# RIS辅助通信的混合场联合信道与可见区域估计

Xiaokun Tuo，IEEE研究生会员，Ming-Min Zhao，IEEE高级会员，Xiang Wang，Changsheng You，IEEE会员，以及Min-Jian Zhao，IEEE会员

arXiv:2602.06313v1 [eess.SP] 6 Feb 2026

摘要——在可重构智能表面（RIS）辅助的毫米波（mmWave）通信系统中，大规模RIS会产生显著的几何效应，导致远场与近场传播并存。此外，随机遮挡会使RIS阵列呈现空间非平稳性，导致来自不同散射体的信号仅照射部分区域，这些区域称为可见区域（VRs）。因此，传统的远场、全可见阵列信道模型已不再适用，信道估计也变得尤具挑战性。本文研究混合场传播环境下的非平稳级联信道估计问题，其中RIS-基站（BS）链路处于远场，而用户-RIS链路则具有近场特征和部分可见性。为解决由此产生的高维耦合估计问题，本文利用级联信道的结构特征，构建了一种降维稀疏双线性表示。具体而言，本文提出一种字典压缩技术，利用由可见性矩阵加权的低维极域字典表示高维耦合字典，从而显著降低问题规模。基于这一表示，本文提出一种涡轮结构化联合贝叶斯估计（TS-JBE）方法，以同时估计信道增益、可见区域和离网参数，从而避免现有序贯方法中固有的误差传播。仿真结果表明，与现有方法相比，所提方法显著提高了估计精度。

索引词——可重构智能表面、混合场、信道估计、可见区域、贝叶斯估计。

## I. 引言

WITH 随着移动设备数量迅速增长以及无线应用日益普及，未来无线网络在峰值数据速率、频谱效率、能量效率和可靠性方面正面临前所未有的挑战 [1], [2]。作为第六代（6G）通信的一种有前景的候选方案，可重构智能表面（RIS）凭借能够以经济高效、节能的方式重构无线传播环境，近来受到广泛关注 [3], [4]。可重构智能表面通常由大量近乎无源的反射单元构成，其反射系数可通过编程来调控入射电磁波的相位 [3], [4]。通过对这些单元进行适当配置，可重构智能表面能够提供额外的自由度，以增强信号覆盖、抑制干扰，并提高频谱效率和能量效率。由于硬件成本低、功耗可忽略且易于部署，可重构智能表面能够密集集成到现有无线基础设施中，因此在大规模、高频段的 6G 场景中尤其具有吸引力。

然而，RIS辅助系统的性能增益在很大程度上依赖于准确的信道状态信息（CSI）。与传统的有源天线阵列不同，RIS单元是无源的，无法接收信号或进行基带处理，这使得CSI获取极具挑战性 [5]。此外，RIS通常包含大量反射单元，导致RIS相关级联信道的维度随阵列规模快速增加。尽管已有研究提出开关反射方案，通过在训练阶段选择性地激活RIS单元来解耦级联信道，从而能够采用传统的信道估计方法 [6], ，但此类方法仍会带来过高的训练开销和较高的计算复杂度。为应对这些挑战，研究人员已对RIS辅助通信系统中的信道估计开展了大量研究。为实现所有RIS单元同时激活条件下的信道估计，研究者在合理设计的训练协议下，提出了基于传统估计器的方法，例如最小二乘（LS） [7], [8] 和线性最小均方误差（LMMSE） [9], 方法。此外，基于压缩感知（CS）的方法利用级联信道的稀疏性来降低导频开销，其中包括改进的正交匹配追踪（OMP）算法 [10], [11]。此外，基于矩阵分解的方法进一步利用级联信道的稀疏性和低秩特性，实现高效的信道估计 [12], [13]。

值得注意的是，上述工作均是在远场平面波假设下开展的。然而，为满足6G系统严苛的性能要求，可重构智能表面预计将以较大的物理孔径进行部署，并工作于毫米波乃至太赫兹频率。因此，瑞利距离显著增大，用户或散射体往往位于可重构智能表面的近场区域。在此类场景下，传统平面波模型变得不再准确，而球面-

X. Tuo、M. M. Zhao 和 M. J. Zhao 就职于中国杭州 310027 的浙江大学信息与电子工程学院，同时就职于中国杭州 310027 的浙江省多模态通信网络与智能信息处理重点实验室（电子邮箱：xktuo@zju.edu.cn；zmmblack@zju.edu.cn；mjzhao@zju.edu.cn）。X. Wang 就职于中国西安 710077 的空军工程大学信息与导航学院（电子邮箱：lleafwx626@126.com）。C. You 就职于中国深圳 518055 的南方科技大学（SUSTech）电子与电气工程系（电子邮箱：youcs@sustech.edu.cn）。

波传播需要被纳入，以实现准确的信道建模与估计。与平面波假设下所呈现的角度域稀疏性不同，采用球面波传播建模的信道在极域中具有固有稀疏性。为有效捕捉这一特性以进行近场信道估计， [14] 提出了一种新颖的极域网格构造方案，从而能够在极域中对近场信道进行稀疏表示。在球面波传播模型的基础上，近期研究探索了可重构智能表面辅助系统的近场信道估计。已提出分阶段方法，以逐步恢复级联信道的角度域与极域参数，从而降低训练开销 [15]。除此之外，针对超大智能反射面（XL-IRS）辅助的正交频分复用（OFDM）系统，已提出统一混合场信道模型，其中采用基于张量的OMP与变分贝叶斯推断（VBI）相结合的方法来联合估计并跟踪信道 [16]。此外， [17] 考虑了双RIS辅助毫米波通信场景，采用了基于球面波的近场信道模型，并提出了一种级联信道建模与分析方法，以刻画近场传播效应并评估系统性能。

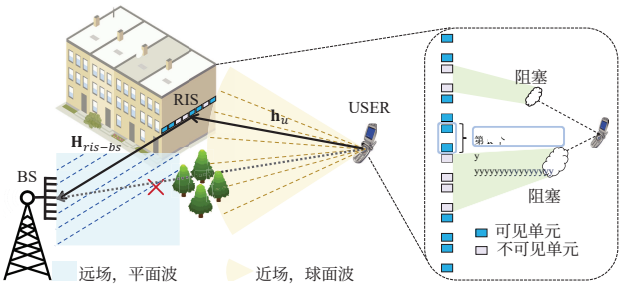



图1：所考虑的可重构智能表面辅助毫米波系统模型。

除了近场传播之外，RIS阵列规模的扩大不可避免地会引入空间非平稳性 [18]。具体而言，由于几何效应和随机遮挡，与不同散射体相关联的信号仅照射RIS的部分区域，这些区域称为可见区域（VR）。忽略空间非平稳性会导致严重的模型失配和性能下降，尤其是在部署大孔径RIS时。为了解决这一问题，一些研究探讨了RIS辅助通信系统中的可见区域检测与信道估计联合处理。例如， [19] 研究了XL-RIS辅助系统中的近场定位与信道重建联合方法。然而，该研究主要考虑RIS与用户之间的视距（LoS）路径，而忽略了非视距（NLoS）多径分量，因此在实际环境中的适用性有限。在 [20], 中，研究者提出了RIS系统的混合信道模型，并引入可见区域的概念，同时提出了一种两阶段算法，用于联合执行信道估计和可见区域检测。然而，两阶段处理所导致的固有误差传播仍不可避免，并会降低整体估计性能。

受上述观测值启发，本文研究可重构智能表面辅助通信系统中的级联信道估计问题。我们提出一种联合贝叶斯估计方法，可同时推断级联稀疏信道增益、可见区域和离网参数。本文的主要贡献总结如下：

- 针对可重构智能表面辅助毫米波系统，构建了一种混合场级联信道模型，其中可重构智能表面-基站（BS）信道采用远场建模，而用户-基站信道则通过显式的可见区域建模来刻画具有近场传播特性的空间非平稳性。

- 通过利用级联的结构特征信道，引入了一种面向高维耦合字典的压缩策略，以构建降维稀疏双线性信道表示，从而显著降低问题规模，并有效缓解由此产生的多维强耦合估计问题。

- 基于所提出的信道表示，提出了一种Turbo结构联合贝叶斯估计（TS-JBE）方法，以联合估计级联稀疏信道增益、可见区域和离网参数，从而避免传统分阶段估计方案中固有的误差传播。

- 仿真结果表明，与现有方法相比，所提出的方法具有更优的归一化均方误差（NMSE）性能，验证了其在混合场和空间非平稳传播条件下的有效性。

本文其余部分安排如下。第二节介绍系统模型。第三节介绍级联信道的稀疏表示和分层稀疏先验模型。第四节详细阐述所提出的 TS-JBE 算法。第五节给出数值结果，以验证所提出方法的有效性。最后，第六节总结全文。

记号：标量、向量和矩阵分别用大小写字母、粗体小写字母和粗体大写字母表示。一般向量 $\mathbf{z}$ 的转置、共轭和共轭转置分别表示为 $\mathbf{z}^T$、$\mathbf{z}^*$ 和 $\mathbf{z}^H$。算子 $\|\cdot\|$ 和 $|\cdot|$ 分别表示 $\ell_2$-范数和绝对值。记号 $\langle f(z)\rangle_{q(z)} = \int f(z)q(z)\,\mathrm{d}z$ 表示关于随机变量 $z$ 的 $f(z)$ 的期望，其中该随机变量服从 $q(z)$。diag(z) 表示对角线为 z 的对角矩阵，vec(Z) 将 Z 的各列堆叠成一个向量。其逆算子 $\mathrm{unvec}_{r\times c}(\cdot)$ 按列方式将长度为 $rc$ 的向量重构为 $r \times c$矩阵。$\Re(\cdot)$ 和 $\Im(\cdot)$分别表示实部和虚部。 $\odot$、 $\otimes$、 $*$和 $\bullet$ 分别表示 Hadamard 积、Kronecker 积、按行卡特里-拉奥积和按列卡特里-拉奥积。$\mathbb{R}$ 和 $\mathbb{C}$ 分别表示实数集和复数集。$\mathcal{CN}(\boldsymbol{z};\,\boldsymbol{\mu},\boldsymbol{\Sigma})$ 表示均值为 $\boldsymbol{\mu}$、协方差为 $\boldsymbol{\Sigma}$的复高斯分布，$\Gamma(z;\,a,b)$ 表示形状参数为 $a$ 、率参数为 $b$的伽马分布。

## II. 系统模型

如图1所示，考虑一种工作于毫米波频段、采用时分双工（TDD）模式的 RIS辅助多输入多输出（MIMO）系统。基站配备 $M$ 根天线，而可重构智能表面包含 $N$个反射单元，满足 $N \gg M$。可重构智能表面被划分为 $K$ 个子阵列，每个子阵列包含 $N/K$ 个反射单元。在每个子阵列内，假设所有单元具有相同的可见性，因为在较小孔径 [21]上，信道可视为空间平稳的。系统为一名单天线用户提供服务，可重构智能表面部署在其附近，以提升通信性能。[1] 基站和可重构智能表面均采用半波长间距的均匀线性阵列（ULA），即 $d = \lambda/2$。假设直达用户-基站链路被障碍物（例如树木或建筑物）阻挡，因此通信完全依赖级联用户-RIS和RIS-基站信道，其中 $\mathbf{h}_u \in \mathbb{C}^{N\times 1}$ 和 $\mathbf{H} \in \mathbb{C}^{M\times N}$ 分别表示相应的信道增益。

### A. 信道模型

在传统阵列建模中，通常采用平面波假设来表征位于远场区域的目标。此时，含有 $N$ 个阵元的 ULA 的阵列响应向量（ARV）为 $\mathbf{a}^f(\varphi) = [1, e^{-j\frac{2\pi}{\lambda}d\varphi}, \cdots, e^{-j\frac{2\pi}{\lambda}(N-1)d\varphi}]^T$，其中 $d$ 为阵元间距，$\lambda$ 为载波波长，$\varphi = \cos\phi$ 为空间角，对应于物理到达角（AoA）或出发角（AoD）。当目标进入近场区域时，平面波模型不再适用，需要采用球面波假设来表征波前曲率 [1]。因此，近场阵列响应向量可表示为 $\mathbf{a}^n(\vartheta, r) = [e^{-j\frac{2\pi}{\lambda}r^{(1)}(\vartheta,r)-r}, \cdots, e^{-j\frac{2\pi}{\lambda}r^{(N)}(\vartheta,r)-r}]^T$（$\vartheta = \cos\theta$），其中 cos 表示空间角，$r$ 表示参考阵元到目标的距离，$r^{(n)}(\vartheta, r)$表示第 $n$ 个阵元与目标之间的距离，该距离由 $(\vartheta, r)$ 和阵列几何结构唯一确定。近场区域与远场区域由瑞利距离 $Z = 2(D_r^2+D_s^2)\lambda$ 划分，其中 $D_r$ 和 $D_s$ 分别表示接收阵列孔径和发射阵列孔径 [1]。在毫米波可重构智能表面辅助的 MIMO系统中，大量天线或反射单元会增大物理孔径。由于可重构智能表面通常部署在用户附近，用户-RIS距离往往与瑞利距离相当，甚至更小。因此，用户-RIS链路工作在近场区域，应采用球面波传播假设进行建模 [22]。相应地，用户-RIS链路和RIS-基站链路分别采用球面波传播和平面波传播建模。不失一般性，考虑一个笛卡尔坐标系，其中可重构智能表面沿 $x$ 轴放置，最左侧的阵元位于原点，即 $\mathbf{n} = [0, 0]^T$。基站阵列沿 $y$ 轴放置，最上方的基站阵元位于 $\mathbf{m} = [x_{BS}, y_{BS}]^T$。[2] 基于这一几何配置，级联信道可建模如下。

