. 非平稳信道估计的条件扩散框架，该框架从因果观测窗口中学习历史条件先验。该框架采用基于 ConvLSTM 的时间编码，并结合跨时间注意力和高斯-马尔可夫自调节以确保时间稳定性。
2. 一种采用信噪比匹配初始化和几何间隔采样计划的加速推理程序。这种方法在使用显著较少的迭代次数的同时，减少了计算复杂性并保持了信号噪声轨迹。
3. 在 3GPP UMi 基准测试中，对于不同速度（从 2-4 到 30-80 英里/小时）的移动用户实现了最先进的性能。所提出的框架达到了 -17.3 分贝平均 NMSE（相较于最佳基线提高了 2.3 分贝），并且在高 SNR 下的操作性能与理想性能相差 2-4 分贝。

2. 问题表述

考虑 UMi 场景下的多用户 OFDM 下行链路，其中包含 U 个用户， F 个活跃子载波（音调），以及离散时间（时隙）索引 $k \in \mathcal{K} \triangleq \{0, 1, \dots, K-1\}$ 。令 $\mathcal{U} \triangleq \{1, \dots, U\}$ 表示用户集， $\mathcal{F} \triangleq \{1, \dots, F\}$ 表示音调集。在整个研究中，参数设置为 $U = 8$ 和 $F = 52^1$ 。除非另有说明，系统采用 N_t 发射和 N_r 接收天线，并且所有符号均指基带频域量。

对于给定的用户 u ，在时间槽 k 和音调 f 下，接收到的向量 $Y_{u,k}[f] \in \mathbb{C}^{N_r}$ 与传输符号向量 $X_{u,k}[f] \in \mathbb{C}^{N_t}$ 和 MIMO 信道频率响应 $H_{u,k}[f] \in \mathbb{C}^{N_r \times N_t}$ 由线性模型

$$Y_{u,k}[f] = H_{u,k}[f]X_{u,k}[f] + N_{u,k}[f], \quad (1)$$

关联，其中 $N_{u,k}[f] \sim \mathcal{CN}(0, \sigma_{u,k}^2 I)$ 表示加性白高斯噪声。在实际操作中，瞬时信道 $H_{u,k}[f]$ 是未知的，必须从已知频域时间子集 $\mathcal{P}_u \subseteq \mathcal{K} \times \mathcal{F}$ 上发送的导频信号中进行估计。在这些导频位置应用粗略的每音调估计算法（例如 LS 或 MMSE）会产生一个有噪声的信道样本

$$\tilde{H}_{u,k}[f] = H_{u,k}[f] + W_{u,k}[f], \quad (2)$$

，其中 $W_{u,k}[f] \sim \mathcal{CN}(0, \tau_{u,k,f}^2 I)$ 表示信道估计误差。随后，在频域时间网格上插值可得到一个由导频辅助的噪声信道状态信息场 $\tilde{H}_k \triangleq \{\tilde{H}_{u,k}[f]\}_{u,f}$ ，该结果近似于真实的信道场 $H_k \triangleq \{H_{u,k}[f]\}_{u,f}$ 。

主要挑战来自于用户移动性。每个用户 $u \in \mathcal{U}$ 以变化的速度 $v_u(k)$ 移动，引起相应的多普勒频率 $f_{D,u}(k) = \frac{f_c}{c} v_u(k)$ ，导致时间选择性和信道老化。这种由移动引起的非平稳性意味着信道的统计特性随时间演变。该信道表现出局部相关性，然而其二阶时间演化可以通过时变相关矩阵

$$\mathbf{R}_k^{(\tau)} \triangleq \mathbb{E}[\text{vec}(H_k) \text{vec}(H_{k-\tau})^H], \quad \tau \in \mathbb{Z}. \quad (3)$$

来表征。这里， $\mathbf{R}_k^{(\tau)}$ 随着时间索引 k 和用户速度集合 $\{v_u(k)\}$ 的变化而变化。在各向同性散射条件下，每用户的时域相关性大约按 $\rho_u^{(\tau)}(k) \approx J_0(2\pi f_{D,u}(k)\tau\Delta t)$ 缩放，直接将信道的相关长度与用户移动性 [12, 13] 联系起来。

