# $F^4$-CKM：利用射频辐射场渲染学习信道知识地图

Kequan Zhou、Guangyi Zhang、Hanlei Li、Yunlong Cai、Shengli Liu 和 Guanding Yu

arXiv:2601.03601v1 [eess.SP] 7 Jan 2026

摘要—**在 6G移动通信中，随着天线阵列规模和带宽不断增加，获取准确且及时的信道状态信息（CSI）变得愈发困难。为减轻 CSI反馈负担，信道知识地图（CKM）应运而生，成为一种颇具前景的方法，它利用环境感知技术，仅根据用户位置预测 CSI。然而，如何有效构建 CKM 仍是一个悬而未决的问题。本文提出 $F^4$-CKM，这是一种新颖的 CKM构建框架，具有四项鲜明特征：辐射场渲染、空间频率感知、无位置使用和快速学习。我们的设计核心是将计算机视觉中的辐射场渲染技术引入射频（RF）领域，并借助一种新颖的无线辐射器表征（WiRARE）网络来捕获无线信道的空间频率特性。此外，我们还引入了一种新颖的整形滤波器模块和角度采样策略，以促进 CKM构建。大量实验表明，在无线信道预测的准确性和效率方面，$F^4$-CKM 显著优于现有基线方法。**

索引词—**信道知识地图、环境感知通信、神经辐射场、信道建模、信道预测。**

## I. 引言

准确且及时的信道状态信息（CSI）对于确保无线通信可靠且具备高吞吐量至关重要。传统的信道状态信息获取方法需要发送导频信号，并通过反馈链路获取估计的信道状态信息 [1]–[3]。然而，随着 6G 通信预计将部署大规模多输入多输出（MIMO）系统并使用宽带宽 [4]–[10], ，传统方法带来的开销将变得难以承受。为解决这一问题，信道知识地图（CKM）已成为一种颇具前景的替代方案 [11]–[13]。CKM 借助环境感知技术，可直接根据用户位置预测信道状态信息，从而显著降低信道状态信息获取开销。尽管 CKM 有望增强未来的 6G网络，但如何有效构建 CKM 仍是一项亟待进一步研究、至关重要且尚未解决的挑战。

### A. 先前工作

CKM构建方法通常可分为两大类：基于模型的方法和无模型方法 [14], ，二者的主要区别在于是否纳入无线信道模型的专家知识。基于模型的方法利用领域知识，使其其本质上具有可解释性、可配置性，并且较少依赖大规模训练数据 [15]–[18]。具体而言，[16] 中的作者提出了一种射线追踪模型，用于模拟无线信号传播，从而实现材料参数校准并提高精度。此外， [18] 中的作者利用期望最大化算法推导出仅含少量可调参数的闭式表达式，从而高效地构建 CKM。尽管具有这些优势，基于模型的方法仍常因理论模型与复杂现实环境之间的差异而面临性能局限。另一方面，无模型方法不依赖专家先验，而是利用数据收集和深度学习技术来提升性能[19]–[24]。具体而言， [23], 提出了一种基于拉普拉斯金字塔的生成方法，通过从形态图中提取多频分量，以分层方式构建 CKM。此外， [24] 提出了一种交叉预测驱动的基于推理的方法，在训练过程中有效利用有标签数据和无标签数据。尽管无模型方法已展现出良好的性能前景，但它们往往受数据稀缺所限，因为获取高质量现场测量既耗时又昂贵。

为兼顾基于模型方法和无模型方法的优势，混合方法日益受到关注[25]–[29]。这些方法将领域知识与数据驱动学习相结合，以提升准确性和可解释性。例如， [25] 探索了神经射线追踪，其中利用神经网络（神经网络）迭代学习射线与场景的交互。同时， [27]中的作者提出了 Neural Materials，这是一种神经射线追踪框架，其中所有可训练参数都具有明确的物理含义。除神经射线追踪之外， [28]还开发了一种虚拟障碍物模型。该模型借助神经网络有效捕捉衍射和散射机制，从而学习得到可解释的 CKM。此外，[29] 中的作者将 CKM构建表述为一个常微分方程（ODE）问题，并利用无线信道的空间相关性。ODE 函数由物理启发神经网络隐式表示，该网络学习求解 ODE 所需的梯度。

计算机图形学的最新进展进一步推动了混合式 CKM构建方法的研究[30]。神经辐射场（NeRF） [31] 和三维高斯泼溅（3DGS） [32] 作为强大的三维场景表示技术应运而生，它们通过视觉辐射场渲染来呈现三维场景。这些方法使用参数化空间单元对三维环境进行建模，并将多视图图像作为训练数据，通过学习场景中的光分布来合成新视图。受无线信号和可见光均为电磁（EM）波这一事实的启发，近期研究开始探索将辐射场渲染技术与无线信道建模相结合

K. Zhou、G. Zhang、H. Li、Y.Cai 和 G. Yu 就职于浙江大学信息科学与电子工程学院，中国杭州 310027（电子邮箱：kqzhou@zju.edu.cn；zhangguangyi@zju.edu.cn；han-leili@zju.edu.cn；ylcai@zju.edu.cn；yuguanding@zju.edu.cn）。

S. Liu 任职于中国上海上海大学通信与信息工程学院。（电子邮箱：victoryliu@shu.edu.cn）。

以构建三维信道知识图谱 [33]–[36]。具体而言，一种受 NeRF 启发的开创性方案 NeRF$^2$ 于 [33] 被提出，用于CKM构建。该方案考虑了射频（RF）信号的独特特性，并调整 NeRF框架以适用于无线信道建模，从而提高CKM构建的准确性。在 [35], , 作者提出了 NeWRF，通过由粗到细训练策略提高数据效率，并将估计的到达角（AoA）信息作为辅助输入，从而即使在数据有限的情况下也能构建 CKM。此外， [36] 提出了一种基于 3DGS 的方法 WRF-GS+，该方法利用球面投影和墨卡托投影，将光学相机模型适配为射频天线模型，从而实现有效的CKM构建。

### *B.* 研究动机与贡献

尽管近年来取得了进展，现有的 CKM构建技术仍面临三项主要局限：

- 缺乏空频感知： 现有的射频辐射场建模和神经网络设计尚未充分考虑无线信道的特性。在空间域中，彼此靠近的天线具有很强的空间相关性；同样，频域中的子载波也存在固有的相关性 [3]。现有方法未能充分捕获这些相关性，导致性能受损。

- 缺乏实用的输入： 大多数现有方法都依赖精确的用户位置作为基于 CKM 的信道状态信息预测的输入。然而，在实践中很难获取精确的位置。例如，民用全球定位系统（GPS）通常只能提供米级精度 [37], , 相较于 sub-6 GHz 和毫米波系统所需的亚波长分辨率，这种精度相当粗略。因此，不准确的位置输入可能会严重降低预测性能。此外，使用位置信息还可能引发隐私问题，并需要进行加密传输，从而带来额外开销和潜在的隐私问题 [38]。

- 构建效率低： 基于位置的方法通常构建效率较低，尤其是在大规模MIMO和正交频分复用（OFDM）系统等高维场景中。这种低效源于位置输入的低维特性，其为学习提供的信息有限。位置编码技术虽能在一定程度上缓解这一问题，但也会使模型更容易受到定位误差的影响，从而增加实际部署的难度。

本文提出 F$^4$-CKM，以解决现有 CKM 构建方法的局限性。为解决第一个局限性，我们提出了一种新颖的射频辐射场模型，能够有效捕捉无线信道的空间频率特性。该模型通过大量空间单元来表示三维信号传播环境，这些空间单元称为虚拟无线辐射器，并以空频感知参数化。随后，为了渲染这一射频辐射场，我们开发了**无线辐射表征**网络（WiRARE），以学习这些辐射器的参数。该网络骨干经过专门设计，用于利用信道中的空间相关性，并进一步结合一系列频率上下文感知（FCA）模块，利用频域依赖关系增强网络。

为解决第二个局限，我们使用上行链路信道状态信息作为CKM的输入，而非依赖用户位置。先前研究[39], [40]表明，由于丰富的多径传播和大规模天线阵列，上行链路信道状态信息与用户位置之间存在强双向映射。因此，CKM基于上行链路信道状态信息进行预测是合理的。此外，上行链路信道状态信息估计技术已在业界成熟应用，且不存在隐私问题，因此是一种实用且安全的替代方案。具体而言，我们提出一种新颖的整形滤波器模块来进行数据增强，以便使用上行链路信道状态信息输入训练WiRARE网络。该模块加快了信道知识图谱模型收敛，从而有效解决第三个局限。为进一步提升构建效率，我们引入一种改进的角度采样策略，利用球面斐波那契网格（SFG） [41] 技术实现更有效的角度采样。

总而言之，本文的主要贡献如下：

- 我们提出了 F$^4$-CKM，这是一种新颖的 CKM构建框架，具有四个鲜明特点：辐射场**F**渲染、空间**F**频率感知、无位置**F**使用以及快速**F**学习。这种统一设计有效解决了现有方法的主要局限，提升了 CKM构建的准确性和效率。

- 我们通过构建一种新颖的射频辐射场模型，提出了基于辐射场渲染的 CKM构建方法，该模型能够捕捉无线信道的空间频率特性。为渲染该辐射场，我们开发了WiRARE网络，其特点是采用具有空间感知能力的主干网络设计，并通过嵌入 FCA模块增强频率敏感性。

- 我们提出使用上行链路信道状态信息作为 CKM输入，而非准确的用户位置，从而避免受到定位误差的影响。我们设计了一种新颖的整形滤波器模块，用于对上行链路信道状态信息输入进行数据增强，实现无位置CKM的使用并加速模型收敛。此外，我们采用一种基于 SFG 的高效角度采样策略，进一步提高构建效率。

- 我们在多种仿真和真实世界数据集上开展了大量实验，涵盖多样化条件，以验证所提方法的有效性。结果表明，与现有基线方法相比，我们的 F$^4$-CKM 在 CKM构建的准确性和效率方面均取得了显著提升。

### *C.* 组织结构与符号说明

本文其余部分安排如下。第二节介绍无线信道建模和 NeRF 技术的基础知识。第三节描述 F$^4$-CKM 框架所依据的系统模型。第四节介绍 F$^4$-CKM 的详细设计。随后，第五节给出仿真结果，第六节总结全文。

除非另有说明，标量、向量和维度大于一的张量分别用小写字母、粗体小写字母和粗体大写字母表示。对于向量$\mathbf{a}$，$\mathbf{a}^H$ 表示其共轭转置。对于向量

和张量，$\|\cdot\|$ 表示其欧几里得范数。最后，$\mathbb{C}^{m\times n}$($\mathbb{R}^{m\times n}$)表示 $m\times n$ 复（实）矩阵空间。

## II. 预备知识

本节概述无线信道建模和 NeRF 技术的基础知识。

### A. 无线信道建模

载波频率为 $f$ 的单天线发射信号可表示为 $x(f) = Ae^{j\phi}$，其中 $A$ 表示幅度，$\phi$ 表示相位。在具有多个天线和子载波的系统中，发射信号表示为 $\mathbf{X} = [\mathbf{x}(f_1)..., \mathbf{x}(f_{N_c})]^T \in \mathbb{C}^{N_c\times N_b}$，其中 $N_c$ 是子载波数量，$N_b$ 是发射天线数量[1]。传播过程中，信号会受到自由空间损耗和多径效应的影响。在自由空间传播中，信号幅度随传播距离 $d$的增加而反比衰减，而相位则随 $d$ 成比例旋转。这些效应在数学上表示为

$$\Delta A = \frac{c}{4\pi fd}, \Delta\phi = \frac{-2\pi fd}{c}, \tag{1}$$

分别为，其中 $c$ 是光速。随后，频率为 $f$ 的接收信号可表示为

$$y(f) = x(f)\Delta Ae^{j\Delta\phi} = A\cdot\Delta Ae^{j(\phi+\Delta\phi)}. \tag{2}$$

考虑多径效应，即信号经由多条路径到达接收机，且每条路径都会引入自身的衰减和相移。因此，接收信号 $y(f)$ 可以更好地表示为

$$y(f) = x(f)\sum_{l=1}^{L}\Delta A^l e^{j\Delta\phi^l}, \tag{3}$$

其中，$L$ 为传播路径的数量，$\Delta A^l$ 和 $e^{j\Delta\phi^l}$分别表示第 $l$ 条路径的衰减和相移。无线信道模型定义为环境对发射信号产生的累积效应，可表示为

$$h(f) \triangleq \frac{y(f)}{x(f)} = \sum_{l=1}^{L}\Delta A^l e^{j\Delta\phi^l}. \tag{4}$$

在多天线系统中，不同发射与接收天线对传输的信号通常会沿相似的物理路径传播。然而，由于天线之间存在空间间隔，这些路径的传播距离可能会产生载波波长量级的差异。这些距离变化会导致信号衰减和相位旋转因路径而异。因此，接收信号 $\mathbf{Y} \in \mathbb{C}^{N_c\times N_u}$ 可表示为

$$\mathbf{Y} = [\mathbf{y}(f_1), ..., \mathbf{y}(f_{N_c})]^T, \tag{5a}$$

$$\mathbf{y}(f) = (\sum_{l=1}^{L}\Delta\mathbf{A}^l(f)\odot\exp(j\Delta\mathbf{\Phi}^l(f)))\mathbf{x}(f), \tag{5b}$$

