



XXXX

# 基于有源器件部署的半有源 IRS 系统多层采样超分辨率信道估计

郑明坤<sup>1</sup>, 刘天乐<sup>1</sup>, 潘鹏<sup>1</sup>, 郑雅文<sup>2</sup>, 聂柏润<sup>3</sup>, 何腾蛟<sup>4</sup>

(1. 杭州电子科技大学通信工程学院, 浙江 杭州 310018;

2. 北京跟踪与通信技术研究所, 北京 100094;

3. 中国电子科技集团公司第五十研究所, 上海 200331;

4. 暨南大学信息科学技术学院, 广东 广州 510632)

**摘要:** 通过传统智能反射面 (IRS) 中引入少量有源器件, 半有源 IRS 可缓解信道估计挑战, 从而增强 IRS 的工程可部署性。然而, 现有研究尚未系统地考虑有源器件部署策略对信道估计的影响, 使得在实际应用中难以平衡估计精度、有源器件数量、算法复杂度和导频开销之间的矛盾。针对上述问题, 本文利用信道矩阵的低秩先验及其协方差矩阵的 Toeplitz 结构特性, 提出一种面向半有源 IRS 的低导频、低复杂度超分辨率信道估计方案。仿真结果表明, 本方案通过利用低秩矩阵补全理论与 Toeplitz 矩阵的结构特点设计采样方案, 有针对性地配置有源器件的位置和数量, 缓解导频开销问题, 实现信道参数的超分辨率估计, 并通过一系列低复杂度算法显著降低现有方案复杂度。

**关键词:** 半有源智能反射面; Toeplitz 结构; 超分辨率信道估计; 低秩矩阵补全

**中图分类号:** TN929.5

**文献标志码:** A

**doi:** 10.11959/j.issn.1000-0801.

## Deployment-Oriented Multi-Layer Sampling-Based Super-Resolution Channel Estimation for Semi-Passive IRS Systems

ZHENG Mingkun<sup>1</sup>, LIU Tianle<sup>1</sup>, PAN Peng<sup>1</sup>, ZHENG Yawen<sup>2</sup>, NIE Bairun<sup>3</sup>, HE Tengjiao<sup>4</sup>

1. School of Communication Engineering, Hangzhou Dianzi University, Hangzhou 310018, China

2. Beijing Institute of Tracking and Telecommunications Technology, Beijing 100094, China

3. The 50th Research Institute of China Electronics Technology Group Corporation (CETC), Shanghai 200331, China

4. School of Information Science and Technology, Jinan University, Guangzhou 510632, Guangdong, China

**Abstract:** By introducing a small number of active elements into conventional intelligent reflecting surfaces (IRSs), semi-passive IRSs can effectively alleviate the challenges of channel estimation, thereby enhancing the practical deployability of IRSs. However, existing studies have not systematically investigated the impact of active element deployment strategies on channel estimation, which makes it difficult in practice to jointly balance estimation accuracy, the number of active elements, algorithmic complexity, and pilot overhead. To address this issue, this paper exploits



the low-rank prior of the channel matrix together with the Toeplitz structure of its covariance matrix, and proposes a low-pilot and low-complexity super-resolution channel estimation scheme for semi-passive IRS systems. Numerical results demonstrate that, by leveraging low-rank matrix completion theory and the structural properties of Toeplitz matrices in the sampling design, the proposed scheme can selectively configure the locations and number of active elements, thereby reducing pilot overhead and enabling super-resolution estimation of channel parameters, while significantly lowering the computational complexity compared with existing methods.

**Key words:** Semi-Active Intelligent Reflecting Surface, Toeplitz Structure, Super-Resolution Channel Estimation, Low-Rank Matrix Completion

## 0 引言

智能反射面 (Intelligent Reflecting Surface, IRS) 因其部署灵活、兼容性强以及低成本等显著优势, 已成为下一代移动通信系统的重要候选技术之一<sup>[1-4]</sup>。现有研究表明, 通过在 IRS 表面引入少量有源器件并形成半有源 IRS 架构, 可使系统具备一定的信号感知与处理能力。在信道估计方面, 有源器件的感知能力有助于缓解导频开销的负担, 有利于该系统的最终落地<sup>[5]</sup>。然而, 即便在半有源架构下, 反射面与基站及用户之间的信道维度仍然较高。随着信道维度的不断增加, 系统往往需要消耗大量导频资源以获取准确的信道状态信息, 导致现有信道估计算法较难平衡导频开销、计算复杂度与估计精度之间的矛盾<sup>[6]</sup>。理论与实践的结果已经发现, 有源器件的部署方式, 对于信道估计性能有着较大影响。因此, 如何通过设计部署方式, 在保证估计精度的前提下, 实现高效的信道估计, 是值得研究的问题<sup>[5]</sup>。

根据信道参数估计的效果, 可将信道估计分为有限分辨率和超分辨率两种。有限分辨率的参数估计, 利用信道稀疏的特点, 基于有限的分辨率的码本和压缩感知理论, 可较为高效地恢复信道状态信息 (Channel State Information, CSI)。例如, 文献[7]基于标准的压缩感知 (Compressed Sensing, CS) 理论, 提出了一种面向半有源 IRS 的信道估计方案, 并使用机器学习提升估计性能。而文献[8]基于深度神经网络辅助的 CS 方案,

进一步提升了估计精度。文献[9]基于有限分辨率码本的压缩感知框架, 提出一种无需已知信道路径数的压缩感知信道估计算法。上述方案基于预设的码本, 当码本的分辨率不足时会对估计性能造成较大挑战, 而提升分辨率亦会对其导频开销和复杂度造成负担<sup>[10]</sup>。

超分辨率算法并不依赖预设的码本, 因此可以有效避免因码本分辨率不足导致的估计性能下降问题。面向半有源 IRS 系统, Evangelos 等学者研究了在信道估计阶段, 使用单个有源射频链路进行超分辨率估计的可行性<sup>[11]</sup>。在该系统中, 用户与反射面, 反射面与基站两段信道可分别在装备有单个有源器件的智能反射面上完成估计。在此基础上, 何继光等学者基于原子范数最小化 (Atomic Norm Minimization, ANM) 理论, 提出了一种超分辨率信道估计方法, 并对比了使用多个有源器件的半有源系统与无源系统的信道估计性能<sup>[12]</sup>。Markku 等学者进一步指出, 通过使用回程线路 (Backhaul Link, BL), 信道估计可以分别在反射面与基站进行, 降低导频开销<sup>[13]</sup>。仿真结果显示, 通过在反射面上随机部署大量的有源器件, 可以提升信道估计的精度。值得注意的是, 上述基于 ANM 的工作, 需要通过求解一个复杂度较高的半正定规划 (Semidefinite Programs, SDP) 问题, 从而为后续超分辨率算法提供观测样本的协方差矩阵。文献[14]基于稀疏贝叶斯学习理论, 提出了一种去格点的化的信道估计方案。而为了缓解对半有源 IRS 系统信道估计

算法复杂度与估计性能之间的矛盾, 文献[15]提出了一种基于残差神经网络估计方案, 结果显示可在一定程度上缓解该矛盾。针对面阵, 文献[16]提出了一种基于L型的有源器件部署方案, 即在面阵的水平和垂直方向均匀部署2套线阵, 并实现了超分辨率的信道估计性能。在此基础上, 文献[17]和[18]指出通过减少了两个线阵中有源器件的个数, 可进一步降低导频开销。此外, 文献[19]考虑将所有有源器件部署在一个均匀的方形范围内, 使用多阶段的方式实现了超分辨率的信道估计性能。而文献[20]基于两个有源IRS和一个无源IRS的结合, 实现了IRS系统信道的超分辨率信道估计。值得注意的是, 上述所有研究均基于随机、均匀的基础方式对有源器件进行了部署, 并未对其部署位置及数量进行信道估计方案的系统性研究。

综上, 针对半有源IRS辅助系统的超分辨率信道估计研究已取得一定进展。但现有工作未结合信道矩阵低秩特性与协方差矩阵Toeplitz结构进行部署策略与信道估计的协同设计, 缺乏部署方案与估计算法的研究, 较难平衡导频开销、计算复杂度与估计精度的矛盾。此不足使得半有源IRS在实际部署中, 难以在保证估计精度的同时, 有效控制有源器件数量, 并应对导频开销与计算复杂度高的挑战<sup>[5]</sup>。目前, 在以点对点通信场景中, 文献[21]在导频发射阶段提出双层采样机制, 结合随机采样与确定性采样以减少导频开销; 在信道恢复阶段, 利用信道矩阵的低秩特性及其协方差矩阵的Toeplitz结构, 借助低秩矩阵补全(Low-Rank Matrix Completion, LRMC)理论与Toeplitz对角线元素相同的结构, 由少量观测样本重构高维协方差矩阵, 并基于子空间谱估计实现超分辨率参数提取。在半有源IRS系统中, 文献[22]已证实可利用信道矩阵的低秩特性, 采用矩阵或张量补全理论, 对该系统的级联信道进行恢复。而文献[23]基于ANM进行了信道估计, 并

