

超大规模可重构智能表面辅助系统近场时变信道估计

邵凯^{1,2}, 邵辰浩¹

(1. 重庆邮电大学通信与信息工程学院, 重庆 400065; 2. 移动通信技术重庆市重点实验室, 重庆 400065)

摘要: 针对超大规模可重构智能表面 (XL-RIS) 辅助近场时变信道估计面临的级联维度高、极域码本复杂度大等问题, 本文提出一种低复杂度贝叶斯信道估计与跟踪方法。首先, 利用基站 (BS)-RIS 链路静态特性及级联信道双结构稀疏性, 对 BS 侧公共支撑进行解耦, 将级联信道估计转化为 RIS 侧等效近场信道估计; 其次, 在第一帧构造多测量向量 (MMV) 模型, 采用多测量向量稀疏贝叶斯学习 (MSBL) 在固定角度采样下更新自适应码本, 获得角度支撑和贝叶斯先验; 最后, 在后续帧固定自适应码本, 利用分层贝叶斯卡尔曼滤波 (HBKF) 递归跟踪时变稀疏系数。仿真结果表明, 所提方法在降低估计复杂度的同时提高了近场时变信道估计精度, 证明了所提贝叶斯估计与跟踪框架在 XL-RIS 辅助近场时变信道估计中的有效性。

关键词: 超大规模可重构智能表面; 信道估计; 近场; 时变; 稀疏贝叶斯学习

中图分类号: TN929

文献标志码: A

Near-field time-varying channel estimation for extremely large-scale reconfigurable intelligent surface-aided systems

Shao Kai^{1,2}, Shao Chenhao¹

1. School of Communications and Information Engineering, Chongqing University of Posts and Telecommunications, Chongqing 400065, China

2. Chongqing Key Laboratory of Mobile Communications Technology, Chongqing 400065, China

Abstract: To address the high dimensionality of cascaded channels and the high complexity of polar-domain codebooks in extremely large-scale reconfigurable intelligent surface (XL-RIS)-assisted near-field time-varying channel estimation, a low-complexity Bayesian channel estimation and tracking method was proposed. First, by exploiting the static property of the base station (BS)-RIS link and the double-structured sparsity of the cascaded channel, the common support at the BS side was decoupled, and the cascaded channel estimation problem was transformed into an equivalent near-field channel estimation problem at the RIS side. Then, a multiple measurement vector (MMV) model was constructed in the first frame, and multiple measurement vector sparse Bayesian learning (MSBL) was employed to update the adaptive codebook with fixed angular sampling, through which the angular support and Bayesian priors were obtained. Finally, in the subsequent frames, the adaptive codebook was fixed, and a hierarchical Bayesian Kalman filter (HBKF) was employed to recursively track the time-varying sparse coefficients. It was shown by simulation results that the estimation accuracy of near-field time-varying channels was improved and the estimation complexity was reduced. The proposed Bayesian estimation and tracking framework demonstrates its effectiveness for XL-RIS-assisted near-field time-varying channel estimation.

Key words: XL-RIS, channel estimation, near-field, time-varying, sparse Bayesian learning

收稿日期: XXXX-XX-XX; 修回日期: XXXX-XX-XX

基金项目: 重庆市自然科学基金(CSTB2025NSCQ-GPX1253)

Foundation Items: The Natural Science Foundation of Chongqing(CSTB2025NSCQ-GPX1253)

0 引言

可重构智能表面 (reconfigurable intelligent surface, RIS) 由大量可编程的无源元件构成, 能动态调控信号反射方向, 进而重塑无线电磁环境^[1]。在毫米波/太赫兹通信中, RIS 可显著提升频谱效率、信道容量与覆盖范围^[2], 已成为下一代通信的关键技术。然而, 获取准确的信道状态信息 (channel state information, CSI) 是发挥 RIS 性能的前提, 也是一大挑战^[3]。由于 RIS 为无源设备, 系统需在基站 (base station, BS) 或用户设备 (user equipment, UE) 端完成 BS-RIS-UE 级联信道的估计。而 RIS 辅助通信系统的信道由 BS-RIS 信道和 RIS-UE 信道级联组成, 随着 RIS 反射单元数量增加, 信道矩阵维度线性增长, 导致导频开销与计算复杂度剧增^[4-5]。在 RIS 辅助的信道估计的研究方法中, 最小二乘或最小均方误差方法在 RIS 单元众多时频谱效率显著下降^[6-7], 深度学习方法泛化能力受限于训练数据与环境变化^[8]。压缩感知和稀疏贝叶斯学习 (sparse bayesian learning, SBL) 能够利用毫米波信道稀疏性, 在欠定观测下实现低开销信道恢复。文献[9]通过级联信道向量化和正则化 SBL 超参数更新挖掘角域稀疏结构。级联信道向量化后容易忽略链路中存在的共享支撑关系, 文献[10]进一步利用 RIS 辅助远场级联信道的双结构稀疏性, 通过双结构正交匹配跟踪联合估计公共行支撑和部分公共列支撑, 以压缩感知方式降低导频开销。在双结构支撑估计的基础上, 文献[11]进一步引入 SBL 对支撑集合和信道系数进行贝叶斯细化, 从而提高级联信道估计精度。此外文献[12]利用所有用户共享的 BS-RIS 公共列块稀疏性, 先估计公共到达角子空间并进行投影, 将原始行列块稀疏级联信道转化为低维行块稀疏恢复问题。

为了满足未来通信网络对高数据速率和大规模连接的需求, 超大规模多输入多输出 (extremely large-scale multiple-input multiple-output, XL-MIMO)、超大规模可重构智能表面 (extremely large-scale reconfigurable intelligent surface, XL-RIS) 等技术也正蓬勃发展。当 RIS 辅助系统扩展到 XL-RIS 场景时, 级联信道估计不仅存在维度高的问题, 还需要面对近场传播带来的建模变化。随着阵列孔径和载波频率增大, 瑞利距离显著扩展, 用户或散射体更容易处于近场区域。此时, 传统远场平

面波假设不再成立, 阵列响应同时依赖角度和距离, 信道需要采用球面波模型刻画。与远场信道主要依赖角域稀疏性不同, 近场信道在角度-距离联合极域中呈现更明显的稀疏结构, 已有研究揭示了近场信道在极域中具有稀疏性, 并通过构建角度-距离采样码本采用压缩感知算法进行估计。为了解决 XL-RIS 辅助系统下级联信道的近场信道估计问题, 文献[13]在文献[10]的基础上针对 XL-RIS 近场传播特性引入极域双结构稀疏性, 通过角度-距离联合字典提升近场级联信道估计精度。然而, 完整极域码本需要同时采样角度和距离, 码本规模随采样点数快速增长, 导致 RIS 辅助系统的近场级联信道计算复杂度大幅提升。为降低近场级联信道估计开销, 文献[14-15]通过混合 RIS 中少量有源单元分别估计 RIS-UE 与 BS-RIS 信道, 再重构级联信道, 但需要额外有源硬件支持, 文献[16]则是通过 RIS 侧等效级联角把级联信道转化为 RIS 侧等效信道来降低级联信道估计开销。针对近场极域码本规模过大的问题, 文献[17]提出自适应码本联合稀疏贝叶斯学习 (joint sparse bayesian learning, JSBL), 利用近场信道能量在角域集中的特性, 先通过 SBL 获得主要角度支撑, 再在固定角度采样下更新活跃原子的距离参数, 从而避免完整二维极域搜索。

然而, 上述研究的相关算法用于信道估计时需要先验信息, 导致此类重构算法仅适用于静态或准静态信道条件。在实践中, 由于收发器的移动性, 维持准静态信道具有挑战性。在近场模型下, 若用户或散射体发生移动, 级联信道会呈现时变特性。若每个传输块都重新估计完整级联信道, 不仅需要重复构造高维观测模型, 还会消耗大量导频并压缩数据传输时间。时变无线信道的路径增益在相邻时刻具有相关性, 文献[18]指出, 时变无线信道的路径增益在相邻时刻之间具有相关性, 这为利用历史 CSI 预测当前信道提供了理论依据。基于该时间相关模型, 文献[19-20]将级联信道表示为状态空间模型, 并利用卡尔曼滤波 (kalman filter, KF) 在预测-更新框架下实现 CSI 的递推跟踪。然而, KF 主要刻画信道系数的时间演化, 难以同时利用毫米波信道的稀疏支撑结构和路径活跃性先验。文献[21-23]尝试在欠采样下, 利用时变稀疏信号的空间稀疏性和时间相关性, 实现低延迟、高精度的实时重建。在此基础上文献[24]提出分层贝叶斯卡尔曼滤