1) 用户-RIS信道：对于用户与RIS之间的第 $l$条传播路径，其中 $l \in \mathcal{L}_U$，$\{1, \ldots, L_U\}$和 $L_U$ 表示与用户相关的路径数量（$l = 1$对应于用户的视距路径），相应散射体（或用户）的位置为$\mathbf{r}_{U,l} = [r_{U,l} \quad \theta_{U,l}]^T$，$r_{U,l}$ 表示从RIS阵列到相应散射体（或用户）的参考距离。具体而言，$\mathbf{r}_{U,1} = \mathbf{u}$对应于用户位置。因此，第 $n$个RIS单元与第 $l$个散射体（或用户）之间的距离为 $r_{U,l}^{(n)} = \|\mathbf{r}_{U,l} - \mathbf{n}_n\|$，其中$\mathbf{n}_n = [(n-1)d, 0]^T$表示第 $n$个RIS单元的位置向量。基于球面波传播模型，与第 $l$条路径相关的近场阵列响应向量定义为$\mathbf{a}(\vartheta_{U,l}, r_{U,l}) = \left[e^{-j\frac{2\pi}{\lambda}(r_{U,l}^{(1)}-r_{U,l})}, \ldots, e^{-j\frac{2\pi}{\lambda}(r_{U,l}^{(N)}-r_{U,l})}\right]^T$，其中$\vartheta_{U,l} = \cos\theta_{U,l}$ 表示相应的空间角。利用菲涅耳近似 [23]，距离 $r_{U,l}^{(n)}$ 可近似为

$$r_{U,l}^{(n)} \approx r_{U,l} - (n-1)d\vartheta_{U,l} + \frac{d^2(n-1)^2(1-\vartheta_{U,l}^2)}{2r_{U,l}}. \quad (1)$$

此外，通常采用二值指示向量来捕捉信道的非平稳特性 [19], [24], [25]。我们引入 $\boldsymbol{\phi}_l \in \{0,1\}^{N\times 1}$ 来表示第 $l$条传播路径上RIS单元的可见性。具体而言，如果第 $n$个RIS单元对第 $l$条路径可见，则 $\boldsymbol{\phi}_l$ 的第 $n$个元素等于1；否则为0。根据此定义，用户-RIS信道可建模为

$$\mathbf{h}_u = \sum_{l=1}^{L_U} \alpha_l \, \mathbf{a}(\vartheta_{U,l}, r_{U,l}) \odot \boldsymbol{\phi}_l, \quad (2)$$

其中，$\alpha_l$ 表示第 $l$条路径的复值路径增益。

2）RIS-BS信道：对于BS-RIS MIMO信道，每条路径由基站处的到达角和RIS处的出发角表征。具体而言，第 $l$条路径的到达角和出发角分别表示为$\vartheta_{B,l} = \cos\theta_{B,l}$和$\varphi_{R,l} = \cos\phi_{R,l}$，其中 $l \in \mathcal{L}_{RB}$、$\{1, \ldots, L_{RB}\}$和 $L_{RB}$表示RIS与基站之间传播路径的总数。因此，RIS-BS信道可表示为

$$\mathbf{H} = \sum_{l=1}^{L_{RB}} \beta_l \, \mathbf{a}_B(\vartheta_{B,l}) \mathbf{a}_R^H(\varphi_{R,l}), \quad (3)$$

其中，$\beta_l$ 表示第 $l$条路径的复值增益。

3）混合场级联信道：用户经由可重构智能表面到基站的有效信道由可重构智能表面-基站信道 H、用户-RIS信道 $\mathbf{h}_u$ 以及施加于可重构智能表面的可配置相移决定。具体而言，第 $n$ 个 RIS单元会对反射信号施加相移 $\nu_n \in [0, 2\pi)$，对应的反射系数为 $\eta_n = e^{j\nu_n}$。将所有反射系数汇集起来，可得相移

[1]通过允许每个用户发送正交导频序列，所提出的方法可扩展到多用户场景，从而能够分离并估计每个用户的级联信道。

[2]尽管为简化起见，本文考虑二维坐标系，但通过适当修改阵列响应字典，所提出的方法可以直接扩展到三维坐标系。

向量 $\boldsymbol{\eta} = [\eta_1, \eta_2, \ldots, \eta_N]^T$，相应的对角相移矩阵表示为 $\boldsymbol{\Theta} = \mathrm{diag}(\boldsymbol{\eta})$。因此，混合场级联信道可表示为

$$\mathbf{h} = \mathbf{H}\,\boldsymbol{\Theta}\,\mathbf{h}_u. \tag{4}$$

在上行训练期间，用户以发射功率 $P_t$发送 $P$ 导频符号。经过导频相关和归一化后，得到的等效观测表示为

$$\mathbf{y}_p = \mathbf{H}\boldsymbol{\Theta}_p\mathbf{h}_u + \mathbf{n}_p = \mathbf{h}_p + \mathbf{n}_p, \mathbf{n}_p \sim \mathcal{CN}(\mathbf{0}, \tfrac{\sigma^2}{P_t}\mathbf{I}_M), \tag{5}$$

其中，$\mathrm{h}_p$ 、$\mathrm{H}\boldsymbol{\Theta}_p\mathrm{h}_u$ 表示与第 $p$ 个导频相关的有效级联信道，$\sigma^2$ 表示噪声方差。将所有导频区间内的信号堆叠可得

$$\tilde{\mathbf{y}} = [\mathbf{y}_1^T, \ldots, \mathbf{y}_P^T]^T = \tilde{\mathbf{h}} + \tilde{\mathbf{n}}, \tag{6}$$

其中，$\tilde{}\mathrm{h} = [\mathrm{h}_1^T$、.....、$\mathrm{h}_P^T]^T$以及 $\tilde{}\mathrm{n} = [\mathrm{n}_1^T$、.....、$\mathrm{n}_P^T]^T$。

III. 稀疏信道表示与先验建模

本节将构建级联信道的稀疏表示，并利用 RIS 辅助混合场传播环境的结构特征，引入相应的先验模型。具体而言，考虑索引为 $p$ 的一般导频传输。为方便记号，在不会产生歧义时省略导频索引 $p$。因此，接收信号、相应的有效级联信道和噪声分别记为 y、h 和 n，它们各自对应于由 $p$ 索引的 $\tilde{}$y、h 和 $\tilde{}$n 中的特定部分 $\tilde{}$。

A. 稀疏表示与模型变换

1）稀疏表示：为利用级联信道固有的稀疏性，采用基于网格的稀疏表示。分别为基站和可重构智能表面定义两个均匀角度网格：$\boldsymbol{\vartheta}, [\vartheta_1, \cdots, \vartheta_M]^T$和 $\boldsymbol{\varphi}, [\varphi_1, \cdots, \varphi_N]^T$，其网格点数分别为$M$和 $N$。网格点表示为$\vartheta_m = \frac{2}{M}\left(m - \frac{M+1}{2}\right)$，其中 $m \in \mathcal{M}, \{1$,$\varphi_n$.$\mp M\}$；以及$\frac{2}{N}\left(n - \frac{N+1}{2}\right)$ $n \in \mathcal{N}$ $\{1, \ldots, N\}$ $_{\mathrm{B}}$ $\vartheta_m$ $\in \mathbb{C}^{M\times 1}$，其中，。

令 a ( ) 和 $\mathrm{a}_{\mathrm{R}}(\varphi_n) \in \mathbb{C}^{N\times 1}$分别表示对应网格点处基站和可重构智能表面的远场阵列响应向量。将这些阵列响应向量堆叠后，可得到远场阵列响应字典 $\mathrm{F}_M \in \mathbb{C}^{M\times M}$和 $\mathrm{F}_N \in \mathbb{C}^{N\times N}$。因此，RIS-BS信道可表示为

。稀疏表示 $\mathrm{H} = \mathrm{F}_M\mathrm{A}\mathrm{F}_N^H$，其中 $\mathrm{A} \in \mathbb{C}^{M\times N}$是稀疏增益矩阵，上标 (○) 表示理想的在网情形。

此外，近场用户-RIS信道的空间稀疏性在极域中能够得到更自然的表征。我们构建非均匀极域网格 $[\boldsymbol{\vartheta}_u, \mathbf{r}_u]$ ，$[\vartheta_1, r_1; \cdots; \vartheta_{\bar{N}}, r_{\bar{N}}]$，其中 $N = N_pS$，而 $N_p$和 $S$分别表示角度和径向采样的数量，遵循 [14]中的离散化规则。令 $\mathrm{a}(\vartheta_{\bar{n}}, r_{\bar{n}}) \in \mathbb{C}^{N\times 1}$表示第 $\bar{n}$ 个网格点处的近场阵列响应向量，并将其堆叠以构成极域字典 $\mathrm{W} \in \mathbb{C}^{N\times\bar{N}}$。

。用户-RIS信道随后表示为 $\mathrm{h}_u = (\mathrm{W}\odot\boldsymbol{\Phi})\mathrm{b}$，其中 $\boldsymbol{\Phi}$ 是一个二进制 VR 矩阵，b 是由复数增益构成的稀疏向量。具体而言，b 的每个非零元素 $b_l$ 对应于第 $l$ 条传播路径，其可见性由 $\boldsymbol{\phi}_l$表示，即 $\boldsymbol{\Phi}$ 的第 $l$ 列，如式（2）所示。基于上述表示，整体混合场级联信道可改写为

$$\mathring{\mathbf{h}} = \mathbf{F}_M\mathbf{A}\mathbf{F}_N^H\,\mathrm{diag}(\boldsymbol{\eta})(\mathbf{W}\odot\boldsymbol{\Phi})\mathbf{b}, \tag{7}$$

2）模型变换：根据式（7）中的级联信道模型，未知参数包括远场稀疏增益矩阵 A、VR 矩阵 $\boldsymbol{\Phi}$和近场稀疏增益向量 b。这些参数通过多线性耦合关系共同表征级联信道。为便于高效进行参数推断，我们利用一些基本的矩阵恒等式对式（7）进行重新表述。具体而言，通过适当重排级联信道表达式，可将接收信号表示为关于 VR 矩阵$\boldsymbol{\Phi}$或向量化后的级联稀疏增益 vec(b$^T\otimes$A) 的等价线性形式，同时将其余参数视为已知。数学上，$\bar{}$定义 W $=$ W $\odot\boldsymbol{\Phi}$ 后，可得

$$\begin{aligned}
\mathring{\mathbf{h}} &= \mathbf{F}_M\mathbf{A}\mathbf{F}_N^H\,\mathrm{diag}(\boldsymbol{\eta})(\bar{\mathbf{W}}\mathbf{b}) \\
&= \mathbf{F}_M\mathbf{A}\mathbf{F}_N^H\,\mathrm{diag}(\bar{\mathbf{W}}\mathbf{b})\boldsymbol{\eta} \\
&\overset{(a)}{=} (\boldsymbol{\eta}^T\otimes\mathbf{I}_M)\,\mathrm{vec}(\mathbf{F}_M\mathbf{A}\mathbf{F}_N^H\,\mathrm{diag}(\bar{\mathbf{W}}\mathbf{b})) \\
&\overset{(b)}{=} (\boldsymbol{\eta}^T\otimes\mathbf{I}_M)\,\mathrm{vec}(\mathbf{F}_M(\mathbf{b}^T\bar{\mathbf{W}}^T\bullet\mathbf{A}\mathbf{F}_N^H)) \\
&\overset{(c)}{=} (\boldsymbol{\eta}^T\otimes\mathbf{I}_M)\,\mathrm{vec}(\mathbf{F}_M(\mathbf{b}^T\otimes\mathbf{A})(\bar{\mathbf{W}}^T\bullet\mathbf{F}_N^H)) \\
&\overset{(d)}{=} (\boldsymbol{\eta}^T\otimes\mathbf{I}_M)((\bar{\mathbf{W}}^T\bullet\mathbf{F}_N^H)^T\otimes\mathbf{F}_M)\,\mathrm{vec}(\mathbf{b}^T\otimes\mathbf{A}) \\
&\overset{(e)}{=} (\boldsymbol{\eta}^T\otimes\mathbf{I}_M)((\bar{\mathbf{W}}*\mathbf{F}_N^*)\otimes\mathbf{F}_M)\,\mathrm{vec}(\mathbf{b}^T\otimes\mathbf{A}),
\end{aligned} \tag{8}$$

其中，($a$) 和 ($d$) 根据向量化恒等式得出，即 vec(ABC) $=$ (C$^T\otimes$A)vec(B)；($b$) 根据对角矩阵与 Khatri-Rao积的性质得出，即 X diag(v) $=$ v$^T\bullet$ X；($c$) 根据 Khatri-Rao积的性质得出，即 (A $\otimes$ B)(C $\bullet$D) $=$ (AC) $\bullet$ (BD)；($e$) 则根据按行和按列的 Khatri-Rao积之间的关系得出，即 A $*$ B $=\left(\mathrm{A}^T\bullet\mathrm{B}^T\right)^T$ [26]。

直接估计级联稀疏信道增益向量 vec(b$^T\otimes$A) $\in\mathbb{C}^{\bar{N}N\times 1}$ 会导致问题规模过大，这是因为近场与远场字典之间存在直接耦合，使得实际信道估计在计算上难以实现。因此，必须利用式（8）中级联信道模型的结构特征，降低估计问题的维度，从而减轻计算负担。具体而言，式（8）中的耦合混合场字典项 W $*$F$_N^*$源于 RIS 处近场与远场字典之间的相互作用，可能导致列冗余，也是维度扩展的主要来源。如果能够高效压缩这一耦合字典，就可以大幅降低整体问题的维度。已有研究表明，近场阵列响应向量与维度兼容的远场阵列响应向量之间的内积，可以等效表示为一个新的近场阵列响应向量 [20]。这种等效性将耦合字典的表示从高维角度-径向参数化压缩为紧凑的

角度-距离对。基于这一发现，命题1进一步证明，当近场阵列响应向量与 VR 指示向量耦合时，近场与远场字典的按行卡特里-拉奥积可以等效表示为低维近场字典。

命题1. 考虑 VR 指示器 W 的近场字典与远场字典 F 的共轭之间的按行卡特里-拉奥积，即 $\mathbf{W} * \mathbf{F}_N^*$，等价于网格为 $[\bar{\boldsymbol{\varphi}}, \bar{\boldsymbol{r}}] \in \mathbb{R}^{\bar{Q}\times 2}$ 的近场字典 $\mathbf{Q} \in \mathbb{C}^{N\times\bar{Q}}$ 与 VR 矩阵 $\bar{\boldsymbol{\Phi}} \in \{0,1\}^{N\times\bar{Q}}$ 之间的 Hadamard 积：

$$\bar{\mathbf{W}} * \mathbf{F}_N^* \quad \Leftrightarrow \quad \mathbf{Q} \odot \bar{\boldsymbol{\Phi}}, \tag{9}$$