[1]不失一般性，我们考虑下行场景，其中基站作为配备 $N_b$ 根天线的发射机，而用户设备作为配备 $N_u$ 根天线的接收机。通过交换发射机和接收机的角色，可以类似地处理上行情况。

其中，$\Delta\mathbf{A}^l(f) \in \mathbb{R}^{N_u\times N_b}$ 和 $\exp(j\Delta\mathbf{\Phi}^l(f)) \in \mathbb{C}^{N_u\times N_b}$ 分别表示第 $l$ 条路径的衰减和相位偏移，$\odot$ 表示矩阵的逐元素乘法运算符。相应的频域多输入多输出信道矩阵为

$$\mathbf{H}(f) \triangleq \frac{1}{P}\mathbf{y}(f)\mathbf{x}^H(f) = \sum_{l=1}^{L}\Delta\mathbf{A}^l(f)\odot\exp(j\Delta\mathbf{\Phi}^l(f)), \tag{6}$$

其中，$P = \mathbf{x}^H(f)\mathbf{x}(f)$表示发射功率。所有子载波上的完整信道表示为

$$\mathbf{H} = [\mathbf{H}(f_1), ..., \mathbf{H}(f_{N_c})]^T. \tag{7}$$

### B. 神经辐射场（*NeRF*）

NeRF 是一种基于深度学习的框架，通过辐射场渲染来表示三维场景。它使用神经网络学习一个连续函数，以此对三维场景进行建模。该函数以三维空间坐标$\mathbf{p} = (p_x, p_y, p_z)$和观测方向$\mathbf{r} = (r_\theta, r_\phi)$为输入，并输出相应的方向体辐射$\mathbf{c} = (r, g, b)$和体密度$\sigma$。这里，密度 $\sigma$ 表示体积块的透射率和不透明度。具体而言，透射率是指未被吸收而穿过体积块的光线比例，而不透明度则描述被体积块吸收并随后辐射出的光线比例。

为了从新视点渲染图像，NeRF 会从每个图像像素发射射线，并沿每条射线采样一组三维点。将这些采样坐标输入神经网络，以预测相应的辐射$\mathbf{c}$ 和体密度 $\sigma$。随后将密度 $\sigma$ 转换为不透明度 $\alpha$。渲染后的ˆ像素颜色 $C(\mathbf{r})$可通过传统的 $\alpha$-混合方法计算，表示为

$$\hat{C}(\mathbf{r}) = \sum_{i=1}^{N}T_i\alpha_i\mathbf{c}_i, \tag{8a}$$

$$T_i = \prod_{j=1}^{i-1}(1-\alpha_j), \quad \alpha_i = 1 - e^{-\sigma_i\delta_i}, \tag{8b}$$

其中，$i$ 和 $N$ 分别表示沿射线$\mathbf{r}$的采样索引和采样点总数，$T$ 表示累积透射率，而 $\delta_i = ||\mathbf{p}^{i+1} - \mathbf{p}_i||$ 表示相邻采样点之间的距离。计算出每个像素的颜色后，即可合成完整图像。随后，将合成图像与真实图像进行比较，以计算重建损失，并利用该损失优化神经网络参数。

如式（6）所示，无线信道通常建模为多条传播路径所产生的失真叠加，这类似于根据不同观测方向上的光照贡献渲染图像。这种类比，加上 NeRF 在三维场景表示方面的卓越表现，促使我们采用神经辐射场技术进行无线信道建模。通过以混合方式整合 NeRF，我们旨在实现更准确的 CKM 构建。

## III. 射频辐射场建模

本节概述 F[4]-CKM 框架所依据的射频辐射场模型的构建方式。

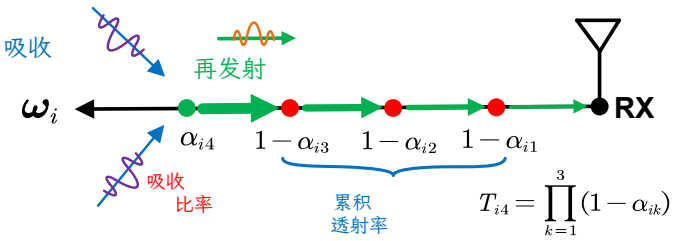


图1：无线辐射体辐射信号的传播建模。

目标是利用基站 (BS) 获取的上行链路信道状态信息，预测用户设备 (UE) 处的下行链路信道状态信息。我们聚焦于一种无线 MIMO-OFDM 系统，其中基站配备 $N_b$ 根天线，用户设备配备 $N_u$ 根天线，系统在 $N_c$ 个 OFDM 子载波上运行。为了实现准确的信道预测，我们旨在学习一个能够捕捉周围环境中射频信号分布的辐射场。具体而言，我们将在第III-A节详细介绍如何调整 NeRF 技术，以实现从光学域到射频域的转换。随后，我们将在第III-B节提出 MIMO-OFDM射频辐射场的构建方式。

### *A.* 射频辐射场

为便于清晰说明，首先分析单天线单载波系统的基本射频辐射场。首先，应将环境离散化为一组体积块。根据惠更斯–菲涅耳原理[33]，当基站发射的原始射频信号 $x$ 沿多条传播路径到达某个体积块时，该体积块可视为一个会重新辐射$x$的次级源。基于这一原理，每个体积块都被建模为一个虚拟无线辐射体，它会吸收来自各个方向的射频信号，并以一定衰减重新辐射。该衰减由辐射体的透射率 $\beta$和吸收比 $\alpha=1-\beta$表征，两者均由辐射体的材料属性 $\sigma$ 和块长度 $\delta$决定。较大的 $\sigma$ 或 $\delta$ 对应较高的吸收比$\alpha$。每个无线辐射体由神经网络学习得到的连续函数 $\mathcal{F}_{\mathbf{\Theta}}(\cdot)$表征，其中 $\mathbf{\Theta}$表示神经网络的参数集。该函数以每个无线辐射体的空间坐标$\mathbf{p}$和辐射方向 $\boldsymbol{\omega}$ 为输入，并输出相应的辐射信号 $s$ 和材料属性 $\sigma$，表示为

$$\mathcal{F}_{\mathbf{\Theta}}(\cdot):(\mathbf{p},\boldsymbol{\omega})\longrightarrow(s,\sigma). \tag{9}$$

为预测下行链路信道状态信息，首先应从用户设备的天线阵列发射的一组射线 $\{\boldsymbol{\omega}_i\}_{i=1}^{N_a}$ 中进行采样，其中 $N_a$ 表示角域内的射线数量。沿每条射线，以间隔 $\{\delta_{ij}\}_{j=1}^{N_r}$对一系列无线辐射体进行采样，其中 $i$ 表示射线索引，$N_r$ 表示径向上采样的无线辐射体数量。根据每个采样无线辐射体的光线方向和空间坐标，可以从神经网络 $\mathcal{F}_{\mathbf{\Theta}}(\cdot)$ 中获取相应的辐射信号和材料属性。与公式 (8b) 类似，材料属性$\sigma$ 被转换为吸收比 $\alpha$ 和累积透射率 $T$，定义为

$$T_{ij}=\prod_{k=1}^{j-1}\beta_{ik},\quad \alpha_{ij}=1-e^{-\sigma_{ij}\delta_{ij}}, \tag{10}$$

其中，$i$ 表示射线索引，$j$ 和 $k$ 均表示每条射线上的辐射器索引，$\beta=1-\alpha$ 表示辐射器的透射率。无线辐射体的辐射信号传播过程如图1所示。随后，用户设备（UE）处的接收信号计算如下

$$\hat{y}=\sum_{i=1}^{N_a}\sum_{j=1}^{N_r}T_{ij}\alpha_{ij}s_{ij}. \tag{11}$$

最后，下行链路信道状态信息可表示为

$$\hat{h}^{\mathrm{D}}=\frac{\hat{y}}{x}=\sum_{i=1}^{N_a}\sum_{j=1}^{N_r}T_{ij}\alpha_{ij}c_{ij}, \tag{12}$$

其中，$c_{ij}=s_{ij}/x$ 表示所有到达无线辐射体的射频信号聚合后的效果。由于我们关注的是下行链路信道状态信息，而非接收信号，因此可将神经网络（NN）输出中的辐射信号 $s$ 替换为辐射器聚合系数 $c$。如第I节所述，使用显式位置信息容易受到定位误差的影响，还可能引发隐私问题。为缓解这一问题，我们将辐射器坐标$\mathbf{p}$替换为通用的辐射器特定查询$\mathbf{q}$，它可以表示任何可用的辐射器特定辅助信息。因此，神经网络（NN）的映射函数 $\mathcal{F}_{\mathbf{\Theta}}(\cdot)$可表示为

$$\mathcal{F}_{\mathbf{\Theta}}(\cdot):(\mathbf{q},\boldsymbol{\omega})\longrightarrow(c,\sigma), \tag{13}$$

其中$\mathbf{q}$ 表示辐射器身份，从而增强对定位误差的鲁棒性并提升隐私保护能力。

### *B.* 多输入多输出正交频分复用射频辐射场

基于基本表述，我们首先深入探讨多输入多输出正交频分复用射频辐射场的表述。在此背景下，仍有两个关键挑战亟待解决:

（i）射频信号跨越多个子载波频率，每个频率所经历的自由空间传播损耗各不相同，且与环境的相互作用也各有特点。因此，表述必须考虑这些频率相关效应，才能准确建模信号行为。（ii）发射机和接收机均配备由多个单元组成的天线阵列，因此表述需要捕捉单元间相互作用，这大幅增加了问题的复杂性。

*1*）频率感知表述：为解决第一个挑战，我们首先将式（10）中的表述重新定义为

$$T_{ij}(f)=\prod_{k=1}^{j-1}\beta_{ik}(f),\quad \alpha_{ij}(f)=1-e^{-\sigma_{ij}(f)\delta_{ij}}, \tag{14}$$

其中，$f$ 表示子载波频率，$\sigma_{ij}(f)$旨在捕捉频率相关的无线辐射器响应。然而，式（14）仍存在物理耦合，其中块长度 $\delta$ 同时控制着两种不同的效应:

(i) 自由空间传播损耗（由球面波前扩展导致的能量扩散），与材料属性无关，以及

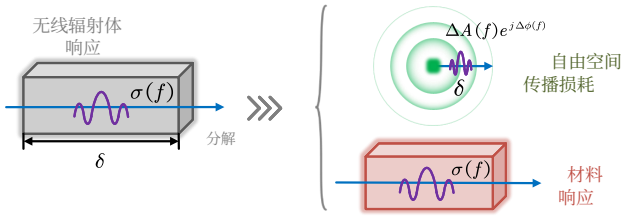


图 2：无线辐射器响应的分解。

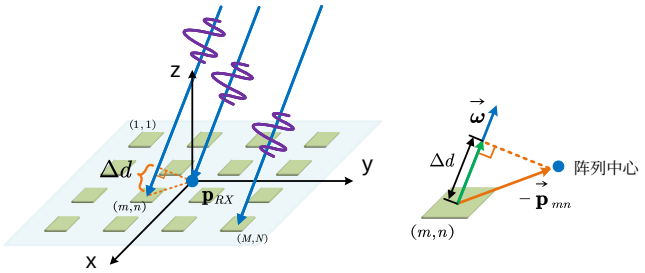


图 3：到达不同接收天线的信号传播距离变化。

(ii) 介质内衰减（距离 $\delta_{ij}$ 内的材料吸收），取决于 $\sigma_{ij}(f)$。

因此，将自由空间传播效应的领域知识嵌入辐射场模型是合理的，从而提升其对新环境的泛化能力。为此，如图 2 所示，我们将自由空间传播效应与单个辐射体的响应解耦。具体而言，根据公式（1），自由空间中的幅度衰减和相位旋转分别作为独立因子进行显式建模，表示为

$$\Delta A_{ij} = \frac{c}{4\pi f \sum_{k=1}^{j-1}\delta_{ik}}, \Delta\phi_{ij} = \frac{-2\pi f \sum_{k=1}^{j-1}\delta_{ik}}{c}. \quad (15)$$

