近场太赫兹通信：基于模型和无模型的信道估计

Ahmet M. Elbir，*IEEE*高级会员，Wei Shi，*IEEE*会员，Anastasios K. Papazafeiropoulos，*IEEE*高级会员，Pandelis Kourtessis *IEEE*会员，以及Symeon Chatzinotas，*IEEE*会士

arXiv:2302.04802v1 [eess.SP] 9 Feb 2023

摘要

太赫兹（THz）频段凭借丰富的可用带宽和极窄的波束宽度，有望成为第六代（6G）无线网络的关键赋能技术之一。由于工作频率较高，系统采用电气尺寸较小的阵列孔径，信号波前在近场呈球面。因此，太赫兹系统中的信道获取应考虑近场信号模型。不同于以往大多忽略近场波束分裂（NB）的影响、仅考虑窄带场景或远场模型的研究，本文针对存在波束分裂的情况，提出了两种宽带太赫兹信道估计方法：一种基于模型，另一种无模型。基于模型的方法采用正交匹配追踪（OMP）算法，并为其设计了感知近场波束分裂的字典。其核心思想是利用波束分裂引起的角度偏差和距离偏差。随后，我们采用能够考虑这些偏差的 OMP 算法，从而自然地减轻波束分裂的影响。此外，我们还提出一种基于联邦学习（FL）的无模型信道估计方法，适用于多用户场景，可降低复杂度和训练开销。数值仿真表明，与现有最先进技术相比，所提出的信道估计方法在宽带太赫兹系统中效果显著。

本研究部分得到了加拿大自然科学与工程研究理事会（NSERC）和爱立信加拿大公司的支持。A. M. Elbir现就职于卢森堡大学安全、可靠性与信任跨学科中心，卢森堡（电子邮箱：ahmetmelbir@gmail.com）。Wei Shi现就职于加拿大渥太华卡尔顿大学信息技术学院（电子邮箱：wei.shi@carleton.ca）。A. K. Papazafeiropoulos和P. Kourtessis现就职于英国哈特菲尔德赫特福德大学通信与智能系统研究组（电子邮箱：tapapazaf@gmail.com, p.kourtessis@herts.ac.uk）。S. Chatzinotas现就职于卢森堡大学安全、可靠性与信任跨学科中心，卢森堡（电子邮箱：symeon.chatzinotas@uni.lu）。

索引词

波束分裂，信道估计，联邦学习，机器学习，近场，正交匹配追踪，稀疏恢复，太赫兹。

一、引言

由于具有丰富的可用带宽，太赫兹（THz）频段有望成为第六代（6G）无线蜂窝网络的关键组成部分。尤其是，太赫兹赋能系统有望在高数据速率（>100Gb/s）、极低传播时延（<1ms）和超高可靠性（99.999%）方面实现革命性提升 [1,2]。

尽管太赫兹频段展现出上述优势，但其中的信号处理仍面临若干太赫兹特有的挑战，需要予以充分考虑。这些挑战包括但不限于：由扩散损耗和分子吸收导致的严重路径损耗、极度稀疏路径模型（例如，见图1）、极短的传输距离，以及波束分裂 （完整列表见 [3, 4]）。为了应对其中的一些挑战，例如路径损耗，受毫米波（mm-Wave）系统中大规模多输入多输出（MIMO）阵列 [5, 6], 的启发，研究者提出了超大规模MIMO架构，其中采用与子载波无关（SI）的模拟波束成形器。在宽带信号处理中，模拟波束成形器的权重仅针对单个子载波频率，即载波频率 [7,8]进行设计。因此，不同子载波处生成波束的方向会发生偏移并指向不同方向，从而导致波束分裂现象（例如，见图2） [3, 9]。

A. 相关工作

尽管文献中已对宽带毫米波信道估计进行了广泛研究 [5,10–13], ，但宽带太赫兹信道估计相对较新 [2]。具体而言，现有方案可分为两类，即基于硬件的技术 [14]和算法方法 [15, 16]。第一类方案考虑采用时延器（TD）网络与移相器，使每个子载波都能获得真时延（TTD），用于波束成形器设计。TD网络用于实现虚拟SD模拟波束成形器，从而减轻波束分裂对混合波束成形的影响 [17]。具体来说， [14] 利用通过TD网络收集的SD信息，提出了一种广义同时正交匹配追踪（GSOMP）技术，因此其性能接近

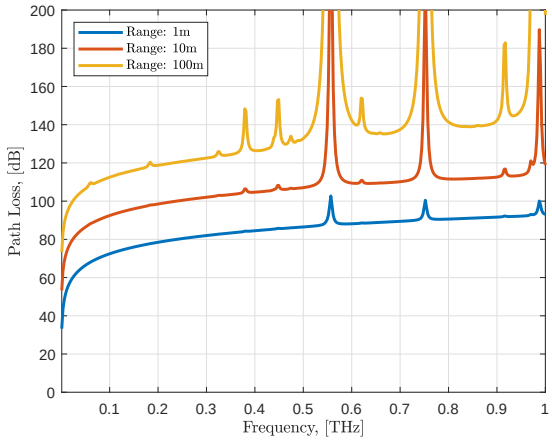

图 1. 不同传输距离下由分子吸收造成的路径损耗（单位：dB）。

最小均方误差（MMSE）性能。然而，这些方案需要额外的硬件，即每个移相器都连接到多个TD，每个TD的功耗约为100 mW，高于太赫兹频段移相器的功耗（40 mW） [3]。第二类方案不使用额外的硬件组件，而是提出了先进的信号处理技术来补偿波束分裂。具体而言，文献 [15] 提出了一种基于OMP的波束分裂模式检测（BSPD）方法，用于恢复波束空间中所有子载波的支撑模式，并在物理方向与空间方向（即波束空间中因波束分裂而偏离的方向）之间建立一一对应关系。此外， [18]提出了一种角度-时延旋转方法，但由于使用了完整的离散傅里叶变换（DFT）矩阵，该方法的波束分裂估计较粗略，且训练开销较高。在[16], 中，研究者提出了一种波束空间支撑对齐（BSA）技术，用于对齐各子载波间偏离的空间波束方向。尽管BSPD和BSA都基于OMP，但后者在太赫兹信道估计中表现出更低的归一化均方误差（NMSE）。然而，这两种方法在支撑检测方面都不够准确，对物理信道方向的估计精度也较低 [19]。

除了上述基于模型的信道估计技术外，也有研究提出采用机器学习（ML）等无模型方法进行太赫兹信道估计 [20, 21]。例如，已有研究提出基于机器学习的学习模型，如深度卷积神经网络（DCNN） [21],生成对抗网络（GAN） [22] 和深度核学习（DKL） [20], ，以降低信道推断过程中涉及的复杂度以及

由超大规模天线单元的使用所带来的复杂度。然而，相关工作 [20, 21] 仅考虑了窄带太赫兹系统，未利用宽带场景，而这正是提升至太赫兹频段以实现更佳通信性能的主要原因。在 [22],中考虑了宽带场景，但忽略了波束分裂的影响。在 [16], 中，针对存在波束分裂的宽带系统，提出了一种基于联邦学习（FL）的太赫兹信道估计方法。然而， [16] 中的算法基于远场用户假设，而该假设在太赫兹频段场景中可能并不成立。

上述太赫兹研究 [14–19] 以及工作于6 GHz以下频段和毫米波频段的传统无线系统 [10–13] 大多采用远场平面波模型，而太赫兹频段的传输距离较短，因此用户通常位于近场区域 [4]。具体而言，当传输距离小于夫琅禾费距离时，近场中的波前呈球面 [23]。因此，信道获取算法应考虑近场模型（参见图3），该模型依赖方向与距离信息，以实现准确的信号处理 [3]。在研究近场信号模型的工作中， [24–28] 考虑了近场场景，但忽略了波束分裂的影响，且仅研究了毫米波场景。具体而言， [27]研究了宽带毫米波信道估计，而 [28] 中的作者则提出了一种基于机器学习（ML）的窄带近场信道估计方法。除纯近场模型外，文献中也提出了混合（近场与远场）模型 [24, 26], ，但其中仅考虑了窄带收发器架构。另一方面，已有多种方法被提出，用于补偿太赫兹信道估计 [14–16、19] 和波束成形 [17, 29, 30] 应用中的远场波束分裂。然而，对于存在近场波束分裂（*NB*）的情况，太赫兹信道估计仍鲜有研究。

B. 贡献

在这项工作中，我们针对存在 NB 的情况，提出了用于近场太赫兹信道估计的基于模型和无模型技术。对于基于模型的方法，我们提出了一种基于 OMP、能够感知 NB 的太赫兹信道估计技术，以下称为 NBA-OMP。对于无模型方法，我们设计了一种联邦学习（FL）方法，与传统的基于集中式学习（CL）的方法相比，该方法的通信效率更高。