其中 $\Leftrightarrow$ 表示级联信道 $\mathbf{h}$ 在字典 $\mathbf{W} * \mathbf{F}_N^*$ 与 $\mathbf{Q} \odot \boldsymbol{\Phi}$ 之间进行变换后，活跃列的数量保持不变。

证明。请参见附录 A。 □

根据命题1，$\mathbf{h}$ 可以改写为

$$\begin{aligned}\mathbf{h} &= (\boldsymbol{\eta}^T \otimes \mathbf{I}_M)((\bar{\mathbf{W}} * \mathbf{F}_N^*) \otimes \mathbf{F}_M)\,\mathrm{vec}(\mathbf{b}^T \otimes \mathbf{A}) \\ &= (\boldsymbol{\eta}^T \otimes \mathbf{I}_M)((\mathbf{Q} \odot \bar{\boldsymbol{\Phi}}) \otimes \mathbf{F}_M)\,\mathrm{vec}(\mathbf{X}),\end{aligned} \tag{10}$$

其中，$\mathbf{X} \in \mathbb{C}^{M\times\bar{Q}}$ 表示与变换后的字典 $(\mathbf{Q} \odot \boldsymbol{\Phi}) \otimes \mathbf{F}_M$ 相关联的联合稀疏矩阵。值得注意的是，上述字典变换也改变了稀疏表示的索引。因此，vec(X) 通常不等同于 vec($\mathbf{b}^T \otimes$A)，但这两种表示都能唯一表征同一级联信道。此外，所提出的变换显著降低了表示维度。具体而言，描述级联信道的稀疏向量由 $\mathrm{vec}(\mathbf{b}^T \otimes \mathbf{A}) \in \mathbb{C}^{MN\bar{N}\times 1}$ 缩减为 $\mathrm{vec}(\mathbf{X}) \in \mathbb{C}^{M\bar{Q}\times 1}$，表示规模也由 $\mathcal{O}(MN^2)$ 降至 $\mathcal{O}(MN)$；这是因为 $\bar{Q}$ 与 $N$ 相当，两者均由同一近场网格生成算法应用于同一阵列得到。维度的降低显著缩小了字典规模，并大幅降低了计算复杂度。基于降维后的表示 X，级联信道可向量化为

$$\mathbf{h} = \mathbf{D}_1(\bar{\boldsymbol{\Phi}})\,\boldsymbol{x}, \tag{11}$$

其中 $\boldsymbol{x}$，向量化(X) 与 $\mathbf{D}_1(\bar{\boldsymbol{\Phi}}) = (\boldsymbol{\eta}^T \otimes \mathbf{I}_M)((\mathbf{Q} \odot \bar{\boldsymbol{\Phi}}) \otimes \mathbf{F}_M)$。这表明 h 关于级联稀疏信道增益向量 $\boldsymbol{x}$ 具有线性表示。

此外，(10) 可以等价地改写为

$$\begin{aligned}\mathbf{h} &= (\boldsymbol{\eta}^T\otimes\mathbf{I}_M)((\mathbf{Q}\odot\bar{\boldsymbol{\Phi}})\otimes\mathbf{F}_M)\boldsymbol{x} \\ &\overset{(f)}{=} (\boldsymbol{x}^T\otimes(\boldsymbol{\eta}^T\otimes\mathbf{I}_M))\mathrm{vec}((\mathbf{Q}\odot\bar{\boldsymbol{\Phi}})\otimes\mathbf{F}_M) \\ &\overset{(g)}{=} (\boldsymbol{x}^T\otimes(\boldsymbol{\eta}^T\otimes\mathbf{I}_M))\mathrm{vec}((\mathbf{Q}\otimes\mathbf{F}_M)\odot(\bar{\boldsymbol{\Phi}}\otimes\mathbf{1}_{M\times M})) \\ &\overset{(h)}{=} (\boldsymbol{x}^T\otimes(\boldsymbol{\eta}^T\otimes\mathbf{I}_M))\mathrm{diag}(\mathrm{vec}(\mathbf{Q}\otimes\mathbf{F}_M))\mathrm{vec}(\bar{\boldsymbol{\Phi}}\otimes\mathbf{1}_{M\times M}),\end{aligned} \tag{12}$$

其中，(*f*) 根据前文提到的向量化恒等式得出，(*g*) 根据 Kronecker 积和 Hadamard 积的混合积性质得出，即 (A⊙B)⊗(C⊙D) =(A ⊗ C) ⊙(B ⊗ D)；(*h*) 根据 Hadamard 积的向量化恒等式得出，即 vec(A ⊙B) =diag(vec(A)) vec(B) [26]。

基于上述矩阵变换，得到了级联信道 h 关于向量化 $(\boldsymbol{\Phi} \otimes \mathbf{1}_{M\times M})$ 的显式线性表示。然而，$\mathbf{1}_{M\times M}$ 与未知VR矩阵 $\boldsymbol{\Phi}$ 之间的耦合并不理想，因为它掩盖了可见区域的内在稀疏结构。为解决这一问题，进一步调用引理1，将向量化$(\boldsymbol{\Phi}\otimes\mathbf{1}_{M\times M})$解耦为 S$(\mathbf{1}_{M\times M})$向量化$(\boldsymbol{\Phi})$。

引理1。对于任意矩阵 $\mathbf{A} = [\mathbf{a}_1, ..., \mathbf{a}_{c_A}] \in \mathbb{C}^{r_A\times c_A}$与 $\mathbf{B} = [\mathbf{b}_1, ..., \mathbf{b}_{c_B}] \in \mathbb{C}^{r_B\times c_B}$，存在变换矩阵 $\mathbf{S}(\mathbf{A}) \in \mathbb{C}^{r_Bc_Br_Ac_A\times r_Bc_B}$ 使得

$$\mathrm{vec}(\mathbf{B}\otimes\mathbf{A}) = \mathbf{S}(\mathbf{A})\,\mathrm{vec}(\mathbf{B}), \tag{13}$$

where $\mathbf{S}(\mathbf{A})$ is explicitly given by $\mathbf{S}(\mathbf{A}) = \mathbf{I}_{c_B} \otimes \begin{bmatrix} \mathbf{I}_{r_B}\otimes\mathbf{a}_1 \\ \vdots \\ \mathbf{I}_{r_B}\otimes\mathbf{a}_{c_A} \end{bmatrix}$.

*Proof.* The proof is omitted due to space limitation. □

根据引理1，级联信道可表示为

$$\mathbf{h} = \mathbf{D}_2(\boldsymbol{x})\mathrm{vec}(\bar{\boldsymbol{\Phi}}), \tag{14}$$

其中 $\mathbf{D}_2(\boldsymbol{x}) = (\boldsymbol{x}^T \otimes (\boldsymbol{\eta}^T \otimes \mathbf{I}_M))\mathrm{diag}(\mathrm{vec}(\mathbf{Q} \otimes \mathbf{F}_M))\mathbf{S}(\mathbf{1}_{M\times M})$。因此，级联信道 h 可表示为关于向量化 VR矩阵 vec$(\boldsymbol{\Phi})$ 的一个线性模型。

通过这些矩阵变换，可得到两个直观的线性模型，即式（11）和式（14）。这些模型通过降维表示 $\boldsymbol{x}$ 和 $\boldsymbol{\Phi}$，明确地将原始未知参数——即远场稀疏矩阵 A、近场VR矩阵 $\boldsymbol{\Phi}$和稀疏增益向量 b——与接收信号联系起来。

3）离网效应校正：需要注意的是，上述稀疏表示依赖于这样的假设：散射体、用户和可重构智能表面相关的角度或位置恰好位于预定义的角度网格或极坐标网格上。然而，在实际中，空间角度 $\vartheta_{B,\,l}$ 和 $\varphi_{R,\,l}$，以及用户/散射体位置 $[\vartheta_{U,l}, r_{U,l}]$ 均为连续值，实际传播参数通常与离散网格不一致，从而导致基失配。为缓解这一问题，引入离网向量来细化字典表示。

具体而言，令 $m_l$，$\arg\min_m |\vartheta_{B,\,l} - \vartheta_m|$ 以及 $q_l$，$\arg\min_q D([\bar{\varphi}_l, \bar{r}_l], [\bar{\varphi}_q, \bar{r}_q])$，对所有 $l \in \mathcal{L}, \{1, \cdots, L_U L_{RB}\}$均成立，其中 $m_l$ 和 $q_l$ 分别表示与 $\vartheta_{B,\,l}$ 和 $[\bar{\varphi}_l, \bar{r}_l]$最接近的预定义角度网格点和极坐标网格点的索引。这里，$D(\cdot,\cdot)$定义为 $D([\bar{\varphi}_1, \bar{r}_1], [\bar{\varphi}_2, \bar{r}_2]) = \sqrt{\bar{r}_1^2 + \bar{r}_2^2 - 2\bar{r}_1\bar{r}_2\cos(\bar{\phi}_2 - \bar{\phi}_1)}$，用于表征两个极坐标域点 $(\bar{\varphi}_1, \bar{r}_1)$ 和 $(\bar{\varphi}_2, \bar{r}_2)$ 之间的距离，其中 $\phi_1 = \arccos\bar{\varphi}_1$ 且 $\phi_2 = \arccos\bar{\varphi}_2$。随后，离网格向量定义为 $\Delta\boldsymbol{\vartheta}$, $[\Delta\vartheta_1, \cdots, \Delta\vartheta_M]^T$, $\Delta\bar{\boldsymbol{\varphi}}$,

$[\Delta\bar{\varphi}_1,\cdots,\Delta\bar{\varphi}_{\bar{Q}}]^T$以及 $\Delta\bar{r}$ $[\Delta\bar{r}_1,\cdots,\Delta\bar{r}_{\bar{Q}}]^T$，其中 $\Delta\vartheta_m(\forall m\in\mathcal{M})$、$\Delta\bar{\varphi}_q$和 $\Delta\bar{r}_q(\forall q\in\mathcal{Q})$由下式给出

$$\Delta\vartheta_m=\begin{cases}\vartheta_{B,l}-\vartheta_m, \text{ if } m=m_l,\\ 0, \text{ if } m\neq m_l,\end{cases} \tag{15}$$

$$\Delta\bar{\varphi}_q=\begin{cases}\bar{\varphi}_l-\bar{\varphi}_q, \text{ if } q=q_l,\\ 0, \text{ if } q\neq q_l,\end{cases}\quad \Delta\bar{r}_q=\begin{cases}\bar{r}_l-\bar{r}_q, \text{ if } q=q_l,\\ 0, \text{ if } q\neq q_l,\end{cases} \tag{16}$$

$\forall l\in\mathcal{L}$，分别。为便于记号表示，我们将$\boldsymbol{\Xi}$、$\{\Delta\bar{\boldsymbol{\varphi}},\Delta\bar{\mathbf{r}},\Delta\boldsymbol{\vartheta}\}$定义为离网参数集。通过纳入 $\boldsymbol{\Xi}$，所得信道可表示为

$$\begin{aligned}\mathbf{h}&=(\boldsymbol{\eta}^T\otimes\mathbf{I}_M)((\mathbf{Q}(\Delta\bar{\boldsymbol{\varphi}},\Delta\bar{\mathbf{r}})\odot\bar{\boldsymbol{\Phi}})\otimes\mathbf{F}_M(\Delta\boldsymbol{\vartheta}))\,\boldsymbol{x}\\&=(\boldsymbol{x}^T\otimes(\boldsymbol{\eta}^T\otimes\mathbf{I}_M))\,\mathrm{diag}(\mathrm{vec}(\mathbf{Q}(\Delta\bar{\boldsymbol{\varphi}},\Delta\bar{\mathbf{r}})\otimes\mathbf{F}_M(\Delta\boldsymbol{\vartheta})))\\&\quad\times\mathbf{S}(\mathbf{1}_{M\times M})\,\mathrm{vec}(\bar{\boldsymbol{\Phi}}).\end{aligned} \tag{17}$$

通过这种方式，所提出的模型明确考虑了连续传播参数相对于预定义字典的离网偏差，从而缓解基失配，并实现对级联信道的精确稀疏域表示。

B. 分层稀疏先验模型

为了充分利用级联稀疏信道增益向量 $\boldsymbol{x}$的稀疏性和结构特征，有必要采用结构感知概率模型。受[27], 启发，我们采用三层分层稀疏（3LHS）先验模型。不同于仅依赖支撑集或方差 [28], [29], 的两层先验，3LHS模型同时考虑这两个组成部分，提供灵活且稳健的概率表示。以往研究 [30], [31] 表明，该模型能够自然地捕获结构化稀疏性，同时保持较低的计算复杂度，因此尤其适用于对本文中的级联信道进行建模。具体而言，3LHS模型由三层组成，即支撑向量 $\boldsymbol{s}$、精度向量 $\boldsymbol{\rho}$和稀疏增益向量 $\boldsymbol{x}$，其联合分布为

$$p(\boldsymbol{x},\boldsymbol{\rho},\boldsymbol{s})=p(\boldsymbol{s})\,p(\boldsymbol{\rho}|\boldsymbol{s})\,p(\boldsymbol{x}|\boldsymbol{\rho}). \tag{18}$$