通过图论的思想进行有针对性的有源器件部署, 提升了估计准确性。但直接使用矩阵填充和ANM恢复的方案, 因未利用到IRS本身阵列结构的特点, 因此估计性能相较于基于子空间的超分辨率算法, 还有进一步提升的空间<sup>[9]</sup>。

受此启发, 本文从信道矩阵的低秩先验出发, 进一步挖掘IRS两阶段信道协方差矩阵所蕴含的Toeplitz结构特性, 系统性地提出一种基于采样的面向半有源IRS的低导频、低复杂度超分辨率信道估计框架。本论文的主要贡献可概括如下:

- 1, 在IRS有源器件部署阶段, 基于IRS-用户与基站-IRS观测样本协方差的Toeplitz结构化特性, 可通过广义嵌套采样(Generalized Nested Sampling, GNS)等确定性采样方案, 减少现有随机部署中有源器件的数量, 从而显著降低由有源器件配置引起的导频开销。在此基础上, 可基于IRS-用户与基站-IRS信道矩阵的低秩特性, 使用随机采样方案, 进一步减少有源器件数量。

- 2, 在IRS-用户与基站-IRS信道协方差恢复与参数估计过程中, 基于LRMC理论, 使用低复杂度的广义条件梯度交替最小化(Generalized Conditional Gradient-based Alternate Minimization, CGC-ALTMIN)以替代现有基于ANM的研究中求解SDP的实现路径, 有效克服了因SDP求解所带来的高复杂度瓶颈。随后, 接收端基于第一次重构得到的协方差矩阵, 利用Toeplitz矩阵对角线元素相同的结构特性进行第二次重构, 进一步提升协方差矩阵维度, 为后续超分辨率算法提供更丰富的观测样本。在此基础上, 采用低复杂度的root-MUSIC实现超分辨率到达角估计, 并基于准确估计的角度信息构建低维度的码本, 结合正交匹配追踪(Orthogonal Matching Pursuit, OMP)完成信道增益估计。需要指出的是, 区别于传统OMP信道估计方案, 本方法在构建码本时, 采用的是使用超分辨率算法恢复的角度信



息, 因此不会产生因分辨率低而导致的估计性能下降。

3, 数值结果表明, 所提方法在较低导频开销与较低计算复杂度条件下即可实现半有源 IRS 系统的超分辨率信道估计; 而相较于现有基于 ANM 类随机部署有源器件的方案, 在相同导频开销下可获得更高的参数估计精度, 并因为避免了 ANM 中 SDP 求解带来的高复杂度问题, 显著降低计算复杂度。

综上, 所提方案基于半有源 IRS 信道矩阵的低秩特性和其协方差矩阵的 Toeplitz 结构, 通过有针对性地部署有源器件位置, 并基于低秩矩阵补全理论, 可在降低有源器件数量的同时, 缓解半有源 IRS 系统在实际部署中面临的高导频开销与信道估计算法复杂度高的问题。

本文中, 用粗斜体的小写字母和大写字母分别表示向量和矩阵,  $(\cdot)^H$ 、 $(\cdot)^T$  和  $(\cdot)^*$  分别表示共轭转置、转置和共轭;  $\text{vec}(\cdot)$  和  $\text{diag}(\cdot)$  分别表示矩阵的向量化和对角化;  $\otimes$ 、 $\diamond$  和  $\|\cdot\|_F$  分别表示

Kronecker 积、Khatri-Rao 积和 Frobenius 范数;  $\mathbb{B}$  表示一个二元集合, 其元素为 0 和 1。

## 1 系统模型

本文考虑工作于毫米波频段的基于 IRS 辅助的大规模多输入多输出 (Multiple Input Multiple Output, MIMO) 系统。如图 1 所示, 假设用户和基站之间的直接通道被阻塞, 需要使用 IRS 来辅助完成从用户到基站的传输。同时假设用户、IRS 和基站分别配备有  $N_t$ 、 $N_n$  和  $N_r$  个器件的均匀线性阵列 (Uniform Linear Array, ULA)。此外, 按照大多数研究中的设置, 在 IRS 和基站之间存在一条回程线路完成对信号的传输<sup>[13]</sup>。

假设用户到 IRS 的信道有  $L_F$  条路径, 则用户与 IRS 之间的信道可建模为:

$$\mathbf{F} = \sqrt{\frac{N_t N_n}{L_F}} \sum_{l=1}^{L_F} \gamma_{F,l} \mathbf{a}_l(\theta_{l,l}) \mathbf{a}_T^H(\phi_{T,l}) = \mathbf{A}_l(\boldsymbol{\theta}_l) \boldsymbol{\Gamma}_F \mathbf{A}_T^H(\boldsymbol{\phi}_T) \in \mathbb{C}^{N_n \times N_t} \#(1)$$

其中,  $\theta_{l,l}$ 、 $\phi_{T,l}$  和  $\gamma_{F,l}$  分别表示 IRS 处的到达角、

表 1 对比表

方法	部署模式	是否考虑孔径与采样位置及采样率的关系	是否通过部署方式降低计算复杂度
文献[16]	L型部署	无	无
文献[19]	方形部署	无	无
文献[23]	基于图论部署	无	无
本文方法	GNS+LRMC 部署	有	有

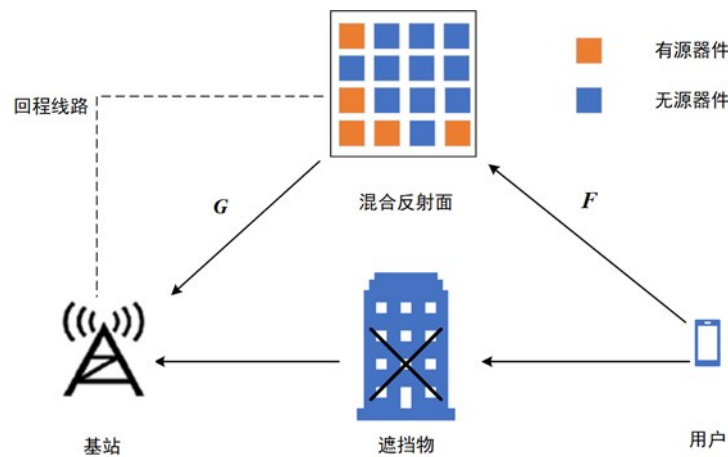


图 1 半有源 IRS 辅助的毫米波通信系统

用户处的离开角和第  $l$  条路径的增益。令  $[\mathbf{A}_I(\boldsymbol{\theta}_I)]_{:,l} = \mathbf{a}_I(\theta_{l,l})$ 、 $[\mathbf{A}_T^H(\boldsymbol{\phi}_T)]_{:,l} = \mathbf{a}_T^H(\phi_{T,l})$ 、 $\boldsymbol{\Gamma}_F = \text{diag}(\boldsymbol{\gamma}_F)$ 、 $\boldsymbol{\gamma}_F = [\gamma_{F,1}, \dots, \gamma_{F,L_F}]$ ，其中  $[\cdot]_{:,l}$  表示矩阵的第  $l$  列。 $\mathbf{a}_I(\theta_{l,l})$  和  $\mathbf{a}_T^H(\phi_{T,l})$  均为阵列响应向量，如式 (2) 和 (3) 所示。

$$\mathbf{a}_I(\theta_{l,l}) = \frac{1}{\sqrt{N_n}} \left[ 1, e^{j\frac{2\pi}{s}d\cos(\theta_{l,l})}, \dots, e^{j(N_n-1)\frac{2\pi}{s}d\cos(\theta_{l,l})} \right]^T \quad \#(2)$$

$$\mathbf{a}_T^H(\phi_{T,l}) = \frac{1}{\sqrt{N_t}} \left[ 1, e^{j\frac{2\pi}{s}d\cos(\phi_{T,l})}, \dots, e^{j(N_t-1)\frac{2\pi}{s}d\cos(\phi_{T,l})} \right]^T \quad \#(3)$$

其中， $s$  为波长， $d=s/2$  为器件间距， $\phi_{T,l}$ 、 $\theta_{l,l}$  服从  $[0, \pi]$  的均匀分布。

同理可得，IRS 和基站之间的信道可建模为：

$$\mathbf{G} = \sqrt{\frac{N_n N_r}{L_G}} \sum_{l=1}^{L_G} \gamma_{G,l} \mathbf{a}_R(\theta_{R,l}) \mathbf{a}_I^H(\phi_{l,l}) = \mathbf{A}_R(\boldsymbol{\theta}_R) \boldsymbol{\Gamma}_G \mathbf{A}_I^H(\boldsymbol{\phi}_I) \in \mathbb{C}^{N_r \times N_n} \quad \#(4)$$