波 (hierarchical bayesian kalman filter, HBKF) 算法来解决稀疏恢复问题,而在文献[25]中采用 HBKF 来解决时变信道参数跟踪和信号重构问题,结合稀疏先验和时间相关性实现递推估计。需要注意的是,时变递推跟踪通常依赖初始 CSI,在无先验信息条件下,需要先通过静态或准静态信道估计获得可靠初始化,再用于后续时变跟踪。文献[26]面向远场毫米波混合 MIMO 系统分别考虑准静态和时间选择性场景,为了获取可靠初始化,在准静态中利用多测量向量 (multiple measurement vector, MMV) 共享角域支撑的特性,建立块稀疏 MMV 模型,并采用 MMV-SBL 恢复信道;在时变阶段利用准静态提供的初始 CSI 结合 HBKF 进行预测更新。文献[27]针对 XL-RIS 近场动态场景,在双结构稀疏基础上通过去噪卷积神经网络-迭代收缩阈值算法获得静态 CSI,并利用具有时间相关函数的 KF 实现近场时变信道估计。

现有研究已分别在级联信道结构降维、近场自适应码本设计和时变稀疏跟踪方面取得进展,但这些环节大多相互独立。针对 XL-RIS 近场时变级联信道,现有工作对 RIS 侧低维稀疏域内级联观测降维、近场参数学习与时变递推跟踪的统一建模与协同处理仍研究不足。综上,本文提出一种结合多测量向量稀疏贝叶斯学习 (multiple measurement vector sparse Bayesian learning, MSBL) 和分层贝叶斯卡尔曼滤波的 MSBL-HBKF 算法实现 XL-RIS 辅助近场时变信道估计。本文的具体贡献如下:(1) 首先,针对完整 BS-RIS-UE 级联信道维度较高的问题,利用 RIS 级联信道的双结构稀疏性和 BS-RIS 公共子空间特征对 BS 侧进行投影,将完整级联信道估计转化为 RIS 侧等效近场信道估计,为后续 MSBL 和时变跟踪建立低维观测模型。(2) 其次,针对 RIS 侧近场信道角度-距离耦合以及后续时变跟踪对准确先验信息的需求,在第一帧内构造多测量向量 (MMV) 观测,利用多测量向量共享支撑,通过自适应 MSBL 完成角度支撑判决和距离参数更新,并获得后续时变跟踪所需的自适应码本 and 贝叶斯先验。(3) 最后,针对后续传输块重复近场估计以及传统 KF 难以保持稀疏结构的问题,固定第一帧获得的自适应码本和稀疏先验,通过 HBKF 递推跟踪自适应码本域的时变稀疏系数,并根据动态误差超参数修正信道稀疏性。

1 系统建模

图 1 所示为 XL-RIS 辅助毫米波通信系统,其中 BS 配备 M 根天线, XL-RIS 采用 N 个反射元件的均匀线性阵列, UE 配备单天线。假设 BS-UE 的直视链路被阻挡,因此只考虑 BS-RIS-UE 间的级联信道通信路径,其中 BS-RIS 信道 $\mathbf{G}_{BR} \in \mathbb{C}^{M \times N}$ 、RIS-UE 信道 $\mathbf{h}_{RU} \in \mathbb{C}^{N \times 1}$ 和 BS-RIS-UE 级联信道 $\mathbf{H} \in \mathbb{C}^{M \times N}$ 。为了简化问题,假设 BS-RIS 相距较远的距离,因此 $\mathbf{G}_{BR}$ 建模为远场静态信道,且只包含单条直视路径。由于 XL-RIS 的超大规模特性, $\mathbf{h}_{RU}$ 建模为近场时变信道,其多径分量只包含近场分量而没有远场分量。远近场的边界取决于瑞利距离 $r = 2D_{RIS}^2/\lambda$, D_{RIS} 为 XL-RIS 的孔径, λ 为信号载波波长。本文假设块衰落信道,即信道参数在每个传输块上保持不变。每个传输块分为导频训练阶段和数据传输阶段,UE 在导频训练阶段,通过 RIS 向 BS 发送 Q 个已知的导频信号用于上行链路估计。




图 1 XL-RIS 辅助通信系统模型

1.1 级联信道建模

根据图 1, BS 配备 M 根天线, XL-RIS 采用 N 个反射元件,则 BS-RIS 远场信道 $\mathbf{G}_{BR}$ 为:

$$\mathbf{G}_{BR} = \sqrt{MN} \alpha_{BR} \mathbf{a}_B(\theta_{BR}^{AOA}) \mathbf{a}_R^H(\varphi_{RB}^{AOD}) \quad (1)$$

其中, α_{BR} 表示 BS-RIS 直视路径的信道增益, $\mathbf{a}_B(\theta_{BR}^{AOA})$ 表示 BS 侧到达角 θ_{BR}^{AOA} 远场导向矢量, $\mathbf{a}_R^H(\varphi_{RB}^{AOD})$ 表示 XL-RIS 侧离开角 φ_{RB}^{AOD} 远场导向矢量。RIS-UE 近场信道 $\mathbf{h}_{RU}$ 表示为:

$$\mathbf{h}_{RU}[t] = \sqrt{\frac{N}{L}} \sum_{\ell=1}^L g_{\ell}[t] \mathbf{b}_R(\varphi_{\ell}^{AOA}, r_{\ell}) \quad (2)$$

其中 g_{ℓ} 为第 L 条路径的增益, φ_{ℓ}^{AOA} , r_{ℓ} 分别表示为

RIS 侧第1条路径到达角和第1个散射体到 RIS 中心的距离, $\mathbf{b}_R(\varphi_\ell^{\text{AOA}}, r_\ell)$ 表示近场导向矢量。

上述 BS 侧和 RIS 侧的远场导向矢量 $\mathbf{a}(\varphi)$ 、近场导向矢量 $\mathbf{b}(\varphi, r)$ 分别表示为:

$$\mathbf{a}_n(\theta) = \frac{1}{\sqrt{N_a}} \left[e^{-j\frac{2\pi}{\lambda}\zeta_1\theta}, e^{-j\frac{2\pi}{\lambda}\zeta_2\theta}, \dots, e^{-j\frac{2\pi}{\lambda}\zeta_n\theta} \right]^H \quad (3)$$

$$[\mathbf{b}(\varphi, r)]_n = \frac{1}{\sqrt{N}} \exp\left(-j\frac{2\pi}{\lambda}(d_n(\varphi, r) - r)\right) \quad (4)$$

其中 ζ_n 表示第 n 个阵元相对于阵列中心的位置为 $\zeta_n = \left(n - \frac{N-1}{2}\right)d$, $d_n(\varphi, r) = \sqrt{r^2 + \zeta_n^2 - 2r\varphi\zeta_n}$, 其中 $n = 0, 1, \dots, N-1$ 。

定义 BS-RIS-UE 链路级联信道 $\mathbf{H} = \mathbf{G}_{\text{BR}} \text{diag}(\mathbf{h}_{\text{RU}}[t])$ 表示。由于 BS-RIS 距离较远, 近似为静态路径 (即在整个传输块中只需要一次估计)。因此, 级联信道 $\mathbf{H}$ 的时变表示 $\mathbf{H}[t] \in \mathbb{C}^{M \times N}$ 为:

$$\mathbf{H}[t] = \sqrt{MN} \alpha_{\text{BR}} \mathbf{a}_B(\vartheta_{\text{BR}}^{\text{AOA}}) \mathbf{a}_R^H(\varphi_{\text{RB}}^{\text{AOD}}) \text{diag}\left(\sqrt{\frac{N}{L}} \sum_{\ell=1}^L g_\ell[t] \mathbf{b}_R(\varphi_\ell^{\text{AOA}}, r_\ell)\right) \quad (5)$$

其中, $g_\ell[t]$ 表示第 t 个传输块的 RIS-UE 信道增益, $g_\ell[t]$ 的时间演化模型可以通过一阶自回归过程近似表示为:

$$g_\ell[t] = \rho g_\ell[t-1] + \sqrt{1-\rho^2} u_\ell[t] \quad (6)$$

其中, $\rho = J_0(2\pi f_D T_B)$ 表示与信道增益对应的时间相关系数, $J_0(\cdot)$ 表示第一类零阶贝塞尔函数, f_D 和 T_B 分别表示为最大多普勒频移和传输块持续时间, $u_\ell[t] \sim (0, \sigma_u^2)$ 表示模型误差, 并且假设与 $g_\ell[t]$ 独立。