此外，吸收比 $\alpha_{ij}(f)$ 被重新定义为仅反映材料引起的响应。因此，$\sigma(f)$ 被解释为有效材料响应，其中对几何长度 $\delta$ 的显式依赖被消除，表示为

$$\alpha_{ij}(f) = 1 - e^{-\sigma_{ij}(f)}. \quad (16)$$

因此，累积衰减因子 $T_{ij}(f)$ 必须结合材料引起的透射率 $\prod_{k=1}^{j-1}\left(1-(\right.$ $\alpha_{ik}$ $f$ $\left.\right)$ 和沿路径的自由空间传播效应，表示为

$$T_{ij}(f) = \Delta A_{ij} e^{j\Delta\phi_{ij}} \prod_{k=1}^{j-1}\Big(1-\alpha_{ik}(f)\Big) \quad (17a)$$

$$= \Delta A_{ij} e^{j\frac{-2\pi f\sum_{k=1}^{j-1}\delta_{ik}}{c}} \prod_{k=1}^{j-1}\beta_{ik}(f) \quad (17b)$$

$$= \Delta A_{ij} \prod_{k=1}^{j-1}\beta_{ik}(f) e^{j\frac{-2\pi f\delta_{ik}}{c}} \quad (17c)$$

$$= \frac{c}{4\pi f\sum_{k=1}^{j-1}\delta_{ik}} \prod_{k=1}^{j-1}\beta_{ik}(f) e^{j\frac{-2\pi f\delta_{ik}}{c}}. \quad (17d)$$

2）空间感知表述：针对第二个挑战，我们聚焦于单个子载波，并分别将发射和接收的射频信号表示为$\mathbf{x}(f) \in \mathbb{C}^{N_b}$和$\mathbf{y}(f) \in \mathbb{C}^{N_u}$。为揭示各个天线单元之间的相互作用，我们将每个辐射器建模为由 $N_u \times N_b$个子辐射体组成的簇，其中每个子辐射体对应一个唯一的收发天线对。因此，第 $j$个射线中的第 $i$个辐射器的材料属性表示为矩阵$\boldsymbol{\sigma}_{ij}(f) \in \mathbb{R}^{N_u\times N_b}$，该矩阵由各子辐射体的材料属性构成。同样，吸收比和透射率分别推广为 $\boldsymbol{\alpha}_{ij}(f) = \mathbf{J} - \exp\Big(\boldsymbol{\sigma}_{ij}(f)\Big)$和$\boldsymbol{\beta}_{ij}(f) = \mathbf{J} - \boldsymbol{\alpha}_{ij}(f)$，其中$\mathbf{J} \in \mathbb{R}^{N_u\times N_b}$表示全一矩阵。此外，辐射信号表示为$\mathbf{s}_{ij}(f) \in \mathbb{C}^{N_u}$。随后，辐射体聚合系数可推导为矩阵$\mathbf{C}_{ij}(f) \in \mathbb{C}^{N_u\times N_b}$，其表达式为

$$\mathbf{C}_{ij}(f) = \frac{1}{P}\mathbf{s}_{ij}(f)\mathbf{x}^H(f), \quad (18)$$

其中 $P = \mathbf{x}^H(f)\mathbf{x}(f)$ 表示基站的发射功率。由于天线阵列孔径通常远小于信号传播距离，因此到达不同天线的信号可以视为平行传播。因此，如图 3 所示，天线之间的空间间隔会导致传播距离略有差异，其尺度通常与信号波长相当。尽管这些变化对信号幅度的影响可以忽略不计，却可能引起显著的相位偏移，导致预测的下行链路CSI出现较大波动。因此，校准到达每个独立接收天线的信号传播距离，对于减轻此类建模误差至关重要。

具体而言，我们考虑一台配备均匀平面阵列（UPA）的用户设备，该阵列由 $M$ 行、$N$ 列天线组成，其中 $M \times N = N_u$，且天线间距预先设定。如图 3 所示，我们的目标是确定到达每个接收天线的信号路径的传播距离变化 $\Delta d$，并以指向阵列中心的路径为参照。对于位于阵列第 $m$ 行、第 $n$ 列的天线（$m$，$n$），距离校准项定义为：

$$\Delta d_{m,n} = \frac{-\vec{\mathbf{p}}_{m,n}\cdot\vec{\boldsymbol{\omega}}}{||\vec{\boldsymbol{\omega}}||}, \quad (19)$$

其中，$\vec{\mathbf{p}}_{m,n}$ 表示从阵列中心指向第（$m,n$）个天线单元的向量。完整的校准因子$\Delta\mathbf{D}$ 通过将各个校准项扩展为矩阵形式构造而成：

$$\Delta\mathbf{D} = [\Delta\mathbf{d}, \Delta\mathbf{d}, ..., \Delta\mathbf{d}]_{N_u\times N_b}, \quad (20a)$$

$$\Delta\mathbf{d} = [\Delta d_{1,1}, ..., \Delta d_{1,N}, ..., \Delta d_{m,n}, ..., \Delta d_{M,N}]^T. \quad (20b)$$

通过这种空间校准，利用逐元素运算将自由空间衰减和相位项从标量扩展为矩阵形式，表示为

$$\Delta\mathbf{A}_{ij} = \frac{c}{4\pi f}\Big(\mathbf{J}\oslash(\Delta\mathbf{D}_{ij} + \mathbf{J}\sum_{k=1}^{j-1}\delta_{ik})\Big), \quad (21a)$$

$$\Delta\boldsymbol{\phi}_{ij} = -\frac{2\pi f}{c}(\Delta\mathbf{D}_{ij} + \mathbf{J}\sum_{k=1}^{j-1}\delta_{ik}), \quad (21b)$$

其中，$\oslash$表示逐元素除法运算。因此，式（17d）中的累积衰减因子为

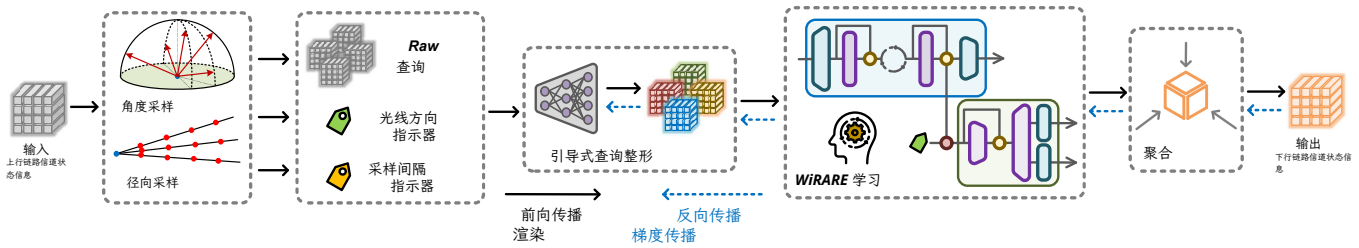


图 4：F$^4$-CKM 的构建流程。将用户设备天线阵列处的上行链路信道状态信息作为输入。我们首先进行角度采样，随后沿每条射线进行径向采样。接着，将原始上行链路信道状态信息的副本与两路作为引导的辅助信息一同输入整形滤波器模块。该模块将信道状态信息副本处理为供 WiRARE 网络使用的增强查询。随后，WiRARE 利用这些查询获取采样辐射体的聚合系数和材料属性，并将其聚合以形成最终的下行链路信道状态信息预测。

更新为

$$\mathbf{T}_{ij}(f) = \Delta\mathbf{A}_{ij} \odot \exp(j\Delta\boldsymbol{\phi}_{ij}) \odot \prod_{k=1}^{j-1} \boldsymbol{\beta}_{ik}(f) \tag{22a}$$

$$= \Delta\mathbf{A}_{ij} \odot \exp(j\frac{-2\pi f}{c}\Delta\mathbf{D}_{ij}) \odot \exp(j\frac{-2\pi f}{c}\mathbf{J}\sum_{k=1}^{j-1}\delta_{ik}) \odot \prod_{k=1}^{j-1} \boldsymbol{\beta}_{ik}(f) \tag{22b}$$

$$= \frac{c}{4\pi f} \cdot \exp(j\frac{-2\pi f}{c}\Delta\mathbf{D}_{ij}) \oslash (\Delta\mathbf{D}_{ij} + \mathbf{J}\sum_{k=1}^{j-1}\delta_{ik}) \odot \prod_{k=1}^{j-1} \boldsymbol{\beta}_{ik}(f) e^{j\frac{-2\pi f \delta_{ik}}{c}}, \tag{22c}$$

其中，$\odot$ 表示逐元素乘法运算，乘积符号 $\prod$ 在矩阵中逐元素应用。最后，式（12）可改写为

$$\hat{\mathbf{H}}^{\mathrm{D}}(f) = \sum_{i=1}^{N_a}\sum_{j=1}^{N_r} \boldsymbol{\alpha}_{ij}(f) \odot \mathbf{T}_{ij}(f) \odot \mathbf{C}_{ij}(f). \tag{23}$$

此外，映射函数 Eq. (13) 更新如下：

$$\mathcal{F}_{\boldsymbol{\Theta}}(\cdot) : \Big(\mathbf{q}(f), \boldsymbol{\omega}\Big) \longrightarrow \Big(\mathbf{C}(f), \boldsymbol{\sigma}(f)\Big), \tag{24}$$

其中，$\mathbf{q}(f)$ 表示频率相关的辐射器专用查询。

## IV. F$^4$-CKM 的构建

本节将深入阐述所提出的 F$^4$-CKM 及其实现细节。

### A. 构建流程

我们的 F$^4$-CKM 通过渲染上述 MIMO-OFDM射频辐射场构建而成。如图 4 所示，整体构建流程以上行链路信道状态信息为输入，并预测相应的下行链路信道状态信息。采用归一化均方误差（NMSE）损失 $\mathcal{L}_{\mathrm{NMSE}}$ 进行神经网络优化，定义为

$$\mathcal{L}_{\mathrm{NMSE}} = \frac{1}{N_s}\sum_{i=1}^{N_s}\frac{1}{N_c}\sum_{j=1}^{N_c}\frac{||\hat{\mathbf{H}}_{ij}^{\mathrm{D}} - \mathbf{H}_{ij}^{\mathrm{D}}||^2}{||\mathbf{H}_{ij}^{\mathrm{D}}||^2}, \tag{25}$$

其中，$\hat{}\mathbf{H}_{ij}^{\mathrm{D}}$ 和$\mathbf{H}_{ij}^{\mathrm{D}}$ 分别表示第 $i$个样本中第 $j$个子载波的预测信道状态信息和真实 CSI，且

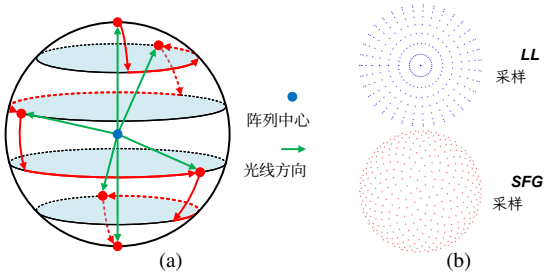


图 5：SFG 采样算法。(a) 展示了 SFG 采样的机制。(b) 分别给出了采用 LL 采样和 SFG 采样获得的 648 条采样射线的俯视图。LL 采样的角分辨率设为 10°。

$N_s$ 表示数据样本总数。具体而言，该流程包含三个主要组成部分：

- 辐射体采样：该模块旨在有效捕捉场景中的电磁分布，包括角度采样和径向采样。具体而言，我们采用 SFG 算法，以确保角度采样具有高度均匀的球面分布。

- 引导式查询整形：作为数据预处理模块，该模块对 WiRARE 网络的上行链路信道状态信息输入进行增强。它利用两个辅助指标提供辅助信息，并引导每个采样无线辐射体处的查询整形。
- ***WiRARE*** 网络：该模块学习映射$\mathcal{F}_{\boldsymbol{\Theta}}(\cdot)$，以表示采样的无线辐射体。其架构经过专门设计，能够有效捕捉输入中的空间-频率相关性。

在接下来的小节中，我们将详细介绍各模块的设计与实现。

### B. 辐射体采样

通常，采样分辨率与计算复杂度之间存在固有的权衡。虽然细粒度采样自然能够提高精度，但也会增加计算开销。为了实现精确且低复杂度的 CKM 构建，关键在于设计一种采样策略，使其在给定采样分辨率下提高采样效率。此外，由于角度采样过程负责捕获接收到的多径射频信号的到达角，因此与径向采样过程相比，它的影响更为显著。因此，我们专注于设计角度采样策略，同时沿径向维度采用均匀采样。

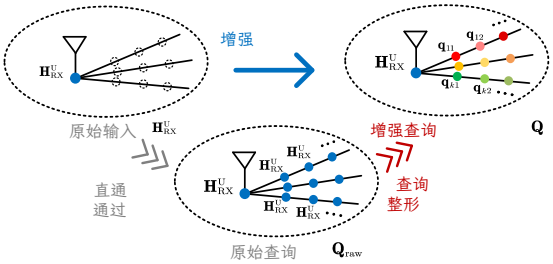


图 6：上行链路 CSI 输入增强过程。

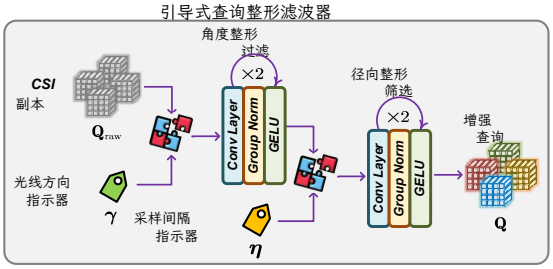


图 7：引导式整形滤波器模块的架构。

以往基于 NeRF 的 CKM 框架主要采用两种角度采样策略：经纬度（LL）采样 [33] 和 AoA 辅助采样 [35]。然而，这两种方法都存在局限性。经纬度（LL）采样策略将球面划分为经度和纬度方向上间距相等的网格点，虽然简单直接，但本身存在缺陷。它会导致赤道附近采样稀疏、两极附近采样密集，进而分别造成欠采样和过采样问题。相比之下，AoA 辅助策略尝试通过神经网络根据用户设备位置预测用户设备天线阵列的到达角，再沿预测方向进行径向采样，以提高采样效率。然而，这种 AoA 预测方法高度依赖用户设备位置输入，而这些输入可能存在定位误差，也可能引发隐私问题，如 I-B 节所述。为克服这些局限性，我们旨在对球面上均匀分布的射线进行采样，而不依赖 AoA 信息。