我们设计了一种新颖的 NBA 字典，其列由近场子载波相关（SD）导向向量组成，覆盖整个角度谱以及传输

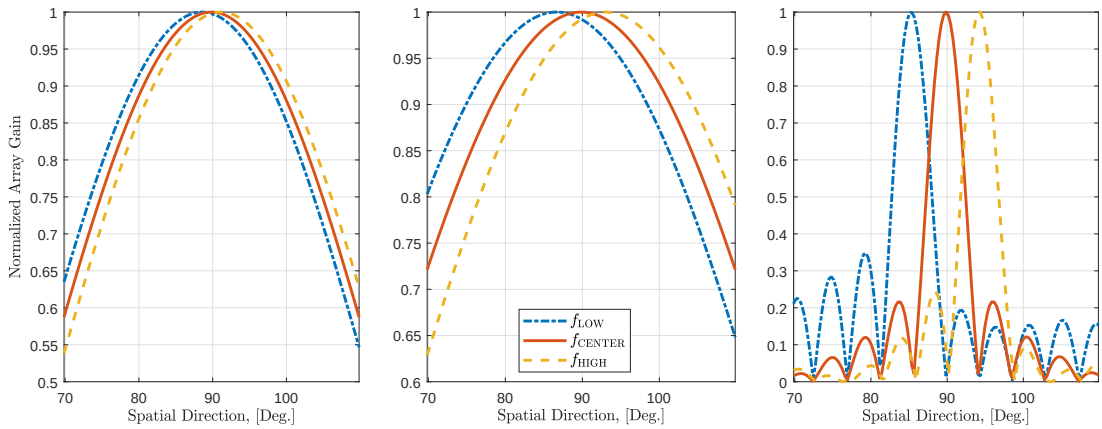

图 2. 在（左）3.5 GHz、$B = 0.1$ GHz；（中）28 GHz、 $B = 2$ GHz；以及（右）300 GHz、30 GHz 下，低、中、高端子载波相对于空间方向的归一化阵列增益。

距离，直至夫琅禾费距离。随后，我们提出了用于宽带太赫兹信道估计的 NBA-OMP 方法。

所提方法的核心思想是：波束分裂程度与未知的用户位置有关，但在进行到达方向（DoA）/距离估计之前即可按比例确定。例如，设 f_m 和 f_c 分别为第 m个子载波和中心子载波的频率。当 θ 为用户物理方向时，第 m个子载波对应的空间方向会偏移 $\frac{f_c}{f_m}\theta$。因此，我们采用 OMP 算法来考虑这一偏差，从而自然地补偿窄带的影响。我们进行了多项数值实验，以证明所提方法相较于现有基于太赫兹信道估计的方法 [15, 24]的有效性。

C. 结构与符号约定

1）结构：在本文余下部分中，我们首先在第 II 节介绍多用户宽带太赫兹超大规模多输入多输出系统的信号模型。随后，我们分别在第 IV 节和第 V 节介绍所提出的用于基于模型和无模型信道估计的 NBA OMP 技术。第 VI 节讨论所提方法的复杂度与开销分析。第 VII 节展示数值仿真结果，并在第 VIII 节通过总结性评论结束本文。

2）符号说明：全文中，我们分别用粗体小写字母和大写字母表示向量和矩阵。转置运算和共轭转置运算分别表示为

$(\cdot)^{\mathsf{T}}$ 和 $(\cdot)^{\mathsf{H}}$。矩阵 $\mathbf{A}$ 的第 n列表示为 $\mathbf{A}_n$ ，而 $\mathbf{A}^{\dagger}$ 表示 Moore-Penrose伪逆。对于向量 $\mathbf{a}$，$\mathbf{a}$ 的第 n个元素表示为 $[\mathbf{a}]_n$。 $\lceil\cdot\rceil$表示向上取整算子， ∇ 表示梯度运算。 $\Sigma(a) = \sin_b \frac{\pi a b}{\pi a \sin}$表示 Dirichlet sinc函数， $\mathbb{E}\{\cdot\}$ 表示期望运算。 $||\cdot||_2$ 和 $||\cdot||_{\mathcal{F}}$ 分别表示 l_2 范数和 Frobenius范数。

II. 系统模型

考虑一种采用混合模拟/数字波束成形的宽带太赫兹MIMO架构，包含M 个子载波。假设基站（BS）配备 N 根天线和 N_{RF} 条射频（RF）链路，为 K 个单天线用户提供服务。令$\mathbf{s}[m] = [s_1[m], \cdots, s_K[m]]^{\mathsf{T}}$ 表示数据符号，其中 $m \in \mathcal{M} = \{1, \cdots, M\}$，它们经由 $K \times K$ SD基带波束成形器$\mathbf{F}_{\mathrm{BB}}[m] = [\mathbf{f}_{\mathrm{BB}_1}[m], \cdots, \mathbf{f}_{\mathrm{BB}_K}[m]]$处理。为了在下行链路中将生成波束指向用户，采用 $N \times N_{\mathrm{RF}}$ SI模拟波束成形器$\mathbf{F}_{\mathrm{RF}}$($N_{\mathrm{RF}} = K < N$)。由于模拟波束成形器由移相器实现，因此它们满足恒模约束，即 $|[\mathbf{F}_{\mathrm{RF}}]_{i,j}| = \frac{1}{\sqrt{N}}$。 于是， $N \times 1$ 发射信号变为

$$\tilde{\mathbf{x}}[m] = \mathbf{F}_{\mathrm{RF}}\mathbf{F}_{\mathrm{BB}}[m]\mathbf{s}[m]. \tag{1}$$

发射信号经过无线信道后，在第 m个子载波处由第 k个用户接收，表示为

$$\begin{aligned} y_k[m] &= \mathbf{h}_k^{\mathsf{T}}[m]\tilde{\mathbf{x}}[m] + w_k[m] \\ &= \mathbf{h}_k^{\mathsf{T}}[m] \sum_{i=1}^{K} \mathbf{F}_{\mathrm{RF}}\mathbf{f}_{\mathrm{BB}_i}[m]s_i[m] + w_k[m], \end{aligned} \tag{2}$$

其中， $w_k[m] \in \mathbb{C}$ 表示方差为 σ_n^2的复加性高斯白噪声，即 $w_k[m] \sim \mathcal{CN}(0, \sigma_n^2)$。

A. 太赫兹信道模型

由于反射路径分量有限且散射可以忽略，太赫兹信道通常构建为单条视距路径与少量辅助非视距路径的叠加 [4, 9, 29]。此外，多径信道模型也得到了广泛应用，尤其是在室内应用中 [4,

31]。因此，我们考虑一种一般场景，其中，第 k 个用户在第 m 个子载波上的 $N \times 1$ 信道矩阵表示为 L 条路径的组合，如下所示 [4]

$$\mathbf{h}_k[m] = \sqrt{\frac{N}{L}} \sum_{l=1}^{L} \alpha_{k,m,l} \mathbf{a}(\phi_{k,l}, r_{k,l}) e^{-j2\pi\tau_{k,l} f_m}, \tag{3}$$

其中，$\tau_{k,\,l}$ 表示与阵列原点对应的第 l条路径的时延。$\alpha_{k,\,m,\,l} \in \mathbb{C}$表示复路径增益，其在室内太赫兹多径模型中的幅度期望值为

$$\mathbb{E}\{|\alpha_{k,m,l}|^2\} = \left(\frac{c_0}{4\pi f_m r_{k,l}}\right)^2 e^{-k_{\text{abs}}(f_m) r_{k,l}}, \tag{4}$$

其中，f_m 为第 m个子载波频率，c_0 为光速，$r_{k,\,l}$ 表示第 k个用户到阵列原点的距离，$k_{\text{abs}}(f_m)$为SD介质吸收系数 [4, 32,33]。此外，$f_m = f_c + \frac{B}{M}(m - 1 - \frac{M-1}{2})$，其中 f_c 和 B 分别为载波频率和带宽。

B. 近场阵列模型

由于工作频率较高且阵列孔径极小，太赫兹频段传输在面向近距离用户时很可能会遇到近场现象。具体而言，远场模型假设用户接收到的发射信号为平面波。然而，当传输距离小于夫琅禾费距离 $F = \frac{2D^2}{\lambda}$ 时，近场中的平面波前呈球面形状，其中 D 为阵列孔径，$\lambda = \frac{c_0}{f_c}$ 为波长 [19, 23]。图3展示了远场模型和近场模型中的波束分裂示意图。对于均匀线性阵列（ULA），阵列孔径为 $D = (N-1)d$，其中$d = \frac{\lambda}{2}$ 为阵元间距。因此，对于太赫兹频段传输，该距离会变得很小，因此应采用近场信号模型，因为$r_{k,\,l} < F$。例如，当 $f_c = 300$ GHz且 $N = 256$时，夫琅禾费距离为 $F = 32.76$ 米。