1.2 问题建立

为了表示方便, 本文采用下标表示传输块间的时间变量 t 。需要说明的是, 本章节首先建立一般时变观测模型, 因此在接收信号和信道变量中保留时间下标 t 。而 2.1 和 2.2 节主要面向第一帧初始化, 用于完成级联信道等效处理、BS 侧投影降维和自适应码本学习, 不涉及传输块间的时变递推, 因此相关公式不显式标注全局时间下标。后续 2.3 节进入时变信道跟踪阶段后, 再使用时间下标描述不同传输块之间稀疏系数和信道状态的演化。定义 RIS

的相移矢量为 $\boldsymbol{\theta} = [\eta_1 e^{j\theta_1}, \eta_2 e^{j\theta_2}, \dots, \eta_n e^{j\theta_n}]$, 表示 RIS 的第 n 个元素的反射相移和振幅。为了简化问题, 假设 $\eta_n = 1, \forall n$ 。则在第 t 个传输块发送第 q 个导频时, 基站侧的有效接收信号 $\mathbf{y}(q) \in \mathbb{C}^{M \times 1}$ 表示为:

$$\begin{aligned} \mathbf{y}_{t,q} &= \mathbf{G} \text{diag}(\boldsymbol{\theta}_q) \mathbf{h}_t s_q + \mathbf{w}_{t,q} \\ &= \mathbf{G} \text{diag}(\mathbf{h}_t) \boldsymbol{\theta}_q s_q + \mathbf{w}_{t,q} = \mathbf{H}_t \boldsymbol{\theta}_q s_q + \mathbf{w}_{t,q} \end{aligned} \quad (7)$$

其中, s_q 表示导频信号, $\mathbf{w}_{t,q} \in \mathbb{C}^{M \times 1} \sim \mathcal{CN}(0, \sigma^2 \mathbf{I}_M)$ 表示信道噪声。假设导频信号为 $s_q = 1, \forall q$, 在 Q 个导频传输完成后, 可以得到接收信号矩阵 $\mathbf{Y}_t = [\mathbf{y}_{t,1}, \dots, \mathbf{y}_{t,Q}] \in \mathbb{C}^{M \times Q}$ 表示为:

$$\mathbf{Y}_t = \mathbf{H}_t \boldsymbol{\Theta} + \mathbf{W}_t \quad (8)$$

其中, $\boldsymbol{\Theta} = [\boldsymbol{\theta}_1, \dots, \boldsymbol{\theta}_Q] \in \mathbb{C}^{N \times Q}$ 是 RIS 的反射矩阵, $\mathbf{W}_t = [\mathbf{w}_{t,1}, \dots, \mathbf{w}_{t,Q}] \in \mathbb{C}^{M \times Q}$ 是噪声矩阵。本文的目标是根据测量矩阵 $\mathbf{Y}_t$ 和式 (6) 描述的增益演化模型得到级联信道 $\mathbf{H}_t$ 的估计。对于 XL-RIS 辅助毫米波系统, 存在几个难点: 1) 若直接对每个训练块的完整级联信道进行估计, 需要恢复高维矩阵, 导频开销和计算复杂度较高; 2) 由于 XL-RIS 阵列孔径较大, RIS-UE 链路呈现近场球面波传播特性, 信道不仅与角度有关, 还与距离有关, 传统远场角域稀疏模型难以准确表征; 而完整角度-距离极域码本又会带来较大的字典维度; 3) 在用户移动场景下, RIS-UE 信道随时间缓慢变化, 若每个传输块均重新估计近场信道, 将进一步增加导频开销。

2 时变信道估计

针对 $\mathbf{H}_t$ 估计的难点, 本文提出如图 2 所示的低复杂度贝叶斯估计与跟踪框架。首先, 对级联信道进行处理, 利用 BS-RIS 静态直视路径和双结构稀疏性, 估计 BS 侧公共支撑得到到达角 $\hat{\theta}_{\text{BR}}^{\text{AOA}}$ 并投影降维, 将完整级联信道转化为 RIS 侧等效近场信道。其次, 在第一帧构造 MMV 模型, 以时间多测量向量共享支撑, 为了避免近场极域角度-距离码本, 设计自适应 MSBL 学习近场信道角度支撑、距离参数、稀疏系数和噪声先验。最后, 固定自适应码本为后续时变信道提供先验信息, 对稀疏系数建立一阶自回归模型, 并利用 HBKF 递推更新超参数、预测协方差、卡尔曼增益和滤波结果, 最终重构时变级联信道。




图2 近场时变信道低复杂度贝叶斯估计与跟踪框架

2.1 基于BS侧投影的级联信道等效处理

利用BS-RIS链路静态远场直视路径的特点，将其在级联信道稀疏表示中视为公共支撑^[10]。若直接估计完整BS-RIS-UE级联信道，需要同时恢复BS侧和RIS侧参数，使BS侧到达角与RIS侧级联角度、距离等多维参数耦合于同一观测模型，导致待估变量维度增大，并引入高维矩阵运算和较高的求解复杂度^[12,16]。因此本文利用BS侧公共支撑投影降低后续待估计信道维度。首先在RIS侧建立等效级联角表示，并构造角度采样固定、距离参数可更新的自适应近场码本；随后结合级联信道的双结构稀疏性，在BS侧估计公共行支撑和到达角 $\hat{\theta}_{BR}^{AOA}$ ，构造对应导向矢量并对接收信号进行投影降维^[16]。从而将原始高维级联信道估计问题转化为RIS侧等效近场信道估计问题。具体过程如图3所示。

2.1.1 RIS侧等效级联角与自适应近场码本构建

在文献[10]中公式(10)针对远场场景指出，公共行对应的BS侧到达角，非零列位置对应RIS侧的RIS侧BS-RIS信道离开角和RIS-UE信道到达角和复合角度。而把RIS-UE信道建模为近场信道无法直接对RIS侧等效级联角度进行相加。依据文献[16]将式(5)中的RIS离开角与L个到达角进行等效合并，得到L个级联角度 $\vartheta = [\vartheta_1, \vartheta_2, \dots, \vartheta_\ell, \vartheta_{\ell+1}, \dots, \vartheta_L]$ ，其中 $\vartheta_\ell = \arcsin(\sin \varphi_\ell^{AOA} - \sin \varphi_{RB}^{AOD})$ ，通过级联角度可以把级联信道简化为：

$$\mathbf{H} = \mathbf{a}_B(\vartheta_{BR}^{AOA}) \mathbf{h}_r^H = \mathbf{a}_B(\vartheta_{BR}^{AOA}) \sqrt{\frac{MN^2}{L}} \sum_{\ell=1}^L \alpha_{H,\ell} \mathbf{b}_R^T(\vartheta_\ell, r_\ell) \quad (9)$$

其中 $\alpha_{H,\ell} = \alpha_G g_\ell$ 为级联信道等效增益， $\mathbf{h}_r^H =$

$\sqrt{\frac{MN^2}{L}} \sum_{\ell=1}^L \alpha_{H,\ell} \mathbf{b}_R^T(\vartheta_\ell, r_\ell)$ 为RIS侧等效近场信道。

为了估计公共行的索引，引入BS侧远场过完备字典 $\mathbf{V} \in \mathbb{C}^{M \times M_{BS}}$ 。对于XL-RIS场景，极域角度和距离采样通常不能太小，否则距离失配会明显影响近场相位拟合精度，因此完整极域码本会带来较高复杂度。为避免在等效级联角—距离二维平面上进行密集搜索进一步减少后续时变信道估计的复杂度，近场码本不采用传统的极域码本，本文参考文献[17]自适应码本思想，只对等效级联角进行均匀采样，并为每个角度原子配置一个可更新距离参数。该类自适应码本通过先捕获角域稀疏信息、再细化距离参数，使码本规模主要由角度分辨率决定，而不再由完整角度-距离二维采样决定，因此RIS侧近场自适应码本 $\mathbf{B}(\mathbf{r}) \in \mathbb{C}^{N \times S}$ ，分别定义为：

$$\mathbf{V} = [\mathbf{a}_B(\theta_1), \dots, \mathbf{a}_B(\theta_{M_{BS}})] \quad (10)$$

$$\mathbf{B}(\mathbf{r}) = [\mathbf{b}(\vartheta_1, r_1), \mathbf{b}(\vartheta_2, r_2), \dots, \mathbf{b}(\vartheta_S, r_S)] \quad (11)$$

其中 $\mathbf{B}(\mathbf{r})$ 为近场导向矢量构建的自适应码本，

$$[\mathbf{b}(\vartheta_i, r_i)]_n \approx \frac{1}{\sqrt{N}} e^{j\pi \left(-\frac{1-\vartheta_i^2}{2r_i} dn^2 + n\vartheta_i \right)}$$