为实现这一目标，我们采用 SFG 算法 [41] 进行角度采样，使采样点在球面上均匀分布，并且射线数量可灵活配置。具体而言，我们考虑从用户设备天线阵列中心$K$发射射线。我们的目标是确定这些 $K$ 射线在笛卡尔坐标中的方向。利用 SFG，第 $k$条射线的方向（$x_k$，$y_k$，$z_k$）可表示为

$$z_k = 1 - \frac{2(k-1)}{K-1}, \tag{26a}$$

$$x_k = \sqrt{1-z_n^2} \cdot \cos(2\pi k\Phi), \tag{26b}$$

$$y_k = \sqrt{1-z_n^2} \cdot \sin(2\pi k\Phi), \tag{26c}$$

其中，$\Phi$ 表示黄金比例（$1+\sqrt{5}$）/2。这里，式（26a）将单位球面划分为 $K-1$ 个等厚层，从极点开始，每层设置一个采样点（对应一条射线）。因此，每层的表面积均为 $4\pi/N$，从而确保沿垂直轴均匀采样。同时，式（26b）和式（26c）利用黄金角 $2\pi\Phi$确定每个点的经度，从而有效地将新点分布到先前采样形成的最大角间隙中。图 5(a)展示了基于 SFG 的采样分布，图 5(b)则对比了使用 LL 方法和 SFG 方法采样的 648 条射线的俯视图。

### C. 引导式查询整形

经过辐射体采样阶段后，我们获得一组$\{\boldsymbol{\omega}_i\}_{i=1}^{N_a}$ 从用户设备的天线阵列发出的射线，以及一系列沿每条射线采样的无线辐射体，采样依据为采样间隔 $\{\delta_{ij}\}_{j=1}^{N_r}$。为了学习式中的映射，(24)，需要辐射器专属查询 $\{\mathbf{q}^{ij}(f)\}$ 。为弥合这一差距，我们综合利用两个来源的可用信息来构造查询。第一种是用户设备的天线阵列 $\mathbf{H}_{\mathrm{RX}}^{\mathrm{U}} \in$ 观测 $\mathbb{R}^{2N_c\times N_u\times N_b}$[2]，到的上行链路信道状态信息，以$\mathbf{H}$表示，它为所有辐射器提供共享的全局信息参考。第二种是辐射器专属几何信息，即射线方向 $\{\boldsymbol{\omega}_i\}_{i=1}^{N_a}$ 和采样间隔 $\{\delta_{ij}\}_{j=1}^{N_r}$，它们能够唯一确定每个辐射器相对于用户设备的空间分布。将二者结合，便可为 WiRARE 网络生成信息丰富的辐射器专属查询。

如图 6 所示，我们首先通过直通初始化，将$\mathbf{H}_{\mathrm{RX}}^{\mathrm{U}}$ 复制到每个采样辐射体，得到初始查询张量$\mathbf{Q}_{\mathrm{raw}} \in \mathbb{R}^{N_a\times N_r\times 2N_c\times N_u\times N_b}$。这些信道状态信息副本作为输入查询，输入 WiRARE 网络，使其具备基本的学习能力。随后，我们引入一种新颖的查询整形过程，并通过专门的引导式整形滤波器模块实现。该模块考虑辐射体的空间分布，在角度和径向维度上微调$\mathbf{Q}_{\mathrm{raw}}$ ，从而实现针对不同辐射体的区分。具体而言，我们将整形滤波器设计为一个分层模块，如图 7 所示，该模块在两个指示器的引导下分两个阶段运行。

在第一阶段，整形滤波器沿$\mathbf{Q}_{\mathrm{raw}}$ 的角度维度进行微调。具体而言，首先将射线方向 $\{\boldsymbol{\omega}_i\}_{i=1}^{N_a}$ 转换为指示器 $\boldsymbol{\gamma}$，再经过维度扩展和张量重塑，表示为

$$\boldsymbol{\gamma} \in \mathbb{R}^{N_a\times 3} \xrightarrow{\text{expand}} \boldsymbol{\gamma} \in \mathbb{R}^{N_a\times N_r\times 3\times N_u\times N_b} \tag{27a}$$

$$\xrightarrow{\text{reshape}} \boldsymbol{\gamma} \in \mathbb{R}^{N_a N_r\times 3\times N_u\times N_b}. \tag{27b}$$

随后，查询张量 $\mathbf{Q}_{\mathrm{raw}}$ 会被重塑，并沿第二个维度与指示器进行张量拼接：

$$\mathbf{Q}_{\mathrm{raw}} \xrightarrow{\text{reshape}} \mathbf{Q}_{\mathrm{raw}} \in \mathbb{R}^{N_a N_r\times 2N_c\times N_u\times N_b} \tag{28a}$$

$$\xrightarrow{\text{concatenate}} \mathbf{A} \in \mathbb{R}^{N_a N_r\times(2N_c+3)\times N_u\times N_b}, \tag{28b}$$

$$\mathbf{A} = \mathbf{Q}_{\mathrm{raw}} \oplus_2 \boldsymbol{\gamma}, \tag{28c}$$

其中，$\mathbf{A}$ 表示拼接张量，$\oplus_2$ 表示沿第二个维度执行的张量拼接操作。接下来，$\mathbf{A}$ 会经过角度整形层$\mathcal{G}_{\boldsymbol{\theta}}(\cdot)$，该层基于二维卷积层设计：

$$\mathbf{Q}_{\mathrm{ang}} = \mathcal{G}_{\boldsymbol{\theta}}(\mathbf{A}) \in \mathbb{R}^{N_a N_r\times 2N_c\times N_u\times N_b}, \tag{29}$$

其中，$\mathbf{Q}_{\mathrm{ang}}$ 表示在.....上微调的查询张量

[2]在实现中，所有复数值信道状态信息数据都会转换为实值格式，以便进行神经网络训练。具体而言，信道状态信息的实部和虚部会沿频率维度拼接。

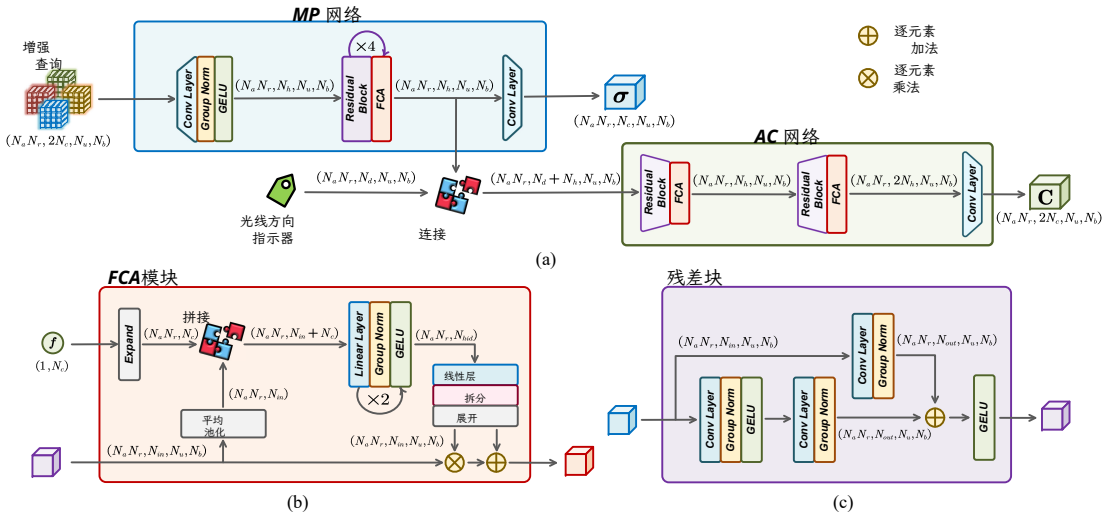


图 8：WiRARE网络的架构。（a）概述了WiRARE的完整架构，该架构基于二维卷积层构建。（b）和（c）分别描绘了WiRARE网络中FCA模块和残差块的内部结构。

角度维度，且 $\boldsymbol{\theta}$ 表示角度整形层的可训练参数。

在第二阶段，整形滤波器沿径向维度细化$\mathbf{Q}^{\text{ang}}$。与第一阶段类似，采样间隔 $\{\delta_{ij}\}_{j=1}^{N_r}$ 被转换为指示器 $\boldsymbol{\eta}$，表示为

$$\boldsymbol{\eta} \in \mathbb{R}^{N_r} \xrightarrow{\text{expand}} \boldsymbol{\eta} \in \mathbb{R}^{N_a \times N_r \times 2N_c \times N_u \times N_b} \tag{30a}$$

$$\xrightarrow{\text{reshape}} \boldsymbol{\eta} \in \mathbb{R}^{N_a \times N_r \times 2N_c \times N_u N_b}. \tag{30b}$$

随后，将$\mathbf{Q}^{\text{ang}}$ 重塑，并沿第二个维度与 $\boldsymbol{\eta}$拼接，表示为

$$\mathbf{Q}_{\text{ang}} \xrightarrow{\text{reshape}} \mathbf{Q}_{\text{ang}} \in \mathbb{R}^{N_a \times N_r \times 2N_c \times N_u N_b} \tag{31a}$$

$$\xrightarrow{\text{concatenate}} \mathbf{B} \in \mathbb{R}^{N_a \times 2N_r \times 2N_c \times N_u N_b}, \tag{31b}$$

$$\mathbf{B} = \mathbf{Q}_{\text{ang}} \oplus_2 \boldsymbol{\eta}, \tag{31c}$$

其中，$\mathbf{B}$ 表示拼接张量。随后，$\mathbf{B}$经由径向整形层 $\mathcal{G}_{\boldsymbol{\phi}}(\cdot)$处理，表示为

$$\mathbf{Q}_{\text{rad}} = \mathcal{G}_{\boldsymbol{\phi}}(\mathbf{B}) \in \mathbb{R}^{N_a \times N_r \times 2N_c \times N_u N_b}, \tag{32a}$$

$$\mathbf{Q}_{\text{rad}} \xrightarrow{\text{reshape}} \mathbf{Q} \in \mathbb{R}^{N_a N_r \times 2N_c \times N_u \times N_b}, \tag{32b}$$

其中，$\mathbf{Q}_{\text{rad}}$ 表示沿径向维度微调后的查询，$\boldsymbol{\phi}$ 表示径向整形滤波器的可训练参数，而$\mathbf{Q}$ 表示引导式整形滤波器模块的最终输出，随后将其输入WiRARE网络。

总之，整个引导式查询整形过程可简洁地表示为以下表达式：

$$\mathbf{Q} = \mathcal{G}_{\boldsymbol{\phi}}(\mathcal{G}_{\boldsymbol{\theta}}(\mathbf{Q}_{\text{raw}} \oplus_2 \boldsymbol{\gamma}) \oplus_2 \boldsymbol{\eta}), \tag{33}$$

其中，维度扩展和张量重塑操作已隐式纳入其中。如下一小节所述，引导式整形滤波器的可训练参数$\{\boldsymbol{\theta}, \boldsymbol{\phi}\}$ 与WiRARE网络以端到端方式联合优化。

### *D. WiRARE*网络

准备好增强查询$\mathbf{Q}$ 后，WiRARE网络旨在预测材料属性以及所有采样无线辐射体的聚合系数。网络架构如图8所示，其特点是采用空间感知骨干网络，并通过FCA模块进行频率感知微调。

*1*）空间感知骨干网络：现有方法 [33], [35],[36] 通常基于全连接层构建场景表示神经网络。虽然这些结构足以学习基本的射频辐射场，但无法有效利用数据中的空间相关性，从而限制了网络在多天线系统中学习更复杂射频辐射场的能力。相比之下，我们的 WiRARE网络采用二维卷积层构建，尤其擅长捕捉数据中的空间相关性。这种空间感知能力显著提升了 WiRARE 执行 MIMO射频辐射场渲染的能力。