我们将对应于物理到达角$\phi_{k,\,l}$ 和距离$r_{k,\,l}$ 的近场导向矢量 $\mathbf{a}(\phi_{k,\,l},\ r_{k,\,l}) \in \mathbb{C}^N$ 定义为

$$\mathbf{a}(\phi_{k,l}, r_{k,l}) = \frac{1}{\sqrt{N}} [e^{-\mathrm{j}2\pi \frac{d}{\lambda} r_{k,l}^{(1)}}, \cdots, e^{-\mathrm{j}2\pi \frac{d}{\lambda_m} r_{k,l}^{(N)}}]^{\mathsf{T}}, \tag{5}$$

其中 $\phi_{k,l} = \sin\tilde{\phi}_{k,l}$其中 $\tilde{\phi}_{k,l} \in [-\frac{\pi}{2}, \frac{\pi}{2}]$，以及 $r_{k\,l}^{(n)}$,表示第 k 个用户与

第 n 个天线之间的距离为

$$r_{k,l}^{(n)} = \left(r_{k,l}^2 + 2(n-1)^2 d^2 - 2r_{k,l}(n-1)d\phi_{k,l}\right)^{\frac{1}{2}}. \tag{6}$$

根据菲涅耳近似， [23, 34],(6) 可写为

$$r_{k,l}^{(n)} \approx r_{k,l} - (n-1)d\phi_{k,l} + (n-1)^2 d^2 \zeta_{k,l}, \tag{7}$$

其中 $\zeta_{k,\,l} = \frac{1-\phi_k^2}{2r_{k\,l}}$。将 (5) 重写为

$$\mathbf{a}(\phi_{k,l}, r_{k,l}) \approx e^{-\mathrm{j}2\pi \frac{f_c}{c_0} r_{k,l}} \tilde{\mathbf{a}}(\phi_{k,l}, r_{k,l}), \tag{8}$$

其中， $\tilde{\mathbf{a}}(\phi_{k,\,l},\ r_{k,\,l}) \in \mathbb{C}^N$ 的第 n 个元素为

$$[\tilde{\mathbf{a}}(\phi_{k,l}, r_{k,l})]_n = e^{\mathrm{j}2\pi \frac{f_c}{c_0}\left((n-1)d\phi_{k,l} - (n-1)^2 d^2 \zeta_{k,l}\right)}. \tag{9}$$

(8) 中的导向矢量对应于物理位置 $(\phi_{k,\,l},\ r_{k,\,l})$，由于缺少 SD模拟波束成形器，它偏移至波束空间中的空间位置 $(\phi_{k,\,m,\,l},\ \bar{r}_{k,\,m,\,l})$。对于该空间位置，(9) 中偏移后的导向矢量的第 n 个元素为

$$[\tilde{\mathbf{a}}(\bar{\phi}_{k,m,l}, \bar{r}_{k,m,l})]_n = e^{\mathrm{j}2\pi \frac{f_m}{c_0}\left((n-1)d\bar{\phi}_{k,m,l} - (n-1)^2 d^2 \bar{\zeta}_{k,m,l}\right)}. \tag{10}$$

C. 问题表述

本工作的目标是在下行场景中存在窄带干扰的情况下估计宽带太赫兹信道$\mathbf{h}_k[m]$ 。

假设 *1*： 对于所提出的基于模型的技术，我们假设用户已同步，并使用基站发送的接收导频信号。我们还假设所有用户都位于基站的近场区域内，即 $r_{k,\,l} \leq F$。

假设 *2*： 对于所提出的无模型技术，假设在模型训练阶段之前已收集所有用户的数据集，并且这些数据集的标签由第 IV 节介绍的基于模型的技术确定。

接下来，我们首先介绍窄带模型，然后介绍在存在窄带的情况下，所提出的基于模型和无模型信道估计方法。

III. 窄带模型

与毫米波频率相比，在太赫兹频段，带宽非常宽，因此波束成形无法采用单波长假设，进而导致空间域中的物理到达方向/距离$\{\phi_{k,l}, r_{k,l}\}$ 分裂。因此，我们通过以下定理定义物理到达方向/距离与空间到达方向/距离之间的关系：

定理1。令$\mathbf{u} \in \mathbb{C}^N$ 和$\mathbf{v}_m \in \mathbb{C}^N$ 分别表示任意近场导向向量[¯]，它们对应于式（*9*）和式（*10*）中给出的物理位置（即 $\{\phi_{k,l}, r_{k,l}\}$）和空间位置（即 $\{\phi_{k,m,l}, \bar{r}_{k,m,l}\}$）。那么，在子载波频率 f_m 下的空间域中，$\mathbf{u}^H\mathbf{v}_m$ 所达到的阵列增益最大，且生成波束聚焦于位置 $\{\bar{\phi}_{k,m,l}, \bar{r}_{k,m,l}\}$，使得

$$\bar{\phi}_{k,m,l} = \eta_m \phi_{k,l}, \ \bar{r}_{k,m,l} = \frac{1-\eta_m^2\phi_{k,l}^2}{\eta_m(1-\phi_{k,l}^2)} r_{k,l}, \tag{11}$$

其中 $\eta_m = \frac{f_c}{f_m}$ 表示到达方向/距离的成比例偏差。

证明。 定义$\mathbf{v}_m$ 在任意用户位置 $\{\phi_{k,l}, r_{k,l}\}$ 处、使用导向矢量$\mathbf{u}$所实现的阵列增益为

$$\begin{aligned}
&G(\phi_{k,l}, r_{k,l}, m) = \frac{|\mathbf{u}^{\mathsf{H}}\mathbf{v}_m|^2}{N^2} \\
&= \frac{1}{N^2}\left|\sum_{n=0}^{N-1} e^{\mathrm{j}\frac{2\pi}{c_0}\left[nd\left(f_m\bar{\phi}_{k,m,l} - f_c\phi_{k,l}\right) - n^2d^2(f_m\bar{\zeta}_{k,m,l} - f_c\zeta_{k,l})\right]}\right|^2 \\
&= \frac{1}{N^2}\left|\sum_{n=0}^{N-1} e^{\mathrm{j}\frac{2\pi n}{c_0}(f_m\kappa_m - f_c\kappa)}\right|^2 \\
&= \frac{1}{N^2}\left|\frac{1-e^{-\mathrm{j}2\pi N(f_m\kappa_m - f_c\kappa)}}{1-e^{-\mathrm{j}2\pi(f_m\kappa_m - f_c\kappa)}}\right|^2 \\
&= \frac{1}{N^2}\left|\frac{\sin(\pi N(f_m\kappa_m - f_c\kappa))}{\sin(\pi(f_m\kappa_m - f_c\kappa))}\right|^2 \\
&= |\Sigma(f_m\kappa_m - f_c\kappa)|^2.
\end{aligned} \tag{12}$$

此外，我们定义

$$\bar{\zeta}_{k,m,l} = \eta_m \zeta_{k,l} = \frac{1-\bar{\phi}^2_{k,m,l}}{2\bar{r}_{k,m,l}}, \tag{13}$$

$$\kappa_m = d(\bar{\phi}_{k,m,l} - nd\bar{\zeta}_{k,m,l}), \tag{14}$$

$$\kappa = d(\phi_{k,l} - nd\zeta_{k,l}) \tag{15}$$

式（12）中的阵列增益表明，由于 Σ(a)的功率聚焦能力，大部分功率仅集中在波束空间的一小部分上；随着 $|f_m - f_c|$ 增大，这种聚焦能力在各个子载波上显著减弱。此外，当 $a = 0$时， $|\Sigma(a)|^2$ 达到峰值，即_ _$f_m\phi_{k,\ m,\ l} = f_c\phi_{k,\ l}$ 以及$f_m\zeta_{k,\ m,\ l} = f_c\zeta_{k,\ l}$。因此，我们有

$$\bar{\phi}_{k,m,l} = \eta_m \phi_{k,l}. \tag{16}$$

¯然后，利用$\zeta_{k,\ m,\ l} = \eta_m\zeta_{k,\ l}$，可得

$$\bar{r}_{k,m,l} = \frac{1-\eta_m^2\phi_{k,l}^2}{\eta_m(1-\phi_{k,l}^2)} r_{k,l}. \tag{17}$$

■

最后，结合（7）、（11）和（17），我们将窄带表示为用户的到达角和距离的函数:

$$\Delta(\phi_{k,l}, m) = \bar{\phi}_{k,m,l} - \phi_{k,l} = (\eta_m - 1)\phi_{k,l}, \tag{18}$$

$$\Delta(r_{k,l}, m) = \bar{r}_{k,m,l} - r_{k,l} = \left(\frac{1-\eta_m^2\phi_{k,l}^2}{\eta_m(1-\phi_{k,l}^2)} - 1\right) r_{k,l}. \tag{19}$$

IV. 基于模型的求解：NBA-OMP

我们首先介绍NBA字典的设计方法，然后给出所提出的NBA-OMP技术的实现步骤。

*A. NBA*字典设计

所提出的NBA字典设计的核心思想是利用 η_m 的先验知识，获得波束分裂校正导向矢量。换言之，对于任意物理到达角和距离，我们都可以轻松找到空间到达角和距离，分别为 $\bar{\phi} = \eta_m\phi$ 和 $\bar{r} = \frac{1-\eta_m^2\phi^2}{\eta_m\ 1-\phi^2}\ ()r$。利用这一