其中， $\phi_{l,l}$ 、 $\theta_{R,l}$  和  $\gamma_{G,l}$  分别表示第  $l$  条路径中 IRS 处的离开角、基站处的到达角和第  $l$  条路径的增益， $L_G$  表示 IRS 和基站之间的路径总数。 $[\mathbf{A}_R(\boldsymbol{\theta}_R)]_{:,l} = \mathbf{a}_R(\theta_{R,l})$ 、 $[\mathbf{A}_I^H(\boldsymbol{\phi}_I)]_{:,l} = \mathbf{a}_I^H(\phi_{l,l})$ 、 $\boldsymbol{\Gamma}_G = \text{diag}(\boldsymbol{\gamma}_G)$ 、 $\boldsymbol{\gamma}_G = [\gamma_{G,1}, \dots, \gamma_{G,L_G}]$ 。 $\mathbf{a}_R(\theta_{R,l})$  和  $\mathbf{a}_I^H(\phi_{l,l})$  均为阵列响应向量，其形式类似 (2) 所示。

用户和基站之间的信道可建模为<sup>[10]</sup>：

$$\mathcal{H}_1 = \mathbf{G}\boldsymbol{\Omega}\mathbf{F} \in \mathbb{C}^{N_r \times N_t} \quad \#(5)$$

其中， $\boldsymbol{\Omega} = \text{diag}(\boldsymbol{\omega})$ ，而  $\boldsymbol{\omega}$  包含 IRS 器件的相移信息，可表示如下：

$$\boldsymbol{\omega} = \left[ \beta_1 e^{j\zeta_1}, \beta_2 e^{j\zeta_2}, \dots, \beta_{N_n} e^{j\zeta_{N_n}} \right]^T \in \mathbb{C}^{N_n \times 1} \quad \#(6)$$

其中， $\beta_n$  和  $\zeta_n$  分别表示第  $n$  个 IRS 器件的反射系数和相移。此外， $\beta_n \in \{0, 1\}$ ， $\beta_n = 1$  表示第  $n$  个器件被激活， $\beta_n = 0$  则表示第  $n$  个器件被关闭。

由公式  $\text{vec}(\mathbf{A}\text{diag}(\mathbf{b})\mathbf{C}) = (\mathbf{C}^T \diamond \mathbf{A})\mathbf{b}$ ，对式

(5) 向量化可得：

$$\text{vec}(\mathcal{H}_1) = \text{vec}(\mathbf{G}\boldsymbol{\Omega}\mathbf{F}) = (\mathbf{F}^T \diamond \mathbf{G})\boldsymbol{\omega} = \mathbf{H}\boldsymbol{\omega} \quad \#(7)$$

其中， $\mathbf{H} = \mathbf{F}^T \diamond \mathbf{G} \in \mathbb{C}^{N_r N_t \times N_n}$  是级联信道。由于器件数量多，导致  $\mathbf{H}$  具有高维性，使得估计  $\mathbf{H}$  面临挑战。因此，本文提出了一种基于分段式与多层采样技术的半有源 IRS 器件部署策略，通过多层采样技术在保证估计精度的前提下，降低计算复杂度和导频开销，高效准确地完成信道估计。

## 2 基于多层采样的超分辨率信道参数估计与有源器件部署方法

现有半有源 IRS 的研究中，缺乏针对有源器件部署位置和数量的信道估计方法，导致信道估计导频开销和计算复杂度高。根据式 (7)，在 IRS 的辅助下，用户到基站之间的信道  $\mathbf{H}$  可分为两部分，分别为用户到 IRS 的信道  $\mathbf{F}$  和 IRS 到基站的信道  $\mathbf{G}$ 。区别于现有方法，本文所提方法通过设计确定性和随机采样模式，有目的地部署有源器件，并基于压缩的观测样本，恢复超分辨率算法所需观测样本的协方差矩阵。本方法的整体流程如图 2 所示，即第一阶段实现对信道  $\mathbf{F}$  中的两个角度信息  $\boldsymbol{\theta}_I$ 、 $\boldsymbol{\phi}_T$  和增益  $\boldsymbol{\gamma}_F$  的估计，利用 IRS 和基站之间存在回程线路，将 IRS 接收到第一个信号  $\mathbf{Y}_F$  传输至基站，基于低秩矩阵补全理论和 OMP 算法得到  $\hat{\mathbf{F}}$ 。第二阶段实现对信道  $\mathbf{G}$  中的两个角度信息  $\boldsymbol{\theta}_R$ 、 $\boldsymbol{\phi}_I$  和增益  $\boldsymbol{\gamma}_G$  的估计。基站向 IRS 发送导频信号，通过回程线路可得到第二个信号  $\mathbf{Y}_G$ ，然后基站通过使用与第一阶段相似的方法完成对  $\mathbf{Y}_G$  的处理得到  $\hat{\mathbf{G}}$ 。最终，通过公式 (7) 得到级联信道  $\hat{\mathbf{H}}$ 。下面详细介绍两阶段具体内容。

本文所提多层采样方法，其中确定性采样用于保证 Toeplitz 矩阵中对角线元素的有足够的样本保证恢复；在此基础上，利用样本矩阵的低秩性进行随机采样，通过 LRMC 恢复足够精度的协



方差，从而在不破坏结构的前提下进一步减少观测测量与有源器件数量。两种采样方式具有协同逻辑，缺一不可：如果仅使用随机采样而缺少固定部署，Toeplitz矩阵中重要的位置可能不能被足够的观测样本恢复，导致协方差结构难以稳定重构并使超分辨率估计性能下降；如果仅使用确定性采样而不引入随机采样，则观测测量与硬件开销仍显著。两者结合能够在保持Toeplitz结构与超分辨率可辨识性的同时，进一步利用低秩性压缩观测测量，从而减少有源器件数量、降低采样率与总体复杂度。基上述协同逻辑，本方法在半有源系统的信道估计中，通过多次采样，大幅降低了所需观测样本数据。

## 2.1 用户到IRS的信道矩阵 $F$ 的估计

第一阶段包含有源器件部署模式、协方差矩阵补全、角度和增益估计。下面详细介绍具体步骤。

### 2.1.1 用户到IRS的信道矩阵 $F$ 的采样

本文所提方法的第一阶段，假设训练长度为  $S$ ，第  $s$  次发送的导频信号为  $x_s$ ，可观测到信号为：

$$y_s = W_s^H F p_s x_s + W_s^H n_s \in \mathbb{C}^{Q_n \times 1} \quad (8)$$

其中， $W_s$  和  $p_s$  为IRS和用户处的预编码，现假设  $x_s=1$ ，噪声  $n_s \in \mathbb{C}^{N_r \times 1} \sim \mathcal{CN}(0, \sigma_n^2 \mathbf{I})$ ，其中  $\sigma_n^2$  是平均噪声功率。基于训练长度为  $S$  的假设，最终可得

到接收信号为：

$$y_F = [y_1^T, y_2^T, \dots, y_S^T]^T \in \mathbb{C}^{SQ_n \times 1} \quad (9)$$

第一阶段信道估计的目的是从  $y_F$  中估计出  $F$ 。

由 (5) 可知，由于IRS中使用了大量的器件，其信道矩阵维度通常较大，增加了信道估计的导频负担和计算复杂度。因此本方法首先通过对有源器件进行部署，对矩阵进行采样得到子矩阵，后续通过多次补全，补全原始协方差矩阵，用于估计角度信息，从而达到降低导频开销和减少有源器件部署的目的。

令  $X_R \in \mathbb{C}^{N_n \times N_{n,s}}$  和  $X_T \in \mathbb{C}^{N_t \times N_{t,s}}$  分别表示IRS和用户处的确定性采样矩阵， $N_{n,s}$  和  $N_{t,s}$  分别表示信道矩阵  $F$  中IRS和用户处有源器件部署数和选择天线数。可得到子矩阵  $C_F$ ：

$$C_F = X_R^H F X_T \in \mathbb{C}^{N_{n,s} \times N_{t,s}} \quad (10)$$

其中，基站、反射面有源器件部署和用户处选择天线的指标分别被记录在  $W_r$ 、 $W_n$  和  $W_t$  组中。则有  $|W_r| = N_{r,s}$ 、 $|W_n| = N_{n,s}$  和  $|W_t| = N_{t,s}$ ，现定义用户端选择的天线  $N_{t,u} \triangleq \max(W_t) - \min(W_t) + 1$ ，以类似的方法定义反射面和基站处器件  $N_{n,u}$ 、 $N_{r,u}$ 。本文采用均匀采样 (Uniform Block Sampling, UBS) 模式和 GNS 模式<sup>[24]</sup>，并以ULA的器件部署为例来展示它们的特性。