$|\vartheta_i - \vartheta_{i+1}| = \frac{2}{S}$ ，且 r_S 根据通信环境自适应更新，

M_{BS} 为BS侧远场码本数， S 为RIS侧近场码本数。

2.1.2 基于双结构稀疏的BS侧公共支撑估计与投影降维

在完成RIS侧等效级联角建立后，需要估计BS侧参数。根据文献[10]双结构稀疏理论，级联角域矩阵的公共行支撑对应BS侧到达角支撑，而每个非零行中的非零列对应RIS侧等效级联角。由于本文假设BS-RIS链路为单条直视路径，因此BS侧公共行支撑数为1，只需要估计一个公共行索引即可。根据上述导向矢量的描述，级联信道 $\mathbf{H}$ 在稀疏




图3 级联信道等效处理

域变换矩阵 V 、 B 字典下被稀疏表示为:

$$H = V\tilde{H}B^H(r) \quad (12)$$

由于本文假设 BS-RIS 链路为单条直视路径, 因此 BS 侧公共行支撑集为 $L_G = 1$, RIS-UE 路径为 L 条, $\tilde{H}$ 将只有 1 个非零行, 该行内有 L 个非零列。将上述分解代入 (9) 中得到观测模型:

$$Y = V\tilde{H}B^H(r)\Theta + W \quad (13)$$

转化为压缩感知模型为:

$$\tilde{Y} = (B^H(r)\Theta)^H \tilde{H}^H + \tilde{W} = \Theta^H B(r) \tilde{H}^H + \tilde{W} \quad (14)$$

其中 $\tilde{Y} = (V^H Y)^H \in \mathbb{C}^{Q \times M_{BS}}$ 等效接收信号, $\tilde{W}$ 是等效噪声。用 RIS 辅助信道的双结构稀疏性估计公共行的索引:

$$\hat{\Omega}_B = \arg \max_m \left\| \mathcal{P}(\tilde{Y}_{:,m}, 1) \right\|_2^2 \quad (15)$$

其中 $\mathcal{P}(X, L)$ 表示对 x 的剪枝算子, 将除最大的 L 个幅值元素以外的所有元素置零, $\hat{\Omega}_B$ 为公共行对应的支撑集, 其中支撑集包括 $a_B(\theta_{BR}^{AOA})$ 的信息。在得到公共行支撑集之后, 根据该索引从 BS 侧远场过完备字典中选取对应的导向原子, 构造对应 BS 侧的导向矢量:

$$\hat{a}_B(\theta_{BR}^{AOA}) = V_{:, \hat{\Omega}_B} \quad (16)$$

利用 BS 侧的导向矢量对接收信号进行左投影得到接收向量 $\bar{y} \in \mathbb{C}^{Q \times 1}$ 为:

$$\bar{y} = \frac{Y^H \hat{a}_B}{\|\hat{a}_B\|_2^2} = Q^H h_r + \bar{w} \quad (17)$$

RIS 侧等效信道在稀疏域中表示为:

$$h_r = B(r)x \quad (18)$$

其中 $x \in \mathbb{C}^{S \times 1}$ 为自适应码本下的稀疏系数向量。把此公式代入解耦后观测模型得到:

$$\bar{y} = \Theta^H B(r)x + \bar{w} = A(r)x + \bar{w} \quad (19)$$

其中 $A(r) = \Theta^H B(r) \in \mathbb{C}^{Q \times S}$ 为自适应等效感知矩阵。

2.2 基于第一帧 MMV 的自适应 MSBL 信道估计

在 RIS 侧等效近场信道中, 近场阵列响应同时依赖等效级联角和距离参数, 直接构造完整的角度-距离极域码本会增加计算复杂度。为此, 本文

在第一帧构建 MMV 观测, 利用慢时变多测量向量间角度、距离近似不变及共享稀疏支撑的特性, 采用自适应 MSBL 估计稀疏系数矩阵 X 、公共稀疏超参数 δ 、等效噪声精度 β 以及距离参数, 并在固定角度网格下完成自适应近场码本优化。所得第一帧的稀疏系数估计、稀疏先验、噪声精度和自适应码本, 为后续 HBKF 时变跟踪提供初始化信息。具体过程如图 4 所示。

2.2.1 第一帧 RIS 侧等效 MMV 观测模型构建

第一帧内选取 K 个短训练块构造 MMV 观测模型, 并通过 MMV 框架对自适应码本的角度支撑集和距离参数进行更新。将第一帧内 K 个训练块的解耦观测按列堆叠, 可得到第一帧 MMV 接收信号:

$$\bar{Y} = A(r)X + \bar{W} \quad (20)$$

其中 $\bar{Y} = [\bar{y}_1, \bar{y}_2, \dots, \bar{y}_K] \in \mathbb{C}^{Q \times K}$, $X = [x_1, x_2, \dots, x_K] \in \mathbb{C}^{S \times K}$, $\bar{W} = [\bar{w}_1, \dots, \bar{w}_K] \in \mathbb{C}^{Q \times K}$, K 为第一帧内用于构造 MMV 的短训练块数, x_k 为第 k 个传输块对应的 RIS 侧等效稀疏系数向量。第一帧内多个训练块共享相同的角度支撑和近似相同的距离参数, 为了刻画原级联稀疏矩阵中 RIS 侧列支撑在多个训练块中的共同稀疏性, 定义第 m 个 RIS 侧字典原子对应的多测系数向量, 即 MMV 系数矩阵 X 的第 m 行转置为:

$$x_m^{MMV} \triangleq X_{m,:}^T = [x_{m,1}, x_{m,2}, \dots, x_{m,K}]^T \quad (21)$$

2.2.2 分层贝叶斯先验与后验推断

引入共享方差超参数 δ_m 并假设 $x_m^{MMV} \sim \mathcal{CN}(0, \delta_m I_K)$, $m = 1, \dots, S$ 。假设稀疏性系数 X 服从高斯先验分布, 根据:

$$p(X|\delta) = \prod_{k=1}^K \mathcal{CN}(x_k; 0, A) \quad (22)$$

其中 δ_m 是自适应码本域第 m 个 RIS 侧自适应近场码本原子的方差型超参数, $A = \text{diag}(\delta_1, \delta_2, \dots, \delta_m) \in \mathbb{C}^{S \times S}$ 为超参数矩阵。当 δ_m 较大时, 第 m 个角度原子更可能为活跃路径; 当 δ_m 逐渐减小到零时, 对应原子被自动抑制。为了进一步促进稀疏性, 对超参数 δ_m 和服从独立同分布复高斯分布噪声精度 $\beta = \sigma^{-2}$ 引入 Gamma 先验:



图4 第一帧 MMV 自适应 MSBL 估计流程

$$p(\delta) = \prod_{m=1}^S \Gamma(\delta_m; 1, \varepsilon) \quad (23)$$

$$p(\beta) = \Gamma(\beta; a, b)$$

其中把 $\Xi = \{\varepsilon, a, b\}$ 为 SBL 推断中的预设超参数集合。在给定 $\mathbf{X}$ 、 β 时, 观测矩阵的条件概率为:

$$p(\bar{\mathbf{Y}}|\mathbf{X}, \beta) = \prod_{k=1}^K \mathcal{CN}(\bar{\mathbf{y}}_k; \mathbf{A}(\mathbf{r})x_k, \beta^{-1}\mathbf{I}_Q) \quad (24)$$

由概率链式法则, 联合概率密度为:

$$p(\bar{\mathbf{Y}}|\mathbf{X}, \delta, \beta; \Xi) = p(\bar{\mathbf{Y}}|\mathbf{X}, \beta) p(\mathbf{X}|\delta) p(\delta) p(\beta) \quad (25)$$

SBL 的目标是通过最大化边缘似然来估计稀疏超参数、噪声精度以及自适应码本。引入任意分布 $q(\mathbf{X})$, 对数边缘似然可分解为:

$$\ln p(\bar{\mathbf{Y}}|\delta, \beta; \Xi) = \mathcal{L}(q, \delta, \beta; \Xi) + \text{KL}(q(\mathbf{X}) \| p(\mathbf{X}|\bar{\mathbf{Y}}, \delta, \beta)) \quad (26)$$

其中 $\text{KL}(\cdot \| \cdot)$ 为 KL 散度, 变分下界为 $\mathcal{L}(q, \delta, \beta; \Xi) = \mathbb{E}_q \left[\ln \frac{p(\bar{\mathbf{Y}}|\mathbf{X}, \delta, \beta; \Xi)}{q(\mathbf{X})} \right]$ 。当 $q(\mathbf{X}) = p(\mathbf{X}|\bar{\mathbf{Y}}, \delta, \beta)$ 时, KL 散度为零, 下界达到最大值:

$$(\delta, \beta, \mathbf{B}(\mathbf{r})) = \arg \max_{\delta, \beta, \mathbf{B}(\mathbf{r})} \mathcal{L}(\delta, \beta, \mathbf{B}(\mathbf{r}); \Xi) \quad (27)$$