观察结果，我们设计了由导向矢量$\mathbf{c}(\phi_m, r_m) \in \mathbb{C}^N$组成的NBA字典，如下所示:

$$\mathcal{C}_m = \{\mathbf{c}(\phi_m, r_m) | \phi_m \in [-\eta_m, -\eta_m], r_m \in \mathbb{R}^+\}, \tag{20}$$

其中，$\mathbf{c}(\phi_m, r_m)$ 的第 n 个元素为

$$[\mathbf{c}(\phi_m, r_m)]_n = e^{\mathrm{j}2\pi \frac{f_m}{c_0}\left((n-1)d\phi_m - (n-1)^2 d^2 \zeta_m\right)}, \tag{21}$$

其中 $\zeta_m = \frac{1-\phi_m^2}{2r_m}$。

使用 NBA字典 $\mathcal{C}_m$，而非 SI 导向向量 $\mathbf{a}(\phi, r)$，可以为 OMP 算法构造 SD虚拟导向向量 $\mathbf{c}(\phi_m, r_m)$。通过 OMP 计算波束空间谱后，即可得到与 SD空间到达方向及距离相对应的稀疏信道支撑集。随后，可以直接求得物理到达角和距离： $\phi = \phi_m/\eta_m$ 和$r = \frac{\eta_m(1-\phi^2)}{1-\eta_m^2\phi^2} r_m$, $\forall m \in \mathcal{M}$。

所提出的 NBA字典 $\mathcal{C}_m$ 也满足空间正交性:

$$\lim_{N\to+\infty} |\mathbf{c}^{\mathsf{H}}(\phi_{m,i}, r_{m,i})\mathbf{c}(\phi_{m,j}, r_{m,j})| = 0, \forall i \neq j. \tag{22}$$

下一节将介绍使用所提出的 NBA字典进行信道估计的过程。

B. 近场信道估计

在下行链路中，所有用户在进行信道训练的同时执行信道估计阶段，即 $k \in \mathcal{K} = \{1, \cdots, K\}$。由于基站采用混合波束成形架构，因此在每次信道使用中仅启用一条射频链来发送导频信号$\tilde{}$，以进行信道获取 [5]。记 $\mathbf{S}[m] = \mathbf{diag}\{\tilde{s}_1[m], \cdots, \tilde{s}_P[m]\}$ 为 $P \times P$正交导频信号矩阵，则基站采用 P波束成形向量作为 $\tilde{}\mathbf{F} = [\tilde{}\mathbf{f}_1, \cdots, \tilde{}\mathbf{f}_P] \in \mathbb{C}^{N\times P}$($|\tilde{}\mathbf{f}_p| = 1/\sqrt{N}$)来发送 P 正交导频，这些导频由第 k个用户接收为

$$\mathbf{y}_k[m] = \tilde{\mathbf{S}}[m]\bar{\mathbf{F}}[m]\mathbf{h}_k[m] + \mathbf{w}_k[m], \tag{23}$$

其中 $\bar{\mathbf{F}}[m] = \tilde{\mathbf{F}}^{\mathsf{T}}[m] \in \mathbb{C}^{P\times N}$。假设 $\bar{\mathbf{F}}[m] = \mathbf{F} \in \mathbb{C}^{P\times N}$和 $\tilde{\mathbf{S}}[m] = \mathbf{I}_P, \forall m \in \mathcal{M}$ [10, 14, 15],，可得

$$\mathbf{y}_k[m] = \mathbf{F}\mathbf{h}_k[m] + \mathbf{w}_k[m]. \tag{24}$$

请注意，通过传统技术（例如最小二乘法（LS）和MMSE估计器）可以分别直接得到如下解：

$$\mathbf{h}_k^{\mathrm{LS}}[m] = (\mathbf{F}^{\mathsf{H}}\mathbf{F})^{-1}\mathbf{F}^{\mathsf{H}}\mathbf{y}_k[m], \tag{25}$$

$$\mathbf{h}_k^{\mathrm{MMSE}}[m] = \left(\mathbf{R}_k^{-1}[m] + \mathbf{F}^{\mathsf{H}}\mathbf{R}_k^{-1}[m]\mathbf{F}\right)^{-1}\mathbf{F}^{\mathsf{H}}\mathbf{y}_k[m], \tag{26}$$

其中$\mathbf{R}_k[m] = \mathbb{E}\{\mathbf{h}_k[m]\mathbf{h}_k^{\mathsf{H}}[m]\}$ 为信道协方差矩阵。尽管如此，这些方法要么需要先验信息（例如MMSE），要么估计性能较差（例如LS） [13,35]。此外，这些方法至少需要 $P \geq N$ 个导频信号，这会带来较大的信道训练开销，而我们提出的方法所需的信道训练开销则低得多（例如，参见第VI节）。

通过利用太赫兹信道稀疏性，可以用支撑向量$\mathbf{x}_k[m] \in \mathbb{C}^Q$在稀疏域中表示太赫兹信道。该向量是一个 L稀疏向量，其非零元素对应于集合

$$\{x_{k,l}[m] | x_{k,l}[m] \triangleq \sqrt{\frac{N}{L}}\alpha_{k,m,l}e^{-j2\pi\tau_{k,l}f_m}\}. \tag{27}$$

于是，式（24）中的接收信号可在稀疏域中改写为

$$\mathbf{y}_k[m] = \mathbf{F}\mathbf{C}_m\mathbf{x}_k[m] + \mathbf{w}_k[m], \tag{28}$$

其中$\mathbf{F}$ 是一个 $P \times N$ 固定矩阵，对应于数据传输期间混合波束赋形器的权重；$\mathbf{C}_m$ 是 $N \times Q$ NBA字典矩阵，覆盖空间域，其中$\phi_{m,q} \in [-\eta_m, \eta_m]$ ($\phi \in [-1, 1]$)和$r_{m,q} \in [0, F]$ 对于 $q = 1, \cdots, Q$ 如下：

$$\mathbf{C}_m = [\mathbf{c}(\phi_{m,1}, r_{m,1}), \cdots, \mathbf{c}(\phi_{m,Q}, r_{m,Q})]. \tag{29}$$

通过利用 NBA字典矩阵 $\mathbf{C}_m$，我们采用 OMP算法来有效恢复稀疏信道支撑集。所提出的 NBA-OMP技术见算法1，该算法以$\mathbf{y}_k[m]$、$\mathbf{C}_m$ 和 η_m 为输入，并输出估计的

算法 1 NBA-OMP

Input: Dictionary $\mathbf{C}_m$, observation $\mathbf{y}_k[m]$ and η_m
Output: $\hat{\mathbf{h}}_k[m]$, $\hat{\Delta}(\phi_{k,l}, m)$ and $\hat{\Delta}(r_{k,l}, m)$.

for $k \in \mathcal{K}$
  $l = 1$, $\mathcal{I}_{l-1} = \emptyset$, $\mathbf{r}_{l-1}[m] = \mathbf{y}_k[m], \forall m \in \mathcal{M}$.
  while $l \leq L$ **do**
    $q^\star = \text{argmax}_q \sum_{m=1}^{M} |\mathbf{c}^{\mathsf{H}}(\phi_{m,q}, r_{m,q})\mathbf{F}^{\mathsf{H}}\mathbf{r}_{l-1}[m]|$.
    $\mathcal{I}_l = \mathcal{I}_{l-1} \bigcup \{q^\star\}$.
    $\hat{\phi}_{k,l} = \frac{\phi_{m,q^\star}}{\eta_m}$.
    $\hat{r}_{k,l} = \frac{\eta_m(1-\phi^2_{m,q^\star})}{1-\eta_m^2\phi_{m,q^\star}} r_{m,q^\star}$.
    $\hat{\Delta}(\phi_{k,l}, m) = (\eta_m - 1)\hat{\phi}_{k,l}$, $\forall m \in \mathcal{M}$.
    $\hat{\Delta}(r_{k,l}, m) = (\eta_m - 1)\frac{1-\eta_m^2\hat{\phi}^2_{k,l}}{\eta_m(1-\hat{\phi}^2_{k,l})}\hat{r}_{k,l}$, $\forall m \in \mathcal{M}$.
    $\mathbf{\Psi}_m(\mathcal{I}_l) = \mathbf{F}\mathbf{C}_m(\mathcal{I}_1)$.
    $\mathbf{r}_l[m] = \left(\mathbf{I}_P - \mathbf{\Psi}_m(\mathcal{I}_l)\mathbf{\Psi}^\dagger_m(\mathcal{I}_l)\right)\mathbf{y}_k[m]$.
    $l = l + 1$.
  end while
  $\mathbf{\Xi}_k = [\mathbf{a}(\hat{\phi}_{k,1}, \hat{r}_{k,1}), \cdots, \mathbf{a}(\hat{\phi}_{k,L}, \hat{r}_{k,L})]$.
  for $m \in \mathcal{M}$
    $\hat{\mathbf{u}}_k[m] = \mathbf{\Psi}^\dagger_m(\mathcal{I}_{l-1})\mathbf{y}_k[m]$.
    $\hat{\mathbf{h}}_k[m] = \mathbf{\Xi}_k\hat{\mathbf{u}}_k[m]$.
  end for
end for