具体而言，WiRARE 由两个子网络组成：材料属性（MP）网络和聚合系数（AC）网络，分别用于预测材料属性 $\boldsymbol{\sigma}$ 和聚合系数 $\mathbf{C}$。输入 $\mathbf{Q}$ 首先由 MP 网络处理，该网络包含一个上采样卷积层，其中有 $N_h$个隐藏通道、一个组归一化（GN）层 [42], 和一个 GELU 激活函数 [43]。经过这些初始层后，输出会通过四个残差块，其内部结构如图 8(c) 所示。具体而言，每个残差块的主分支由两个卷积层组成，并结合 GN 层和 GELU 激活函数。此外，第二个卷积层的输出还会接入一条捷径连接，其实现方式为：(i) 恒等映射（隐藏维度保持不变时），或 (ii) $1\times1$ 卷积（应用下采样时）。随后，主分支和捷径分支的输出之和会经过一个最终的 GELU 激活函数，再传递至后续层。这些残差块的输出特征随后分为两条不同的处理路径。第一条路径包含一个下采样卷积层，用于生成材料属性的预测 $\boldsymbol{\sigma}$。第二条路径则将特征送入 AC 网络，以预测聚合系数 $\mathbf{C}$。值得注意的是，我们将无线辐射体建模为各向异性源，可辐射方向

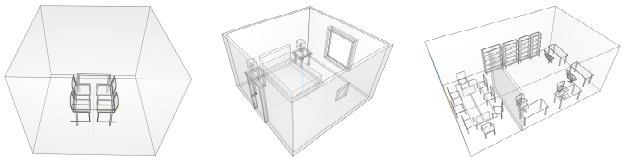


图 9：三个室内三维环境模型的几何结构。

相关的射频信号，从而增强网络捕获多径传播效应的能力。为便于学习这些方向特征，MP 网络的输出特征会与射线方向指示器 $\boldsymbol{\gamma}$ 拼接，然后输入 AC 网络。对于 AC 网络，输入特征首先经过一个下采样残差块，接着经过一个上采样残差块和一个下采样卷积层。最后，预测得到的聚合系数 $\mathbf{C}$ 以实数形式生成，其实部和虚部沿频率维度拼接。随后，利用预测结果 $\boldsymbol{\sigma}$ 和 $\mathbf{C}$，根据公式（23）得到下行链路信道状态信息的最终预测值 $\hat{\mathbf{H}}^{\mathrm{D}}$。

*2*）频率感知微调：为了在空间感知骨干网络设计的基础上进一步提升 WiRARE 的预测性能，我们通过开发 FCA 模块引入频率感知微调。该模块充当特征调制器，将每个子载波的明确频率值 $f$（GHz）作为辅助信息，以此优化中间特征。

具体而言，FCA 模块通过仿射变换对输入特征进行微调。这些变换的权重和偏置由输入特征和每个子载波的频率值共同确定。如图 8(b) 所示，首先分别对输入特征进行平均池化、对频率值进行维度扩展，以对齐二者的维度并合并这两路信息。随后，采用三个全连接层，并结合 GN 层和 GELU 激活函数，对合并后的信息流进行处理。最后，根据处理后的信息生成对输入特征进行最终仿射变换所需的权重和偏置。需要注意的是，$\boldsymbol{\sigma}$ 和$\mathbf{C}$ 都依赖于频率。因此，如图 8(a) 所示，FCA模块被嵌入 MP 网络和 AC 网络中，并连接在残差块的末端。

## V. 仿真结果

本节通过大量实验评估 F$^4$- CKM 的性能。我们采用多种评价指标和先进的基线方法，对仿真及真实世界的多输入多输出 OFDM 信道数据集进行性能比较。

### *A.* 仿真设置

*1)* 数据集：

- 仿真数据集。仿真数据集使用 MATLAB平台生成。数据集生成采用了 [35] 中提及的三个室内三维环境模型。这些环境的几何结构和物理尺寸

表I：仿真数据集生成的参数设置。

| 环境 | 参数 | | 规模（训练|测试） |
|---|---|---|---|
| | 发射端坐标（米） | 频段（上行|下行） | |
| 会议室 | $[-1.2, 0.0, 1.7]$ | 2.415\|2.465 GHz | $9,863\|1,976$ |
| | $[-1.2, 0.0, 1.7]$ | 3.515\|3.565 GHz | $9,869\|1,973$ |
| | $[-1.2, 0.0, 1.7]$ | 6.715\|6.765 GHz | $9,889\|1,976$ |
| | $[-1.2, 0.0, 1.7]$ | 28.015\|28.065 GHz | $9,922\|1,983$ |
| 卧室 | $[-1.2, 0.0, 2.7]$ | 2.415\|2.465 GHz | $17,824\|3,589$ |
| 办公室 | $[0.3, 3.7, 2.7]$ | 2.415\|2.465 GHz | $28,082\|5,633$ |

如图 9 所示。在每个环境中，均设置一台配备 $4 \times 4$ 均匀平面阵列的固定发射机，以及多个随机分布在场景中的接收机，每台接收机均配备 $2 \times 2$均匀平面阵列。上行链路和下行链路的 OFDM 带宽均设为 20 MHz，分为 64 个子载波，相邻子载波间隔为 312.5 KHz。在实验中，我们使用这 64 个子载波中的 52 个进行信道测量。上行链路与下行链路之间的频段间隔设为 50 MHz。我们采用射线发射与反弹追踪（SBR）方法，获取每个接收机的仿真上行链路和下行链路信道测量数据。在 2.4 GHz 频段为每个环境构建数据集；此外，还针对会议室场景分别在 3.5 GHz、6.7 GHz 和 28.0 GHz 频段生成了三个额外的数据集。仿真数据集生成的详细参数设置见表I。

- 真实世界数据集。 此外，还引入了公开的 Argos 信道数据集 [44] 用于性能评估。该数据集包含在各种环境中采集的真实世界多输入多输出正交频分复用信道测量数据，其中基站配备了 104 根天线，最多可服务 8 个用户设备。OFDM 带宽设置为 20 MHz，划分为 64 个子载波，其中 52 个用于信道测量。与先前的研究一致 [33], [36], ，我们将前 26 个子载波指定用于上行链路，其余 26 个子载波用于下行链路。

*2*）评价指标： 我们采用三种评价指标来评估信道预测的准确性，分别称为预测信噪比（PSNR）、平方广义余弦相似度（SGCS）和频谱效率。PSNR 定义为

$$\mathrm{PSNR}\ (\mathrm{dB}) = -10\log_{10}\left(\frac{||\hat{\mathbf{H}}^{\mathrm{D}} - \mathbf{H}^{\mathrm{D}}||^2}{||\mathbf{H}^{\mathrm{D}}||^2}\right), \tag{34}$$

其中，$\hat{\mathbf{H}}^{\mathrm{D}}$ 和 $\mathbf{H}^{\mathrm{D}}$ 分别表示预测的下行链路信道状态信息和实际的下行链路信道状态信息。PSNR 越高，表示预测越准确。此外，用于评估信道状态信息预测角域准确性的 SGCS 指标定义为

$$\mathrm{SGCS} = \frac{1}{N_c}\sum_{i=1}^{N_c}\frac{||\mathbf{w}_i^H\hat{\mathbf{w}}_i||^2}{||\mathbf{w}_i||^2||\hat{\mathbf{w}}_i||^2}, \tag{35}$$

其中，$\hat{\mathbf{w}}$ 和$\mathbf{w}$ 分别表示根据预测的和实际的信道状态信息矩阵导出的理想特征向量。SGCS 值越高，表示信道状态信息的预测越准确，

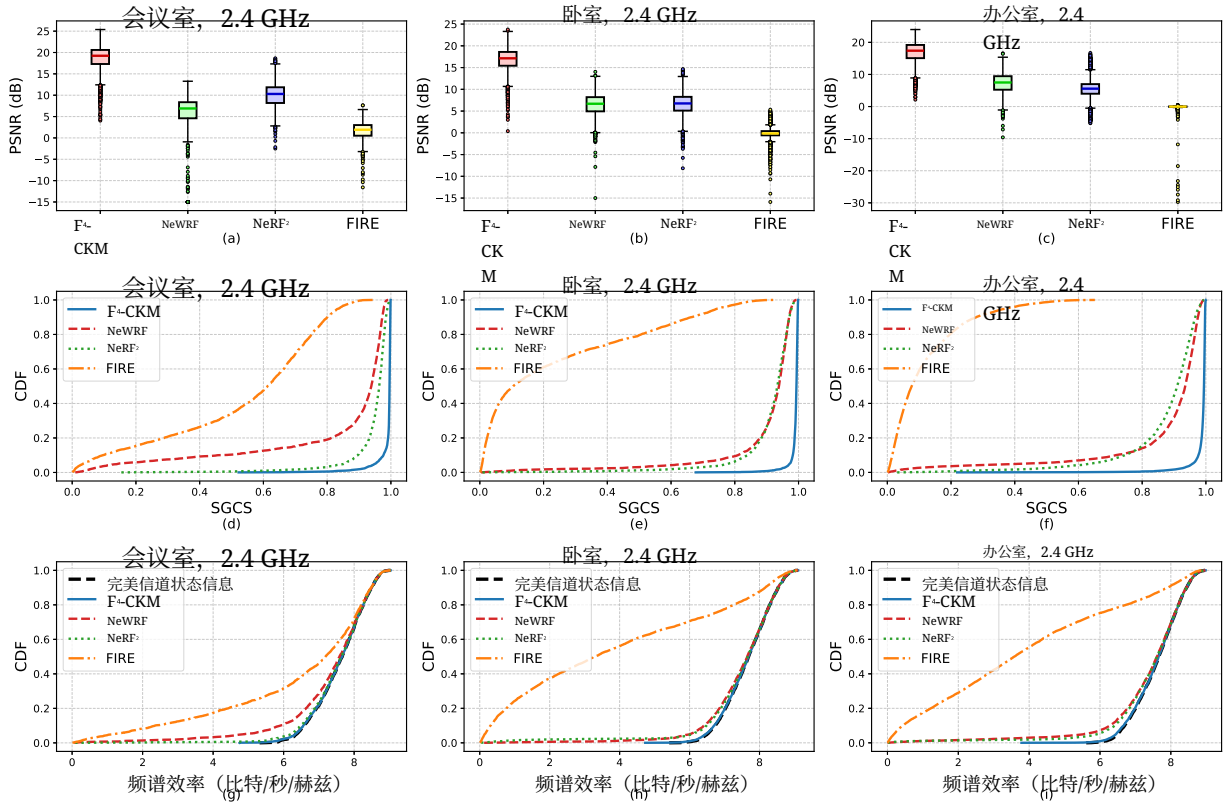


图10：不同室内环境下的峰值信噪比、SGCS和频谱效率表现。

这有利于 MIMO系统中的波束成形。此外，频谱效率用于评估端到端系统性能。我们假设基站和用户设备均采用离散傅里叶变换码本，且信噪比为 $\gamma = 10$ 分贝，则频谱效率计算如下

$$R\ (\text{bps/Hz}) = \frac{1}{N_c}\sum_{f}\log_2\left(1+\gamma\cdot||\mathbf{w}_*^H\mathbf{H}^{\text{D}}(f)\mathbf{f}_*||^2\right), \quad (36)$$

其中，$\mathbf{f}_* \in \mathbb{C}^{N_b}$ 和$\mathbf{w}_* \in \mathbb{C}^{N_u}$ 分别表示发射和接收波束成形向量，它们根据预测的下行链路CSI $\hat{}\mathbf{H}^{\text{D}}(f)$选择，以最大化信道增益，具体如下：

$$(\mathbf{w}_*, \mathbf{f}_*) = \arg\max_{\mathbf{f}\in\mathcal{F},\mathbf{w}\in\mathcal{W}} \frac{1}{N_c}\sum_{f}||\mathbf{w}^H\hat{\mathbf{H}}^{\text{D}}(f)\mathbf{f}||^2, \quad (37)$$

其中，$\mathcal{F}$ 和 $\mathcal{W}$ 分别是基站和用户设备的码本。

*3)* 基线方法：我们将 F -CKM[4]与四种基线方法进行比较。

- **NeWRF** [35]：NeWRF 是一种基于 NeRF 的方法，利用用户位置预测信道状态信息。我们使用该方法的开源代码，并在我们的数据集上对其进行训练。由于其代码是为单输入单输出（SISO）系统设计的，因此我们通过将天线维度并入数据样本维度并逐元素预测信道状态信息，将 NeWRF 方法适配到我们的多输入多输出数据集。
- **NeRF²** [33]：NeRF² 是一种基于 NeRF 的方法，可根据上行链路信道状态信息预测下行链路信道状态信息。我们使用了作者提供的开源代码。
- **FIRE** [19]：FIRE 是一种基于变分自编码器（VAE）架构的无模型方法，可根据上行链路信道状态信息预测下行链路信道状态信息。我们使用了该方法提供的开源代码。

*4)* 实现细节：我们使用 PyTorch 平台、2.60 GHz Intel(R) Xeon(R) Platinum 8350C CPU 和 NVIDIA GeForce RTX 4090 GPU 实现 F⁴-CKM 及所有基线方法。训练 F⁴-CKM 时，采用 Adam优化器 [45]，初始学习率为 $5\times10^{-5}$，批量大小为 8。使用 ReduceLROnPlateau调度器动态调整学习率，其耐心值为 10，衰减因子为 0.9。采样射线的数量以及沿每条射线采样的辐射器数量分别设为 24 和 32，径向采样范围设为 9 m。代码地址：https://github.com/kqzzzz/F4CKM。