具体而言，引入支撑向量 $\boldsymbol{s}$，用于表示级联稀疏信道增益向量 $\boldsymbol{x}$ 中的每个元素是否为零。具体来说，$s_n=0$ 表示 $x_n$ 为零，而 $s_n\neq 0$ 表示 $x_n$ 非零。此外，通过对支撑向量 $\boldsymbol{s}$ 进行恰当建模，可以有效刻画 $\boldsymbol{x}$ 独特的稀疏结构。在所考虑的场景中，级联稀疏信道增益向量$\boldsymbol{x}$ 具有以下结构特征：$\mathbf{h}_u$ 包含$L_U$ 条路径，而 H 包含 $L_{RB}$ 条路径。因此，稀疏矩阵 A 包含 $L_U$ 个非零元素，而稀疏向量 b 包含 $L_{RB}$ 个非零元素。由此，等效稀疏矩阵 X 包含 $L_UL_{RB}$ 个非零元素。此外，不难看出，X 的每一列至多包含一个非零元素，这表明 RIS 侧的每条等效路径至多对应一个出发角。这种列稀疏结构意味着无需在不同的支撑集条目之间施加显式依赖。因此，将支撑向量 $\boldsymbol{s}$建模为独立同分布（i.i.d.）能够提供一种足够灵活且简洁的稀疏模式描述。因此，对于 $\boldsymbol{s}$，有

$$\mathrm{unvec}_{M\times\bar{Q}}(\boldsymbol{s})=\begin{bmatrix}s_{1,1}&s_{1,2}&\cdots&s_{1,\bar{Q}}\\ s_{2,1}&s_{2,2}&\cdots&s_{2,\bar{Q}}\\ \vdots&\vdots&\ddots&\vdots\\ s_{M,1}&s_{M,2}&\cdots&s_{M,\bar{Q}}\end{bmatrix}\in\{0,1\}, \tag{19}$$

其概率分布表示为

$$p(\boldsymbol{s})=\prod_{m=1}^{M}\prod_{q=1}^{\bar{Q}}(\lambda_{m,q})^{s_{m,q}}(1-\lambda_{m,q})^{1-s_{m,q}}, \tag{20}$$

其中 $\lambda_{m,\,q}$ 由 $\boldsymbol{x}$的稀疏性决定。此外，精度向量 $\boldsymbol{\rho}$ 控制 $\boldsymbol{x}$ 的方差，例如，$1/\rho_{m,\,q}$表示$x_{m,\,q}$的方差。条件概率$p(\boldsymbol{\rho}|\boldsymbol{s})$表示为

$$\begin{aligned}p(\boldsymbol{\rho}|\boldsymbol{s})=\prod_{m=1}^{M}\prod_{q=1}^{\bar{Q}}&\Gamma(\rho_{m,q};a_{m,q},b_{m,q})^{s_{m,q}}\\&\times\Gamma(\rho_{m,q};\bar{a}_{m,q},\bar{b}_{m,q})^{1-s_{m,q}},\end{aligned} \tag{21}$$

其中 $\Gamma(\rho;\,a,b)$ 作为共轭先验，以实现闭式后验推断。具体而言，当 $s_{m,\,q}=1$时，精度倒数$1/\rho_{m,\,q}$预期接近 1，这意味着$\rho_{m,\,q}$ 的均值满足 $a_{m,\,q}/b_{m,\,q}=\mathbb{E}[\rho_{m,q}]=\Theta(1)$。反之，当 $s_{m,\,q}=0$时，$1/\rho_{m,\,q}$ 应接近 0，¯这会使均值显著增大，即 $\bar{a}_{m,\,q}/b_{m,\,q}$ =$\mathbb{E}[\rho_{m,q}]\gg 1$。最后，基于精度参数 $\boldsymbol{\rho}$，我们为级联稀疏信道增益向量 $\boldsymbol{x}$ 设定零均值复高斯先验，其方差由相应的精度参数控制，即

$$p(\boldsymbol{x}|\boldsymbol{\rho})=\prod_{m=1}^{M}\prod_{q=1}^{\bar{Q}}\mathcal{CN}(x_{m,q};0,\rho_{m,q}^{-1}). \tag{22}$$

C. 马尔可夫平稳聚类先验模型

如第二节所述，采用 0/1 变量表示每个 RIS 单元是否能够反射用户信号，同一子阵列中的所有单元具有相同的可见性。为明确描述子阵列级可见性结构，我们将可重构智能表面的子阵列VR矩阵定义为 $\bar{\boldsymbol{\Phi}}_s\in\{0,1\}^{K\times\bar{Q}}$。根据此定义，完整可重构智能表面的¯ ¯VR 矩阵为 $\boldsymbol{\Phi}=\boldsymbol{\Phi}_s\otimes\mathbf{1}_{\frac{N}{K}\times 1}$，其中每个子阵列的可见性会复制到该子阵列中的所有单元。因此，接收信号模型可等价地改写为

$$\mathbf{y}=\mathbf{D}_1(\bar{\boldsymbol{\Phi}}_s,\boldsymbol{\Xi})\boldsymbol{x}+\mathbf{n}=\mathbf{D}_2(\boldsymbol{x},\boldsymbol{\Xi})\mathrm{vec}(\bar{\boldsymbol{\Phi}}_s)+\mathbf{n}, \tag{23}$$

其中 $\mathbf{D}_1(\bar{\boldsymbol{\Phi}}_s,\boldsymbol{\Xi})=(\boldsymbol{\eta}^T\otimes\mathbf{I}_M)((\mathbf{Q}(\Delta\bar{\boldsymbol{\varphi}},\Delta\bar{\mathbf{r}})\odot(\bar{\boldsymbol{\Phi}}_s\otimes\mathbf{1}_{\frac{N}{K}\times 1}))\otimes\mathbf{F}_M(\Delta\boldsymbol{\vartheta}))$，且 $\mathbf{D}_2(\boldsymbol{x},\boldsymbol{\Xi})=(\boldsymbol{x}^T\otimes(\boldsymbol{\eta}^T\otimes\mathbf{I}_M))\,\mathrm{diag}(\mathrm{vec}(\mathbf{Q}(\Delta\bar{\boldsymbol{\varphi}},\Delta\bar{\mathbf{r}})\otimes\mathbf{F}_M(\Delta\boldsymbol{\vartheta})))\mathbf{S}(\mathbf{1}_{M\times M})\mathbf{S}(\mathbf{1}_{\frac{N}{K}}\times 1)$。为刻画子阵列之间的空间相关性，引入马尔可夫链来描述相邻子阵列之间可见性的依赖关系 [25]。相应地，子阵列VR矩阵的先验分布表示为

$$p(\bar{\boldsymbol{\Phi}}_s)=\prod_{q=1}^{\bar{Q}}p(v_{1,q})\prod_{k=2}^{K}p(v_{k,q}|v_{k-1,q}). \tag{24}$$

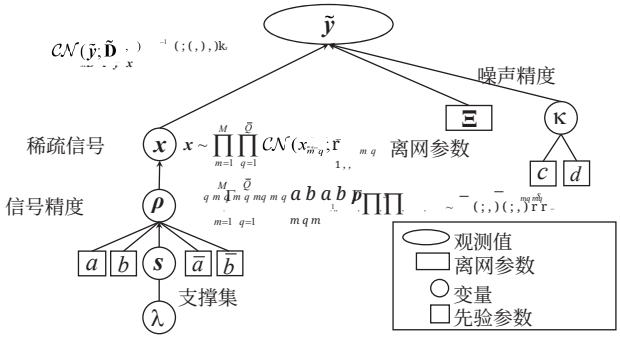



图 2：接收信号的联合概率模型。

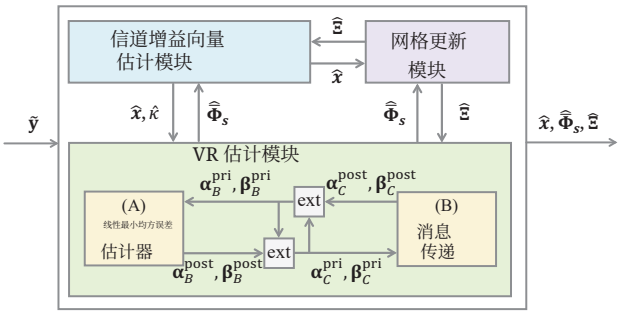



图3：所提算法的流程图。

此处，初始概率和转移概率分别定义为$p(v_{1,\ q}\ =\ 1)$ $=\ \lambda_{VR}$ 和 $p(v_{k,\ q}\ =\ 1|v_{k-1,\ q}\ =\ 0)\ =\ p_{01}$，其余转移概率 $p_{10}$、$p_{00}$和 $p_{11}$ 以类似方式定义，并满足

$$p_{10}+p_{11}=1,\quad p_{00}+p_{01}=1,\quad \lambda_{VR}\triangleq\frac{p_{01}}{p_{01}+p_{10}},\quad (25)$$

其中，$\lambda_{VR}$ 表示可见区域（VR）的稀疏率，即用户可见的RIS单元所占的比例。(25)中的最后一个等式确保马尔可夫链以 $\lambda_{VR}$ 作为其稳态概率。

### D. 接收信号的联合概率模型

如(6)所示，接收信号 $\tilde{\mathbf{y}}$可由含加性噪声的线性观测模型描述。在建立级联信道的概率模型后，我们接着对噪声分量 $\tilde{\mathbf{n}}$进行统计特性建模。具体而言，噪声向量 $\tilde{\mathbf{n}}$被建模为复高斯随机向量，即 $\tilde{\mathbf{n}}\ \sim\mathcal{CN}(\mathbf{0},\kappa^{-1}\mathbf{I})$，其中 $\kappa$ 表示噪声精度。此外，为噪声精度 $\kappa$ 指定Gamma先验 $p(\kappa)$ $=\Gamma(\kappa;\ c,d)$，其中 $c$和 $d$ 为相应的超参数。于是，所有潜变量和参数的联合分布——包括接收信号 $\tilde{\mathbf{y}}$、级联稀疏信道增益向量 $\boldsymbol{x}$、子阵列VR矩阵 $\boldsymbol{\Phi}_s$、分层稀疏变量$\boldsymbol{\rho}$ 和 $\boldsymbol{s}$、离网参数 $\boldsymbol{\Xi}$以及噪声精度 $\kappa$——可分解为

$$\begin{aligned}p(\tilde{\mathbf{y}},\boldsymbol{x},\bar{\boldsymbol{\Phi}}_s,\boldsymbol{\Xi},\boldsymbol{\rho},\boldsymbol{s},\kappa)&=p(\tilde{\mathbf{y}}|\boldsymbol{x},\bar{\boldsymbol{\Phi}}_s,\kappa,\boldsymbol{\Xi})\\&\quad\times p(\boldsymbol{x},\boldsymbol{\rho},\boldsymbol{s})\,p(\bar{\boldsymbol{\Phi}}_s)\,p(\kappa),\end{aligned}\quad (26)$$

其中，$p(\tilde{\mathbf{y}}|\boldsymbol{x},\boldsymbol{\Phi}_s,\kappa,\boldsymbol{\Xi})$ 表示似然函数。具体而言，在给定 $\boldsymbol{x}$、$\boldsymbol{\Phi}_s$、$\boldsymbol{\Xi}$ 和 $\kappa$ 的条件下，接收信号 $\tilde{\mathbf{y}}$ 服从复高斯分布，表示为

$$\tilde{\mathbf{y}}\sim\mathcal{CN}(\tilde{\mathbf{D}}_1(\bar{\boldsymbol{\Phi}}_s,\boldsymbol{\Xi})\boldsymbol{x},\kappa^{-1}\mathbf{I}),\quad (27)$$

其中，$\mathbf{D}_1(\boldsymbol{\Phi}_s,\boldsymbol{\Xi})$ 由与 $P$ 导频符号对应的感知矩阵按行拼接构成。$\mathbf{D}_2(\boldsymbol{x},\boldsymbol{\Xi})$ 的定义方式类似。结构化稀疏先验 $p(\boldsymbol{x},\boldsymbol{\rho},\boldsymbol{s})$ 以及子阵列 VR 矩阵$p(\boldsymbol{\Phi}_s)$ 的先验分别在第 III-B 节和第 III-C 节中说明。所有变量之间由此产生的概率依赖关系总结于图 2。基于上述概率建模，本文提出一种高效算法，用于估计级联信道参数。为了同时利用信道的结构化稀疏性和潜变量的概率先验，本文采用统一的贝叶斯推断框架。在该框架下，下一节将介绍 TS-JBE 算法，该算法结合信道结构和先验信息，联合估计级联信道参数。

## IV. 涡轮结构化联合贝叶斯估计算法

由于接收信号具有双线性结构，且先验函数与似然函数的形式各不相同，直接对 $\boldsymbol{x}$、$\boldsymbol{\Phi}_s$和$\boldsymbol{\Xi}$ 进行联合最大后验（MAP）估计是难以处理的。为应对这一挑战，我们提出TS-JBE算法，该算法遵循交替MAP推断框架，迭代更新未知参数。具体而言，联合优化问题表述为

$$(\boldsymbol{x}^*,\bar{\boldsymbol{\Phi}}_s^*,\boldsymbol{\Xi}^*)=\arg\max_{\boldsymbol{x},\bar{\boldsymbol{\Phi}}_s,\boldsymbol{\Xi}}\ln p(\tilde{\mathbf{y}},\boldsymbol{x},\bar{\boldsymbol{\Phi}}_s,\boldsymbol{\Xi},\boldsymbol{\rho},\boldsymbol{s},\kappa).\quad (28)$$

### A. TS-JBE算法概述

所提方法由三个核心模块组成，即信道增益估计模块、VR估计模块和网格更新模块，如图3所示。这三个模块交替运行直至收敛，其功能概述如下。

- 信道增益估计模块：给定当前的$\hat{\ }$ $\bar{\ }$ $\hat{\ }$ VR 矩阵 $\boldsymbol{\Phi}_s$ 和离网参数 $\boldsymbol{\Xi}$，该模块通过最大化后验分布，联合估计级联稀疏信道增益向量$\boldsymbol{x}$ 和噪声精度 $\kappa$。此步骤利用了式（18）中建立的信道结构化稀疏先验，以及由接收信号确定的似然函数。
- 可见区域估计模块：在固定估计得到的级联稀疏信道增益向量$\hat{\boldsymbol{x}}$ 和离网参数 $\boldsymbol{\Xi}\bar{\ }$后，该模块更新子阵列VR矩阵 $\boldsymbol{\Phi}_s$，利用可见性模式的先验信息，识别每条路径对应的可见RIS单元。
- 网格更新模块：为减轻离网失配，该模块根据接收信号 $\tilde{\mathbf{y}}$ 与利用$\hat{\ }$当前估计值 $\hat{\boldsymbol{x}}$ 和 $\boldsymbol{\Phi}_s$ 重构出的信号之间的残差误差，通过梯度下降步骤细化离网参数 $\boldsymbol{\Xi}$ 。