$\mathbf{X}$ 的后验分布仍为复高斯分布:

$$p(\mathbf{X}|\bar{\mathbf{Y}}, \delta, \beta) = \prod_{k=1}^K \mathcal{CN}(\mathbf{x}_k; \boldsymbol{\mu}_k, \boldsymbol{\Sigma}) \quad (28)$$

其中

$$\boldsymbol{\Sigma} = (\beta \mathbf{A}^H(\mathbf{r}) \mathbf{A}(\mathbf{r}) + \mathbf{I}^{-1})^{-1} \quad (29)$$

$$\boldsymbol{\mu}_k = \beta \boldsymbol{\Sigma} \mathbf{A}^H(\mathbf{r}) \bar{\mathbf{y}}_k \quad (30)$$

2.2.3 基于变分下界的超参数更新与自适应码本优化

根据 EM 迭代思想, 在 E 步中, 已经计算出后验均值和后验协方差, 在 M 步骤中更新系数超参数 δ_m 需要最大化关于 δ 的期望对数先验:

$$\delta = \arg \max_{\delta} \mathbb{E}_{\mathbf{X}|\bar{\mathbf{Y}}} [\ln p(\mathbf{X}|\delta) + \ln p(\delta)] \quad (31)$$

忽略与 δ 无关的常数项得并对 δ 求导令其为 0, 进而超参数 δ_m 可以更新为:

$$\delta_m = \frac{1}{K} \|\mathbf{U}_{m,:}\|_2^2 + [\boldsymbol{\Sigma}]_{m,m}, \quad m = 1, \dots, S \quad (32)$$

其中 $\mathbf{U} = [\boldsymbol{\mu}_1, \boldsymbol{\mu}_2, \dots, \boldsymbol{\mu}_K] \in \mathbb{C}^{S \times K}$ 表示稀疏系数矩阵 $\mathbf{X}$ 的后验均值, 且 $\|\mathbf{U}_{m,:}\|_2^2 = \sum_{k=1}^K |\mathbf{U}_{m,k}|^2$ 。由 (32) 可知, 公共稀疏超参数 δ_m 由第 m 个码本原子在

MMV 观测中的后验均值平均能量与后验方差共同构成, 等价于该原子对应稀疏系数在 K 个测量向量上的平均后验功率, 用于表征其活跃程度。 δ_m 越大, 对应原子的活跃程度越高; 当 δ_m 趋近于零时, 该原子受到抑制。因此, 相比单测量向量估计, MSBL 通过 k 个测量向量的共同支撑信息, 提高了角度支撑判决的稳定性。

根据变分下界中与 β 相关的项, 有对噪声精度的更新需要最大化关于 β 的期望对数似然:

$$\beta = \arg \max_{\beta} \mathbb{E}_{\mathbf{X}|\bar{\mathbf{Y}}} [\ln p(\bar{\mathbf{Y}}|\mathbf{X}, \beta) + \ln p(\beta)] \quad (33)$$

忽略与 β 无关的常数项得并对 β 求导令其为 0 进而噪声精度 β 更新为:

$$\beta = \frac{QK}{\|\bar{\mathbf{Y}} - \mathbf{A}(\mathbf{r})\mathbf{U}\|_F^2 + K \text{tr}(\mathbf{A}(\mathbf{r}) \boldsymbol{\Sigma} \mathbf{A}^H(\mathbf{r}))} \quad (34)$$

与固定字典 MSBL 不同, 本文需要进一步更新 $\mathbf{B}(\mathbf{r})$, 根据变分下界, 保留与相关的项 $\mathbf{B}(\mathbf{r})$, 可得码本优化问题:

$$\mathbf{B}(\mathbf{r}) = \arg \min \mathcal{L}_{\mathbf{B}(\mathbf{r})} \quad (35)$$

其

中

$$\mathcal{L}_{\mathbf{B}(\mathbf{r})} = \beta \|\bar{\mathbf{Y}} - \mathbf{A}(\mathbf{r})\mathbf{U}\|_F^2 + \beta K \text{tr}(\mathbf{A}(\mathbf{r}) \boldsymbol{\Sigma} \mathbf{A}^H(\mathbf{r})).$$

直接求解二维 (角度+距离) 优化问题计算复杂度极高, 根据文献[17]中证明了近场信道的波束域能量在角域是高度集中的, 因此可以采用固定角采样和距离更新的低复杂度策略, 这种策略将二维优化问题降为一维优化问题, 极大降低了计算复杂度, 同时保证了估计精度。对距离更新的方式采用逐步搜索方案在每次迭代中更新 $\mathbf{B}(\mathbf{r})$ 中的距离:

$$\frac{1}{r^{(i+1)}} = \frac{1}{r^{(i)}} - \alpha \nabla_r \mathcal{L}_{\mathbf{B}(\mathbf{r})} \big|_{r=r^{(i)}} \quad (36)$$

为了进一步降低复杂度, 在码本采样时会均匀采样角度, 且在每次迭代无需对所有码本的距离参数进行更新, 只需要对前 $2L$ 个高概率对应距离进行更新即可。

2.3 基于自适应码本先验的 HBKF 时变参数跟踪

第一帧 MSBL 完成后, 系统获得 RIS 侧自适应码本及贝叶斯先验。基于后续慢时变传输块中角度支撑和距离参数短时近似不变, 本文固定第一帧码本, 仅将稀疏系数作为状态变量, 并采用一阶自回归模型描述其时间演化。为避免逐帧重新估计带来的导频和计算开销, 同时弥补传统 KF 难以保持稀

疏结构的问题^[25], 利用第一帧先验初始化 HBKF, 并通过动态稀疏超参数更新完成后续状态递推和信道重构, 具体过程如图 5 所示。

第一帧得到的自适应码本, 在后续短时跟踪窗口内保持固定。对于后续第 t 个跟踪传输块, RIS 侧近场信道表示为:

$$\mathbf{h}_{r,t} = \mathbf{B}(\mathbf{r})\mathbf{x}_t \quad (37)$$

第一帧 MSBL 得到的稀疏超参数反映不同自适应码本原子的活跃程度。本文考虑慢时变场景, 在短时跟踪窗口内主要传播路径的角度、距离和路径集合近似保持不变, 因此相邻传输块的稀疏系数近似共享公共支撑 $\mathcal{S}$ 。该建模方式与文献[26]中的动态稀疏建模思路一致。基于此, 本文采用一阶自回归模型描述后续稀疏状态演化:

$$\mathbf{x}_t = \rho\mathbf{x}_{t-1} + \sqrt{1 - \rho^2}\mathbf{u}_t \quad (38)$$

其中, $\mathbf{u}_t \sim \mathcal{CN}(\mathbf{0}, \mathbf{\Gamma}_t)$ 表示归一化模型误差, $\mathbf{\Gamma}_t = \text{diag}(\gamma_{1,t}, \gamma_{2,t}, \dots, \gamma_{m,t})$ 表示状态创新稀疏协方差。 $\gamma_{m,t}$ 表示第 m 自适应码本原子的创新方差。当 $\gamma_{m,t}$ 趋近于零时, 对应原子在递推过程中受到抑制。对任意 $m \notin \mathcal{S}$, 有 $\mathbf{x}_{m,t} = \mathbf{x}_{m,t-1} = 0$, 由式 (38) 可得, $\mathbf{u}_{m,t} = 0$, 即 $\text{supp}(\mathbf{u}_t) \subseteq \mathcal{S}$ 。进一步令 $\delta_{m,t} = E\left\{\left|\mathbf{x}_{m,t}\right|^2\right\}$, $\gamma_{m,t} = E\left\{\left|\mathbf{u}_{m,t}\right|^2\right\}$ 。在 $\mathbf{u}_t$ 与 $\mathbf{x}_{t-1}$ 相互独立的条件下, 由式 (38) 可得:

$$\delta_{m,t} = \rho^2\delta_{m,t-1} + (1 - \rho^2)\gamma_{m,t} \quad (39)$$

对于短时跟踪窗口采用局部平稳近似 $\delta_{m,t} \approx \delta_{m,t-1}$, 可得 $\gamma_{m,t} \approx \delta_{m,t}$ 。因此, 第一帧 MSBL 得到的 $\hat{\delta}_m$ 可作为 HBKF 动态过程方差的初始尺度, 即 $\mathbf{\Gamma}_0 = \hat{\mathbf{\Delta}} = \text{diag}(\hat{\delta})$ 。该参数仅用于初始化, 后续 $\mathbf{\Gamma}_t$ 仍由当前观测通过 EM 迭代自适应更新。