### *B.* 仿真数据集上的评估

在图10中，我们比较了F⁴-CKM与三种不同室内环境下的基线方法。具体而言，图10(a)、图10(b)和图10(c)分别展示了会议室、卧室和办公室中的峰值信噪比表现。F⁴-CKM在这些环境中取得的峰值信噪比中位数分别为19.23分贝、17.13分贝和17.39分贝。相比之下，基线方法中的最高峰值信噪比分别为9.71分贝、6.67分贝和7.48分贝。此外，图10(d)、图10(e)和图10(f)通过累积分布函数（CDF）曲线展示了SGCS表现。值得注意的是，当SGCS接近1.0时，F⁴-CKM的CDF曲线几乎垂直上升。具体而言，在所有三种环境中，F⁴-CKM超过90%的结果均达到SGCS

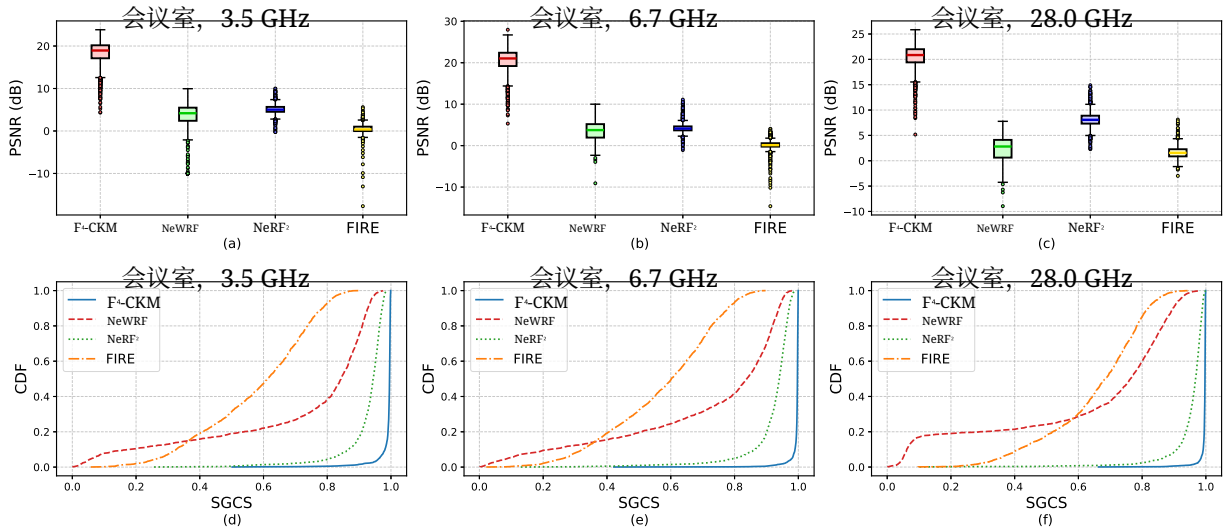


图11：会议室环境中不同频段下的峰值信噪比和SGCS性能。对于每个频段，所有算法均在该频段上进行训练和评估。

值高于0.976。这种出色的一致性证明了F⁴-CKM在波束成形相关应用中的可靠性。

此外，图10(g)、10(h)和10(i)展示了系统级性能评估结果，其中“完美信道状态信息”曲线对应于假设下行链路信道状态信息获取无误差时的频谱效率上界。值得注意的是，F⁴-CKM的CDF曲线与“完美信道状态信息”的曲线非常接近，表明其信道预测具有很高的可靠性。具体而言，对于测试集中的所有样本，F⁴-CKM实现的频谱效率均超过4.7比特/秒/赫兹（会议室和卧室）和3.7比特/秒/赫兹（办公室），而基线方法的性能则存在显著波动，表明其预测偶尔会失败。显然，F⁴-CKM在所有三种环境中均显著优于所有基线方法。这一优势归因于F⁴-CKM的空频感知系统表述和网络设计，这些设计能够有效捕捉无线信道的特性。

图 11 展示了 F⁴-CKM 在会议室环境中不同频段下的性能。显然，F⁴-CKM 的峰值信噪比表现稳定在约 20 分贝，且 SGCS 值始终紧密集中在 1.0 附近，优于所有基线方法。这种稳健性源于 F⁴-CKM 的频率感知系统表述以及 FCA 模块的设计。通过将频率值作为辅助信息，FCA 模块使 F⁴-CKM 能够在广泛的频谱范围内保持稳定的性能。

### *C.* 真实世界数据集评估

为进一步展现我们方法在实际应用中的有效性，我们使用 Argos真实世界数据集 [44]评估 F⁴-CKM 的性能。具体而言，图 12 展示了 F⁴-CKM、NeRF², 和 FIRE 在 Argos 数据集上的峰值信噪比与 SGCS 性能的详细对比。从图 12(a)可以看出，F⁴-CKM 明显优于所有基线方法，其中位数峰值信噪比超过 30 分贝。此外，F⁴-CKM 的箱线图明显比 NeRF² 和 FIRE 的箱线图更平坦，这表明 F⁴-CKM

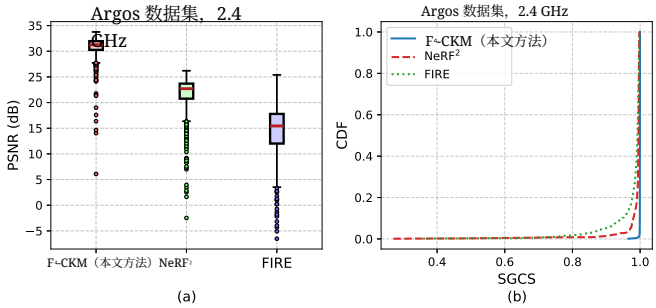


图 12：Argos 数据集上的峰值信噪比和 SGCS 性能。

表 II：Argos 数据集上的峰值信噪比性能比较。

| | 上须状线 | 上四分位数 | 中位数 | 下四分位数 | 下须状线 |
|---|---|---|---|---|---|
| F⁴-CKM | 34.30 分贝 | 31.85 分贝 | 31.19 分贝 | 30.22 分贝 | 27.77 分贝 |
| WRF-GS+ | 29.00 分贝 | 25.51 分贝 | 23.91 分贝 | 20.88 分贝 | 14.40 分贝 |
| WRF-GS | 26.73 分贝 | 24.35 分贝 | 22.98 分贝 | 20.83 分贝 | 15.65 分贝 |
| NeRF² | 26.80 分贝 | 22.26 分贝 | 21.17 分贝 | 19.24 分贝 | 14.70 分贝 |
| FIRE | 26.46 分贝 | 17.79 分贝 | 15.44 分贝 | 12.01 分贝 | 3.34 分贝 |
| R2F2 | 11.54 分贝 | 9.63 分贝 | 8.57 分贝 | 6.82 分贝 | 2.65 分贝 |
| OptML | 11.07 分贝 | 9.37 分贝 | 8.47 分贝 | 6.10 分贝 | 1.25 分贝 |

表现出更稳健、更可靠的性能。此外，图12(b)显示，对于100%的测试数据，F⁴-CKM取得了高于0.965的SGCS分数。这一结果进一步凸显了F⁴-CKM在信道预测方面的卓越性能。为了更直观地展示结果，图13选取PSNR中位数对应的样本，并对真实值与预测的下行链路CSI进行了比较。具体而言，沿天线维度提取一个切片。我们将复数形式的CSI分解为幅度和相位分量，并绘制这些数值随子载波索引变化的曲线。可以观察到，

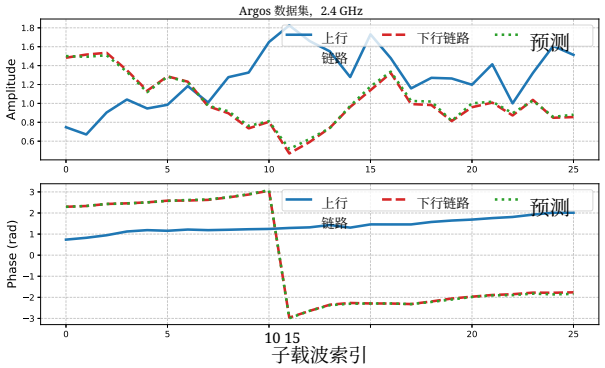


图13：使用 F[4]-CKM 对真实值与预测的下行链路CSI进行比较，展示幅度和相位随子载波索引的变化。

表III：Argos 数据集中的延迟和计算开销比较

| 模型 | 延迟 (ms) | 十亿次浮点运算 | 参数 (M) | 平均峰值信噪比 (dB) |
|---|---|---|---|---|
| F[4]-CKM | 5.756 | 37.27 | 3.41 | 30.74 |
| F[4]-CKM-Lite | 4.326 | 6.34 | 0.51 | 27.40 |
| NeRF[2] | 8.775 | 117.03 | 0.71 | 21.51 |
| FIRE | 0.460 | $9.45 \times 10^{-5}$ | 0.05 | 14.47 |

预测曲线与真实值曲线几乎完全重合，凸显了F[4]-CKM在信道预测任务中的卓越准确性。

表 II 详细说明了图 12 所示的峰值信噪比结果，并将比较扩展到另外四种基线方法，即 WRF-GS [36], WRF-GS+ [36]、R2F2 [46]，和 OptML [47]。

- **R2F2**：这种基于模型的方法通过求解优化问题来确定用于预测的多径信息，并利用上行链路信道状态信息推断下行链路信道状态信息。
- **OptML**：OptML 利用深度学习技术从上行链路信道状态信息中提取多径信息，随后利用这些信息推断下行链路信道状态信息。
- **WRF-GS**：WRF-GS 将 3DGS 方法与神经网络相结合，以重建射频辐射场，从而根据上行链路信道状态信息预测下行链路信道状态信息。
- **WRF-GS+**：WRF-GS 的增强版本，采用可变形三维高斯对射频辐射场的静态和动态成分进行建模。

为确保公平性和一致性，这四种基线方法的结果均取自 [36]，其中它们使用了相同的数据集进行评估。从该表可以看出，我们的 F[4]- CKM 方法相比所有基线方法都实现了显著的性能跃升。值得注意的是，F[4]-CKM 取得了最佳性能，其中位数峰值信噪比为 31.19 分贝，比最先进的方法 WRF-GS+ 高出 7.28 分贝。

*D.* 复杂度分析

由于所提出的 F[4]-CKM 会引入额外计算，因此有必要分析其计算复杂度，以考量效率问题。主要计算开销来自 WiRARE 网络和公式（ 23 ）中的辐射器聚合操作。

- **WiRARE网络：** WiRARE的计算复杂度主要由其残差块和FCA模块决定。每个FCA模块的计算量为$\mathcal{O}\big(N^2_{\text{hid}} + N_{\text{in}}N_{\text{hid}} + N_cN_{\text{hid}} + N_{\text{in}}N_uN_b\big)$ 次浮点运算（FLOPs），主要来自全连接层和逐通道仿射变换。这里，$N_{\text{in}}$表示FCA模块输入特征的通道维度，$N_{\text{hid}}$ 表示隐藏维度。每个残差块产生 $\mathcal{O}\big(N_{\text{out}}\ N_{\text{in}} + (\ )\ N_{\text{out}}\ N_uN_b\big)$ $N_{\text{in}}$ $N_{\text{out}}$ 次浮点运算，其中，和分别为输入和输出通道数（由于卷积核大小 $K$ 固定为3，因此省略了 $K^2$ 因子）。对于包含 $L$ 个交错排列的残差块–FCA阶段的完整WiRARE网络，并假设 $N_{\text{in}}$，$N_{\text{out}} = \mathcal{O}(N_{\text{hid}})$，总体计算复杂度按 $\mathcal{O}\big(N_{\text{hid}}(LN_{\text{hid}} + N_c)N_uN_b\big)$的规律增长。该结果表明，计算复杂度随MIMO阵列规模线性增长，而 $N_{\text{hid}}$ 和 $L$则提供了实用的复杂度控制手段。
- **辐射器聚合：** 辐射器聚合操作的复杂度主要由公式（22）中的逐元素累积乘积决定。对于每条射线，计算最多 $j-1$ 个矩阵 $\boldsymbol{\beta}_{ij}(f) \in \mathbb{C}^{N_u \times N_b}$（ $j = 1, \ldots\ldots, N_r$）的乘积需要 $\mathcal{O}(N_r^2 N_u N_b)$ 次运算。相比之下，公式（23）中的后续加权求和每条射线仅需 $\mathcal{O}(N_r N_u N_b)$ 次运算，因此总复杂度为 $\mathcal{O}(N_a N_r^2 N_c N_u N_b)$。

总之，F[4]-CKM 的整体复杂度为

$$\begin{aligned}\mathcal{F}_{\text{total}} &= \mathcal{O}\big(N_aN_r \cdot \big(N_{\text{hid}}(LN_{\text{hid}} + N_c)N_uN_b\big) \\ &\quad + N_aN_r^2N_cN_uN_b\big) \\ &= \mathcal{O}\big(N_aN_rN_uN_b \cdot \big(N_{\text{hid}}(LN_{\text{hid}} + N_c) + N_rN_c\big)\big),\end{aligned} \tag{38}$$