B. 信道增益向量估计模块

$\hat{}$ $\hat{}$给定 $\tilde{}$y、$\boldsymbol{\Phi}_s$ 和 $\boldsymbol{\Xi}$，通过最大后验估计推断级联稀疏信道增益向量$\boldsymbol{x}$ 和噪声精度 $\kappa$。具体而言，它们的估计值为

$$\begin{aligned}\boldsymbol{x}^* &= \arg\max_{\boldsymbol{x}} p(\boldsymbol{x}|\tilde{\mathbf{y}}, \hat{\bar{\boldsymbol{\Phi}}}_s, \hat{\boldsymbol{\Xi}}),\\ \kappa^* &= \arg\max_{\kappa} p(\kappa|\tilde{\mathbf{y}}, \hat{\bar{\boldsymbol{\Phi}}}_s, \hat{\boldsymbol{\Xi}}),\end{aligned} \tag{29}$$

$\hat{}\hat{}$ $\hat{}$分别表示，其中 $p(\boldsymbol{x}|\tilde{}\mathbf{y}\ \boldsymbol{\Phi}_s, \boldsymbol{\Xi})$和 $p(\kappa|\tilde{}\mathbf{y}\ \boldsymbol{\Phi}_s, \boldsymbol{\Xi})$分别表示 $\boldsymbol{x}$ 和 $\kappa$的后验分布。根据式（26）中的联合分布，对$\boldsymbol{x}$ 和 $\kappa$ 进行联合估计构成一个高维贝叶斯推断问题，其中涉及多个存在概率耦合的潜变量，包括 $\boldsymbol{\rho}$ 和s。为实现高效且易于处理的后验推断，同时利用 $\boldsymbol{x}$的结构化稀疏性，本文提出一种结构化子空间约束变分贝叶斯推断（SSC-VBI）方法，用于推断 $\boldsymbol{x}$ 和 $\kappa$。

与现有基于 VBI 的稀疏估计方法（如 SC-VBI [31], ）不同，本文提出的 SSC-VBI 将级联信道的结构化稀疏性和子空间约束明确纳入变分推断框架。通过利用信道的结构特征来优化子空间选择策略，SSC-VBI 在高维稀疏场景中能够实现更稳健、高效的后验估计，因此尤其适用于结构化信道估计。为简化符号，令 $\psi_j$表示集合 $\boldsymbol{\Psi}$、$\{\boldsymbol{x}, \boldsymbol{\rho}, \boldsymbol{s}, \kappa\}$中的一个变量，并定义索引集 $\mathcal{H}$、$\{j|\psi_j \in \boldsymbol{\Psi}\}$。令 $p(\boldsymbol{\Psi}|\tilde{}\mathbf{y})$表示 $\boldsymbol{\Psi}$的$\hat{}$ $\hat{}$后验分布，其中$\boldsymbol{\Phi}_s$ 和 $\boldsymbol{\Xi}$ 在观测矩阵 $\tilde{}\mathbf{D}_1$、$\tilde{}\mathbf{D}_1(\hat{}\bar{\boldsymbol{\Phi}}_s, \hat{}\boldsymbol{\Xi})$中视为固定值。根据 VBI 方法，近似后验 $q(\boldsymbol{\Psi})$通过最小化 $p(\boldsymbol{\Psi}|\tilde{}\mathbf{y})$与$q(\boldsymbol{\Psi})$之间的 KL散度（KLD）获得，并满足因子化形式约束，具体如下： [29],

$$\begin{aligned}\mathcal{A}_{\mathrm{VBI}}: \quad &\min_{q(\boldsymbol{\Psi})} \int q(\boldsymbol{\Psi}) \ln \frac{q(\boldsymbol{\Psi})}{p(\boldsymbol{\Psi}|\tilde{\mathbf{y}})}\, d\boldsymbol{\Psi}\\ &\text{s.t. } q(\boldsymbol{\Psi}) = \prod_{j\in\mathcal{H}} q(\psi_j), \int q(\psi_j)\, d\psi_j = 1.\end{aligned} \tag{30}$$

由于在固定其他所有变分分布时， $\mathcal{A}_{\mathrm{VBI}}$ 中的 Kullback–Leibler 散度关于每个单独变量 $\psi_j$ 都是凸的，因此可以交替更新变分分布以获得驻点解，更新规则如下:

$$q(\psi_j) = \frac{\exp\left(\left\langle \ln p(\boldsymbol{\Psi}, \tilde{\mathbf{y}})\right\rangle_{\prod_{k\neq j} q(\psi_k)}\right)}{\int \exp\left(\left\langle \ln p(\boldsymbol{\Psi}, \tilde{\mathbf{y}})\right\rangle_{\prod_{k\neq j} q(\psi_k)}\right) d\psi_j}. \tag{31}$$

显然，根据上述更新规则，更新 $q$（$\boldsymbol{x}$）需要计算高维矩阵求逆。为减轻这一计算负担，SC-VBI 算法在变分优化问题 $\mathcal{A}_{\mathrm{VBI}}$中引入了额外的结构约束，即:

$$q(\boldsymbol{x}) = \mathcal{CN}(\boldsymbol{x}; \boldsymbol{\mu}, \mathrm{diag}(\boldsymbol{\sigma}^2)), \tag{32}$$

其中 $\boldsymbol{\sigma}^2 = [\sigma_1^2, \sigma_2^2, \ldots, \sigma_{M\bar{Q}}^2]^T$。该约束强制稀疏向量元素彼此独立，从而得到对角后验协方差，并消除了高维矩阵求逆，因为 $\boldsymbol{x}$ 的结构依赖关系已由 3LHS模型中的潜变量 $\boldsymbol{s}$ 显式捕获。基于带有附加约束 (32) 的变分优化问题 (30) 以及更新规则 (31)，变分后验更新如下所示。

1） $\boldsymbol{x}$的更新方程：根据 [31], 中的引理 2， $\boldsymbol{x}$ 的变分后验形式为

$$q(\boldsymbol{x}) = \mathcal{CN}(\boldsymbol{x}; \boldsymbol{\mu}, \mathrm{diag}(\boldsymbol{\sigma}^2)), \tag{33}$$

其中 $\boldsymbol{\mu} = \mathbf{G}^{-1}\ \tilde{}\mathbf{D}_1^H\ \tilde{}\mathbf{y}\ \boldsymbol{\sigma}^2 = [G_1^{-1}, G_2^{-1}, \ldots, G_{M\bar{Q}}^{-1}]$，且 $\mathbf{G} = \mathrm{diag}(\langle\boldsymbol{\rho}\rangle) + \langle\kappa\rangle\ \tilde{}\mathbf{D}_1^H\ \tilde{}\mathbf{D}_1$.

2） $\boldsymbol{\rho}$的更新方程： $q$（$\boldsymbol{\rho}$）可推导为

$$q(\boldsymbol{\rho}) = \prod_{m=1}^{M}\prod_{q=1}^{\bar{Q}} \Gamma(\rho_{m,q}; \tilde{a}_{m,q}, \tilde{b}_{m,q}), \tag{34}$$

$\tilde{}$其中$\tilde{a}_{m,q} = \langle s_{m,q}\rangle a_{m,q} + \langle 1 - s_{m,q}\rangle a_{m,q} + 1$,$b_{m,q} = \langle s_{m,q}\rangle b_{m,q} + \langle 1 - s_{m,q}\rangle b_{m,q} + \langle |x_{m,q}|^2\rangle$.

3) $\boldsymbol{s}$的更新方程：后验分布 $q(\boldsymbol{s})$为

$$q(\boldsymbol{s}) = \prod_{m=1}^{M}\prod_{q=1}^{\bar{Q}} (\tilde{\lambda}_{m,q})^{s_{m,q}} (1 - \tilde{\lambda}_{m,q})^{1-s_{m,q}}. \tag{35}$$

4) $\kappa$的更新方程： $\boldsymbol{\kappa}$的变分后验可推导为

$$q(\kappa) = \Gamma(\kappa; \tilde{c}, \tilde{d}), \tag{36}$$

其中 $\tilde{c} = c + MP$， $d = d + \left\langle \|\tilde{}\mathbf{y} - \tilde{}\mathbf{D}^1\boldsymbol{x}\|^2\right\rangle_{q(\boldsymbol{x})}$·除了利用上述独立性消除后验协方差 $\boldsymbol{\sigma}^2$中的矩阵求逆外，还进一步利用 $\boldsymbol{x}$ 的稀疏性来确定活动索引集，从而避免在后验均值 $\boldsymbol{\mu}$的更新中进行高维矩阵求逆。具体而言，根据上一迭代中确定的活动索引集$S_\mu$ ，首先将第 $i_x$次迭代（$i_x \in \mathcal{I}_x, \{1, 2, \ldots, I_x\}$）中 $\boldsymbol{x}$ 的后验均值更新为

$$\boldsymbol{u}_{i_x}^{(0)}(S_\mu) = \langle\kappa\rangle \mathbf{G}(S_\mu, S_\mu)^{-1} \tilde{\mathbf{D}}_1(:, S_\mu)^H \tilde{\mathbf{y}}. \tag{37}$$

为改进估计，SC-VBI 算法将 $\boldsymbol{u}_{i_x}^{(0)}$ 作为以下优化问题的初始解

$$\min_{\boldsymbol{u}} \varphi(\boldsymbol{u}) \triangleq \boldsymbol{u}^{\mathrm{H}}\mathbf{G}\boldsymbol{u} - 2\Re\left\{\boldsymbol{u}^{\mathrm{H}}\tilde{\mathbf{D}}_1^{\mathrm{H}}\tilde{\mathbf{y}}\right\}, \tag{38}$$

根据式（31）中的更新规则，这等价于在固定所有其他变分参数的情况下，关于 $\boldsymbol{x}$ 最小化 Kullback–Leibler 散度。随后采用基于梯度的更新方案对 $\boldsymbol{u}$ 进行迭代优化，表示为

$$\boldsymbol{u}_{i_x}^{(i_g)} = \boldsymbol{u}_{i_x}^{(i_g-1)} - \epsilon^{(i_g)} \nabla_{\boldsymbol{u}} \varphi(\boldsymbol{u})\Big|_{\boldsymbol{u}=\boldsymbol{u}_{i_x}^{(i_g-1)}}, \tag{39}$$

其中， $i_g \in \mathcal{I}_g$、$\{1, \ldots, I_g\}$ 表示梯度下降迭代的索引，$\epsilon^{(i_g)}$ 是相应的步长。因此，所得的 $\boldsymbol{\mu}^{(i_x)}$ $\boldsymbol{u}^{(I_g)\, i_x}$ 作为 $\boldsymbol{x}$ 的后验均值估计。

在所考虑的问题中，稀疏向量 $\boldsymbol{x}$ 呈现列稀疏模式，其中每列至多包含一个非零元素。受此观察启发，

我们对 SC-VBI 进行改进，明确纳入 $\boldsymbol{x}$ 的列稀疏结构，以指导子空间索引集的构建，从而提高估计精度。具体而言，令 $\boldsymbol{\mu}^{(i_x-1)}$ 表示在第 $(i_x-1)$ 次迭代后得到的后验均值向量。将 $\boldsymbol{\mu}^{(i_x-1)}$重塑为矩阵形式 $\mathrm{U}^{(i_x-1)} \triangleq \mathrm{unvec}_{M\times\bar{Q}}\left(\boldsymbol{\mu}^{(i_x-1)}\right)$，并根据以下基于能量的阈值判定准则识别活跃列：

$$\mathcal{Q}_{\mu^{(i_x-1)}} \triangleq \left\{ q \in \bar{\mathcal{Q}} \;\middle|\; \left\|\mathbf{U}_{:,q}^{(i_x-1)}\right\|^2 > \varepsilon_\mu \right\}, \tag{40}$$

其中，阈值 $\varepsilon_\mu$ 的选取应使 $\mathcal{Q}_{\mu^{(i_x-1)}}$ 中所选列占 $\mathrm{U}^{(i_x-1)}$ 总能量的主要部分，例如不低于 95%。对于每个活跃列 $q \in \mathcal{Q}_{\mu^{(i_x-1)}}$，将主导行索引选为 $m_q = \arg\max_m |\mathrm{U}^{(i_x-1)}_{m,\,q}|$。相应地，最终的子空间索引集定义为

$$S_\mu \triangleq \left\{ (q-1)M + m_q \;\middle|\; q \in \mathcal{Q}_{\mu^{(i_x-1)}} \right\}. \tag{41}$$

随后，仅针对式 (41) 中的索引更新后验均值向量 $\boldsymbol{\mu}^{(i_x)}$，再通过式 (37) 和 (39) 中的更新规则进行细化。

C. VR 估计模块

给定信道增益估计模块得到的 $\tilde{\mathrm{y}}$、$\hat{\boldsymbol{x}}$、$\boldsymbol{\Xi}$ 和 $\hat{\kappa}$，还根据线性观测模型，通过最大后验方法估计子阵列VR矩阵 $\boldsymbol{\Phi}_s$。

$$\tilde{\mathbf{y}} = \tilde{\mathbf{D}}_2(\hat{\boldsymbol{x}}, \hat{\boldsymbol{\Xi}})\mathrm{vec}(\bar{\boldsymbol{\Phi}}_s) + \tilde{\mathbf{n}} = \tilde{\mathbf{D}}_2\mathrm{vec}(\bar{\boldsymbol{\Phi}}_s) + \tilde{\mathbf{n}}, \tag{42}$$

其中，$\tilde{\mathrm{D}}_2$，$\tilde{\mathrm{D}}_2(\hat{\boldsymbol{x}}, \hat{\boldsymbol{\Xi}})$。基于该模型，采用 Turbo方法进行可见区域估计，通过在线性高斯观测模型与结构感知VR先验之间迭代交换外信息，获得可靠的估计性能。具体而言，所提出的方法由两个相互连接的子模块组成：一个通过消息传递（MP）算法纳入VR的结构先验，另一个根据当前观测模型更新VR后验分布。通过这两个子模块之间的迭代信息交换，所提出的方法能够可靠地估计VR，同时捕捉其稀疏性和结构依赖关系。