信道$\mathbf{h}_k[m]$，以及以到达方向和距离表示的近场波束分裂，即 $\Delta(\phi_{k,l}, m)$和$\hat{}\Delta(r_{k,l}, m)$。在算法1的步骤 $4-6$ 中，检查残差观测向量$\mathbf{r}_l[m]$ 与字典矩阵各列之间的正交性，方法如下：

$$q^\star = \underset{q}{\text{argmax}} \sum_{m=1}^{M} |\mathbf{c}^{\mathsf{H}}(\phi_{m,q}, r_{m,q})\mathbf{F}^{\mathsf{H}}\mathbf{r}_{l-1}[m]|, \tag{30}$$

其中，$q^\star$ 表示第 l次路径迭代的支撑索引。随后，可分别得到到达方向和距离估计值$\hat{}\phi_{k,l} = \frac{\phi_m}{\eta_m}_{,q^\star}$and $\hat{}r_{k,l} = \frac{\eta_m}{(1-\phi^2_{m,q^\star})\,1-\eta_m^2\phi_{m,q^\star}} r_{m,q^\star}$。类似地，对应的波束分裂项为$\hat{}\Delta(\phi_{k,l}, m) = (\eta_m - 1)\,\hat{}\phi_{k,l}$and $\hat{}\Delta(r_{k,l}, m) = (\eta_m - 1)\frac{1-\eta_m^2}{\hat{}\phi^2_{k,\eta_m}\,1-\phi^2_{k\,l}}(\hat{}\,,)\,\hat{}r_{k,l}$。获得到达方向和距离后，即可根据估计支撑构建太赫兹信道：$\hat{}\mathbf{h}_k[m] = \mathbf{\Xi}_k\hat{}\mathbf{u}_k[m]$，其中 $\mathbf{\Xi}_k = [\mathbf{a}(\hat{}\phi_{k,1}, \hat{}r_{k,1}) \cdots$、$\mathbf{a}(\hat{}\phi_{k,L}, \hat{}r_{k,L})]$ 以及$\hat{}\mathbf{u}_k[m] = \mathbf{\Psi}^\dagger_m(\mathcal{I}_L)\mathbf{y}_k[m]$，其中 $\mathbf{\Psi}_m(\mathcal{I}_L) = \mathbf{F}\mathbf{C}_m(\mathcal{I}_L)$，而 $\mathcal{I}_L$ 包含估计支撑索引。

V. 无模型解决方案：NBA-OMP-FL

由于工作波长较短且路径损耗严重，预计太赫兹通信将采用超大规模阵列。这会导致需要处理的阵列数据量极大。例如，采用基于学习的技术时，数据集的大小与天线数量成正比。因此，基于协作学习的技术 [16, 36, 37]会因传输这些数据集而产生巨大的通信开销。为降低这一开销，本节提出一种基于联邦学习的近场太赫兹信道估计方案。

分别将 $\boldsymbol{\theta} \in \mathbb{R}^Z$ 和 $\mathcal{D}_k$ 记为第k个用户的可学习参数向量和本地数据集。于是，学习模型的输入（表示为 $\boldsymbol{\theta}$）与其预测值 $\mathcal{Y}_k^{(i)} = f(\boldsymbol{\theta})\mathcal{X}_{(i)\,k}$之间存在关系 $f(\boldsymbol{\theta})$。本地数据集的样本索引为 $i = 1, \ldots, \mathrm{D}_k$，其中 $\mathrm{D}_k = |\mathcal{D}_k|$ 表示第 k个本地数据集中的样本数。此外，令 $\mathcal{X}_k^{(i)}$ 和 $\mathcal{Y}_k^{(i)}$ 分别表示输入和输出，则本地数据集的输入-输出元组为 $\mathcal{D}_k^{(i)} = (\mathcal{X}_k^{(i)}, \mathcal{Y}_k^{(i)})$。

输入数据为接收导频，即$\mathbf{y}_k[m]$。对于输出（标签）数据，我们考虑通过算法1中的NBA-OMP方法获得的信道估计值。然后，使用 $\hat{}\mathbf{h}_k[m]$，构造输出数据如下

$$\mathcal{Y}_k = \left[\mathrm{Re}\{\hat{\mathbf{h}}_k[m]\}^{\mathsf{T}}, \mathrm{Im}\{\hat{\mathbf{h}}_k[m]\}^{\mathsf{T}}\right]^{\mathsf{T}} \in \mathbb{R}^{2N}. \tag{31}$$

在设计输入数据时，融入$\mathbf{y}_k[m]$ 的实部、虚部和角度信息，以提高学习模型的特征提取性能。因此，每个输入样本均具有大小为 $N_{\mathrm{RF}} \times 3$ [36]的“三通道”结构。于是，我们有 $[\mathcal{X}_k]_1 = \mathrm{Re}\{\mathbf{y}_k[m]\}$、$[\mathcal{X}_k]_2 = \mathrm{Im}\{\mathbf{y}_k[m]\}$ 和 $[\mathcal{X}_k]_3 = \angle\{\mathbf{y}_k[m]\}$。

为使所有用户以分布式方式参与训练，每个用户计算其模型参数，并旨在最小化平均均方误差代价。因此，基于联邦学习的模型训练问题可表示为

$$\begin{aligned} &\underset{\boldsymbol{\theta}}{\text{minimize}} \ \frac{1}{K}\sum_{k=1}^{K} \mathcal{L}_k(\boldsymbol{\theta}) \\ &\text{subject to: } f(\mathcal{X}_k^{(i)}|\boldsymbol{\theta}) = \mathcal{Y}_k^{(i)}, \end{aligned} \tag{32}$$

其中，$\mathcal{L}_k(\boldsymbol{\theta})$ 是在第 k 个用户处计算的学习模型的损失函数，并且

定义为

$$\mathcal{L}_k(\boldsymbol{\theta}) = \frac{1}{\mathsf{D}_k} \sum_{i=1}^{\mathsf{D}_k} ||f(\mathcal{X}_k^{(i)}|\boldsymbol{\theta}) - \mathcal{Y}_k^{(i)}||_{\mathcal{F}}^2, \tag{33}$$

其中，$f(\mathcal{X}_{(i)\,k}\ |\boldsymbol{\theta})$ 表示学习模型输入 $\mathcal{X}_{(i)\,k}$ 后的输出。为高效求解式（32）中提出的优化问题，可以采用迭代技术，根据本地数据集在每次迭代中计算学习模型参数。具体而言，首先在用户端计算学习模型参数，然后将其传输至服务器进行聚合。因此，第 t 次迭代的模型参数更新规则描述如下：

$$\boldsymbol{\theta}_{t+1} = \boldsymbol{\theta}_t - \varepsilon \frac{1}{K} \sum_{k=1}^{K} \boldsymbol{\beta}_k(\boldsymbol{\theta}_t), \tag{34}$$

对于 $t = 1, \ldots, T$。这里，$\boldsymbol{\beta}_k(\boldsymbol{\theta}_t) = \nabla \mathcal{L}_k(\boldsymbol{\theta}_t) \in \mathbb{R}^Z$ 是梯度向量，ε 是学习率。

在模型训练期间，每个用户只需将其模型更新向量 $\boldsymbol{\beta}_k(\boldsymbol{\theta}_t)$ 传输至基站，以进行 $k \in \mathcal{K}$。假设模型 $\boldsymbol{\beta}_k(\boldsymbol{\theta}_t)$ 在每个子载波上被划分为 $U = \frac{Z}{M}$ 个等长块，表示为

$$\boldsymbol{\beta}_k(\boldsymbol{\theta}_t) = [\boldsymbol{x}_K^{(t)^{\mathsf{T}}}[1], \ldots, \boldsymbol{x}_K^{(t)^{\mathsf{T}}}[M]]^{\mathsf{T}}, \tag{35}$$

其中，$\boldsymbol{x}_k^{(t)}[m] \in \mathbb{C}^U$ 表示第 k 个用户的数据符号（模型更新），这些符号将传输至服务器进行聚合。随后，基站接收如下的 $N \times U$ 上行链路信号：

$$\boldsymbol{Y}^{(t)}[m] = \sum_{k=1}^{K} \boldsymbol{h}_k^{(t)}[m] \boldsymbol{x}_k^{(t)^{\mathsf{T}}}[m] + \boldsymbol{N}[m], \tag{36}$$

其中，$\boldsymbol{h}_k^{(t)}[m] \in \mathbb{C}^N$ 表示模型传输期间的上行链路信道，$\boldsymbol{N}[m] \in \mathbb{C}^{N \times U}$表示添加到传输数据中的噪声项。