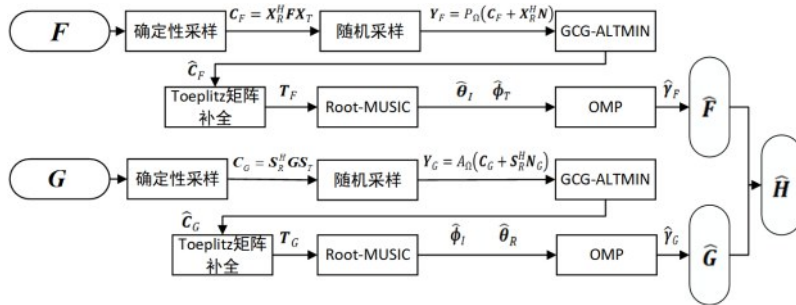


图2 半有源IRS信道估计方法流程图。以信道矩阵  $F$  的估计过程为例，如图3所示，通过式(11)中的UBS确定性采样，在含12个器件的原始阵列中激活前6个器件作为有源观测节点(基于GNS的采样模式可参考图4)。之后引入式(14)的随机采样方法得到  $Y_F$ ，则可运用式(21)恢复出子信道矩阵  $\hat{C}_F$ ；运用式(23)构建协方差矩阵  $T_F$ ，然后使用Root-MUSIC算法估计出  $\hat{\theta}_I$  和  $\hat{\phi}_T$ ，进而通过式(24)估计出  $\hat{y}_F$ ，最终运用式(25)实现信道矩阵  $F$  的完整恢复。信道矩阵  $G$  的恢复是类似的。

在采用 UBS 模式时，子阵列器件的部署方式为：从规模为  $N$  个器件的原始阵列的首个器件开始，直至第  $N_s$  个器件，按均匀间隔的规则完成部署。UBS 模式的矩阵构造如下：

$$[\mathbf{X}_{\text{UBS}}]_{i,j} = \begin{cases} 1, & i=j \text{ 且 } 1 \leq i \leq N_s \\ 0, & \text{其他} \end{cases} \quad \#(11)$$

其中， $N_s \leq N$ ，如图 3 所示，可清晰看到子阵列的孔径会随选定器件的数量而减少。

在部署有源器件数量相同的条件下，采用 GNS 方案相比 UBS 方案能够获得更大的阵列孔径。这一优势可在降低导频开销的同时，维持原始阵列的空间分辨率，进而提升信道估计的准确性。一个 GNS 矩阵  $\mathbf{X}_{\text{GNS}} \in \mathbb{B}^{N_s \times N}$  可构造为<sup>[24]</sup>：

$$[\mathbf{X}_{\text{GNS}}]_{i,j} = \begin{cases} 1, & i=j \text{ 且 } 1 \leq i \leq \Gamma(N) \\ 1, & j = [i - \Gamma(N)]\Theta(N) + i \text{ 且 } \Gamma(N) < i \leq N \\ 0, & \text{其他} \end{cases} \quad \#(12)$$

其中， $\Theta(N) = \left\lfloor \sqrt{N + \frac{1}{4}} - \frac{1}{2} \right\rfloor$ ,  $\Gamma(N) = 1 + N - \Theta^2(N)$ ，总体部署的有源器件为  $N_s = \Gamma(N) + \Theta(N) - 1$ ，如图 4 所示。

通过上述采样过程，得到子信道  $\mathbf{C}_F$ ，由于矩阵  $\mathbf{F}$  具有低秩特性，在确定性采样后，所得子信道矩阵  $\mathbf{C}_F$  仍保持低秩属性，利用该低秩性可进一步采样，从而继续降低导频开销。为了实现该目标，可再对反射面处的器件进行随机的部署，从而减少需要部署有源器件数量，然后使用 LRMC 恢复  $\mathbf{C}_F$ 。

通过设计  $\mathbf{W}_s$  和  $\mathbf{p}_s$ ，在确定性采样的基础上完成随机采样过程，接收到的信号可表达为一组关于信道矩阵  $\mathbf{F}$  的带噪采样。例如，假设  $\mathbf{X}_R = \begin{bmatrix} \mathbf{I}_{N_{n,s}} \\ \mathbf{0} \end{bmatrix}$ ,  $\mathbf{X}_T = \begin{bmatrix} \mathbf{I}_{N_{l,s}} \\ \mathbf{0} \end{bmatrix}$ ，其中， $\mathbf{I}_{N_{n,s}}$  和  $\mathbf{I}_{N_{l,s}}$  分别表示大小为  $N_n \times N_{n,s}$  和  $N_l \times N_{l,s}$  的单位阵， $\mathbf{0}$  是全零矩阵， $\mathbf{W}_s = \mathbf{X}_R(:, 1:2)$  且  $\mathbf{p}_s = \mathbf{X}_T(:, 1)$  时，表示选取了  $\mathbf{C}_F$  第一行和第二行的第一个元素，即：

$$\begin{bmatrix} [\tilde{\mathbf{C}}_F]_{1,1} \\ [\tilde{\mathbf{C}}_F]_{2,1} \end{bmatrix} = \mathbf{y}_s = \mathbf{W}_s^H \mathbf{F} \mathbf{p}_s x_s + \mathbf{W}_s^H \mathbf{n}_s \quad \#(13)$$

如文献[25]所述，采样算子  $P_\Omega(\cdot)$  为：

$$[P_\Omega(\tilde{\mathbf{C}}_F)]_{i,j} = \begin{cases} [\tilde{\mathbf{C}}_F]_{i,j}, & (i,j) \in \Omega \\ 0, & \text{其他} \end{cases} \quad \#(14)$$

其中， $[\cdot]_{i,j}$  表示矩阵的第  $(i,j)$  个元素， $\Omega$  代表采样域。根据文献[25]和[26]，本文选取均匀随机采样模式，以保障  $\mathbf{C}_F$  的每一行和每一列中至少有一个元素能够被观测。不失一般性，假设导频信号为单位信号，含噪声的观测样本可通过下式进行表达：

$$\mathbf{Y}_F = P_\Omega(\mathbf{C}_F + \mathbf{X}_R^H \mathbf{N}_F) \quad \#(15)$$

其中， $\mathbf{N}_F$  为加性高斯白噪声， $\tilde{\mathbf{C}}_F$  是  $\mathbf{C}_F$  的噪声模式，即  $\tilde{\mathbf{C}}_F = \mathbf{C}_F + \mathbf{X}_R^H \mathbf{N}_F$ ，其中  $\mathbf{N}_F \in \mathbb{C}^{N_n \times N_l}$ 。所以观测结果  $\mathbf{Y}_F$  是  $\tilde{\mathbf{C}}_F = \mathbf{C}_F + \mathbf{X}_R^H \mathbf{N}_F$  的一个子集。将非零观测值向量化表示为：

$$\mathbf{y}_F = P_\Omega \text{vec}(\tilde{\mathbf{C}}_F) \quad \#(16)$$

其中， $P_\Omega \in \mathbb{B}^{\rho_{\Omega,F} N_{n,s} N_{l,s} \times N_{n,s} N_{l,s}}$ ，同时  $\rho_{\Omega,F}$  表示随机




图3 UBS 模式




图4 GNS 模式



采样的采样比率, 即

$$\rho_{\Omega,F} \triangleq \frac{\|\mathbf{Y}_F\|_{l_0}}{N_{n,s}N_{t,s}} \#(17)$$

其中,  $\|\cdot\|_{l_0}$  是  $l_0$  范数, 其计算出向量中非零项数量。导频开销由总体采样比决定, 总体采样比定义为样本数与  $\mathbf{F}$  中条目数的比值, 即:

$$\rho_{O,F} = \rho_{\Omega,F} \frac{N_{n,s}N_{t,s}}{N_iN_n} \#(18)$$

### 2.1.2 基于压缩样本恢复 $\mathbf{C}_F$

得到接收信号  $\mathbf{Y}_F$  后采用 LRMC 恢复  $\mathbf{C}_F$ 。由于  $\mathbf{C}_F = \mathbf{X}_R^H \mathbf{F} \mathbf{X}_T$  的低秩特性, 可通过求解以下低秩矩阵补全问题估计  $\mathbf{C}_F$ :

$$\min_{\mathbf{C}_F} \text{rank}(\mathbf{C}_F), \text{使得} \|\mathbf{P}_{\Omega}(\mathbf{C}_F) - \mathbf{Y}_F\|_F^2 \leq \delta^2 \#(19)$$

其中  $\delta^2$  为容差, 应用核范数正则化方法重新表述公式 (19) 为:

$$\hat{\mathbf{C}}_F \triangleq \arg \min_{\mathbf{C}_F} \frac{1}{2} \|\mathbf{P}_{\Omega}(\mathbf{C}_F) - \mathbf{Y}_F\|_F^2 + \mu \|\mathbf{C}_F\|_* \#(20)$$