1) 预处理与重构：在介绍具体的估计模块之前，利用 $\hat{\boldsymbol{x}}$ 的稀疏性以及 VR 的实值特性，对目标 VR 及相应的观测模型进行重构。首先，由于 $\boldsymbol{x}$ 具有稀疏性，只有 $\boldsymbol{\Phi}_s$ 中的少数列会对信道产生贡献。为降低计算复杂度，因此将可见区域估计限制在这些占主导地位的列上。该限制被纳入交替推断框架，在该框架中，$\boldsymbol{x}$ 和 $\boldsymbol{\Phi}_s$ 交替更新，从而避免因固定 $\boldsymbol{x}$ 的早期估计值而产生的不利影响。具体而言，如 IV-B节所示，根据 $\hat{\boldsymbol{x}}$ 确定活跃列索引集，记为 $\mathcal{Q}_v$，$\mathcal{Q}_{\mu^{(i_x)}}$。相应地，仅针对对应的子阵列VR矩阵 $\bar{\boldsymbol{\Phi}}_{s,\,\mathcal{Q}_v} = \bar{\boldsymbol{\Phi}}_s(:,\,\mathcal{Q}_v) \in \mathbb{R}^{K\times|\mathcal{Q}_v|}$执行可见区域估计，并采用相应的选定测量矩阵 $\mathrm{D}_{2,\,\mathcal{Q}_v}$。

由于 $\boldsymbol{\Phi}_{s,\,\mathcal{Q}_v}$ 为实值，因此将模型转换为等效的实值形式 $\bar{\mathrm{y}} = [\Re[\tilde{\mathrm{y}}]^T, \Im[\tilde{\mathrm{y}}]^T]^T$，并相应地定义 $\bar{\mathrm{D}}_{2,\,\mathcal{Q}_v}$ 和 $\bar{\mathrm{n}}$，从而得到实值模

$$\bar{\mathbf{y}} = \bar{\mathbf{D}}_{2,\mathcal{Q}_v}\mathrm{vec}(\bar{\boldsymbol{\Phi}}_{s,\mathcal{Q}_v}) + \bar{\mathbf{n}}. \tag{43}$$

通过这种重新表述，可将可见区域估计问题转化为等效的压缩实值推断形式，并开发一种由两个相互连接的模块组成的 Turbo 方法，用于估计子矩阵 $\boldsymbol{\Phi}_{s,\mathcal{Q}_v}$。具体而言，线性最小均方误差模块基于变换后的观测模型执行线性估计，而消息传递模块则利用可见区域的结构特征。通过在这两个模块之间迭代交换信息，可实现可靠且准确的可见区域估计。

2）模块 A：在模块 A 中，线性最小均方误差估计器将消息传递模块提供的先验信息纳入考量，为 $\boldsymbol{x}$ 构建高斯先验，并据此获得线性最小均方误差估计。具体而言，首先接收先验均值向量和方差向量$\boldsymbol{\alpha}_{A,pri}$ 和 $\boldsymbol{\beta}_{A,pri}$，并将其用于将子矩阵$\boldsymbol{\Phi}_{s,\mathcal{Q}_v}$ 建模为高斯随机向量。因此，$\boldsymbol{\Phi}_{s,\mathcal{Q}_v}$ 的先验分布为$\mathcal{N}\left(\mathrm{vec}(\bar{\boldsymbol{\Phi}}_{s,\mathcal{Q}_v}); \boldsymbol{\alpha}_{A,pri}, \mathrm{diag}(\boldsymbol{\beta}_{A,pri})\right)$. 在第一次迭代时，$\boldsymbol{\alpha}_{A,pri}$ 和 $\boldsymbol{\beta}_{A,pri}$ 以无偏方式初始化。给定上述先验模型和变换后的观测模型，根据 LMMSE 估计原理可得到$\boldsymbol{\Phi}_{s,\mathcal{Q}_v}$ 的后验分布。由此得到的后验协方差矩阵和均值向量分别表示为

$$\boldsymbol{\Gamma}_{A,post} = \left(\hat{\kappa}\bar{\mathbf{D}}_{2,\mathcal{Q}_v}^T\bar{\mathbf{D}}_{2,\mathcal{Q}_v} + \mathrm{diag}\left(\frac{1}{\boldsymbol{\beta}_{A,pri}}\right)\right)^{-1}, \tag{44}$$

$$\boldsymbol{\alpha}_{A,post} = \boldsymbol{\Gamma}_{A,post}\left(\frac{\boldsymbol{\alpha}_{A,pri}}{\boldsymbol{\beta}_{A,pri}} + \hat{\kappa}\bar{\mathbf{D}}_{2,\mathcal{Q}_v}^T\bar{\mathbf{y}}\right). \tag{45}$$

根据 Turbo 处理原理，本模块得到的后验统计量不能直接传递至后续的消息传递模块，因为它们与先验信息相关。因此，为生成外信息，需要执行去相关操作 [32]。模块B的先验均值和方差为

$$\boldsymbol{\alpha}_{B,pri} = \boldsymbol{\beta}_{B,pri}\left(\frac{\boldsymbol{\alpha}_{A,post}}{\boldsymbol{\beta}_{A,post}} - \frac{\boldsymbol{\alpha}_{A,pri}}{\boldsymbol{\beta}_{A,pri}}\right), \tag{46}$$

$$\boldsymbol{\beta}_{B,pri} = \left(\frac{1}{\boldsymbol{\beta}_{A,post}} - \frac{1}{\boldsymbol{\beta}_{A,pri}}\right)^{-1}. \tag{47}$$

3）模块B：模块B中的MP估计器以线性最小均方误差估计结果为基础，通过纳入关于可见区域结构特征的先验信息来提升估计性能。具体而言，先验均值和方差向量 $\boldsymbol{\alpha}_{B,\,pri}$ 和 $\boldsymbol{\beta}_{B,\,pri}$ 被解释为二元VR变量的等效含噪观测，其建模方式如下：

$$\boldsymbol{\alpha}_{B,pri} = \mathrm{vec}(\bar{\boldsymbol{\Phi}}_{s,\mathcal{Q}_v}) + \mathbf{z}, \mathbf{z} \sim \mathcal{N}(\mathbf{0}, \mathrm{diag}(\boldsymbol{\beta}_{B,pri})). \tag{48}$$

根据上述模型，$\boldsymbol{\alpha}_{B,pri}$ 和_$\boldsymbol{\Phi}_{s,\mathcal{Q}_v}$ 的联合分布可表示为

$$p(\boldsymbol{\alpha}_{B,pri}, \bar{\boldsymbol{\Phi}}_{s,\mathcal{Q}_v}) = p(\bar{\boldsymbol{\Phi}}_{s,\mathcal{Q}_v})\prod_{k=1}^{K}\prod_{q=1}^{|\mathcal{Q}_v|} p(\alpha_{B,k,q}^{pri}|v_{k,q}), \tag{49}$$

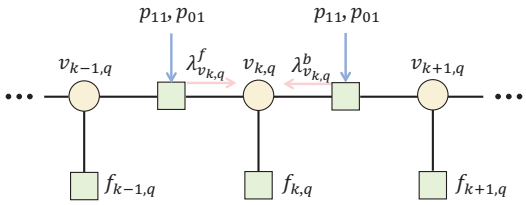



图 4：第 $q$ 列子阵列可见区域的因子图。

其中，$\bar{\boldsymbol{\Phi}}_{s,\mathcal{Q}_v}$ 的先验分布为

$$p(\bar{\boldsymbol{\Phi}}_{s,\mathcal{Q}_v}) = \prod_{q=1}^{|\mathcal{Q}_v|} p(v_{1,q}) \prod_{k=2}^{K} p(v_{k,q}|v_{k-1,q}). \tag{50}$$

根据式（50），相应的因子图如图 4 所示。对于每个因子节点，其对应的似然函数为

$$f_{k,q} \triangleq \mathcal{N}\left(v_{k,q}; \alpha^{pri}_{B,k,q}, \beta^{pri}_{B,k,q}\right), k \in \{1,\ldots,K\}, q \in \mathcal{Q}_v. \tag{51}$$

根据和积规则，节点$v_{k,q}$的前向消息和后向消息（分别记为 $\lambda^{\mathrm{f}}_{v,k,q}$ 和 $\lambda^{\mathrm{b}}_{v,k,q}$）按照式（53）和式（54）进行更新，如下一页顶部所示，其中外部输入激活概率$\pi^{in}_{v,k,q}$ 为

$$\pi^{in}_{v,k,q} = \frac{\mathcal{N}(1; \alpha^{pri}_{B,k,q}, \beta^{pri}_{B,k,q})}{\mathcal{N}(1; \alpha^{pri}_{B,k,q}, \beta^{pri}_{B,k,q}) + \mathcal{N}(0; \alpha^{pri}_{B,k,q}, \beta^{pri}_{B,k,q})}. \tag{52}$$

结合前向消息和后向消息，可得到外部输出激活概率：

$$\pi^{out}_{v,k,q} = \frac{\lambda^f_{v,k,q}\lambda^b_{v,k,q}}{(1-\lambda^f_{v,k,q})(1-\lambda^b_{v,k,q}) + \lambda^f_{v,k,q}\lambda^b_{v,k,q}}. \tag{55}$$

此时，计算$v_{k,q} = 1$ 的后验概率：

$$\hat{p}(v_{k,q}=1) = \frac{\pi^{in}_{v,k,q}\pi^{out}_{v,k,q}}{\pi^{in}_{v,k,q}\pi^{out}_{v,k,q} + (1-\pi^{in}_{v,k,q})(1-\pi^{out}_{v,k,q})}. \tag{56}$$

相应地，计算$v_{k,q}$ 的后验均值和方差：

$$\alpha^{post}_{B,k,q} = \sum_{a\in\{0,1\}} a\,\hat{p}(v_{k,q}=a), \tag{57}$$

$$\beta^{post}_{B,k,q} = \sum_{a\in\{0,1\}} (a-\alpha^{post}_{B,k,q})^2 \hat{p}(v_{k,q}=a). \tag{58}$$

与模块 A 类似，后验统计量经过进一步处理后生成外信息，再反馈至线性最小均方误差模块。相应的外部均值和方差为

$$\alpha^{pri}_{A,k,q} = \beta^{pri}_{A,k,q}\left(\frac{\alpha^{post}_{B,k,q}}{\beta^{post}_{B,k,q}} - \frac{\alpha^{pri}_{B,k,q}}{\beta^{pri}_{B,k,q}}\right), \tag{59}$$

$$\beta^{pri}_{A,k,q} = \left(\frac{1}{\beta^{post}_{B,k,q}} - \frac{1}{\beta^{pri}_{B,k,q}}\right)^{-1}. \tag{60}$$

最后，通过将后验概率与 0.5 进行比较，得到关于 $\boldsymbol{\Phi}_{s,\mathcal{Q}_v}$ 的二元判决；随后，通过设置 $\boldsymbol{\Phi}_s(:,\mathcal{Q}_v) = \boldsymbol{\Phi}_{s,\mathcal{Q}_v}$，重构完整的子阵列可见区域 – 矩阵 $\boldsymbol{\Phi}_s$。

D. 网格更新模块

给定估计的可见区域 $\boldsymbol{\Phi}_s$ 和级联信道增益 $\boldsymbol{x}$，通过求解以下最大似然（ML）问题来细化离网参数 $\boldsymbol{\Xi}$：

$$\begin{aligned}\max_{\Delta\bar{\boldsymbol{\varphi}},\Delta\bar{\mathbf{r}},\boldsymbol{\vartheta}} L(\Delta\bar{\boldsymbol{\varphi}},\Delta\bar{\mathbf{r}},\Delta\boldsymbol{\vartheta}) = -\sum_{p=1}^{P}\Big\|\mathbf{y}_p - (\boldsymbol{\eta}_p^T \otimes \mathbf{I}_M) \\ \times ((\mathbf{Q}(\Delta\bar{\boldsymbol{\varphi}},\Delta\bar{\mathbf{r}}) \odot \hat{\bar{\boldsymbol{\Phi}}}) \\ \otimes \mathbf{F}_M(\Delta\boldsymbol{\vartheta}))\,\hat{\boldsymbol{x}}\Big\|^2,\end{aligned} \tag{61}$$

其中 $\bar{\boldsymbol{\Phi}}, \bar{\boldsymbol{\Phi}}_s \otimes \mathbf{1}_{\frac{N}{K}\times 1}$。为方便起见，定义 $\mathrm{F}_p, \boldsymbol{\eta}_p^T \otimes \mathrm{I}_M$，$\bar{\mathrm{F}}_M$、$\mathrm{F}_M(\Delta\boldsymbol{\vartheta})$ 和 $\bar{\mathrm{Q}}_V$、$\mathrm{Q}(\Delta\bar{\boldsymbol{\varphi}}, \Delta\bar{\mathrm{r}}) \odot \bar{\boldsymbol{\Phi}}$。则问题 (61) 的目标函数可重写为

$$L(\Delta\bar{\boldsymbol{\varphi}},\Delta\bar{\mathbf{r}},\Delta\boldsymbol{\vartheta}) = -\sum_{p=1}^{P}\left\|\mathbf{y}_p - \mathbf{F}_p(\bar{\mathbf{Q}}_V \otimes \bar{\mathbf{F}}_M)\hat{\boldsymbol{x}}\right\|^2. \tag{62}$$

为便于计算 $L(\Delta\bar{\boldsymbol{\varphi}},\Delta\bar{\mathrm{r}}\ \Delta\boldsymbol{\vartheta})$ 关于离网参数集 $\boldsymbol{\Xi}$ 的导数，我们引入中间项。对于第 $q$ 个近场角度分量，定义

$$\begin{aligned}\boldsymbol{y}_p^{(\Delta\bar{\varphi}_q)} &= \left((\mathbf{a}_q^{(\bar{\varphi}_q)} \odot \hat{\bar{\boldsymbol{\phi}}}_q) \otimes \bar{\mathbf{F}}_M\right)^H \mathbf{F}_p^H \mathbf{y}, \\ \boldsymbol{z}_p^{(\Delta\bar{\varphi}_q)} &= \left((\mathbf{a}_q^{(\bar{\varphi}_q)} \odot \hat{\bar{\boldsymbol{\phi}}}_q) \otimes \bar{\mathbf{F}}_M\right)^H \mathbf{F}_p^H \mathbf{F}_p(\bar{\mathbf{Q}}_V \otimes \bar{\mathbf{F}}_M)\hat{\boldsymbol{x}}.\end{aligned} \tag{63}$$