VI. 复杂度与开销

A. 计算复杂度

NBA-OMP 的计算复杂度与传统 OMP技术相同 [5],，这主要是由第 4 步中的矩阵乘法（$O(QMNP(NP + P))$）和第 10 步

表 I 学习模型参数

层	Type	参数
1	输入	大小： $N_{\mathrm{RF}} \times 3$
2	卷积	大小： 3×3 @128
3	归一化	-
4	卷积	大小： 3×3 @128
5	归一化	-
6	卷积	尺寸： 3×3 @128
7	归一化	-
8	全连接层	尺寸： 1024×1
9	丢弃法	比率：0.5
10	全连接层	大小： 1024×1
11	丢弃法	比率：0.5
12	输出（回归）	大小： $2N \times 1$

（$O(PNL\bar{L})$）、第 11 步（$O(P^2L\bar{L} + P^2)$）以及第 16 步（$O(L(P+N))$）导致的，其中 $\bar{L} = (L+1)/2$。因此，总体复杂度为 $O(QMNP(NP+P) + (PLL+1)(N+P))$。

B. 信道训练开销

NBA-OMP 的信道训练开销仅需使用 P 的信道进行导频信令（低至传统方法的 1/8，见第 VII 节），而传统方法（如 LS 和最小均方误差估计）至少需要使用 N 的信道。

C. 模型训练开销

基于学习的方法的通信开销可以根据模型训练期间/用于模型训练而传输的数据符号数量来衡量 [16, 35, 37–39]。因此，集中式学习的通信开销（即，$\mathcal{T}_{\mathrm{CL}}$）涉及从用户向服务器传输的数据集数量，而联邦学习的通信开销（即，$\mathcal{T}_{\mathrm{FL}}$）则可计算为训练期间用户与服务器之间交换的模型参数数量。于是，我们有

$$\mathcal{T}_{\mathrm{CL}} = \sum_{k=1}^{K} \mathsf{D}_k (3N_{\mathrm{RF}} + \xi 2N), \tag{37}$$

其中，D_k 表示第 k 个数据集的样本数量，$3N_{\mathrm{RF}} + 2N$ 表示每个输入-输出（即 $\mathcal{X}_k^{(i)} - \mathcal{Y}_k^{(i)}$）元组中的符号数量。在（37）中，$\xi$ 表示是否还需要将标签从用户传输至服务器。因此，如果标签是在用户处计算的，则

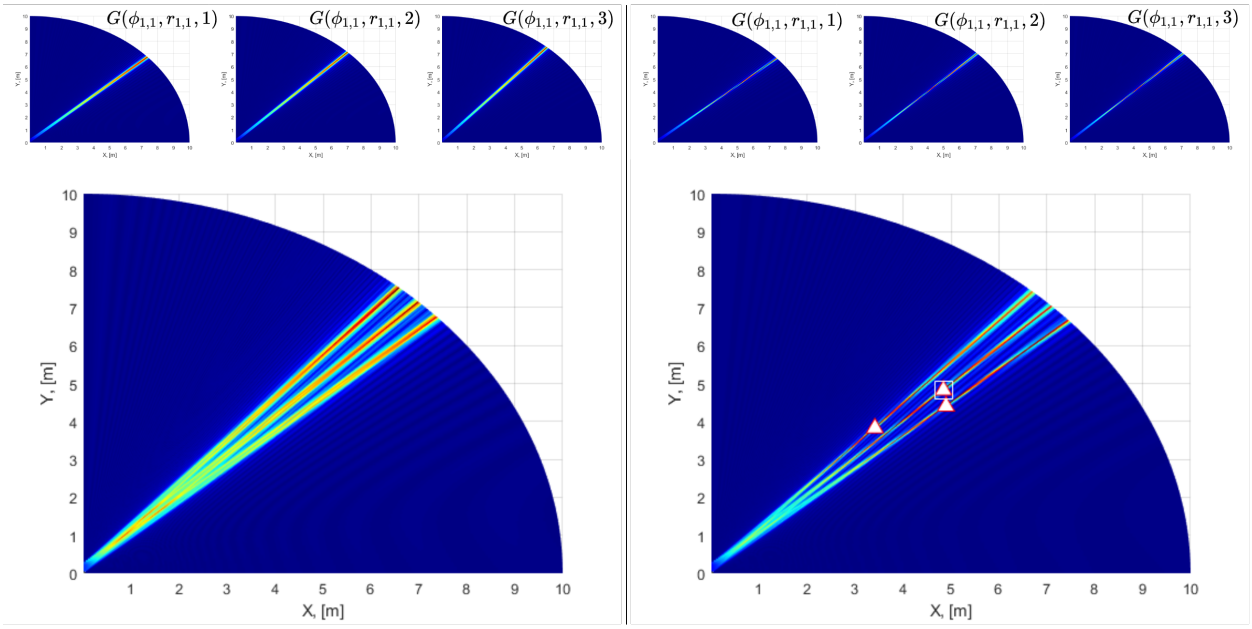

图3. 远场（45°，6000m）（左）和近场（45°，6m）（右）中单个用户（$K = 1$, $L = 1$）在笛卡尔坐标下的阵列增益 $G(\phi_{1,1}, r_{1,1}, m)$。其中，$M = 3$, $f_c = 300\,\text{GHz}$，且 $B = 30\,\text{GHz}$。顶部图中展示了不同子载波的增益，这些增益相加后得到底部的复合阵列增益，清楚地显示了远场和近场情况下的波束分裂。正方形表示用户位置，三角形表示不同子载波下的空间位置（即达到最大阵列增益的位置）。远场波束分裂仅发生在角度上，而近场分裂则同时涉及距离域和角度域。

需要将其传输至服务器，并产生额外的开销，此时有 $\xi = 1$。另一方面，如果将接收到的输入传输至服务器，由服务器负责标注（信道估计），则 $\xi = 0$ （标签不在用户处计算），从而可以实现更低的通信开销。接下来，我们将联邦学习的通信开销定义为

$$\mathcal{T}_{\text{FL}} = 2ZTK, \tag{38}$$

其中，用户与服务器之间进行双向传输：可学习参数从 K个用户传输至服务器，持续 T 次连续迭代。

VII. 数值仿真

我们将所提出的信道估计方法与当前最先进的信道估计技术进行比较，评估其性能，例如远场OMP（FF-OMP） [40], 近场OMP（NF-OMP） [24],波束分裂模式检测（BSPD） [15] 以及最小二乘法和最小均方误差。请注意，在仿真过程中，最小均方误差估计器按子载波分别计算，因此具有无波束分裂基准性能。

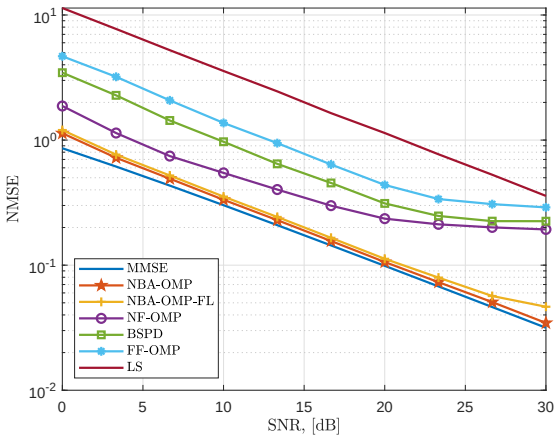

图4. 近场太赫兹宽带信道估计归一化均方误差与信噪比的关系。 $N = 256$、 $f_c = 300$ GHz、 $M = 128$ 和 $B = 30$ GHz。

在整个仿真过程中，除非另有说明，信号模型采用$f_c = 300$ GHz、 $B = 30$ GHz、 $M = 128$、 $K = N_{\mathrm{RF}} = 8$、 $L = 3$、 $P = 8$ 和 $N = 256$构建，其夫琅禾费距离为 $F = 32.76$ m。NBA字典矩阵采用$Q = 10N$构建，用户方向和距离分别选为$\phi_{k,\ l} \in$均匀分布$[-\frac{\pi}{2}, \frac{\pi}{2}]$、 $r_{k,\ l} \in$均匀分布$[5, 30]$m。

通过超参数优化 [37, 39]设计了一个卷积神经网络（CNN），其参数列于表I中。随后，使用该学习模型进行 $T = 100$ 次迭代训练，期间用户与服务器交换模型参数更新。学习率设为 $\varepsilon = 0.001$。在数据集生成过程中，我们首先生成了 $V = 1000$个独立的信道实现。然后，在生成的信道数据上添加加性高斯白噪声合成噪声，以模拟无线信道中的缺陷/失真特性。该合成噪声水平是在预先设定的噪声水平基础上，针对三个信噪比（SNR）级别获得的，即 $\mathrm{SNR}_{\mathrm{TRAIN}} = \{15, 20, 25\}$ dB；为提高鲁棒性，每种信道数据均获得 $G = 1000$ 个实现 [35]。在信道生成过程中，我们考虑了具有非独立同分布特性的本地数据集，其中，第 k个用户的数据集依据到达方向信息$\vartheta_{k,\ l} \in [-\frac{\pi}{2} + \frac{\pi}{K}(k-1)\ -\frac{\pi}{2} + \frac{\pi}{K}k)$进行选择。