其中,  $\mu > 0$  为正则化参数,  $(\cdot)_*$  表示核范数。利用核范数的 Frobenius 范数表征, 令  $\mathbf{C}_F = \mathbf{U}\mathbf{V}^H$ , 其中,  $\mathbf{U}$  表示低秩矩阵分解的左因子矩阵;  $\mathbf{V}$  表示低秩矩阵分解的右因子矩阵。通过求解公式 (21) 恢复  $\mathbf{C}_F$

$$\min_{\mathbf{U}, \mathbf{V}} \frac{1}{2} \|\mathbf{P}_{\Omega}(\mathbf{U}\mathbf{V}^H) - \mathbf{Y}_F\|_F^2 + \frac{1}{2} \mu (\|\mathbf{U}\|_F^2 + \|\mathbf{V}\|_F^2) \#(21)$$

得到  $\hat{\mathbf{C}}_F$  和估计出的秩为  $\hat{L}_F$ , 接下来恢复信道路径的到达角  $\theta_l$ 、离开角  $\phi_T$  和路径增益  $\gamma_F$ 。首先恢复第一个信道中反射面上的到达角  $\theta_l$ , 用户

上的离开角  $\phi_T$  的估计是类似的。通过补全 Toeplitz 矩阵, 可利用其结构信息进行奇异值分解 (Singular Value Decomposition, SVD), 避免复杂的优化算法。

### 2.1.3 补全 Toeplitz 协方差矩阵 $\mathbf{T}_F$

当使用 UBS 模式时, 可直接简单地对  $\hat{\mathbf{C}}_F$  使用 SVD 方法, 从而获得用户和 IRS 处 ULA 的阵列响应量所张成的子空间。但当使用 GNS 时, 由于有源器件并非连续部署, 部分器件并没有被激活, 因此不能直接使用 SVD 方法。这个问题可通过以下方法有效地解决。根据 [21], 首先构造虚拟信道  $\mathbf{X} \in \mathbb{C}^{N_{n,u} \times N_{t,u}}$ ,  $\mathbf{X}$  的第  $n$  列  $\mathbf{x}_n$  可建模为:

$$\mathbf{x}_n = \sum_{l=1}^{L_F} \gamma_{l,n} \mathbf{a}_{N_{n,u}}(\theta_{l,l}) \#(22)$$

其中,  $\gamma_{l,n} = \gamma_{F,l} [\mathbf{a}_{N_{t,u}}^H(\phi_{T,l})]_n$ ,  $\mathbf{a}_{N_{n,u}}(\theta_{l,l})$  表示具有  $N_{n,u}$  个有源器件的 ULA 的阵列响应,  $[\cdot]_n$  表示取一个向量的第  $n$  项。将  $\gamma_{l,n}$  建模为不相关的随机“源”信号, 则可得到  $\mathbf{x}_n$  的协方差矩阵为  $\mathbf{T}_F$ 。

由于  $\mathbf{T}_F$  是一个 Toeplitz 矩阵, 各对角线上元素具有一致性, 可对  $\mathbf{T}_F$  进行特征值分解, 然后用 root-MUSIC 算法估计反射面上的 AoAs。令  $\mathbf{T}_F \triangleq \text{Toep}(\mathbf{t})$ , 其中  $\mathbf{t} \triangleq [t_0, t_1, \dots, t_{N_{n,u}-1}]^T$  是一个包含  $N_{n,u}$  常数的向量。  $\mathbf{T}_F$  依据下式可从  $\hat{\mathbf{C}}_F$  中估计出来,

$$[\mathbf{t}]_d = \frac{1}{I_d} \sum_{k_i \in \mathbf{W}_n, k_j \in \mathbf{W}_n, k_i - k_j = d} [\hat{\mathbf{C}}_F]_{i,:} [\hat{\mathbf{C}}_F]_{j,:}^H \#(23)$$

其中,  $[\cdot]_{i,:}$  表示矩阵的第  $i$  行,  $I_d$  表示加项的总和,  $k_i \in \mathbf{W}_n$  表示对应  $\hat{\mathbf{C}}_F$  的第  $i$  行有源器件的索

表 2 基于多层采样的有源器件部署方案

算法 1	
输入:	$N_i, N_n$ 和 $\Omega, F$
输出:	$\{\mathbf{C}_F\}$ 和 $\{\mathbf{Y}_F\}$
1:	根据公式 (11) 或 (12) 生成 UBS 或 GNS 的确定性采样模式 $\{\mathbf{X}_R\}, \{\mathbf{X}_T\}$
2:	使用确定性采样模式得到 $N_{n,s}$ 和 $N_{t,s}$ 以及公式 (10) 生成 $\mathbf{C}_F \in \mathbb{C}^{N_{n,s} \times N_{t,s}}$
3:	使用生成的 $\{\mathbf{C}_F\}$ 和均匀空间采样模式 $\Omega, F$ 根据公式 (15) 生成 $\{\mathbf{Y}_F\}$
4:	返回噪声观测 $\{\mathbf{Y}_F\}$




图5 协方差矩阵  $T_F$  和其中被采样的元素

$$\min_{\gamma_F} \left\| P_{\Omega}((X_T^* A_T^*(\hat{\phi}_T)) \otimes (X_R A_I(\hat{\theta}_I))) \gamma_F - y \right\|^2 \text{ 满足 } \|\gamma_F\|_{l_0} = \hat{L}_F \# (24)$$

该问题可通过使用 OMP 算法高效地完成增益估计和角度配对。最后，可基于估计的角度与路径增益信息，重建用户和 IRS 之间的信道矩阵：

$$\hat{F} = \text{Mat} \left( \left( A_T^*(\hat{\phi}_T) \otimes A_I(\hat{\theta}_I) \right) \hat{\gamma}_F \right) \# (25)$$

其中， $\text{Mat}(\cdot)$  表示将括号中的参数重构为完整的信道矩阵。

## 2.2 基站到 IRS 的信道矩阵 $G$ 的估计

### 2.2.1 信道矩阵 $G$ 的采样和角度估计

第二阶段目标是估计信道  $G$  中的两个角度信息  $\theta_R$ 、 $\phi_I$  和增益  $\gamma_G$ 。与前面类似，用  $S_R \in \mathbb{C}^{N_n \times N_{n,s}}$  表示反射面处有源器件部署矩阵和  $S_T \in \mathbb{C}^{N_r \times N_{r,s}}$  表示基站处有源器件部署矩阵。

$$C_G = S_R^H G S_T \in \mathbb{C}^{N_{r,s} \times N_{n,s}} \# (26)$$

与  $Y_F$  类似，考虑均匀随机采样模式，确保  $C_G$  的每一列和每一行中至少有一个元素被观测到，在不失一般性的情况下，同样假设导频信号为单位信号，则可使用下式表示有噪声的观测样本，得到第二个信号  $Y_G$ ：

$$Y_G = A_{\Omega}(C_G + S_R^H N_G) \# (27)$$

其中，采样算子  $A_{\Omega}(\cdot)$  形式类似公式 (14)，并假

引。当  $\hat{C}_F$  有大量的列时，可精准地构建  $T_F$ ，从而准确地估计角度。根据得到的  $T_F$  和 Root-MUSIC 算法，恢复出反射面上的 AoAs 为  $\hat{\theta}_I$ 。按照相同的步骤，可恢复用户的 AoDs 为  $\hat{\phi}_T$ 。

### 2.1.3 信道矩阵 $F$ 的增益估计和重构

得到  $\hat{\phi}_T$  和  $\hat{\theta}_I$  后，可构造  $A_T^*(\hat{\phi}_T)$  和  $A_I(\hat{\theta}_I)$ ，并估计路径增益  $\gamma_F$ 。上述路径估计问题，可通过解决以下问题完成：

设  $N_G$  为加性高斯白噪声，则  $\tilde{C}_G$  是  $C_G$  的噪声模式，即  $\tilde{C}_G = C_G + S_R^H N_G$ ，其中  $N_G \in \mathbb{C}^{N_r \times N_n}$ 。非零观测值向量化表示为：

$$y_G = A_{\Omega} \text{vec}(\tilde{C}_G) \# (28)$$

其中， $A_{\Omega} \in \mathbb{B}^{\rho_{\Omega, G} N_{r,s} N_{n,s} \times N_{r,s} N_{n,s}}$ 。

可再次使用 LRMC 从  $Y_G = A_{\Omega}(\tilde{C}_G)$  中估计  $\theta_R$  和  $\phi_I$ ，由于  $C_G = S_R^H G S_T$  为低秩，估计  $C_G$  可通过求解以下式：

$$\min_{C_G} \text{rank}(C_G), \text{ 使得 } \|A_{\Omega}(C_G) - Y_G\|_F^2 \leq \delta^2 \# (29)$$

应用核范数正则化方法重新公式 (29) 为：

$$\hat{C}_G \triangleq \arg \min_{C_G} \frac{1}{2} \|A_{\Omega}(C_G) - Y_G\|_F^2 + \mu \|C_G\|_* \# (30)$$