在对后续 t 个传输块进行时变估计时, HBKF 主要包括状态预测、基于当前观测的稀疏超参数更新、卡尔曼增益计算、状态校正和信道重构。根据一阶自回归衰落模型, 信道预测估计 $\hat{\mathbf{x}}_{t|t-1}$ 和预测误差为 $\mathbf{y}_{e,t}$:

$$\hat{\mathbf{x}}_{t|t-1} = \rho\hat{\mathbf{x}}_{t-1|t-1} \quad (40)$$

$$\mathbf{y}_{e,t} = \mathbf{y}_t - \rho\mathbf{A}(\mathbf{r})_t\hat{\mathbf{x}}_{t-1|t-1} \quad (41)$$

在对超参数进行更新时, 按照 EM 算法的过程对后验均值和后验协方差按照下列公式进行更新:

$$\boldsymbol{\Sigma}_{m,t}^{(j)} = \left((1 - \rho^2)\mathbf{A}(\mathbf{r})_t^H \mathbf{R}_w^{-1} \mathbf{A}(\mathbf{r})_t + (\mathbf{\Gamma}_t^{(j)})^{-1}\right)^{-1} \quad (42)$$

$$\boldsymbol{\mu}_{m,t}^{(j)} = \sqrt{1 - \rho^2} \boldsymbol{\Sigma}_{m,t}^{(j)} \mathbf{A}(\mathbf{r})_t^H \mathbf{R}_w^{-1} \mathbf{y}_{e,t} \quad (43)$$

在 M 步骤中得到超参数的更新为:

$$\gamma_{m,t}^{(j+1)} = \boldsymbol{\Sigma}_{m,t}^{(j)} + |\boldsymbol{\mu}_{m,t}^{(j)}|^2 \quad (44)$$

在得到收敛超参数结果输入至滤波器中来修正预测误差协方差:

$$\mathbf{P}_{t|t-1} = \rho^2 \mathbf{P}_{t-1|t-1} + (1 - \rho^2) \mathbf{\Gamma}_t \quad (45)$$

卡尔曼增益:

$$\mathbf{K}_t = \mathbf{P}_{t|t-1} \hat{\mathbf{A}}(\mathbf{r})_t^H \left(\hat{\mathbf{A}}(\mathbf{r})_t \mathbf{P}_{t|t-1} \hat{\mathbf{A}}(\mathbf{r})_t^H + \sigma^2 \mathbf{I} \right)^{-1} \quad (46)$$

滤波更新:

$$\hat{\mathbf{x}}_{t|t} = \hat{\mathbf{x}}_{t|t-1} + \mathbf{K}_t \mathbf{y}_{e,t} \quad (47)$$

滤波后误差协方差:

$$\mathbf{P}_{t|t} = (\mathbf{I} - \mathbf{K}_t \hat{\mathbf{A}}(\mathbf{r})_t) \mathbf{P}_{t|t-1} \quad (48)$$

完成第 t 个传输块的状态更新后, RIS 侧近场信道估计为:

$$\hat{\mathbf{h}}_t = \hat{\mathbf{B}}(\mathbf{r}) \hat{\mathbf{x}}_{t|t} \quad (49)$$

结合以上描述, 得到本文所提信道估计算法的完整流程如算法 1 所示。

3 仿真与分析

3.1 仿真参数

本文通过仿真验证所提方法在 XL-RIS 辅助近场时变通信系统下的有效性。仿真参数设置 BS 侧天线数为 64, RIS 侧反射单元数为 256, 天线间距固定为 0.5λ 。假设 RIS-UE 信道路径为 $L=6$, 载波频率为 72GHz^[25], 移动速度 $v = 5\text{km/h}$, 多普勒频移为 $f_D = 130\text{Hz}$ 。相干时间设置为 $T_c = 5\text{ms}$, 传输块长度设置为 $T_B = \frac{T_c}{10}$, 则对应时间选择性信道模




图5 后续传输块HBKF近场时变信道跟踪

算法1 所提出近场时变信道估计算法

输入: 接收信号 $\mathbf{Y}_t$, RIS 训练矩阵 $\mathbf{\Theta}_t$, BS 侧字典 $\mathbf{V}$, 自适应码本 $\mathbf{B}(\mathbf{r}^{(0)})$, 相关系数 ρ , 噪声方差 σ^2 , 停止阈值 ϵ , 路径数 L , 最大迭代次数 $I_{\max}$, $J_{\max}$

输出: $\hat{\mathbf{H}}_t$

1) 根据式(19)得到 RIS 侧等效观测信号

初始化 $\mathbf{r}^{(0)} = \frac{d_r}{4}, \Delta^{(0)} = 1, \beta^{(0)} = 1$

while $\|\delta^{(i+1)} - \delta^{(i)}\|_2 / \|\delta^{(i)}\|_2 \leq \epsilon$ 或 $i \geq I_{\max}$

2) 根据式(29) (30)更新稀疏系数后验均值和后验协方差 $\Sigma^i, \mathbf{U}^i$

3) 根据式(32)更新方差型稀疏超参数 δ^i

4) 根据式(34)更新噪声精度 β^i

5) 根据式(36)更新距离 $\mathbf{r}^i$

6) 更新自适应码本 $\mathbf{B}(\mathbf{r}^{(i)})$

end while

7) 初始化 HBKF 的状态估计、预测误差协方差和动态稀疏超参数矩阵 $\hat{\mathbf{x}}_{0|0} = \hat{\mathbf{U}}_{:,S_0}, \mathbf{P}_{0|0} = \hat{\Sigma}, \mathbf{r}_0 = \hat{\mathbf{A}}$

for $t = 1, \dots, T$ do

8) 根据式(40)进行预测估计 $\hat{\mathbf{x}}_{t|t-1}$

9) 根据式(41)计算预测误差 $\mathbf{y}_{e,t}$

while $\|\hat{\mathbf{y}}_t^{(j)} - \hat{\mathbf{y}}_t^{(j-1)}\| > \epsilon$ 或 $j < J_{\max}$

10) 根据式(42)、(43)更新预测误差后验均值和后验协方差 $\mu_{m,t}^{(j)}, \Sigma_{m,t}^{(j)}$

11) 根据式(44)更新动态稀疏超参数 $\gamma_t^{(j+1)} = [\gamma_{1,t}^{(j+1)}, \gamma_{2,t}^{(j+1)}, \dots, \gamma_{S,t}^{(j+1)}]^T$

12) 得到 $\mathbf{r}_t^{(j+1)} = \text{diag}(\gamma_t^{(j+1)})$

end while

13) 根据式(45)更新预测协方差 $\mathbf{P}_{t|t-1}$

14) 根据式(46)计算卡尔曼增益 $\mathbf{K}_t$

15) 根据式(47)更新稀疏系数估计 $\hat{\mathbf{x}}_{t|t}$

16) 根据式(48)更新滤波后协方差 $\mathbf{P}_{t|t}$

更新传输块 $t++$

end for

17) 输出: 级联信道 $\hat{\mathbf{H}}_t$

型的相关系数 $\rho \approx 0.75$ 。仿真采用归一化均方误差 (normalized mean square error, NMSE) 作为信道估计的性能评估指标, 其表达式为: $\text{NMSE} = \|\mathbf{H} - \hat{\mathbf{H}}\|_2^2 / \|\mathbf{H}\|_2^2$ 。其中 $\mathbf{H}$ 表示实际的信道, $\hat{\mathbf{H}}$ 表示估计信道。

3.2 方案设计

本节围绕所提 MSBL-HBKF 框架开展仿真验证。第一, 在第一帧估计阶段, 比较自适应 MSBL、固定距离 MSBL 的 NMSE 性能。其中, 自适应 MSBL 利用 MMV 联合稀疏建模进行公共支撑判决, 并在迭代中更新距离参数; 固定距离 MSBL 保持距离参数不变, 用于分析近场距离失配对码本匹配精度的影响。第二, 设置不同中心频率和带宽配置, 分析 MSBL 在不同系统参数下的估计性能。第三, 在时变跟踪阶段, 将 MSBL-KF、MSBL-HBKF、P-KF (polar-domain KF, P-KF)、P-HBKF (polar-domain HBKF, P-HBKF)、P-SBL-KF (polar-

domain sparse bayesian learning KF)、P-SBL-HBKF (polar-domain sparse bayesian learning HBKF)、P-SOMP (polar-domain simultaneous orthogonal matching pursuit, P-SOMP) [28] 和 Oracle KF 进行对比。其中, MSBL-KF 和 MSBL-HBKF 均采用第一帧自适应 MSBL 获得的码本和先验信息, 后续分别采用 KF 和 HBKF 跟踪稀疏系数; P-KF 和 P-HBKF 采用固定极域码本从零状态开始递推; P-SBL-KF 和 P-SBL-HBKF 首先通过极域 P-SBL 获得第一帧先验, 再分别采用 KF 和 HBKF 跟踪 [26]; 极域 P-SOMP 不采用 KF/HBKF 状态递推 [28]; Oracle KF 表示已知真实支撑后的理想卡尔曼跟踪结果。通过不同导频长度、信噪比 (signal-to-noise ratio, SNR)、传输块和 MMV 数量下的 NMSE 对比, 验证所提方法的有效性。