为了解决这个估计挑战并采用数据驱动的方法，问题被重新定义为对信道快照序列进行去噪的任务。令 $\{x_k\}_{k \in \mathbb{Z}}$ 表示清洁信道快照的离散时间序列²，其中每个 $x_k \in \mathbb{R}^{C \times H \times W}$ 都代表复数 CSI 的真实值张量表示。这里， $C = 2$ 包含堆叠的实部和虚部组件， H 表示天线维度（例如， $H = N_t \times N_r$ ），而 W 表示频域-时间网格大小。相应的噪声观测被建模为

$$y_k = x_k + n_k, \quad n_k \sim \mathcal{N}(0, \sigma_k^2 I), \quad \text{SNR}_k = \frac{\mathbb{E}\|x_k\|_2^2}{\sigma_k^2}. \quad (4)$$

目标是通过利用因果窗口 $\mathcal{T}_k = \{y_{k-T_w+1}, \dots, y_{k-1}\}$ 中捕获的时间相关性从噪声观测 y_k 恢复干净的信道 x_k ，其中 $T_w \geq 2$ 表示时间窗口长度。由于学习框架在实值张量上运行，因此使用定义为 $x_k = [\Re(H_k); \Im(H_k)]$ 的真实-虚部堆叠操作将复数信道矩阵转换。为了保持统计正确性，在训练过程中强制执行适当的噪声缩放。标准的复高斯噪声样本由两个实高斯分量 $\varepsilon_{\Re}, \varepsilon_{\Im} \sim \mathcal{N}(0, \frac{1}{2}I)$ 构成，使得 $\varepsilon = [\varepsilon_{\Re}; \varepsilon_{\Im}]$ 满足 $\varepsilon \sim \mathcal{N}(0, I)$ ，且复数等效表现出单位方差： $\mathbb{E}[|\varepsilon_{\Re} + j\varepsilon_{\Im}|^2] = 1$ 。

¹ $U = 8$ 捕捉多用户调度场景，而 $F = 52$ 对应于在移除导频和保护音调后的标准 OFDM 资源块大小 [11]。

² 每个潜在的无噪声 CSI 快照 x_k （实部和虚部堆叠在一起）在仿真中作为真实值，并作为实际数据的质量参考。




Fig. 1: 结合噪声前向扩散、ConvLSTM-注意力时间先验以及自条件引导逆向扩散通过 FiLM 参数。

3. 基于条件先验的非平稳估计

3.1. 前向扩散过程

为了通过分数匹配实现原理性的去噪，采用了一个前向扩散过程，该过程逐渐用高斯噪声污染干净的信道快照。给定一个单调的噪声时间表 $\beta_t \in (0, 1)$ 用于 $t = 1, \dots, T$ 扩散步骤，累积噪声参数被定义为 $\alpha_t = 1 - \beta_t$ 和 $\bar{\alpha}_t = \prod_{s=1}^t \alpha_s$ 。正向过程允许以下封闭形式的解，可以在任意扩散步骤直接采样 t

$$q(x_t | x_0) = \mathcal{N}(\sqrt{\bar{\alpha}_t} x_0, (1 - \bar{\alpha}_t)I), \quad (5)$$

$$x_t = \sqrt{\bar{\alpha}_t} x_0 + \sqrt{1 - \bar{\alpha}_t} \epsilon, \quad \epsilon \sim \mathcal{N}(0, I). \quad (6)$$

第 t 步的噪声方差是 $\sigma_t^2 = 1 - \bar{\alpha}_t$ ，从 $\sigma_1^2 \approx 0$ 单调增加到 $\sigma_T^2 \approx 1$ 。此噪声调度定义了一个每步的信噪比 (SNR)， $\text{SNR}(t) = \bar{\alpha}_t / (1 - \bar{\alpha}_t)$ ，该比率随后被用于实现与 SNR 匹配的逆初始化（第 3.5 节）。

3.2. 条件先验和训练目标

扩散过程依赖于时间上下文，以适应时变信道统计特性。历史信息 $\mathcal{T}_k$ 被压缩成一个上下文向量 $C_k \in \mathbb{R}^{d_c}$ ，它定义了干净快照上的条件先验 $p(x_0 | C_k)$ 。令 $p_t(x_t | C_k)$ 表示步骤 t 的 C_k 条件边缘。反向扩散则由条件得分函数引导

$$s^*(x_t, t | C_k) = \nabla_{x_t} \log p_t(x_t | C_k). \quad (7)$$

利用噪声参数化和得分-噪声恒等式，这个得分等价于

$$s^*(x_t, t | C_k) = -\frac{1}{\sigma_t} \mathbb{E}[\epsilon | x_t, C_k], \quad (8)$$