其随阵列规模（$N_uN_b$）线性增长，并可通过射线数量 $N_a$、每条射线的辐射器数量$N_r$、网络深度 $L$和隐藏维度 $N_{\text{hid}}$进行控制。

为进行定量复杂度分析，我们测量了 F[4]-CKM 的平均推理延迟、浮点运算次数和模型大小。作为对比，我们还报告了代表性基线模型的延迟和计算开销。评估在 Argos 数据集上进行，结果汇总于表 III。所有测试均在单个图形处理器上进行，每项指标均在整个测试集上进行 10 次独立运行并取平均值，以降低测量方差。可以观察到，与 NeRF[2], 等主流辐射场模型相比，F[4]-CKM 的推理延迟和计算开销更低，同时能够显著提高信道状态信息预测保真度。根据 3GPP 第 18 [48]，版技术规范（TS）38.331，F[4]-CKM 测得的推理延迟与常见的信道状态信息报告周期配置（如 10 ms 和 20 ms）相兼容。

此外，我们通过将网络深度从 6 层降至 4 层，并将隐藏维度从 128 缩减至 32，开发了轻量版 F[4]-CKM，命名为 F[4]-CKM-Lite。该轻量变体将浮点运算次数减少了 80% 以上，而峰值信噪比仅略有下降，同时仍优于所有基线方法。这些结果证实，我们的架构能够灵活控制复杂度，且仅造成轻微的保真度损失，从而实现了良好的复杂度—精度权衡。此外，值得注意的是，成熟的模型压缩和加速技术还可以进一步降低复杂度和延迟，这些技术被视为正交增强手段。

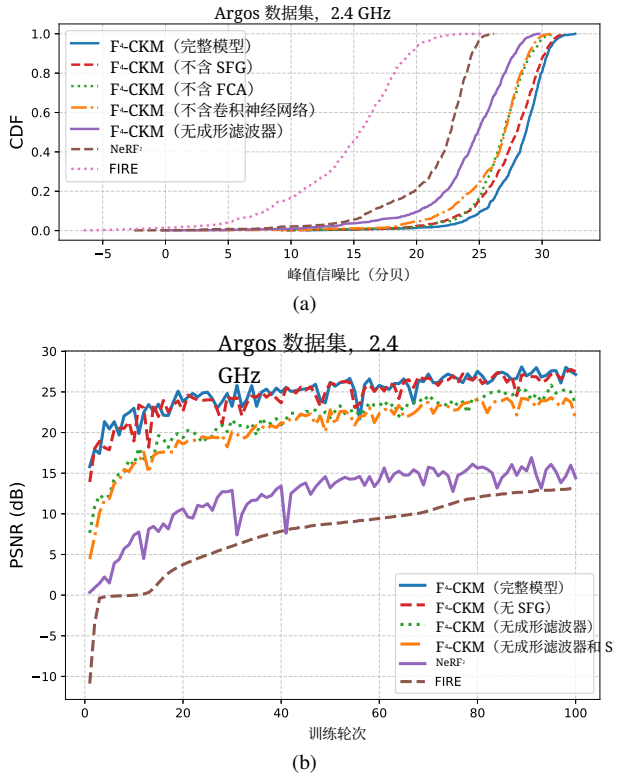


图14：对 F⁴-CKM 的 (a) 峰值信噪比性能和 (b) 训练效率进行消融分析。

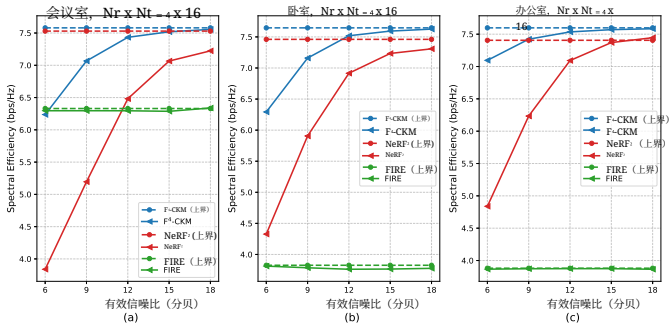


图15：三个室内环境中频谱效率性能随有效信噪比变化的曲线。所有模型均使用完美的上行链路信道状态信息进行训练。

## *E.* 消融研究

为了系统评估 F⁴-CKM 中各个组件对性能的独立贡献，我们开展了全面的消融研究。如图14(a)所示，完整的 F⁴-CKM 模型在所有百分位上均取得最高的峰值信噪比，显著优于所有基线方法和消融变体。在各项消融实验中，移除整形滤波器（SF）导致的性能下降最为严重，证实了它对于 F⁴-CKM 保持高保真度信道预测至关重要。移除二维卷积神经网络骨干（并替换为容量相当的多层感知机）造成了第二大幅度的性能损失，凸显了具备空间感知能力的架构对于准确预测的重要性。禁用 FCA模块会造成中等程度的性能损失，这表明尽管 FCA 有助于增强跨频率一致性，但捕捉空间上下文更为重要。最后，将 SFG 采样替换为

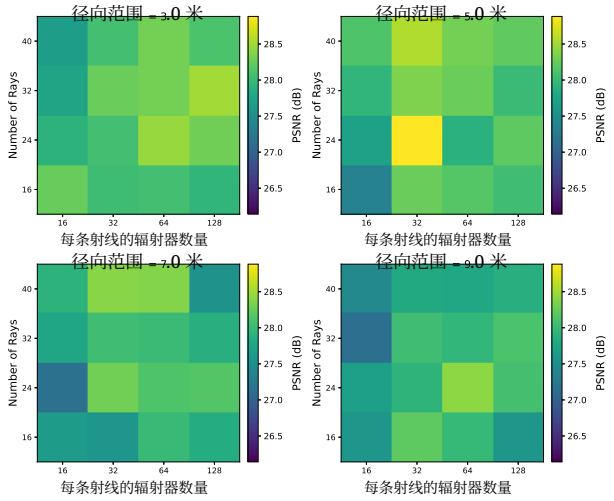


图16：Argos 数据集中峰值信噪比性能随采样分辨率和径向范围变化的曲线。每个模型均训练 100 个训练轮次，并在完整测试集上评估性能。

采用经纬度采样的策略所带来的性能损失最小，这表明 SFG 主要提升了角度均匀性和训练效率，而不是改变模型的核心表征能力。

此外，图14(b)评估了 SF 和 SFG 带来的收敛加速效果；它们是 F⁴-CKM 中仅有的专为快速学习而设计的组件。值得注意的是，移除 SF 会严重减缓收敛速度并降低最终峰值信噪比，而移除 SFG 的变体收敛稍慢，但仍能取得相当的最终性能。由此可见，SF 是快速学习的主要驱动因素，而 SFG 则作为效率增强组件，在不影响准确性的前提下加速训练。为便于全面比较，文中还列出了两种基线方法的训练曲线。值得注意的是，所有方法的学习率和批量大小均保持一致。尤其值得一提的是，F⁴-CKM 在第一个训练轮次就实现了显著的性能跃升，几乎超过了基线方法收敛后的性能。这些观察结果突显了 F⁴-CKM 在构建效率方面的显著优势，并表明其能够快速微调并适应新数据。

## *F.* 不完美上行链路 *CSI* 下的评估

在图15中，我们考察了不完美上行链路 CSI 输入下 F⁴-CKM 的系统级性能。为模拟这些不完美情况，我们在上行链路信道状态信息输入中引入不同程度的加性白高斯噪声。此外，我们采用一个定义为估计信噪比（ESNR）的指标来量化上行链路 CSI 估计误差，其定义为

$$\mathrm{ESNR} = 10\log_{10}\left(\frac{||\mathbf{H}^{\mathrm{U}}||^2}{||\hat{\mathbf{H}}^{\mathrm{U}} - \mathbf{H}^{\mathrm{U}}||^2}\right), \tag{39}$$

其中$\mathbf{H}^{\mathrm{U}}$ 表示实际上行链路 CSI，$\hat{\mathbf{H}}^{\mathrm{U}}$ 表示估计的上行链路 CSI。接着，我们评估 F⁴-CKM 在三种室内环境中的频谱效率表现随有效信噪比的变化，并将其与 NeRF² 和 FIRE 进行比较。所有方法均在理想上行链路 CSI 条件下训练，并在有效信噪比为 6 分贝至 18 分贝的范围内进行评估。作为参考，所有受评估方法在理想

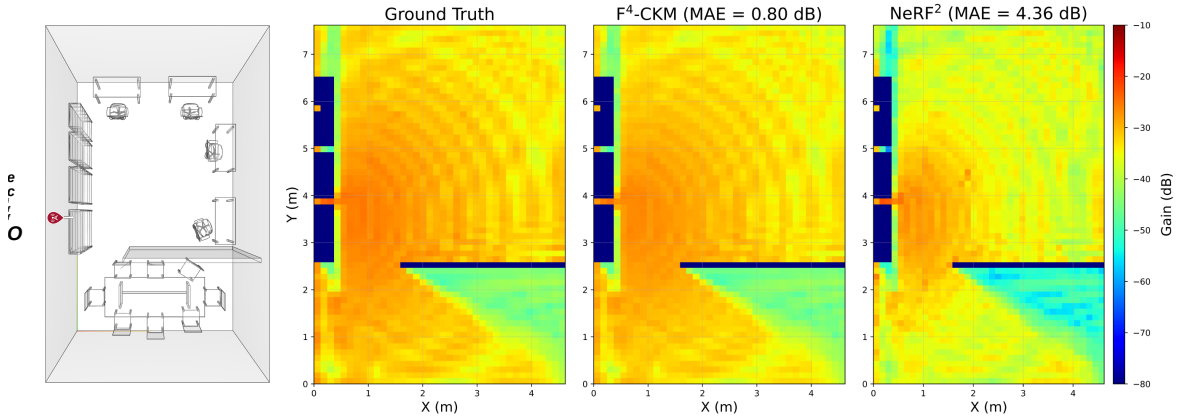


图17：所学习的 信道知识图谱的可视化结果。所有热力图均在间距为一个波长的二维网格上进行采样（在 2.4 GHz 下为 ≈ 12.5 cm z).

上行链路 CSI 条件下的表现也在图15中展示，并标记为“上界 (UB)”。显然，F⁴-CKM 能够有效应对上行链路 CSI 估计误差，展现出其在实际应用中的可靠性。

### *G.* 超参数敏感性分析

在图16中，我们针对三个关键超参数进行了系统的敏感性研究，即采样射线的数量、每条射线的辐射器数量以及径向采样范围。具体而言，我们在 Argos 数据集上训练并评估了多个不同模型，每个模型分别对应以下参数组合：

- **射线数量：** $\{16, 24, 32, 40\}$;
- **每条射线的辐射器数量：** $\{16, 32, 64, 128\}$;
- **径向采样范围：** $\{3.0, 5.0, 7.0, 9.0\}$ 米。

结果表明，F⁴-CKM 在不同采样配置下均表现稳健；在中等采样分辨率（24 条射线、32 个辐射器）和 5.0 米径向范围下，表现最佳。我们建议在类似场景中优先采用这一配置。对于新环境，可通过对采样范围和分辨率进行轻量级网格搜索，高效完成适配。

### *H.* 信道知识图谱可视化

在图17中，我们提供了定性可视化结果，以证实 F⁴-CKM 的物理基础。具体而言，我们在办公室场景中生成了高度为 1.2 米处的信道增益热力图，并将真实信道增益与 F⁴-CKM 和 NeRF² 的预测结果进行比较。作为参考，我们提供了场景的俯视平面图，并将其与热力图坐标系对齐，以便直接进行空间解读。结果表明，F⁴-CKM 能够以高度的物理保真度捕获精细尺度的传播特性。值得注意的是，F⁴-CKM 准确保留了角落和家具附近的干扰模式，并再现了墙后方的阴影区域，与真实情况高度吻合。F⁴-CKM 预测结果表现出的强几何一致性表明，它学习到了受波传播物理规律支配的环境感知表征。

## VI. 结论

本文提出了F⁴-CKM，这是一种用于构建高精度、高效率CKM的创新框架。具体而言，我们提出了一种基于辐射场渲染的方法。首先，我们构建了一个MIMO-OFDM射频辐射场模型，用于捕捉无线信道的空间-频率特性。随后，我们开发了一种新型WiRARE网络，用于射频辐射场渲染，该网络采用空间感知骨干网络，并通过FCA模块增强频率感知能力。为加快收敛速度，我们设计了一种新型整形滤波器模块，对上行链路信道状态信息输入执行数据增强。该模块还支持无位置CKM的使用，使其能够抵抗定位误差。此外，我们采用了基于SFG的角度采样策略，以提高效率。值得注意的是，F⁴-CKM在下行链路信道状态信息预测任务中实现了最先进性能，显著优于现有方法。在不同条件和环境下，该方法还展现出出色的鲁棒性和较高的构建效率，凸显了其在实际应用中的潜力。