3.3 仿真结果及分析

在导频长度固定为 128、真实路径距离为 10 m 的第一帧初始化场景下, 图 6 比较了不同 MMV 数量下自适应距离更新 MSBL 与固定距离 MSBL 的 SNR-NMSE 性能, 其中固定距离 MSBL 的距离参数固定为 25 m。图 7 在 MMV=3、导频长度为 128 的条件下, 进一步比较不同固定距离取值对近场 MSBL 估计性能的影响。结果表明, 随着 MMV 数量由 1 逐步增加至 2、3、5、10, MSBL 的 NMSE 性能稳步提升。多测量向量一方面增强了公共角度-距离支撑的判决可靠性, 减少支撑错选引入的估计偏差; 另一方面通过多观测联合估计提升稀疏系数估计精度, 同时提升了自适应距离更新与超参数估计的稳定性。图 7 表明, 固定距离越接近真实距离, 估计性能越好。相比固定距离方法, 自适应 MSBL 能够迭代修正活跃原子的距离参数, 从而降低近场码本距离失配带来的估计误差。




图6 不同MMV数量下自适应MSBL与固定距离MSBL的性能对比




图7 不同固定距离下MSBL的SNR-NMSE性能对比

图8对比了28、60、72GHz三种中心频率与100、500、1000MHz三种带宽配置下MSBL的信道估计性能。所有配置的NMSE均随信噪比升高持续下降，相同载频下带宽越大性能增益越显著，1000MHz带宽较100MHz可带来约7~8dB的性能提升，原因在于带宽扩展增加了多测量向量的观测维度，有效提升了公共支撑判决、超参数估计与自适应距离更新的稳定性。相同带宽下，60GHz与72GHz性能接近且整体优于28GHz。28GHz波长更长，距离维度相位敏感度不足，自适应距离更新精度受限，码本失配更突出。该结果表明，所提MSBL方法在不同中心频率和带宽配置下具有较好的适用性。




图8 不同中心频率和带宽配置下MSBL估计性能对比

图9比较了SNR=10 dB、第一帧MMV=3时各算法随导频长度Q的NMSE性能。随着Q增加，各算法NMSE总体下降；MSBL-KF/MSBL-HBKf整体优于固定极域P-KF/P-HBKf，P-SBL初始化也能明显改善对应KF/HBKf性能，说明自适应码本和稀疏先验均有利于后续跟踪。为进一步量化逐块重估的导频代价，并减小单测量向量下角度、距离估计误差造成的性能偏差，MSBL在每个传输块采用3个长度均为Q的测量向量重新执行完整MSBL，

因此总导频为3Q，而MSBL-HBKf后续每块仅使用Q。在Q=80~200时，MSBL-HBKf仍较MSBL获得约0.45~2.02dB增益，即在逐块导频降低66.7%的情况下保持更低NMSE；当Q=240和256时两者性能趋近，但MSBL仍需3倍导频。结果表明，所提递推框架能够在保持跟踪精度的同时显著降低逐块重新估计的导频开销。




图9 导频长度和NMSE关系

图10和图11分别给出了MMV=1和MMV=3时各算法随SNR及传输块变化的跟踪性能。随着MMV由1增至3，第一帧支撑、距离及稀疏先验估计更加可靠，后续跟踪性能相应提升。P-SBL-KF/HBKf优于对应的零状态P-KF/HBKf，说明稀疏先验初始化可降低递推初始不确定性；在相同KF或HBKf递推下，MSBL方法总体优于P-SBL方法，表明自适应距离更新能够减小固定极域码本的距离失配。相比P-SOMP，KF/HBKf进一步利用时间相关性进行递推，其中HBKf还可通过动态稀疏超参数抑制非活跃分量。上述结果验证了MMV初始化、自适应码本和稀疏时变递推的有效性。

为验证所提框架对更一般传播场景的适用性，设置4种场景：S0为单BS-RIS路径和纯近场RIS-UE多径，S1扩展为3条BS-RIS远场路径，S2考虑RIS-UE远近场混合传播，S3同时考虑BS-RIS多径和RIS-UE远近场混合传播。由图12可见，4种场景的NMSE均随SNR提高而下降；S1较S0约损失2dB，主要源于多公共支撑估计与子空间解耦误差，而S0与S2、S1与S3性能接近，说明远近场混合传播未引入明显额外退化。结果表明，所提框架经相应模型扩展后仍适用于有限BS-RIS多径及RIS-UE远近场混合场景。

3.4 计算复杂度与存储开销分析

为定量比较不同信道跟踪方案的计算代价，分





图10 MMV为1时SNR、传输块和NMSE的关系





图11 MMV为3时SNR、传输块和NMSE的关系

别统计各算法的字典及状态维度、第一帧初始化主导复杂度、后续单传输块跟踪主导复杂度和核心存储开销,结果如表1所示。表中 I_M 和 I_P 分别表示自适应MSBL和固定极域P-SBL的迭代次数; J_A 和 J_P




图12 不同传播结构下MSBL-HBKF的SNR-NMSE性能

分别表示MSBL-HBKF和极域HBKF的超参数更新次数; W 和 K_s 分别表示P-SOMP测量向量数和选择的支撑数,为了方便对比零 $M_A = S = N$ 。核心存储开销按照统一矩阵存储口径统计,包括工作字典、状态及误差协方差和单块递推所需主要中间矩阵,不计不同程序实现产生的临时变量复用差异。由表1可见,BS侧等效投影后,各算法开销主要取决于RIS侧码本维度和跟踪方式。固定极域方法需维护高维状态及协方差;P-SBL虽改善第一帧先验,却未降低后续滤波维度;P-SOMP开销较低,但不维护基于自回归模型的Kalman状态递推。MSBL-HBKF仅在第一帧执行MSBL,后续在低维自适应码本域更新稀疏超参数并递推,避免逐块重复稀疏恢复,在性能、复杂度与存储间取得较好折中。进一步地,若MSBL-HBKF不进行BS侧公共支撑投影,联合状态维度为 $M_J = M_{BS}M_A$,降维后维度为 M_A 使主导复杂度降低了 M_{BS}^3 。由此,BS侧投影、自适应MSBL码本和HBKF递推分别缓解了级联信道维度高、二维极域码本复杂度大及逐传输块重复估计开销高的问题,实现了低复杂度XL-RIS近场时变信道估计。

4 结束语

本文在超大规模可重构智能表面(XL-RIS)毫米波近场时变信道估计场景,针对级联信道维度高、二维极域码本计算复杂度大、时变场景下逐传输块重复估计导频开销较高的问题,提出一种低复杂度贝叶斯信道估计与跟踪框架。依托级联信道双结构稀疏特性完成信道解耦,将高维BS-RIS-UE级联信道转化为RIS侧等效近场稀疏信道。第一帧采用多测量向量稀疏贝叶斯学习,在固定角度网格下迭代更新距离参数构建自适应码本,同步获取路径支撑与可靠贝叶斯先验;后续帧固定自适应码本,