其中 $\epsilon = (x_t - \sqrt{\bar{\alpha}_t} x_0) / \sigma_t$ 。一个去噪神经网络 ε_θ 被训练来通过采样 $t \sim \text{Unif}\{1, \dots, T\}$ 和 $\epsilon \sim \mathcal{N}(0, I)$ 来最小化目标

$$\mathcal{L}_{\text{noise}}(\theta) = \mathbb{E}_{x_0, t, \epsilon} [\|\epsilon - \varepsilon_\theta(x_t, t, C_k)\|_2^2]. \quad (9)$$

近似噪声的条件期望。这个目标对应于条件得分匹配，其中学习到的去噪器提供了分数函数的一个估计值： $\hat{s}_\theta(x_t, t | C_k) = -\frac{1}{\sigma_t} \varepsilon_\theta(x_t, t, C_k)$ 。

3.3. 时间上下文编码

条件方法的有效性在很大程度上取决于从历史 $\mathcal{T}_k$ 构造 C_k 的方式。使用三阶段流水线来捕捉空间结构和时间依赖关系：

阶段 1：空间编码。共享的 CNN ϕ_{pre} 使用时间独立参数处理每个观测以提取空间特征

$$z_i = \phi_{\text{pre}}(y_i) \in \mathbb{R}^{d \times H' \times W'}, \quad i \in \{k - T_w + 1, \dots, k - 1\}. \quad (10)$$

第二阶段：ConvLSTM 聚合。一个 ConvLSTM 在更新其隐藏状态和单元状态的同时保持特征的空间网格


$$(h_i, c_i) = \text{ConvLSTM}(z_i, h_{i-1}, c_{i-1}). \quad (11)$$

每个隐藏状态 h_i 都被空间池化以生成向量 u_i ，这些向量被堆叠成序列矩阵 $U = [u_{k-T_w+1}, \dots, u_{k-1}] \in \mathbb{R}^{(T_w-1) \times d}$ 。

第三阶段：跨时间注意力。使用最新的状态 $q = u_{k-1}$ 作为查询，并将历史序列 U 作为键和值，跨注意力机制生成最终的时间上下文向量 C_k 。这种设置产生了一个紧凑的表示形式，追踪瞬时相干长度，反过程随后利用这一点。

3.4. FiLM 条件控制

给定上下文 C_k ，去噪器 ε_θ 使用三个嵌入进行条件设置：扩散步骤 $e_t = f_t(\text{PE}(t))$ ，序列索引 $e_k =$



(a) 用户速度与相关性衰减在 UMi 中的表现 (b) NMSE 与 SNR: 扩散 vs 基线 (c) NMSE 与不同信噪比下的扩散步骤对比

Fig. 2: UMi 基准测试和扩散结果: (a) 移动性配置文件和相关性, (b) 在不同信噪比下的准确性, (c) 收敛与扩散步骤对比。

$f_k(\text{PE}(k))$ 以及时间上下文 $e_{\text{temp}} = f_{\text{temp}}(\mathcal{C}_k)$ 。这些嵌入被融合以生成 FiLM 参数

$$z_k = f_{\text{fuse}}([e_t; e_k; e_{\text{temp}}]) \in \mathbb{R}^{2d}, \quad (12)$$

, 其分解为 $z_k = (\gamma_k, \beta_k)$ 与 $\gamma_k, \beta_k \in \mathbb{R}^d$ 。特征线性调制门控通过 $\tilde{v} = (1 + \gamma_k) \odot \phi_{\text{pre}}(x_t) + \beta_k$ 调节空间特征, 并且 ϕ_{post} 解码 $\tilde{v}$ 至噪声预测。FiLM 将扩散时间、时态上下文和序列位置耦合, 而无需架构复杂性, 引导去噪沿着与上下文相关的方向进行。

3.5. 反向加速过程

在推理过程中, 使用训练好的去噪器将前向过程反转。反向步骤的重新参数化均值是

$$\mu_{\theta}(x_t, t, \mathcal{C}_k) = \frac{1}{\sqrt{\alpha_t}} \left(x_t - \frac{\beta_t}{\sqrt{1 - \alpha_t}} \varepsilon_{\theta}(x_t, t, \mathcal{C}_k) \right). \quad (13)$$