利用核范数的 Frobenius 范数表征，令  $C_G = UV^H$ ，估计  $C_G$  可通过求解下式：

$$\min_{U, V} \frac{1}{2} \|A_{\Omega}(UV^H) - Y_G\|_F^2 + \frac{1}{2} \mu (\|U\|_F^2 + \|V\|_F^2) \# (31)$$

得到恢复后的  $\hat{C}_G$  和估计出的秩为  $\hat{L}_G$ ，可估计信道路径的到达角  $\phi_I$ 、离开角  $\theta_R$  和路径增益  $\gamma_G$ 。这与前面信道  $F$  的恢复是类似的。首先补全



低秩的 Toeplitz 协方差矩阵  $\mathbf{T}_G$ ，然后使用 root-MUSIC 算法进行估计。最后，可估计出  $\hat{\phi}_I$  和  $\hat{\theta}_R$ 。

### 2.2.2 信道矩阵 $\mathbf{G}$ 的增益估计和重构

得到  $\hat{\theta}_R$  和  $\hat{\phi}_I$  后，可构造  $\mathbf{A}_R^*(\hat{\theta}_R)$  和  $\mathbf{A}_I(\hat{\phi}_I)$ ，

$$\min_{\gamma_G} \left\| \mathbf{A}_\Omega \left( \left( \mathbf{S}_R^* \mathbf{A}_I^*(\hat{\phi}_I) \right) \otimes \left( \mathbf{S}_T \mathbf{A}_R(\hat{\theta}_R) \right) \right) \gamma_G - \mathbf{y}_G \right\|^2 \text{ 满足 } \|\gamma_G\|_{l_0} = \hat{L}_G \# (32)$$

使用 OMP 算法可有效解决这个问题。最后，基于配对的角度信息和路径增益信息，可构建出基站和 IRS 之间的矩阵为：

$$\hat{\mathbf{G}} = \text{Mat} \left( \left( \mathbf{A}_I^*(\hat{\phi}_I) \otimes \mathbf{A}_R(\hat{\theta}_R) \right) \hat{\gamma}_G \right) \# (33)$$

### 2.3 用户到基站的信道矩阵 $\mathbf{H}$ 的重建

得到了用户到 IRS 之间的原始全维信道矩阵  $\hat{\mathbf{F}}$  和 IRS 到基站的矩阵  $\hat{\mathbf{G}}$  后根据公式 (7)，可将级联信道重建为：

$$\hat{\mathbf{H}} \triangleq \hat{\mathbf{F}}^T \diamond \hat{\mathbf{G}} \# (34)$$

## 3 性能分析

### 3.1 计算复杂度分析

本小节分析所提方法的计算复杂度。根据文献[25]，总结了所需实数浮点运算次数。计算复杂度主要来源于 LRMC、角度估计、增益估计和角度配对，下面将详细介绍以上方法的复杂度：

LRMC: 算法 2 步骤 1 应用了文献[26]中的 GCG-ALTMIN 算法完成低秩矩阵补全，而 LRMC

过程需要  $8\hat{L}_F B N_{l,s} N_{n,s} + \frac{1}{3} \hat{L}_F (\hat{L}_F +$

但尚须对角度进行配对，并估计路径增益  $\gamma_G$ 。上述问题可通过解下述问题完成：

$1) \left[ \rho_{\Omega_F} N_{l,s} N_{n,s} (16\hat{L}_F + 32) + (N_{l,s} + N_{n,s}) (3\hat{L}_F^2 + 19\hat{L}_F + 18) \right]$  次实数运算，其中  $B = 93 + 4\rho_{\Omega_F}$ ， $I$  表示迭代次数。毫米波信道通常是比较稀疏的，因此信道矩阵的秩一般较低。依据文献[26]，迭代次数  $I = 10$ ，路径数  $\hat{L}_F \ll N_n$ ，2 或 3 是其典型取值。相比之下，若将文献[25]中基于 LRMC 的方法直接应用于未采样的原始信道，其计算复杂度为： $8\hat{L}_F B N_n N_t + \frac{1}{3} \hat{L}_F (\hat{L}_F + 1) \left[ \rho_{\Omega_F} N_n N_t (16\hat{L}_F + 32) + (N_n + N_t) (3\hat{L}_F^2 + 19\hat{L}_F + 18) \right]$ 。例如，当  $N_t = N_n = 128$ 、 $N_{l,s} = N_{n,s} = 22$  时，所提估计器可将 LRMC 的复杂度降低  $(128/22)^2 \approx 34$  倍。

角度估计：算法 2 步骤 2 由于涉及的协方差矩阵具有 Toeplitz 结构， $\mathbf{T}_F$  的计算复杂度较低，为  $\mathcal{O}(N_s^3)$ ，同时，算法 2 步骤 3 中的 root-MUSIC 算法的复杂度为  $\mathcal{O}(N_\mu^3)$ 。所以角度估计大约需要  $\mathcal{O}(N_{l,u}^3 + N_{n,u}^3)$  次实数运算。

增益估计和角度配对：本部分运用的 OMP 算法基于估计出的角度信息设计码本，其维度极

表 3 半有源 IRS 信道参数估计与重建

算法 2
输入: $\{\mathbf{Y}_F\}$ 和 $\{\mathbf{Y}_G\}$
输出: $\{\hat{\mathbf{H}}\}$
1: 使用 GCG-ALTMIN 算法分别从 $\{\mathbf{Y}_F\}$ 和 $\{\mathbf{Y}_G\}$ 中恢复 $\{\hat{\mathbf{C}}_F\}$ 和 $\{\hat{\mathbf{C}}_G\}$
2: 利用协方差矩阵的 Toeplitz 结构按照公式 (23) 构建 $\{\mathbf{T}_F\}$ 和 $\{\mathbf{T}_G\}$
3: 通过 root-MUSIC 算法分别从 $\{\mathbf{T}_F\}$ 和 $\{\mathbf{T}_G\}$ 中估计出 $\{\hat{\theta}_I\}$ 、 $\{\hat{\phi}_T\}$ 、 $\{\hat{\theta}_R\}$ 、 $\{\hat{\phi}_I\}$
4: 使用 OMP 算法，并基于 $\{\hat{\theta}_I\}$ 、 $\{\hat{\phi}_T\}$ 、 $\{\hat{\theta}_R\}$ 、 $\{\hat{\phi}_I\}$ 同时完成角度配对并估计出增益 $\{\hat{\gamma}_F\}$ 和 $\{\hat{\gamma}_G\}$
5: 通过公式 (25) 和 (33) 构建信道 $\{\hat{\mathbf{F}}\}$ 和 $\{\hat{\mathbf{G}}\}$
6: 利用估计出的 $\{\hat{\mathbf{F}}\}$ 和 $\{\hat{\mathbf{G}}\}$ 公式 (34) 重建级联信道 $\{\hat{\mathbf{H}}\}$

低，因此算法2步骤4中路径增益估计和角度配对的运算量较低，仅需  $20\hat{L}_F^2 N_{t,s} N_{n,s}$  次实数运算。

上述复杂度分析表明，本方法复杂度主要取决于  $N_s$  和  $N_u$ 。使用确定性采样可降低整体采样率  $\rho_{O,F}$ ，并获得较小的  $N_s$ 。具体而言，采用 GNS 模式时，满足  $N_{t,s} \ll N_{t,u} \leq N_t, N_{n,s} \ll N_{n,u} \leq N_n$ ，而基于 UBS 模式  $N_{t,s} = N_{t,u} \ll N_t, N_{n,s} = N_{n,u} \ll N_n$ 。因此，使用 GNS 比文献[26]中的方法复杂度更低，因为后者需要对大小为  $N_n \times N_t$  的信道矩阵进行 LRMC 估计，而不是大小为  $N_{n,s} \times N_{t,s}$  的子信道  $C_F$ 。此外，与部署相同数量有源器件的 UBS 相比，GNS 由于  $N_{n,s} \ll N_{n,u}$ ，可获得更大的孔径，空间分辨率更好<sup>[21]</sup>。与基于 ANM 的估计器相比，所提方法由于独特的多层采样过程，复杂性较低。此外，ANM 估计的复杂性主要由求解 SDP 决定，需要  $\mathcal{O}\left((N_t + N_n)^{3.5}\right)$  次操作，通常较高<sup>[13]</sup>。总体而言，本文所提方法可根据不同的采样模式适应各种应用需求，实现复杂性和性能之间的权衡。

### 3.2 导频开销分析

本小节分析所提方法的导频开销。本文通过使用确定性采样器  $X_T, X_R, S_T, S_R$  和随机采样器  $P_\Omega, A_\Omega$  显著降低了  $F$  和  $G$  的维度，从而极大地减少了导频开销。导频开销由总体采样率决定，即  $\rho_{O,F}$  和  $\rho_{O,G}$ 。以估计  $F$  信道矩阵为例，当部署  $N_{n,s}$  和  $N_{t,s}$  个器件以及  $Q_n$  个反射面射频链路组成子信道  $C_F \in \mathbb{C}^{N_{n,s} \times N_{t,s}}$  时，需要发射  $\rho_{\Omega,F} N_{n,s} N_{t,s}$  个导频信号，而恢复子信道仅需要使