令阵列响应向量 $\mathrm{a}_q$ 关于离网角度扰动 $\Delta\bar{\varphi}_q$ 的导数为 $\mathrm{a}^{(\Delta\bar{\varphi}_q)}_q = \frac{\partial \mathbf{a}([\bar{\varphi}_q+\Delta\bar{\varphi}_q,\bar{r}_q])}{\partial\Delta\bar{\varphi}_q}$，~~利用上述中间~~项，$L(\Delta\bar{\boldsymbol{\varphi}},\Delta\bar{\mathrm{r}}\ \Delta\boldsymbol{\vartheta})$ 关于 $\Delta\bar{\varphi}_q$ 的梯度可简洁地写为

$$\frac{\partial L}{\partial\Delta\bar{\varphi}_q} = 2\,\Re\sum_{p=1}^{P}\hat{\boldsymbol{x}}^H_{(q-1)M+1:qM}\left(\boldsymbol{y}_p^{(\Delta\bar{\varphi}_q)} - \boldsymbol{z}_p^{(\Delta\bar{\varphi}_q)}\right). \tag{64}$$

类似地，关于 $\Delta\bar{r}_q$ 和 $\Delta\vartheta_m$ 的梯度也可以分别推导得到。最后，通过基于梯度的更新，按如下方式依次细化离网参数：

$$\Delta\bar{\boldsymbol{\varphi}}^{(i+1)} = \Delta\bar{\boldsymbol{\varphi}}^{(i)} - \varepsilon_{\bar{\varphi}}\frac{\partial L(\Delta\bar{\boldsymbol{\varphi}}^{(i)},\Delta\bar{\mathbf{r}}^{(i)},\Delta\boldsymbol{\vartheta}^{(i)})}{\partial\Delta\bar{\boldsymbol{\varphi}}^{(i)}}, \tag{65}$$

$$\Delta\bar{\mathbf{r}}^{(i+1)} = \Delta\bar{\mathbf{r}}^{(i)} - \varepsilon_{\bar{r}}\frac{\partial L(\Delta\bar{\boldsymbol{\varphi}}^{(i+1)},\Delta\bar{\mathbf{r}}^{(i)},\Delta\boldsymbol{\vartheta}^{(i)})}{\partial\Delta\bar{\mathbf{r}}^{(i)}}, \tag{66}$$

$$\Delta\boldsymbol{\vartheta}^{(i+1)} = \Delta\boldsymbol{\vartheta}^{(i)} - \varepsilon_{\vartheta}\frac{\partial L(\Delta\bar{\boldsymbol{\varphi}}^{(i+1)},\Delta\bar{\mathbf{r}}^{(i+1)},\Delta\boldsymbol{\vartheta}^{(i)})}{\partial\Delta\boldsymbol{\vartheta}^{(i)}}, \tag{67}$$

其中，步长 $\varepsilon_{\bar{\varphi}}$、$\varepsilon_{\bar{r}}$ 和 $\varepsilon_{\vartheta}$ 通过回溯线搜索 [33] 自适应地选取。

E. 复杂度分析

我们在算法 1 中总结了所提出的 TS-JBE 方法。在信道增益向量估计模块中，SSC-VBI 将运算限制在大小为 $\mathbb{C}^{|S_\mu|\times|S_\mu|}$的降维子空间内，并结合若干次矩阵-向量乘法，避免大规模矩阵求逆，实现每次迭代的复杂度为 $\mathcal{O}(M^2\bar{Q}+|S_\mu|^3)$。在可见区域估计模块中，LMMSE估计器需要对大小为$\mathbb{C}^{(K|\mathcal{Q}_v|)\times(K|\mathcal{Q}_v|)}$的矩阵求逆，复杂度为 $\mathcal{O}((K|\mathcal{Q}_v|)^3)$；而 MP 更新的复杂度为线性。在网格更新模块中，主要开销来自计算

$$\lambda_{v,k,q}^{f}=\begin{cases}\lambda_{VR}, & k=1,\\ \dfrac{p_{01}(1-\pi_{v,k-1,q}^{in})(1-\lambda_{v,k-1,q}^{f})+p_{11}\pi_{v,k-1,q}^{in}\lambda_{v,k-1,q}^{f}}{(1-\pi_{v,k-1,q}^{in})(1-\lambda_{v,k-1,q}^{f})+\pi_{v,k-1,q}^{in}\lambda_{v,k-1,q}^{f}}, & k>1,\end{cases} \tag{53}$$

$$\lambda_{v,k,q}^{b}=\begin{cases}0.5, & k=K,\\ \dfrac{p_{10}(1-\pi_{v,k+1,q}^{in})(1-\lambda_{v,k+1,q}^{b})+p_{11}\pi_{v,k+1,q}^{in}\lambda_{v,k+1,q}^{b}}{(p_{00}+p_{10})(1-\pi_{v,k+1,q}^{in})(1-\lambda_{v,k+1,q}^{b})+(p_{11}+p_{01})\pi_{v,k+1,q}^{in}\lambda_{v,k+1,q}^{b}}, & k<K.\end{cases} \tag{54}$$

算法 1 所提出的 TS-JBE算法 输入：接收信号 $\tilde{\mathbf{y}}$，外层迭代次数 $I_{out}$，信道向量迭代次数 $I_x$，可见区域迭代次数 $I_v$，梯度更新迭代次数 $I_g$。 输出：信道稀疏向量 $\hat{\boldsymbol{x}}$、可见区域矩阵 $\boldsymbol{\Phi}_s$、离网格参数 $\boldsymbol{\Xi}$。 1: 对于 $i_{out}=1,\ldots,I_{out}$ 2: 初始化 $q(\boldsymbol{s})$、 $q(\boldsymbol{\rho})$、$q(\boldsymbol{\kappa})$。 3: 信道增益估计模块 4: 对于 $i_x=1,\ldots,I_x$5: 使用 (33) 更新 $q(\boldsymbol{x})$，其中后验均值 $\boldsymbol{\mu}$ 通过执行 (39) 中的梯度更新获得，初始点取自 (37) 和 (41)，迭代 $I_g$ 次。 6: 使用 (34) 更新 $q(\boldsymbol{\rho})$。 7: 使用 (35) 更新 $q(\boldsymbol{s})$。 8: 使用 (36) 更新 $q(\boldsymbol{\kappa})$。 9: 结束 For 10: 估计 $\hat{\boldsymbol{x}}=\boldsymbol{\mu}^{(I_x)}$、$\hat{\boldsymbol{\kappa}}=\frac{\tilde{c}}{d}$。 11: 将接收信号模型变换为 (43)。 12: 可见区域估计模块 13: 对于 $i_v=1,\ldots,I_v$14: %模块A：LMMSE 15: 使用 (44) 和 (45) 计算 $\boldsymbol{\Gamma}_A^{post}$，$\boldsymbol{\alpha}_A^{post}$。 16: 使用 (46) 和 (47) 计算 $\boldsymbol{\alpha}_B^{pri}$，$\boldsymbol{\beta}_B^{pri}$。 17: %模块B：MP 18: 使用 (52) 计算 $\pi_{\nu}^{in}{}_{,k,q}$。 19: 使用 (53) 和 (54) 计算 $\lambda_{\nu}^{f}{}_{,k,q}$, $\lambda_{\nu,k,q}^{b}$。 20: 使用 (55) 计算 $\pi_{\nu}^{out}{}_{k,,q}$。 21: 使用 (57) 和 (58) 计算 $\boldsymbol{\alpha}_B^{post}$，$\boldsymbol{\beta}_B^{post}$。 22: 使用 (59) 和 (60) 计算 $\boldsymbol{\alpha}_A^{pri}$，$\boldsymbol{\beta}_A^{pri}$。 23: 使用 0.5 阈值估计 $\boldsymbol{\Phi}_s$。 24: 结束 For 25: 网格更新模块_26: 使用 (65)、(66) 和 (67) 估计 $\boldsymbol{\Xi}$。 27: 结束 For

关于极坐标网格参数 $[\bar{\boldsymbol{\varphi}},\bar{\boldsymbol{r}}]$ 的梯度，计算复杂度为 $\mathcal{O}(\bar{Q}^2)$。分别用 $I_x$ 和 $I_v$ 表示信道增益模块和 VR 模块的迭代次数，则 TS-JBE 每次外层迭代的总体计算复杂度为 $\mathcal{O}\big(I_x(M^2\bar{Q}+|S_\mu|^3)+I_v(K|\mathcal{Q}_v|)^3+\bar{Q}^2\big)$。

## V. 仿真结果

本节给出数值结果，以验证所提出的 TS-JBE 算法的有效性。我们考虑一个载波频率为 $f=28$ GHz、工作于时分双工模式的 RIS 辅助 MIMO 系统。基站配备一个由 $M=16$ 根天线组成的均匀线性阵列，阵元间距为$d=\frac{\lambda}{2}$。可重构智能表面包含 $N=128$ 个反射单元，并以相同间距排列成均匀线性阵列；假设有一个单天线用户。基站和可重构智能表面分别沿 $y$ 轴和 $x$ 轴排列，其参考位置分别为 $[-90\ \mathrm{m}\ -30\mathrm{m}]^T$和 $[0\mathrm{m},\ 0\mathrm{m}]^T$。用户到可重构智能表面的距离介于 10 m 和 20 m 之间。根据阵列孔径和载波波长，可重构智能表面的瑞利距离约为 87.5 m。基站到可重构智能表面的距离约为 95.2 m，表明基站位于可重构智能表面的远场，而用户位于近场区域。该配置符合所考虑的混合场传播场景。大尺度路径损耗遵循 $PL=\alpha_{PL}+10\beta_{PL}\log_{10}(d)+\xi_{PL}$(分贝),$\xi_{PL}\sim\mathcal{N}(0,\sigma_{PL}^2)$，模型和参数取自 [34]。除非另有说明，否则考虑 $L_{RB}=L_U=3$ 条路径，极域字典包含 $Q=256$ 个点，可重构智能表面划分为 $K=8$ 个子阵列，VR 稀疏率为 0.875，信噪比为 20 dB。本文采用级联信道的归一化均方误差作为性能指标。级联信道向量定义为 $\mathrm{h}_c=$向量化(Hdiag($\mathrm{h}_u$))。相应地，归一化均方误差定义为 $\|\hat{\mathrm{h}}_c-\mathrm{h}_c\|^2/\|\mathrm{h}_c\|^2$，$\hat{\ }$，其中 $\mathrm{h}_c=((\mathrm{Q}(\Delta\boldsymbol{\varphi},\Delta\mathrm{r})\odot\boldsymbol{\Phi})\otimes\mathrm{F}_M(\Delta\boldsymbol{\vartheta}))\hat{\boldsymbol{x}}$ 表示重构的级联信道向量。为进行性能比较，我们考虑以下基准算法：

- OMP：该方法假设所有 RIS 单元均对信号可见，并采用正交匹配追踪来估计级联信道。
- SBL：与 OMP 类似，但使用稀疏贝叶斯学习（SBL）进行级联信道估计。
- RFSBL：鲁棒快速 SBL（RFSBL）算法通过两阶段过程 [20]估计级联稀疏信道增益、可见区域和离网格参数。
- 不进行可见区域估计的 TS-JBE：该基准采用所提出的 TS-JBE 算法，同时禁用可见区域估计模块。仅估计级联稀疏信道增益和离网参数。
- Oracle最小二乘：在已知路径距离、角度、散射体位置和可见区域的情况下进行最小二乘估计，作为性能下界。

在展示性能结果之前，图5验证了所考虑算法的收敛性。所提出的算法在早期迭代中归一化均方误差迅速下降，约经过25次迭代后收敛至稳定值，且呈单调下降趋势，表明其具有良好的稳定性。这种

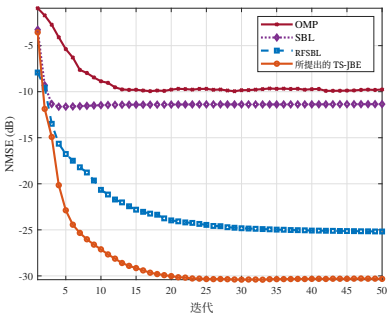



图5：所考虑算法的收敛行为

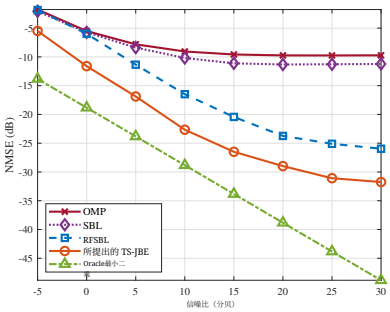



图6：所考虑算法的归一化均方误差性能随信噪比的变化。

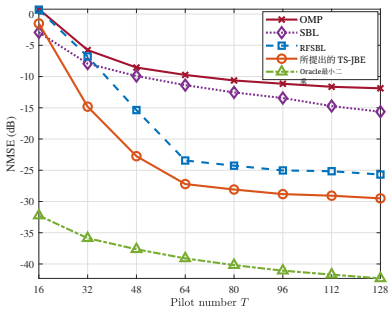



图7：不同导频数量下的归一化均方误差性能。

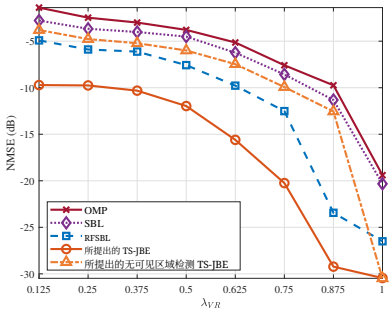



图 8：不同可见区域稀疏率下的归一化均方误差性能。

良好的收敛行为源于所提出的联合迭代方法：级联稀疏信道增益、可见区域和离网参数交替更新，从而在迭代过程中实现一致的信息交换与渐进细化。相比之下，SBL和正交匹配追踪由于迭代结构较为简单且不进行联合可见区域与离网参数估计，因此收敛更快；而同样采用多参数交替更新的RFSBL收敛较慢，约经过30次迭代后趋于稳定。