图3分别展示了远场和近场场景下笛卡尔坐标中的阵列增益。当子载波总数为$M = 3$、 $f_c = 300$ GHz 和 $B = 30$ GHz（即 $f_{\mathrm{Low}} = 285$ GHz 和 $f_{\mathrm{High}} = 315$ GHz）时，发射机位于 (0，0) m，而用户位于 $45°$，距离分别为 6000 m（远场）和 8 m（近场）。在

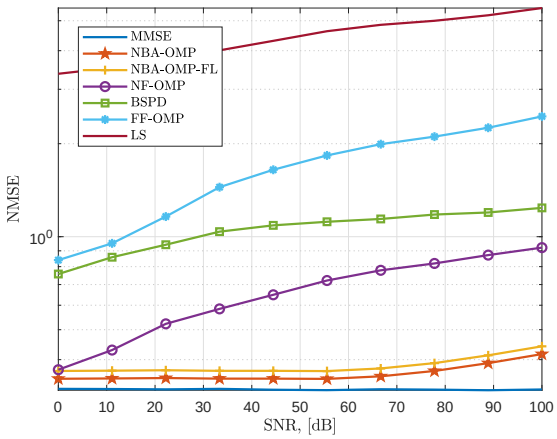

图 5. 信噪比为 $= 10$ dB时，近场太赫兹宽带信道估计归一化均方误差随带宽的变化。

远场模型中可以看到，在仿真中，阵列增益在最远距离处达到最大值，只有方向存在偏差。然而，对于近场情况，由于窄带，随着子载波频率变化，阵列增益会在不同位置（即不同方向和距离）达到峰值。这一观察清楚地表明，窄带会因物理域与空间域之间的位置/方向失配而导致显著的性能损失。因此，正如后续实验所讨论的，应补偿窄带的影响。

图4展示了不同信噪比下的信道估计归一化均方误差性能。可以看出，所提出的 NBA-OMP 和 NBA-OMP-FL 技术优于其他竞争方法，且性能接近最小均方误差性能。NBA-OMP 的优异性能归因于它利用由空间可分离导向矢量组成的 NBA 字典，准确补偿了波束分裂对方向参数和距离参数的影响。另一方面，其余方法在高信噪比区域均未能达到如此高的精度。这是因为这些方法要么未考虑窄带 [24] ，要么只考虑远场信号模型 [7, 15]。此外，所提出的方法无需额外硬件组件即可实现空间可分离字典矩阵导向矢量，因此具有硬件效率。与 NBA-OMP 相比，基于联邦学习的方法由于使用分布不均的数据集进行模型训练，性能略有下降。因此，NBA-OMP 的性能可作为联邦学习方法的衡量基准，因为基于学习的方法无法优于其标签 [36]。

图 5 比较了带宽为 $B \in [0, 100]$ GHz 时的归一化均方误差性能。我们

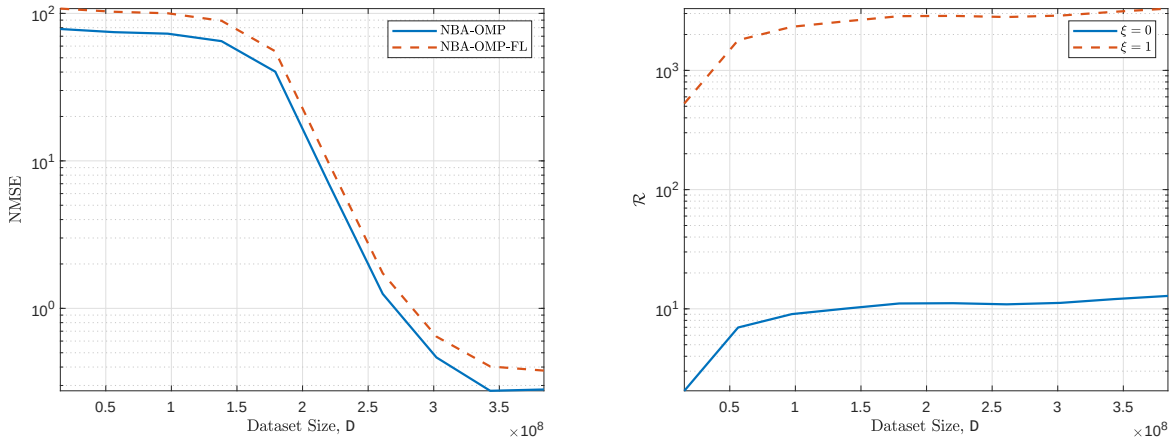

(a) (b)

图 6. SNR $= 10$ dB 时的信道估计归一化均方误差 (a) 和通信效率比 (b)。

可以看到，所提出的 NBA-OMP 方法能够有效补偿波束分裂的影响，适用带宽范围可达 $B < 70$ GHz。

最后，我们分析所提出的联邦学习方法的通信开销。为此，我们首先计算集中式学习的开销，为 $\mathcal{T}_{\mathrm{CL}} = 8 \cdot \mathrm{D}_k \cdot (3 \cdot 8) = 24.57 \times 10^9$，当 $\xi = 0$ 时（注意，当 $\xi = 1$ 时 $\mathcal{T}_{\mathrm{CL}} = 6.31 \times 10^{12}$），其中数据集中的输入-输出元组数量为 $\mathrm{D}_k = 3MVG = 3 \cdot 128 \cdot 1000 \cdot 1000 = 384 \times 10^6$。另一方面，联邦学习的通信开销为 $\mathcal{T}_{\mathrm{FL}} = 2 \cdot 1,196, 928 \cdot 100 \cdot 8 = 1.91 \times 10^9$；当 $\xi = 0$ ($\xi = 1$) 时，其开销约比集中式学习低 12（3300）倍。这一观察结果表明，联邦学习方法对信道估计任务十分有效，尤其是在天线数量非常多时。值得一提的是，如果由服务器负责标注，即 $\xi = 0$，采用联邦学习所带来的收益非常显著。基于此分析，图 6 展示了信道估计归一化均方误差和通信效率比（即 $\mathcal{R} = \frac{\mathcal{T}_{\mathrm{CL}}}{\mathcal{T}_{\mathrm{FL}}}$）随数据集大小 $\mathrm{D} = \sum_{k=1}^{K} \mathrm{D}_k$ 的变化情况，其中信噪比 $= 10$ dB。我们可以看到，使用较小的数据集训练学习模型，可以加快收敛速度，但代价是归一化均方误差性能较差。如果 $\mathrm{D} \approx 3 \times 10^8$，则可以获得令人满意的信道估计性能（即归一化均方误差 $\approx 10^{-1}$）。正如预期，较大的数据集会导致更长的训练时间；从仿真中我们观察到，在此类设置下，迭代次数约为 $T = 100$。在这种情况下，当 $\xi = 0$ 和 $\xi = 1$ 时，通信效率比 $\mathcal{R}$ 分别约为 12 和 3300。

VIII. 结论

我们研究了存在近场波束分裂时的近场宽带太赫兹信道估计问题。我们提出了基于模型和无模型两种方法，以较低的复杂度和开销有效估计信道。基于模型的方法采用OMP技术，并专门设计了 NBA字典，使空间域到达角和距离参数能够得到准确匹配，从而获得波束分裂校正信道估计。无模型方法基于联邦学习方案，数据标签则由基于模型的方法生成。与现有技术相比，所提出的方法具有更低的信道开销和模型训练开销。具体而言，与传统技术相比，所提出的基于模型的方法仅需使用八分之一的信道资源，即可达到接近最小均方误差的性能；而所提出的无模型技术与集中式方案相比，通信开销减少了 12 倍。所提出的 NBA-OMP 尤其适用于太赫兹频段应用，因为这类应用会使用超大规模天线数量，导致计算复杂度很高，而且近场波束分裂可能会降低系统性能。