为了加速推理, 该过程从边缘信噪比与测量输入信噪比匹配的扩散步骤开始初始化。起始步骤 t^* 被选为

$$t^* = \arg \min_{t \in \{1, \dots, T\}} |\text{SNR}(t) - \text{SNR}_k|,$$

初始状态设置为 $x_{t^*}^{(0)} = \sqrt{\frac{\text{SNR}_k}{1 + \text{SNR}_k}} y_k$ 。该过程随后遍历一个缩短的调度 $\mathcal{S} = \{t_1 = t^* > t_2 > \dots > t_L = 0\}$, 具有几何间距 $t_{\ell} = \lfloor r^{\ell-1} t^* \rfloor$, 对于某个比率 $r \in (0, 1)$ 。这种方法在使用远少得多的步骤 ($L \ll T$) 的同时保持了信噪比轨迹。

3.6. 时间自条件

为了利用时隙间的一致性, 将之前的干净估计值 $\hat{x}_0^{(k-1)}$ 注入上下文向量 $\mathcal{C}_k$ 中。这创建了一个隐式的高斯-马尔可夫先验, 通过全方差法则减少估计方差

$$\text{Var}(x_0^{(k)} | \mathcal{I}_k, \hat{x}_0^{(k-1)}) \leq \text{Var}(x_0^{(k)} | \mathcal{I}_k), \quad (14)$$

其中 $\mathcal{I}_k$ 表示时间点 k 处的所有可用信息。任何步骤 t 的干净预测由

$$\hat{x}_0(x_t, t) = \frac{1}{\sqrt{\alpha_t}} (x_t - \sqrt{1 - \alpha_t} \varepsilon_{\theta}(x_t, t, \mathcal{C}_k)). \quad (15)$$

给出在训练过程中, 通过 $\hat{x}_0^{(k-1)}$ 停止梯度 (即使用 $\text{sg}[\hat{x}_0^{(k-1)}]$), 以防止反馈不稳定, 同时仍允许模型学习适当的时间耦合。

3.7. 时间正则化

为了补充自我条件设置并确保物理上合理的演变, 在训练期间仅添加了一个时间平滑项。

$$\mathcal{L}_{\text{total}} = \mathcal{L}_{\text{noise}} + \lambda \|\hat{x}_0^{(k)} - \hat{x}_0^{(k-1)}\|_2^2, \quad \lambda \ll 1. \quad (16)$$

这个正则化器鼓励连续的估计与移动性暗示的一致性保持一致, 同时使测试时的估计器无偏。

4. 实验结果与分析

条件扩散框架在模拟的 3GPP UMI 环境中以 $f_c = 3.5\text{GHz}$ 的载波频率和 80MHz 带宽进行了基准测

试。该基准测试特征为移动引起的非平稳性，其中用户速度随时间变化，从 $v_u(0) \in [2, 4]$ 英里/小时加速到 $v_u(K-1) \in [30, 80]$ 英里/小时，在 $t_{\text{accel}} \in [1.0, 2.5]$ 秒的时间段内。这种加速度增加了多普勒扩展，缩短了相干时间，并加速了信道老化（图 2a）。在更高速度下相关性衰减更快验证了问题设置并突显了需要具备时间感知的估计方法。所提出的框架将基于扩散的去噪与时间先验相结合以适应非平稳信道。它始终优于 LMMSE [14], GMM [15], LSTM [16] 和 LDAMP [17], 在高信噪比下接近近乎最优性能，同时在低信噪比环境下保持稳健（图 2b）。这些结果证明了将时间先验与基于扩散的去噪技术结合用于非平稳信道的有效性。

图 2c 中的计算效率分析表明，该框架通过信噪比相关的收敛行为将计算努力适应任务复杂性。高信噪比条件实现快速收敛，仅需总迭代次数的一小部分，而低信噪比场景则得益于延长的去噪计划来充分利用扩散过程。这种自适应权衡表明，所提出的模型在各种条件下均能保持估计质量而不增加不必要的计算开销。

5. 结论

本文介绍了一种基于条件先验的扩散模型用于非平稳信道估计。所提出的框架结合了 ConvLSTM-注意力编码器和 FiLM 条件，实现了接近最优的准确性，并降低了采样复杂度。本工作的未来扩展包括将框架扩展到大规模 MIMO 系统、适应表现出更强非平稳性的多样化传播环境以及集成联邦学习以实现分布式部署。