此外，本文主要关注室内静态场景，将 F⁴-CKM 扩展至大规模室外动态环境仍是一项尚待解决的挑战。一个关键难点在于，在公里级区域内，所需辐射体密度会大幅增加，从而带来难以承受的内存和计算开销。一种有前景的缓解策略是采用集成与压缩框架：将覆盖区域划分为数十米见方的子区域，在每个子区域部署轻量化的 F⁴-CKM 实例，并通过模型压缩（例如剪枝或量化）控制存储和推理开销。此外，在动态环境中，移动散射体可能扰动辐射分布，导致参数漂移以及学习场的不确定性，进而降低预测保真度。为应对这一影响，可偶尔利用稀疏下行导频反馈进行在线重新校准，但其调度设计和校准机制仍有待进一步研究。

## 参考文献

[1] H. Wu、Y. Shao、E. Ozfatura、K. Mikolajczyk 和 D. G¨und¨uz，“借助 Transformer 和信道反馈的无线图像传输”，*IEEE Trans. Wireless Commun.*，第 23 卷，第 9 期，第 11904–11919 页，2024年9月。[2] G. Zhang、Q. Hu、Y. Cai 和 G. Yu，“SCAN：具有自适应信道反馈的语义通信”，*IEEE Trans. Cognit. Commun. Netw.*，第 10 卷，第 5 期，第 1759–1773 页，2024年10月。[3] Z. Chen、Z. Zhang、Z. Xiao、Z. Yang 和 K.-K. Wong，“将信道视为序列而非图像：一种用于高效多输入多输出正交频分复用 CSI反馈的二维 Seq2Seq 方法”，*IEEE Trans. Wireless Commun.*，第 22 卷，第 11 期，第 7393–7407 页，2023年11月。

[4] J. Wang、H. Wang、J. Huang、W. Wang和C. Chen，“面向6G超大规模MIMO无线通信系统的非平稳非平稳太赫兹信道模型，”IEEE通信领域精选期刊，第39卷，第6期，第1576–1589页，2021年6月。[5] H. Lu和Y. Zeng，“与超大规模阵列/表面进行通信：统一建模与性能分析，”IEEE无线通信汇刊，第21卷，第6期，第4039–4053页，2022年6月。[6] C. You、Y. Cai、Y. Liu、M. Di Renzo、T. M. Duman、A. Yener和A. Lee Swindlehurst，“面向6G及后续发展的下一代先进收发器技术，”IEEE通信领域精选期刊，第43卷，第3期，第582–627页，2025年3月。[7] B. Wang、H. Li和Z. Cheng，“双功能雷达通信系统的动态混合波束成形设计，”IEEE车辆技术汇刊，第73卷，第2期，第2842–2847页，2024年2月。[8] Z. Zhao、Z. Yang、M. Chen、C. Zhu、W. Xu、Z. Zhang和K. Huang，“空天地一体化网络中的能效概率语义通信，”IEEE无线通信汇刊，提前在线发表，2025年5月19日，DOI: 10.1109/TWC.2025.3569102。[9] K. Zhou、G. Zhang、Y. Cai、Q. Hu、G. Yu和A. Lee Swindlehurst，“具有时空重要性感知能力的语义通信特征分配，”IEEE无线通信汇刊，提前在线发表，2025年5月20日，10 1109 2025 3569320 DOI: . /TWC. . . [10] B. Wang、H. Li、S. Shen、Z. Cheng和B. Clerckx，“由超对角可重构智能表面赋能的双功能雷达通信系统，”IEEE通信汇刊，第73卷，第3期，第1501–1516页，2025年3月。[11] Y. Zeng和X. Xu，“借助信道知识地图实现环境感知的6G通信，”IEEE无线通信，第28卷，第3期，第84–91页，2021年6月。[12] Y. Zeng、J. Chen、J. Xu、D. Wu、X. Xu、S. Jin、X. Gao、D. Gesbert、S. Cui和R. Zhang，“面向6G的信道知识地图环境感知通信教程，”IEEE通信调查与教程，第26卷，第3期，第1478–1519页，2024年第3季度。[13] X. Liu、S. Sun、M. Tao、A. Kaushik和H. Yan，“面向6G无线网络的信道知识地图：构建、应用与未来挑战，”arXiv预印本 arXiv:2505.24151，2025年。[14] W. Xie、X. Xu、Z. Dai和Y. Zeng，“关于信道增益图的构建：基于模型还是无模型方法？”载于IEEE车辆技术会议（VTC）论文集，新加坡，新加坡，2024年6月。[15] A. Karttunen、A. F. Molisch、S. Hur、J. Park和C. J. Zhang，“适用于微蜂窝城市环境中28 GHz信道的空间一致逐街路径损耗模型，”IEEE无线通信汇刊，第16卷，第11期，第7538–7550页，2017年11月。[16] O. Kanhere和T. S. Rappaport，“NYURay校准：利用室内、室外和工厂信道测量校准三维毫米波与亚太赫兹射线追踪器，”载于IEEE国际通信会议（ICC）论文集，意大利罗马，2023年5月，第5054–5059页。[17] R. Charbonnier、C. Lai、T. Tenoux、D. Caudill、G. Gougeon、J. Senic、C. Gentile、Y. Corre、J. Chuang和N. Golmie，“基于28 GHz定向城市信道测量，校准含漫散射的射线追踪，”IEEE车辆技术汇刊，第69卷，第12期，第14 264–14 276页，2020年12月。[18] K. Li、P. Li、Y. Zeng和J. Xu，“面向环境感知通信的信道知识地图：用于地图构建的EM算法，”载于IEEE无线通信与网络会议（WCNC）论文集，美国德克萨斯州奥斯汀，2022年4月，第1659–1664页。[19] Z. Liu、G. Singh、C. Xu和D. Vasisht，“FIRE：为FDD MIMO系统实现互易性，”载于ACM移动计算与网络国际会议（MobiCom）论文集，美国路易斯安那州新奥尔良，2021年10月，第628–641页。[20] S. Fu、Z. Wu、D. Wu和Y. Zeng，“利用扩散模型和部分观测数据构建生成式CKM，”arXiv预印本 arXiv:2412.14812，2024年。[21] H. Si、X. Hou、J. Wang、G. O. Boateng、Z. Zhang、X. Guo和D. Niyato，“面向众包轨迹数据的无监督定位：一种深度强化学习方法，”IEEE无线通信汇刊，提前在线发表，2025年4月30日，DOI: 10.1109/TWC.2025.3563766。[22] T. Hehn、M. Peschl、T. Orekondy、A. Behboodi和J. Brehmer，“基于几何Transformer的可微分、可学习无线仿真，”arXiv预印本 arXiv:2406.14995，2024年。[23] Z. Jin、L. You、J. Wang、X.-G. Xia和X. Gao，“用于高效信道知识地图构建的I2I修复方法，”IEEE无线通信汇刊，第24卷，第2期，第1415–1429页，2025年2月。[24] H. Sifaou和O. Simeone，“通过交叉预测驱动推断进行无线系统半监督学习，”IEEE《机器学习与通信网络汇刊》，第3卷，第30–44页，2025年。[25] T. Orekondy、P. Kumar、S. Kadambi、H. Ye、J. Soriaga和A. Behboodi，“WiNeRT：迈向用于无线信道建模和可微仿真的神经射线追踪，”载于国际学习表征会议（ICLR）论文集，卢旺达基加利，2023年5月。[26] Y. Jin、A. Maatouk、S. Girdzijauskas、S. Xu、L. Tassiulas和R. Ying，“SANDWICH：迈向离线，更2024神经[29] J. Hoydis、F. Ait Aoudia、A. Cammerer、M. Nimier-David、S. T. Brink和A. Keller，《通过可微射线追踪学习无线电环境》，IEEE《机器学习与通信网络汇刊》，第2卷，第1527–1539页，2024年。[28] W. Chen和J. Chen，《利用几何模型辅助深度学习，结合衍射与散射特性的无线电地图和环境重建》，IEEE无线通信汇刊，第23卷，第12期，第19 804–19 819页，2024年12月。[29] Z. Xiao、Z. Zhang、Z. Chen、Z. Yang、C. Huang和X. Chen，《从数据驱动学习到物理启发推断：一种基于神经常微分方程的新型移动MIMO信道预测方案》，IEEE无线通信汇刊，第23卷，第7期，第7186–7199页，2024年7月。[30] G. Wu、Z. Lyu、J. Zhang和J. Xu，《拥抱6G中的辐射场渲染：基于三维内容的空中训练与推理》，IEEE开放获取通信学会期刊，第5卷，第4275–4292页，2024年。[31] B. Mildenhall、P. P. Srinivasan、M. Tancik、J. T. Barron、R. Ramamoor-thi和R. Ng，《NeRF：将场景表示为用于视图合成的神经辐射场》，《ACM通讯》，第65卷，第1期，第99–106页，2021年12月。[32] B. Kerbl、G. Kopanas、T. Leimk¨uhler和G. Drettakis，《用于实时辐射场渲染的三维高斯泼溅》，《ACM图形学汇刊》，第42卷，第4期，第1–14页，2023年7月。[33] X. Zhao、Z. An、Q. Pan和L. Yang，《NeRF2：神经射频辐射场》，载于ACM移动计算与网络国际会议（MobiCom）论文集，西班牙马德里，2023年10月，第1–15页。[34] L. Zhang、H. Sun、S. Berweger、C. Gentile和R. Q. Hu，《RF-3DGS：利用无线电辐射场和三维高斯泼溅进行无线信道建模》，arXiv预印本arXiv:2411.19420，2024年。[35] H. Lu、C. Vattheuer、B. Mirzasoleiman和O. Abari，《NeWRF：用于无线辐射场重建和信道预测的深度学习框架》，载于机器学习国际会议（ICML）论文集，奥地利维也纳，2024年7月，第33 147–33 159页。[36] C. Wen、J. Tong、Y. Hu、Z. Lin和J. Zhang，《无线辐射场重建的神经表示：一种三维高斯泼溅方法》，arXiv预印本arXiv:2412.04832，2024年。[37] L. Lee、M. Jones、G. S. Ridenour、S. J. Bennett、A. C. Majors、B. L. Melito和M. J. Wilson，《支持GPS的移动设备的准确度与精度比较》，载于IEEE计算与信息技术国际会议（CIT）论文集，斐济楠迪，2016年12月，第73–82页。[38] Y. Yang、F. Gao、X. Tao、G. Liu和C. Pan，《环境语义辅助无线通信：毫米波波束预测与阻塞预测案例研究》，IEEE通信领域精选期刊，第41卷，第7期，第2025–2040页，2023年7月。[39] J. Vieira、E. Leitinger、M. Sarajlic、X. Li和F. Tufvesson，《用于大规模MIMO基于指纹的定位的深度卷积神经网络》，载于IEEE年度个人、室内与移动无线电通信国际研讨会（PIMRC）论文集，加拿大魁北克省蒙特利尔，2017年10月。[40] Y. Xie、J. Xiong、M. Li和K. Jamieson，《mD-Track：利用多维特性进行被动室内Wi-Fi跟踪》，载于ACM移动计算与网络国际会议（MobiCom）论文集，墨西哥洛斯卡沃斯，2019年10月，第1–16页。[41] R. Swinbank和R. James Purser，《斐波那契网格：全球建模的一种新方法》，《英国皇家气象学会季刊》，第132卷，第619期，第1769–1793页，2006年7月。[42] Y. Wu和K. He，《组归一化》，载于欧洲计算机视觉会议（ECCV）论文集，德国慕尼黑，2018年9月，第3–19页。[43] D. Hendrycks和K. Gimpel，《高斯误差线性单元（GELU）》，arXiv预印本arXiv:1606.08415，2016年。[44] C. Shepard、J. Ding、R. E. Guerra和L. Zhong，《理解真实的多天线MU-MIMO信道》，载于Asilomar信号、系统与计算会议论文集，美国加利福尼亚州太平洋格罗夫，2016年11月，第461–467页。[45] D. P. Kingma和J. Ba，《Adam：一种随机优化方法》，arXiv预印本arXiv:1412.6980，2014年。[46] D. Vasisht、S. Kumar、H. Rahul和D. Katabi，《在下一代蜂窝网络中消除信道反馈》，载于ACM数据通信特别兴趣小组会议（SIGCOMM）论文集，巴西弗洛里亚诺波利斯，2016年8月，第398–411页。[47] A. Bakshi、Y. Mao、K. Srinivasan和S. Parthasarathy，《利用机器学习快速高效地进行跨频段信道预测》，载于ACM移动计算与网络国际会议（MobiCom）论文集，墨西哥洛斯卡沃斯，2019年10月，第1–16页。[48] 3GPP，《NR；无线资源控制（RRC）；协议规范》，第三代合作伙伴计划（3GPP），技术规范（TS）38.331，2025年3月，版本18.5.0。 [在线]。可访问：https://portal.3gpp.org/desktopmodules/Specifications/SpecificationDetails.aspx?specificationId=3197

，可微分的 ，完全可训练的无线