用  $\max\{N_{t,s}, \lceil \rho_{\Omega,F} N_{n,s} N_{t,s} / Q_n \rceil\}$  次信道以获得观测信号  $y_F$ ，对比文献 [25] 中需要使用  $\max\{N_t, \lceil \rho_{\Omega,F} N_t N_n / Q_n \rceil\}$  次信道获得观测信号，所提方法能够显著降低导频开销。

### 3.3 功耗分析

本小节分析所提方法对于功耗的作用。半有源 IRS 中有源器件功耗由  $P_{IRS} = N_{n,s} P_{RF}$  决定，其中  $N_{n,s}$  是半有源系统中部署的有源器件数量， $P_{RF}$  是每个有源器件的功率。由此可知半有源 IRS 中有源器件功耗与有源器件的数量成正比，因此，采用多层采样模式减少有源器件的部署数量，可降低功耗。

## 4 仿真分析

本节围绕半有源 IRS 信道估计的仿真结果展开分析。基于引言所综述的内容，现有针对超分辨率信道估计的研究多基于均匀采样的部署方案与 ANM 理论的算法框架方法，因此本部分选择基于均匀采样及 ANM 方法，用于对比所提方法在导频开销、计算复杂度以及估计精度性能。在本文的仿真实验中，设置用户端和 IRS 之间的路径数  $L_F = 2$ ，IRS 和基站之间的路径数  $L_G = 2$ 。IRS 总器件数为  $N_n = 128$ ，用户和基站处器件数为  $N_t = N_r = 64$ ，蒙特卡洛循环次数为 400 次。式 (1) 和 (2) 中的路径增益  $\gamma_{F,l}$  和  $\gamma_{G,l}$  服从  $\mathcal{CN}(0, 1)$ ，同时所有的 AoDs 和 AoAs 在  $[30^\circ, 150^\circ]$  内均匀分布。半有源信道的归一化均方误差 (Normalized Mean Square Error, NMSE) 定

表3 计算复杂度分析

算法	计算复杂度
ANM <sup>[13]</sup>	$\mathcal{O}\left((N_t + N_n)^{3.5}\right)$
LRMC	$\frac{1}{3} \hat{L}_F (\hat{L}_F + 1) \left[ \rho_{\Omega,F} N_{t,s} N_{n,s} (16\hat{L}_F + 32) + (N_{t,s} + N_{n,s}) (3\hat{L}_F^2 + 19\hat{L}_F + 18) \right] + 8\hat{L}_F (93 + 4\rho_{\Omega,F}) N_{t,s} N_{n,s}$
角度估计	$\mathcal{O}\left(N_{t,u}^3 + N_{n,u}^3\right)$
增益估计和角度配对	$20\hat{L}_F^2 N_{t,s} N_{n,s}$



义为:

$$NMSE = \frac{\left\| \text{vec}(\mathbf{H}) - \text{vec}(\hat{\mathbf{H}}) \right\|_F^2}{\left\| \text{vec}(\mathbf{H}) \right\|_F^2} \quad (35)$$

同时, 设置导频信噪比  $\text{PNR} = 10 \log_{10} \left( \frac{1}{\sigma_n^2} \right)$ 。

本文研究了不同PNR下的均方误差。

图6中展示了五种不同采样比率的随机采样和LS估计结果及其95%的置信区间, 采样比率分别为5%、10%、25%、50%、全采样。结果显示, 所提方法的NMSE在低导频开销时好于传统的LS估计方法, 并且所提方法的NMSE性能随着随机采样比率的增大会逐渐变好, 在PNR=10 dB时, 全采样的NMSE比5%采样率的NMSE低17.47 dB, 同时比LS估计方法低21.69 dB。

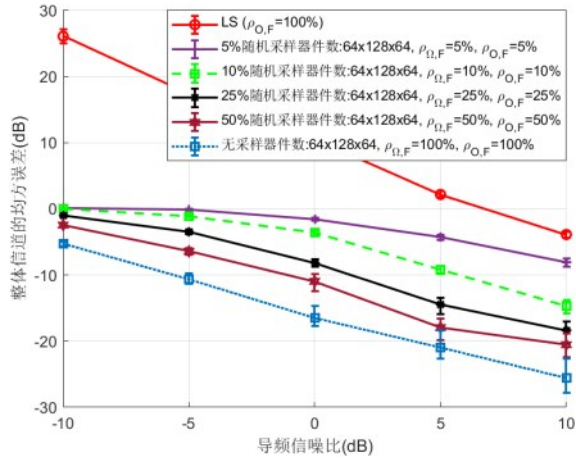


图6 所提方法在不同采样率下的NMSE性能对比其95%的置信区间

图7中展示了所提方法在UBS模式和GNS模式下的NMSE性能, 并将所提方法与LS估计方法进行对比。结果显示, 随着PNR的增大, GNS模式的估计精度会逐渐好于UBS模式, 在PNR=10 dB时GNS模式的NMSE比UBS低3.53 dB, 同时比LS估计方法低16.98 dB, 这表明GNS模式在信道恢复方面具有显著优势。

图8展示了所提方法在UBS+LRMC采样模




图7 基于UBS和GNS模式的NMSE性能对比

式和GNS+LRMC采样模式下的NMSE性能。结果显示, 当 $\rho_{O,F}$ 分别为2.36%和5.91%时GNS+LRMC的双层采样模式的NMSE比UBS+LRMC的双层采样模式的NMSE低3.72 dB和3.81 dB, 且再导频开销进一步减小的情况下, 如当 $\rho_{O,F}=2.36\%$ 时, GNS+LRMC双层采样模式的NMSE为-11.28 dB, 仍可准确地估计信道参数, 这进一步表明GNS模式在信道恢复方面具有显著优势。




图8 基于UBS/GNS+LRMC采样模式的NMSE性能对比

图9对比了UBS、GNS、LRMC、GNS+LRMC、UBS+LRMC、无采样六种不同采样模式的NMSE性能。结果显示, 由于随机和确定性采样减少了导频需求, 导频开销非常低, 但所提方法的NMSE性能仍然表现良好。此外, 当PNR=

10 dB 且采样比率  $\rho_{O,F}=11.82\%$  时, GNS 模式的 NMSE 比 UBS 模式的 NMSE 低 3.5 dB, 这是因为 GNS 的子阵列的孔径大于 UBS。当在 GNS 基础上结合第二层采样, 即 GNS+LRMC 时采样比率  $\rho_{O,F}=5.91\%$ , 其 NMSE 仍比 UBS+LRMC 低 3.81 dB, 比随机采样低 6.8 dB。这是因为如果仅采用随机采样而不缺乏确定性部署, Toeplitz 矩阵的关键位置易因观测样本不足而无法有效恢复, 这会导致协方差结构的重构难以稳定实现, 造成超分辨率估计性能受损。因此, 本文将确定性采样与随机采样相融合: 通过确定性采样确保 Toeplitz 矩阵的对角线元素获得充足观测样本, 以保障其可靠恢复; 在此基础上, 利用样本矩阵的低秩特性实施随机采样, 并通过 LRMC 恢复出满足精度要求的协方差矩阵, 从而在不破坏矩阵固有结构的前提下, 进一步减少观测数据量与有源器件的使用数量。基于这一精心设计的采样模式, 仅需少量观测数据, 即可在低训练开销与计算成本下, 实现超分辨率参数的有效估计。这清晰地表明 GNS+LRMC 模式在信道恢复方面具有显著优势。




图9 单独GNS/UBS与GNS/UBS+LRMC的NMSE性能对比

图 10 对比了本文所提方法和经典的 ANM 估计方法在不同 PNR 条件下, 有源器件数相同时, 反射面的 NMSE 性能。用户端和 IRS 之间的路径

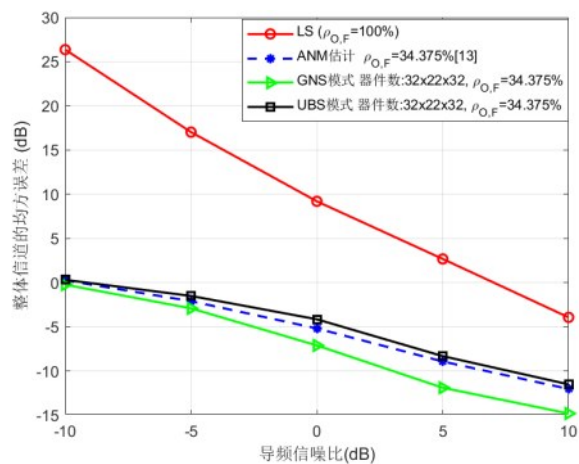


图10 所提方法与ANM方法的NMSE性能对比

数  $L_F=2$ , IRS 和基站之间的路径数  $L_G=2$ 。IRS 总器件数为  $N_n=64$ , 用户和基站处器件数为  $N_t=N_r=32$ , 400 次蒙特卡洛循环。用户和 IRS 之间的信道  $\mathbf{F}$  的总体采样比率  $\rho_{O,F}=34.375\%$ , IRS 上有源器件数为 22。结果表明, 当 PNR = 10 dB 且有源器件数相同时, UBS 模式的估计精度接近传统的 ANM 方法, 但 ANM 方法的计算复杂度约为 UBS 模式的 100 倍。而 GNS 模式在相同采样比率下的 NMSE 比 ANM 方法低 3.26 dB 且 ANM 方法的计算复杂度约为 GNS 模式的 15 倍。这进一步表明 GNS 模式在信道恢复方面具有显著优势。