参考文献

[1] T. S. Rappaport、Y. Xing、O. Kanhere、S. Ju、A. Madanayake、S. Mandal、A. Alkhateeb 和 G. C. Trichopoulos，“100 GHz 以上的无线通信与应用：面向 6G 及更高代际的机遇与挑战”，*IEEE Access*，第 7 卷，第 78 729–78757 页，2019年6月。[2] I. F. Akyildiz、C. Han、Z. Hu、S. Nie 和 J. M. Jornet，“太赫兹频段通信：重新审视一个老问题及未来十年的研究方向”，*IEEE* 通信汇刊，第 70 卷，第 6 期，第 4250–4285 页，2022年5月。[3] A. M. Elbir、K. V. Mishra、S. Chatzinotas 和 M. Bennis，“太赫兹频段通感一体化：挑战与机遇”，*arXiv* 预印本 *arXiv:2208.01235*，2022年8月。[4] H. Sarieddeen、M.-S. Alouini 和 T. Y. Al-Naffouri，“太赫兹通信信号处理技术概述”，*Proceedings of the IEEE*，第 109 卷，第 10 期，第 1628–1665 页，2021年。[5] R. W. Heath、N. Gonz´alez-Prelcic、S. Rangan、W. Roh 和 A. M. Sayeed，“毫米波MIMO系统信号处理技术概述”，*IEEE* 信号处理精选主题期刊，第 10 卷，第 3 期，第 436–453 页，2016年2月。[6] A. M. Elbir、K. V. Mishra、S. A. Vorobyov 和 W. Heath Robert, Jr.，“波束成形二十五年发展：从凸优化和非凸优化到学习技术”，*arXiv* 预印本 *arXiv:2211.02165*，2022年11月。[7] A. Alkhateeb 和 R. W. Heath，“有限反馈毫米波系统的频率选择性混合预编码”，*IEEE* 通信汇刊，第 64 卷，第 5 期，第 1801–1818 页，2016年。[8] X. Yu、J. Shen、J. Zhang 和 K. B. Letaief，“毫米波MIMO系统混合预编码的交替最小化算法”，*IEEE* 信号处理精选主题期刊，第 10 卷，第 3 期，第 485–500 页，2016年4月。[9] J. Tan 和 L. Dai，“太赫兹大规模多输入多输出系统的宽带波束跟踪”，*IEEE* 通信领域精选期刊，第 39 卷，第 6 期，第 1693–1710 页，2021年4月。

[10] A. Alkhateeb、G. Leus 和 R. W. Heath，“多用户毫米波系统的有限反馈混合预编码”，IEEE 无线通信汇刊，第 14 卷，第 11 期，第 6481–6494 页，2015年7月。[11] H. Yin、D. Gesbert、M. Filippou 和 Y. Liu，“大规模多天线系统信道估计的协同方法”，IEEE 通信领域精选期刊，第 31 卷，第 2 期，第 264–273 页，2013年2月。[12] Z. Marzi、D. Ramasamy 和 U. Madhow，“毫米波微微蜂窝大型阵列的压缩信道估计与跟踪”，IEEE 信号处理精选主题期刊，第 10 卷，第 3 期，第 514–527 页，2016年4月。[13] J. Wang、Z. Lan、C. woo Pyo、T. Baykas、C. sean Sum、M. A. Rahman、J. Gao、R. Funada、F. Kojima、H. Harada 和 S. Kato，“基于波束码本的多吉比特每秒毫米波无线个域网系统波束成形协议”，IEEE 通信领域精选期刊，第 27 卷，第 8 期，第 1390–1399 页，2009年10月。[14] K. Dovelos、M. Matthaiou、H. Q. Ngo 和 B. Bellalta，“宽带太赫兹大规模多输入多输出系统的信道估计与混合合并”，IEEE 通信领域精选期刊，第 39 卷，第 6 期，第 1604–1620 页，2021年4月。[15] J. Tan 和 L. Dai，“太赫兹大规模多输入多输出系统的宽带信道估计”，《中国通信》，第 18 卷，第 5 期，第 66–80 页，2021年5月。[16] A. M. Elbir、W. Shi、K. V. Mishra 和 S. Chatzinotas，“太赫兹宽带信道与到达方向估计的联邦多任务学习”，arXiv 预印本 arXiv:2207.06017，2022年7月。[17] A. M. Elbir，“太赫兹宽带混合波束成形中的波束分裂抑制统一方法”，arXiv 预印本 arXiv:2209.12097，2022年9月。[18] B. Wang、F. Gao、S. Jin、H. Lin 和 G. Y. Li，“毫米波大规模多输入多输出系统中的空间与频率宽带效应”，IEEE 信号处理汇刊，第 66 卷，第 13 期，第 3393–3406 页，2018年5月。[19] A. M. Elbir、W. Shi、A. K. Papazafeiropoulos、P. Kourtessis 和 S. Chatzinotas，“通过阵列扰动模型进行太赫兹频段信道与波束分裂估计”，arXiv 预印本 arXiv:2208.03683，2022年8月。[20] S. Nie 和 I. F. Akyildiz，“0.06–10 THz 超大规模多输入多输出通信中的基于深度核学习的信道估计”，载于 2019年 IEEE Globecom 研讨会（GC Wkshps）。IEEE，2019年12月，第 1–6 页。[21] Y. Chen 和C.Han，“太赫兹超大规模多输入多输出系统的基于深度卷积神经网络的球面波信道估计”，载于 2020年全球通信大会——2020年 IEEE 全球通信大会。IEEE，2020年12月，第 1–6 页。[22] E. Balevi 和 J. G. Andrews，“利用生成对抗网络进行宽带信道估计”，IEEE 无线通信汇刊，第 20 卷，第 5 期，第 3049–3060 页，2021年1月。[23] E. Bj¨ornson、 ¨O. T. Demir 和 L. Sanguinetti，“阵列与可重构智能表面的近场波束成形入门”，arXiv 预印本 arXiv:2110.06661，2021年10月。[24] X. Wei 和 L. Dai，“超大规模大规模多输入多输出的信道估计：远场、近场还是远近场混合？”，IEEE 通信快报，第 26 卷，第 1 期，第 177–181 页，2021年11月。[25] M. Cui 和 L. Dai，“超大规模多输入多输出的信道估计：远场还是近场？”，IEEE 通信汇刊，第 70 卷，第 4 期，第 2663–2677 页，2022年1月。[26] W. Yu、Y. Shen、H. He、X. Yu、J. Zhang 和 K. B. Letaief，“利用不动点网络进行太赫兹超大规模多输入多输出的远场与近场混合信道估计”，arXiv 预印本 arXiv:2205.04944，2022年5月。[27] X. Zhang、H. Zhang 和 Y. C. Eldar，“6G无线通信中的近场稀疏信道表示与估计”，arXiv 预印本 arXiv:2212.13527，2022年12月。[28] X. Zhang、Z. Wang、H. Zhang 和 L. Yang，“超大规模阵列通信的近场信道估计：基于模型的深度学习方法”，arXiv 预印本 arXiv:2211.15440，2022年11月。[29] A. M. Elbir、K. V. Mishra 和 S. Chatzinotas，“ 太赫兹频段联合超大规模多输入多输出雷达通信：基于模型和无模型的混合波束成形 ”，IEEE 信号处理精选主题期刊，第 15 卷，第 6 期，第 1468–1483 页，2021年10月。

[30] L. Dai、J. Tan、Z. Chen 和 H. V. Poor，《面向宽带太赫兹大规模多输入多输出的时延相位预编码》，*IEEE* 无线通信汇刊，第 1 页，2022年3月。[31] S. Tarboush、H. Sarieddeen、H. Chen、M. H. Loukil、H. Jemaa、M. S. Alouini 和 T. Y. Al-Naffouri，《TeraMIMO：面向宽带超大规模太赫兹多输入多输出通信的信道仿真器》，*arXiv*，2021年4月。[32] H. Yuan、N. Yang、K. Yang、C. Han 和 J. An，《频率选择性衰落下太赫兹多载波系统的混合波束成形》，*IEEE* 通信汇刊，第 68 卷，第 10 期，第 6186–6199 页，2020年7月。[33] H. Yuan、N. Yang、X. Ding、C. Han、K. Yang 和 J. An，《面向海量设备太赫兹通信的基于簇的多载波混合波束成形》，*IEEE* 通信汇刊，第 70 卷，第 5 期，第 3407–3420 页，2022年3月。[34] M. Cui、L. Dai、Z. Wang、S. Zhou 和 N. Ge，《近场彩虹：超大规模多输入多输出的宽带波束训练》，*IEEE* 无线通信汇刊，第 1 页，2022年11月。[35] A. M. Elbir 和 S. Coleri，《传统及 RIS 辅助大规模多输入多输出中的信道估计联邦学习》，*IEEE* 无线通信汇刊，第 21 卷，第 6 期，第 4255–4268 页，2021年11月。[36] A. M. Elbir、A. K. Papazafeiropoulos 和 S. Chatzinotas，《物理层设计的联邦学习》，*IEEE*通信杂志，第 59 卷，第 11 期，第 81–87 页，2021年11月。[37] H. B. McMahan、E. Moore、D. Ramage、S. Hampson 和 B. A. y. Arcas，《利用去中心化数据进行深度网络的通信高效学习》，*arXiv*，2016年2月。[38] M. M. Amiri 和 D. G¨und¨uz，《无线衰落信道上的联邦学习》，*IEEE* 无线通信汇刊，第 19 卷，第 5 期，第 3546–3557 页，2020年。[39] M. Mohammadi Amiri 和 D. G¨und¨uz，《无线边缘的机器学习：空中分布式随机梯度下降》，*IEEE* 信号处理汇刊，第 68 卷，第 2155–2169 页，2020年。[40] J. Rodr´ıguez-Fern´andez、N. Gonz´alez-Prelcic、K. Venugopal 和 R. W. Heath，《频率选择性混合毫米波多输入多输出系统的频域压缩信道估计》，*IEEE* 无线通信汇刊，第 17 卷，第 5 期，第 2946–2960 页，2018年3月。