图6比较了不同算法在各种信噪比下的归一化均方误差性能。如图所示，随着信噪比提高，所有方案的估计精度均有所提升。在整个信噪比范围内，所提出的 TS-JBE 始终优于正交匹配追踪、稀疏贝叶斯学习和 RFSBL。正交匹配追踪和稀疏贝叶斯学习未考虑非平稳性或离网效应，因此性能在中信噪比区域趋于饱和，超过 15 分贝后几乎没有提升。RFSBL 和 TS-JBE 均对可见区域和离网效应进行显式建模，因此性能远优于正交匹配追踪和稀疏贝叶斯学习。然而，RFSBL 的两阶段估计容易产生误差传播，从而限制了最终精度。相比之下，TS-JBE 采用基于三层先验和马尔可夫结构约束的联合估计，实现了稳定的性能增益，并准确刻画信道和可见区域结构。与 Oracle 最小二乘基准相比，TS-JBE 在低至中等信噪比下保持近似恒定的差距，展现出对噪声的鲁棒性和稳定的估计性能。

图7展示了不同算法的归一化均方误差随导频数量 $T$ 的变化。随着 $T$ 增加，所有方案的归一化均方误差均单调下降。当 $T > 20$ 时，所提出的 TS-JBE 始终优于所有基准方法，并且在整个范围内均优于 RFSBL。当超过 $T = 64$ 后，其性能趋于饱和，表明使用 64 个导频即可达到令人满意的估计精度。相比之下，OMP 和稀疏贝叶斯学习的归一化均方误差下降速度要慢得多，且性能明显较差，因为它们未考虑信道非平稳性和离网效应，因此无法充分利用更长的导频序列。

图 8 展示了不同算法在不同可见区域稀疏率 $\lambda_{VR}$ 下的归一化均方误差性能。随着 $\lambda_{VR}$ 增大，由于更多可见RIS单元带来了更丰富的观测，所有方案的归一化均方误差通常都会降低。显式建模可见区域的算法始终优于假设RIS完全可见的基线算法，例如正交匹配追踪和稀疏贝叶斯学习，这凸显了可见区域建模的优势。在这些算法中，即使在低可见性条件下，所提出的 TS-JBE 仍持续优于 RFSBL，表明该算法具有稳定性。此外，在部分可见场景中，纳入可见区域估计可显著提升性能；而当 $\lambda_{VR} = 1$ 时，这种增益便不复存在，因为此时所有RIS单元均可见，无需显式建模可见区域。

## VI. 结论

本文研究了混合场传播环境下 RIS辅助毫米波系统中的非平稳级联信道估计。利用级联信道结构，设计了一种基于可见性矩阵加权低维极域字典的压缩策略，以构建降维稀疏双线性表示。基于这一表示，提出了一种 TS-JBE 方法，用于联合估计级联稀疏信道增益、可见区域和离网参数。仿真结果表明，与现有方法相比，所提方法显著降低了归一化均方误差。

## 附录

### A. 命题1的证明

$(n_x,\ (n_{\bar{y}}-1)N+n_y)$阶的 $\bar{\mathbf{W}}*\mathbf{F}_N^*$ 元素，在给定 $\bar{}$ by $\mathbf{W}(n_x,n_{\bar{y}})\ \mathbf{F}_N^*(n_x,n_y)$ 时，表示为

$$\boldsymbol{\phi}_{n_x,n_{\bar{y}}}e^{-j\frac{2\pi}{\lambda}\left(-(n_x-1)d\left(\vartheta_{n_{\bar{y}}}-\varphi_{n_y}\right)+\frac{d^2(n_x-1)^2}{2r_{n_{\bar{y}}}}\left(1-\vartheta_{n_{\bar{y}}}^2\right)\right)}, \tag{68}$$

其中 $n_x$、 $n_y\in\mathcal{N}$和 $n_{\bar{y}}\in\bar{\mathcal{N}}$。定义 $\bar{\varphi}=\vartheta_{n_{\bar{y}}}-\varphi_{n_y}$和 $\bar{r}=\frac{r_{n_{\bar{y}}}}{(1-\bar{\varphi}^2)}^{1-\vartheta_{n_{\bar{y}}}^2}$。然后，(68) 可改写为

$$\boldsymbol{\phi}_{n_x,n_{\bar{y}}}e^{-j\frac{2\pi}{\lambda}\left(-(n_x-1)d\,\bar{\varphi}+\frac{d^2(n_x-1)^2}{2\bar{r}}(1-\bar{\varphi}^2)\right)}. \tag{69}$$

(69) 中的相位项与近场阵列响应向量的解析形式相符，而幅度项对应于$\bar{}$VR指示器。因此，$\mathbf{W}*\mathbf{F}_N^*$的每一列都可解释为由 $(\bar{\varphi},\bar{r})$ 参数化、并由相应 VR 指示器加权的近场阵列响应向量。通过在 $(\bar{\varphi},\bar{r})$ 上构造新的极域网格 $\{(\bar{\varphi}_q,\bar{r}_q)\}_{q=1}^{\bar{Q}}$，其中 $\bar{Q}$表示网格点的数量，由此得到的阵列响应向量构成等效的近场字典 Q。同时，引入 VR 矩阵$\bar{\mathbf{\Phi}}$，以便在$\bar{}$字典变换后保持一一对应关系。因此，$\mathbf{W}*\mathbf{F}_N^*$可表示为等效形式 $\mathbf{Q}\odot\bar{\mathbf{\Phi}}$。

## 参考文献


[1] H. Lu、Y. Zeng、C. You、Y. Han、J. Zhang、Z. Wang、Z. Dong、S. Jin、C.-X. Wang、T. Jiang、X. You 和 R. Zhang，“面向6G的近场超大规模MIMO通信教程”，IEEE Commun. Surveys Tuts.，第26卷，第4期，第2213–2257页，2024年第4季度。[2] C. You、Y. Cai、Y. Liu、M. Di Renzo、T. M. Duman、A. Yener 和 A. Lee Swindlehurst，“面向6G及 beyond 的下一代先进收发机技术”，IEEE J. Sel. Areas Commun.，第43卷，第3期，第582–627页，2025年3月。[3] X. Shao、C. You 和 R. Zhang，“智能反射面辅助的无线感知：应用与设计问题”，IEEE Wireless Commun.，第31卷，第3期，第383–389页，2024年6月。[4] M. Rihan、A. Zappone、S. Buzzi、G. Fodor 和 M. Debbah，“用于感知与通信一体化的被动与主动可重构智能表面：挑战与机遇”，IEEE Network，第38卷，第3期，第218–226页，2024年5月。[5] B. Zheng、C. You、W. Mei 和 R. Zhang，“智能反射面辅助无线通信中的信道估计与实用被动波束成形设计综述”，IEEE Commun. Surveys Tuts.，第24卷，第2期，第1035–1071页，2022年第2季度。[6] D. Mishra 和 H. Johansson，“被动智能表面辅助多输入单输出无线能量传输的信道估计与低复杂度波束成形设计”，载于 IEEE 国际声学、语音与信号处理会议（ICASSP）论文集，2019年5月，第4659–4663页。[7] Y. Wei、M.-M. Zhao、M.-J. Zhao 和 Y. Cai，“具有误差传播抑制的 IRS辅助的多用户通信信道估计”，IEEE Trans. Wireless Commun.，第21卷，第4期，第2725–2741页，2022年4月。[8] C. You、B. Zheng 和 R. Zhang，“智能反射面的信道估计与被动波束成形：离散相移与渐进细化”，IEEE J. Sel. Areas Commun.，第38卷，第11期，第2604–2620页，2020年11月。[9] Q. Li、M. El-Hajjar、I. Hemadeh、Y. Mestrah、A. Shojaeifard 和 L. Hanzo，“RIS辅助多用户无线通信的低复杂度信道估计”，载于 IEEE 国际通信会议（ICC）论文集，2025年6月，第6179–6184页。[10] X. Bian、W. Xu 和 Y. Wang，“基于稀疏表示的超大规模可重构智能表面辅助系统稳健信道估计”，载于 IEEE 第100届车辆技术会议（VTC-Fall）论文集，2024年10月，第1–6页。[11] M. Gao、H. Li、Y. Wang 和 J. Yang，“可重构智能表面辅助MIMO系统的稀疏信道估计”，载于 IEEE 国际个人、室内与移动无线电通信研讨会（PIMRC）论文集，2023年9月，第1–6页。[12] J. Lee 和 S. Hong，“RIS辅助多用户多输入多输出系统的近场视距/非视距信道估计：分段低秩近似方法”，IEEE Trans. Wireless Commun.，第24卷，第6期，第4781–4792页，2025年6月。[13] Z.-Q. He 和 X. Yuan，“大型智能超表面辅助大规模多输入多输出的级联信道估计”，IEEE Wireless Commun. Lett.，第9卷，第2期，第210–214页，2020年2月。[14] 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 Trans. Commun.，第70卷，第4期，第2663–2677页，2022年4月。[15] S. Yang、W. Lyu、Z. Hu、Z. Zhang 和 C. Yuen，“近场超大规模可重构智能表面辅助毫米波混合波束赋形架构的信道估计”，IEEE Trans. Veh. Technol.，第72卷，第8期，第11029–11034页，2023年8月。[16] X. Tuo、Z. Chen、M.-M. Zhao、C. You 和 M.-J. Zhao，“超大规模智能反射面辅助宽带毫米波系统的近场稀疏贝叶斯信道估计与跟踪”，arXiv预印本 arXiv:2511.18752，2025年。[17] E. Dong、Z. Lian、Y. Wang、Y. Li、Y. Su、B. Wang 和 L. Ling，“双可重构智能表面辅助的毫米波近场通信：信道建模与性能分析”，IEEE Internet Things J.，第12卷，第11期，第16023–16036页，2025年6月。[18] E. D. Carvalho、A. Ali、A. Amiri、M. Angjelichinoski 和 R. W. Heath，“超大规模海量多输入多输出中的非平稳性”，IEEE Wireless Commun.，第27卷，第4期，第74–80页，2020年8月。[19] Y. Han、S. Jin、C.-K. Wen 和 T. Q. S. Quek，“超大规模可重构智能表面辅助大规模多输入多输出系统的定位与信道重构”，IEEE J. Sel. Top. Signal Process.，第16卷，第5期，第1011–1025页，2022年8月。[20] X. Yu、W. Shen、R. Zhang、C. Xing 和 T. Q. S. Quek，“超大规模可重构智能表面辅助毫米波系统的信道估计”，IEEE Trans. Commun.，第71卷，第9期，第5519–5533页，2023年9月。[21] Z. Yuan、J. Zhang、Y. Ji、G. F. Pedersen 和 W. Fan，“面向大规模多输入多输出系统的空间非平稳近场信道建模与验证”，IEEE Trans. Antennas Propag.，第71卷，第1期，第921–933页，2023年1月。[22] K. Liu、Z. Zhang 和 L. Dai，“用户侧可重构智能表面：在用户侧实现大规模阵列”，载于 IEEE 全球通信大会（GLOBECOM）论文集，2021年12月，第1–6页。[23] K. T. Selvan 和 R. Janaswamy，“孔径天线的夫琅禾费距离与菲涅尔距离：统一推导”，IEEE Antennas Propag. Mag.，第59卷，第4期，第12–15页，2017年8月。[24] C. Zhou、C. You、S. Gong、B. Lyu、B. Zheng 和 Y. Gong，“具有双侧可见区域的超大规模智能反射面辅助无线系统信道估计”，载于 IEEE 第16届无线通信与信号处理国际会议（WCSP）论文集，2024年10月，第456–461页。[25] A. Tang、J.-B. Wang、Y. Pan、W. Zhang、X. Zhang、Y. Chen、H. Yu 和 R. C. de Lamare，“超大规模多输入多输出系统的联合可见区域与信道估计”，IEEE Trans. Commun.，第72卷，第10期，第6087–6101页，2024年10月。[26] X. Zhang，《矩阵分析与应用》。英国剑桥：剑桥大学出版社，2017年。[27] A. Liu、G. Liu、L. Lian、V. K. N. Lau 和 M.-J. Zhao，“具有不确定感知矩阵的结构化稀疏信号稳健恢复：Turbo变分贝叶斯推断方法”，IEEE Trans. Wireless Commun.，第19卷，第5期，第3185–3198页，2020年5月。[28] P. Schniter，“结构化稀疏信号的Turbo重构”，载于2010年第44届信息科学与系统年会（CISS）论文集，2010年3月，第1–6页。[29] D. G. Tzikas、A. C. Likas 和 N. P. Galatsanos，“贝叶斯推断的变分近似”，IEEE Signal Process Mag.，第25卷，第6期，第131–146页，2008年11月。[30] W. Xu、A. Liu、B. Zhou 和 M.-J. Zhao，“用于联合稀疏信号恢复与动态网格参数估计的逐次线性近似VBI”，IEEE Trans. Wireless Commun.，第24卷，第11期，第9645–9659页，2025年11月。[31] A. Liu、Y. Zhou 和 W. Xu，“具有动态网格的结构化压缩感知的子空间约束变分贝叶斯推断”，IEEE Trans. Signal Process.，第73卷，第781–794页，2025年1月。[32] L. Chen、A. Liu 和 X. Yuan，“使用马尔可夫先验的面向大规模多输入多输出信道估计的结构化Turbo压缩感知”，IEEE Trans. Veh. Technol.，第67卷，第5期，第4635–4639页，2018年5月。[33] J. Nocedal 和 S. J. Wright，《数值优化》，第2版。美国纽约州纽约：Springer，2006年。[34] M. R. Akdeniz、Y. Liu、M. K. Samimi、S. Sun、S. Rangan、T. S. Rappaport 和 E. Erkip，“毫米波信道建模与蜂窝容量评估”，IEEE J. Sel. Areas Commun.，第32卷，第6期，第1164–1179页，2014年6月。