### 5 结束语

本文系统性的提出了一种基于确定性和随机采样的半有源 IRS 系统超分辨率信道估计方案, 旨在解决半有源 IRS 信道估计中存在的高导频开销和高计算复杂度的问题。该方法利用半有源 IRS 信道矩阵的低秩特性和其协方差矩阵的 Toeplitz 结构, 通过设计多层采样方案, 有针对性地部署有源器件从而减少其数量, 可显著降低导频开销。在恢复阶段, 利用 LRMC 理论结合 GCG-ALTMIN 算法有效降低了计算复杂度, 随后采用低复杂度的 root-MUSIC 算法实现超分辨率的角度估计, 并基于准确估计的角度信息构建



低维度的码本，结合 OMP 完成信道增益估计。结果表明，所提方法相较于现有基于 ANM 类随机有源器件部署的方案，在相同导频开销下可显著降低计算复杂度。基于具有更大孔径的 GNS 模式部署有源器件位置，并配置其数量，所提方案可获得更高的参数估计精度。上述仿真结果验证了所提方案在半有源 IRS 系统信道参数估计中的实用性和高效性。此外，本研究还可扩展至更广泛场景，包括均匀平面阵列、高速移动以及多用户场景。

### 参考文献:

- [1] Kang Z, You C, Zhang R. Active-passive IRS aided wireless communication: New hybrid architecture and elements allocation optimization[J]. *IEEE Transactions on Wireless Communications*, 2023, 23(4): 3450-3464.
- [2] Hu X, Liu C, Peng M, et al. IRS-based integrated location sensing and communication for mmWave SIMO systems[J]. *IEEE Transactions on Wireless Communications*, 2022, 22(6): 4132-4145.
- [3] Wu Q, Zhang S, Zheng B, et al. Intelligent reflecting surface-aided wireless communications: A tutorial[J]. *IEEE Transactions on Communications*, 2021, 69(5): 3313-3351.
- [4] Wu Q, Zhang R. Towards smart and reconfigurable environment: Intelligent reflecting surface aided wireless network[J]. *IEEE Communications Magazine*, 2019, 58(1): 106-112.
- [5] Zheng B, You C, Mei W, et al. A survey on channel estimation and practical passive beamforming design for intelligent reflecting surface aided wireless communications[J]. *IEEE Communications Surveys & Tutorials*, 2022, 24(2): 1035-1071.
- [6] Zappone A, Di Renzo M, Shams F, et al. Overhead-aware design of reconfigurable intelligent surfaces in smart radio environments[J]. *IEEE Transactions on Wireless Communications*, 2020, 20(1): 126-141.
- [7] Taha A, Alrabeiah M, Alkhateeb A. Enabling large intelligent surfaces with compressive sensing and deep learning[J]. *IEEE Access*, 2021, 9: 44304-44321.
- [8] Liu S, Gao Z, Zhang J, et al. Deep denoising neural network assisted compressive channel estimation for mmWave intelligent reflecting surfaces[J]. *IEEE Transactions on Vehicular Technology*, 2020, 69(8): 9223-9228.
- [9] Han Z, Wang H, Wang Y, et al. Adaptive Channel Estimation for Semi-Passive IRS with Optimized Sensor Deployment[J]. *Sensors*, 2025, 25(21): 6797.
- [10] Masood K F, Tong J, Xi J, et al. Inductive matrix completion and root-MUSIC-based channel estimation for intelligent reflecting surface (IRS)-aided hybrid MIMO systems[J]. *IEEE Transactions on Wireless Communications*, 2023, 22(11): 7917-7931.
- [11] Alexandropoulos G C, Vlachos E. A hardware architecture for reconfigurable intelligent surfaces with minimal active elements for explicit channel estimation[C]//ICASSP 2020-2020 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP). IEEE, 2020: 9175-9179.
- [12] Schroeder R, He J, Juntti M. Passive RIS vs. hybrid RIS: A comparative study on channel estimation[C]//2021 IEEE 93rd Vehicular Technology Conference (VTC2021-Spring). IEEE, 2021: 1-7.
- [13] Schroeder R, He J, Brante G, et al. Two-stage channel estimation for hybrid RIS assisted MIMO systems[J]. *IEEE Transactions on Communications*, 2022, 70(7): 4793-4806.
- [14] Jian M, Zhao Y. A modified off-grid SBL channel estimation and transmission strategy for RIS-assisted wireless communication systems[C]//2020 International Wireless Communications and Mobile Computing (IWCMC). IEEE, 2020: 1848-1853.
- [15] Jin Y, Zhang J, Zhang X, et al. Channel estimation for semi-passive reconfigurable intelligent surfaces with enhanced deep residual networks[J]. *IEEE Transactions on Vehicular Technology*, 2021, 70(10): 11083-11088.
- [16] Chen X, Shi J, Yang Z, et al. Low-complexity channel estimation for intelligent reflecting surface-enhanced massive MIMO [J]. *IEEE Wireless Communications Letters*, 2021, 10(5): 996-1000.
- [17] Haider M A, Zhang Y D, Aboutanios E. Channel estimation and prediction in wireless communications assisted by semi-passive RIS[C]//ICASSP 2024-2024 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP). IEEE, 2024: 8601-8605.
- [18] Haider M A, Zhang Y D, Ding Y, et al. Semi-Passive RIS-Aided Sequential Channel Estimation and Prediction[C]//2024 IEEE 13rd Sensor Array and Multichannel Signal Processing Workshop (SAM). IEEE, 2024: 1-5.
- [19] Hu X, Zhang R, Zhong C. Semi-passive elements assisted channel estimation for intelligent reflecting surface-aided communications[J]. *IEEE Transactions on Wireless Communications*, 2021, 21(2): 1132-1142.
- [20] Hu X, Liu C, Peng M, et al. IRS-based integrated location sensing and communication for mmWave SIMO systems[J]. *IEEE*

Transactions on Wireless Communications, 2022, 22(6): 4132-4145.

[21] Liu T, Masood K F, Tong J, et al. Two-Fold Sampling-Based Super-Resolution Estimation of Low-Rank MIMO-OFDM Channels[J]. IEEE Open Journal of the Communications Society, 2024.

[22] Lin Y, Jin S, Matthaiou M, et al. Tensor-based algebraic channel estimation for hybrid IRS-assisted MIMO-OFDM[J]. IEEE Transactions on Wireless Communications, 2021, 20(6): 3770-3784.

[23] Li H, He B, Li G, et al. Graph-Based Element Deployment and Channel Estimation for IRS-Aided Wireless Communications [J]. IEEE Wireless Communications Letters, 2025.

[24] Qiao H, Pal P. Generalized Nested Sampling for Compressing

Low Rank Toeplitz Matrices[J]. IEEE Signal Processing Letters, 2015, 22(11): 1844-1848.

[25] Hu R, Tong J, Xi J, et al. Matrix completion-based channel estimation for mmWave communication systems with array-inherent impairments[J]. IEEE Access, 2018, 6: 62915-62931.

[26] Masood K F, Hu R, Tong J, et al. A low-complexity three-stage estimator for low-rank mmWave channels[J]. IEEE Transactions on Vehicular Technology, 2021, 70(6): 5920-5931.

[作者简介]

郑明坤（2001-），男，杭州电子科技大学通信工程学院硕士生，主要研究方向为智能反射面通信系统。



刘天乐（1988-），男，杭州电子科技大学通信工程学院讲师，主要研究方向为绿色通信。



潘鹏（1983-），男，杭州电子科技大学通信工程学院教授，主要研究方向为MIMO及大规模



MIMO 预编码和容量分析、多用户检测。

郑雅文（1995-），女，北京跟踪与通信技术研究所，主要研究方向为5GNTN。





聂柏润（1994-），男，博士，中国电子科技集团公司第五十研究所总体部工程师，主要研究方向



为通感一体、太赫兹通信、信号处理等。

何腾蛟（1990-），男，暨南大学信息科学技术学院副教授，主要研究方向为边缘智能。