6. REFERENCES

- [1] Le Liang, Wei Xu, and Xiaodai Dong, “Low-complexity hybrid precoding in massive multiuser MIMO systems,” *IEEE Wireless Communications Letters*, vol. 3, no. 6, pp. 653–656, 2014.
- [2] Azam Khalili, Amir Rastegarnia, and Wael M Bazzi, “Effect of fading channels on the performance of distributed networks with cyclic cooperation,” in *2015 International Conference on Information and Communication Technology Research (ICTRC)*. IEEE, 2015, pp. 32–35.
- [3] Reza Abdolee, Benoit Champagne, and Ali H Sayed, “Diffusion LMS strategies for parameter estimation over fading wireless channels,” in *2013 IEEE International Conference on Communications (ICC)*. IEEE, 2013, pp. 1926–1930.
- [4] Muhammad Umer, Muhammad Ahmed Mohsin, Ahsan Bilal, and John M. Cioffi, “Neural gaussian radio fields for channel estimation,” 2025.
- [5] Sagnik Bhattacharya, Muhammad Ahmed Mohsin, Kamyar Rajabalifardi, and John M. Cioffi, “Successive interference cancellation-aided diffusion models for joint channel estimation and data detection in low rank channel scenarios,” in *ICASSP 2025 - 2025 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, 2025, pp. 1–5.
- [6] Amalia Eka Rakhmania, Hudiono Hudiono, Umi Anis Ro’isatin, and Nurul Hidayati, “Channel estimation methods in massive MIMO: A comparative review of machine learning and traditional techniques,” *Infocommunications Journal*, vol. 17, no. 1, pp. 19–31, 2025.
- [7] Marius Arvinte and Jonathan I Tamir, “MIMO channel estimation using score-based generative models,” *IEEE Transactions on Wireless Communications*, vol. 22, no. 6, pp. 3698–3713, 2022.
- [8] Muhammad Ahmed Mohsin, Syed Muhammad Jameel, Hassan Rizwan, Muhammad Iqbal, Tabinda Ashraf, and Jen-Yi Pan, “Transformer-based distributed machine learning for downlink channel estimation in ris-aided networks,” in *2025 IEEE International Conference on Acoustics, Speech, and Signal Processing Workshops (ICASSPW)*, 2025, pp. 1–5.

- [9] Benedikt Fesl, Michael Strasser, Michael Joham, and Wolfgang Utschick, “Diffusion-based generative prior for low-complexity MIMO channel estimation,” *IEEE Wireless Communications Letters*, 2024.
- [10] Benedikt Fesl, Benedikt Böck, Florian Strasser, Michael Baur, Michael Joham, and Wolfgang Utschick, “On the asymptotic mean square error optimality of diffusion models,” *arXiv preprint arXiv:2403.02957*, 2024.
- [11] Pouya Agheli, Tugce Kobal, François Durand, and Matthew Andrews, “Learning-based multiuser scheduling in MIMO-OFDM systems with hybrid beamforming,” in *2025 Joint European Conference on Networks and Communications & 6G Summit (EuCNC/6G Summit)*. IEEE, 2025, pp. 1–6.
- [12] Yuwen Yang, Feifei Gao, Xiaoli Ma, and Shun Zhang, “Deep learning-based channel estimation for doubly selective fading channels,” *IEEE Access*, vol. 7, pp. 36579–36589, 2019.
- [13] Raghunandan M Rao, Vuk Marojevic, and Jeffrey H Reed, “Adaptive pilot patterns for CA-OFDM systems in nonstationary wireless channels,” *IEEE Transactions on Vehicular Technology*, vol. 67, no. 2, pp. 1231–1244, 2017.
- [14] Jorge F Arellano, Carlos Daniel Altamirano, Henry Ramiro Carvajal Mora, Nathaly Verónica Orozco Garzón, and Fernando Darío Almeida García, “On the performance of MMSE channel estimation in massive MIMO systems over spatially correlated Rician fading channels,” *Wireless Communications and Mobile Computing*, vol. 2024, no. 1, pp. 5445725, 2024.
- [15] K. Shoukath Ali, Sajan P. Philip, and T. Perarasi, “Gaussian mixture–expectation maximization-based learned AMP network with CNN deep residual network for millimeter wave communication,” *International Journal of Communication Systems*, vol. 38, no. 4, 2025.
- [16] Amish Ranjan and Bikash Chandra Sahana, “Deep learning empowered channel estimation in massive MIMO: unveiling the efficiency of hybrid deep learning architecture,” *Journal of Ambient Intelligence and Humanized Computing*, vol. 16, no. 2, pp. 375–390, 2025.
- [17] Hengtao He, Chao-Kai Wen, Shi Jin, and Geoffrey Ye Li, “Deep learning-based channel estimation for beamspace mmWave massive MIMO systems,” *IEEE Wireless Communications Letters*, vol. 7, no. 5, pp. 852–855, 2018.