表1 不同算法计算复杂度与核心存储开销对比

算法	字典维度	第一帧复杂度对比	每个传输块复杂度对比	存储开销/MiB
MSBL-KF	$M_A = N$	$\mathcal{O}[I_M(M_A^3 + QM_A^2 + 2LQN)]$	$\mathcal{O}(M_A^3 + QM_A^2)$	4.27
MSBL-HBKF	$M_A = N$	$\mathcal{O}[I_M(M_A^3 + QM_A^2 + 2LQN)]$	$\mathcal{O}[(J_A + 1)(M_A^3 + QM_A^2)]$	4.27
P-KF	$M_P = N_\theta N_r \gg N$	$\mathcal{O}[K(QM_P^2 + M_P^3)]$	$\mathcal{O}(M_P^3 + QM_P^2)$	84.32
P-HBKF	$M_P = N_\theta N_r \gg N$	$\mathcal{O}[K(J_A + 1)(M_P^3 + QM_P^2)]$	$\mathcal{O}[(J_A + 1)(M_P^3 + QM_P^2)]$	84.32
P-SBL-KF	$M_P = N_\theta N_r \gg N$	$\mathcal{O}[I_P(M_P^3 + QM_P^2 + KQM_P)]$	$\mathcal{O}(M_P^3 + QM_P^2)$	84.32
P-SBL-HBKF	$M_P = N_\theta N_r \gg N$	$\mathcal{O}[I_P(M_P^3 + QM_P^2 + KQM_P)]$	$\mathcal{O}[(J_A + 1)(M_P^3 + QM_P^2)]$	84.32
P-SOMP	$M_P = N_\theta N_r \gg N$	—	$\mathcal{O}(WK_s QM_P + WQK_s^2 + WK_s^3)$	15.18

通过分层贝叶斯卡尔曼滤波递推跟踪时变稀疏系数，降低逐传输块重复估计带来的导频开销。所提框架能够可有效缓解固定码本的距离失配问题，多测量向量能显著提升支撑判别精度，在低导频开销下兼具优异的估计精度与跟踪稳定性。后续可进一步研究高速移动条件下的支撑动态跳变及相应的自适应跟踪方法。

参考文献:

- [1] Xie H, Li D. Number configuration for RIS-aided systems: opportunities and challenges[J]. IEEE Internet of Things Journal, 2025, 12(6): 6396-6417.
- [2] Chen Z, Chen G J, Tang J, et al. Reconfigurable-intelligent-surface-assisted B5G/6G wireless communications: challenges, solution, and future opportunities[J]. IEEE Communications Magazine, 2023, 61(1): 16-22.
- [3] 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.
- [4] Wang J, Zhou X, Wang C, et al. RCANet-based user partitioning channel estimation for RIS-assisted mmWave MIMO systems[J]. IEEE Transactions on Green Communications and Networking, 2026, 10: 1419-1432.
- [5] Zheng B, You C, Zhang R. Intelligent reflecting surface assisted multi-user OFDMA: channel estimation and training design[J]. IEEE Transactions on Wireless Communications, 2020, 19(12): 8315-8329.
- [6] Guo J, Liu G, Wu Q, et al. Parallel attention-based transformer for channel estimation in RIS-aided 6G wireless communications[J]. IEEE Transactions on Vehicular Technology, 2024, 73(11): 15927-15940.
- [7] Kundu N K, McKay M R. Channel estimation for reconfigurable intelligent surface aided MISO communications: from LMMSE to deep learning solutions[J]. IEEE Open Journal of the Communications Society, 2021, 2: 471-487.
- [8] Chen R, Sun Y, Liu T, et al. Research on channel estimation technique based on convolutional neural network[C]//Proceedings of the 2025 10th International Conference on Intelligent Computing and Signal Processing (ICSP). Piscataway: IEEE Press, 2025: 186-189.
- [9] Yang H, Zhang A, Sun Y, et al. Regularized sparse Bayesian learning based channel estimation for RIS-assisted wireless communication system[J]. IEEE Communications Letters, 2024, 28(6): 1412-1416.
- [10] Wei X, Shen D, Dai L. Channel estimation for RIS assisted wireless communications-Part II: an improved solution based on double-structured sparsity[J]. IEEE Communications Letters, 2021, 25(5): 1403-1407.
- [11] Yang H, Zhang A, Tian D, et al. Dual-structure regularized sparse Bayesian learning channel estimation for RIS assisted wireless communication[C]//Proceedings of the 2023 9th International Conference on Computer and Communications (ICCC). Piscataway: IEEE Press, 2023: 924-929.
- [12] Chen J, Liang Y C, Cheng H V, et al. Channel estimation for reconfigurable intelligent surface aided multi-user mmWave MIMO systems[J]. IEEE Transactions on Wireless Communications, 2023, 22(10): 6853-6869.
- [13] Jin Y, Qi H. Near-field channel estimation for RIS assisted 6G wireless communication[C]//Proceedings of the 2023 IEEE International Conference on Signal Processing, Communications and Computing (ICSPCC). Piscataway: IEEE Press, 2023: 1-6.
- [14] Lu Z, Han Y, Wang J, et al. Low-overhead separate channel estimation for hybrid XL-RIS-aided MIMO systems[J]. IEEE Transactions on Communications, 2024, 72(11): 7168-7181.
- [15] Lu Z, Han Y, Li M, et al. Time-varying channel estimation and extrapolation for XL-HRIS aided mobile multiuser systems[J]. IEEE Transactions on Vehicular Technology, 2025, 74(12): 18858-18872.
- [16] 邵凯, 花凡玉, 王光宇. 超大规模可重构智能表面混合远-近场信道估计[J]. 电子与信息学报, 2025, 47(11): 4231-4241.
- [17] Shao Kai, Hua Fanyu, Wang Guangyu. Hybrid Far-Near Field Channel Estimation for XL-RIS Assisted Communication Systems[J]. Journal of Electronics & Information Technology, 2025, 47(11): 4231-4241.
- [18] Zhu Z, Yang R, Li C, et al. Adaptive joint sparse Bayesian approaches for near-field channel estimation[J]. IEEE Transactions on Wireless Communications, 2025, 24(3): 2590-2605.
- [19] Srivastava S, Patro C S K, Jagannatham A K, et al. Sparse, group-sparse, and online Bayesian learning aided channel estimation for doubly-selective mmWave hybrid MIMO OFDM systems[J]. IEEE

- Transactions on Communications, 2021, 69(9): 5843-5858.
- [19] Cai Penghao ,Zong Jun ,Luo Xiliang ,et al. Downlink Channel Tracking for Intelligent Reflecting Surface-Aided FDD MIMO Systems. [J]. IEEE TRANSACTIONS ON VEHICULAR TECHNOLOGY, 2021, 70 (4) : 3341-3353.
- [20] Mao Z, Peng M, Liu X. Channel estimation for reconfigurable intelligent surface assisted wireless communication systems in mobility scenarios[J]. China Communications, 2021, 18(3): 29-38.
- [21] Vaswani N. Kalman filtered Compressed Sensing[C]//Proceedings of the 2008 15th IEEE International Conference on Image Processing. Piscataway: IEEE Press, 2008: 893-896.
- [22] Ziniel J, Potter L C, Schniter P. Tracking and smoothing of time-varying sparse signals via approximate belief propagation[C]//Proceedings of the 2010 Conference Record of the Forty Fourth Asilomar Conference on Signals, Systems and Computers. Piscataway: IEEE Press, 2010: 808-812.
- [23] Charles A, Asif M S, Romberg J, et al. Sparsity penalties in dynamical system estimation[C]//Proceedings of the 45th Annual Conference on Information Sciences and Systems. Piscataway: IEEE Press, 2011: 1-6.
- [24] Karseras E, Leung K, Dai W. Tracking dynamic sparse signals using hierarchical Bayesian Kalman filters[C]//Proceedings of the 2013 IEEE International Conference on Acoustics, Speech and Signal Processing. Piscataway: IEEE Press, 2013: 6546-6550.
- [25] 邵凯, 鲁奔, 王光宇. 可重构智能表面辅助通信系统时变级联信道估计[J]. 通信学报, 2024,45(1):119-128.
Shao Kai, Lu Ben, Wang Guangyu. Time-varying channel estimation in reconfigurable intelligent surface assisted communication system[J]. Journal on Communications, 2024, 45(1): 119-128.
- [26] Srivastava S, Mishra A, Rajoriya A, et al. Quasi-static and time-selective channel estimation for block-sparse millimeter wave hybrid MIMO systems: sparse Bayesian learning based approaches[J]. IEEE Transactions on Signal Processing, 2019, 67(5): 1251-1266.
- [27] Yuan Y, Chen Y, Guo X, et al. Near-field tracking with extremely large-scale RIS: a sparse learning approach[C]//Proceedings of the 2024 IEEE Wireless Communications and Networking Conference (WCNC). Piscataway: IEEE Press, 2024: 1-6.
- [28] Cui Mingyao ,Dai Linglong . Channel Estimation for Extremely Large-Scale MIMO: Far-Field or Near-Field?. [J]. IEEE Transactions on communications, 2022, 70 (4) : 2663-2677.

[作者简介]



邵辰浩 (2001-), 男, 河南周口人, 重庆邮电大学硕士生, 主要研究方向为可重构智能表面、信道估计。

邵凯 (1977-), 男, 云南普洱人, 重庆邮电大学副教授、硕士生导师, 主要研究方向为智能感知与信息系统、信号与信息智能处理等。