

基于变分贝叶斯推断的近场双重稀疏信道估计与多用户检测

王姣姣, 戴继生

(东华大学信息与智能科学学院, 上海 201620)

摘要: 面向6G的超大规模多输入多输出(Extremely large-scale multiple-input multiple-output, XL-MIMO)通信系统,其近场效应使得传统基于远场平面波前模型的信道估计方法面临性能瓶颈。现有近场方案多依赖存在建模误差的菲涅尔近似,且普遍将信道估计与多用户激活检测分步处理,导致误差累积。为应对上述挑战,本文提出一种基于精确近场球面波信道模型的信道估计与多用户激活检测框架。该框架创新性地联合利用了XL-MIMO信道在极域与用户域的双重稀疏性,通过引入独立向量变分贝叶斯推断技术,将高维耦合的稀疏恢复问题解耦为各用户独立的稀疏恢复问题,从而实现了近场阵列流型与多用户导频的有效分离,额外引入的离网参数更新策略进一步规避了网格失配问题。仿真结果验证了所提方法在信道估计精度及用户激活检测性能方面的有效性与优越性。

关键词: 6G;近场信道估计;多用户激活检测;稀疏表示;变分贝叶斯推断

中图分类号: TN911.7

文献标志码: A

引用格式: 王姣姣,戴继生.基于变分贝叶斯推断的近场双重稀疏信道估计与多用户检测[J].数据采集与处理,2026,41(5):1409-1420. WANG Jiaojiao, DAI Jisheng. Near-field doubly-sparse channel estimation and multi-user detection based on variational Bayesian inference [J]. Journal of Data Acquisition and Processing, 2026, 41(5): 1409-1420.

引言

下一代6G无线通信系统需支持Tbps量级的峰值速率、承载海量设备的连接容量,并具备在复杂环境下的强抗干扰能力^[1-2]。为充分发挥6G通信系统性能,准确获取信道状态信息至关重要;然而大规模多输入多输出(Multiple-input multiple-output, MIMO)技术的引入给6G通信系统的信道估计带来了极大挑战^[3]。现有研究工作大多基于远场假设(平面波前模型),利用无线传播环境中有限的局部散射效应,将大规模MIMO信道在角度域稀疏展开,以降低导频开销并提高估计精度^[4]。常规稀疏信道估计方法包括:正交匹配追踪(Orthogonal matching pursuit, OMP)^[5-6]、稀疏贝叶斯学习(Sparse Bayesian learning, SBL)^[7-8]以及近似消息传递(Approximate message passing, AMP)^[9]。

若部署超大规模多输入多输出(Extremely large-scale multiple-input multiple-output, XL-MIMO)阵列,远场假设将不再成立,需考虑近场效应带来的不利影响^[10]。与远场平面波前模型相比,近场球面波前模型由角度和距离两个参数共同决定,且在阵列流型中无法分离,近场信道估计的难度显著提升^[11]。Pan等^[12]利用近场信道在极域的稀疏特性,对近场信道进行二维菲涅尔(Fresnel)近似,并通过下采样托普利兹(Toeplitz)协方差矩阵实现角度参数与距离参数的解耦,分步估计方位角、仰角以及距离。然而,这种分步估计方法可能会造成误差积累。针对该问题,Cui等^[13]提出了一种联合估计信道的极域OMP

方法,从网格中同时选出最能匹配信道的角度和距离组合,并用一种离网极域同步迭代无网格加权算法提升信道估计的精度。需要指出的是,上述方法均依赖Fresnel近似,不可避免地引入信道建模误差,从而在实际系统应用中性能损失较大。

另一方面,为在有限频谱资源约束下实现高效的大规模用户接入,通常需引入用户激活检测策略,因此,亟待解决激活信道的联合检测与近场估计难题^[14]。利用少量激活用户的稀疏性,Qiao等^[15]提出将总阵列的近场问题分解为各子阵列的远场问题处理,利用XL-MIMO信道的公共子阵列激活用户的稀疏性,先恢复信道再估计角度。尽管该方法极大降低了问题复杂度,但其核心思路是将近场信道近似为多个远场信道,模型失配较严重,且其分步估计的流程会导致误差累积。针对上述局限,本文提出了一种基于精确近场球面波信道的信道估计与用户激活检测框架,该框架联合利用了XL-MIMO信道在极域与用户域的双重稀疏性,通过引入独立向量变分贝叶斯(Variational Bayesian inference, VBI)技术,将高维耦合稀疏恢复问题解耦为用户独立的稀疏恢复问题,从而有效地分离近场阵列流型和多用户导频矩阵,额外引入的离网模型进一步避免了网格失配。所提方法在归一化均方误差与用户激活成功率方面均表现出显著优势,证实了所提方法的有效性。

1 系统模型与现有方法回顾

如图1所示,考虑一个大规模上行链路场景,其中基站XL-MIMO阵列配有 M 根天线,移动用户配有单根天线,移动用户总数为 K ,但仅有 K_a 个用户被激活($K_a \ll K$),且 T 个快拍构成的观测窗口内,用户激活状态保持不变。本文假设信道响应满足块衰落模型^[16],当观测窗口 T 小于信道相干时间,信道响应几乎不变。因此,基站在 t 时刻($t = 1, 2, \dots, T$)接收的上行链路信号可表示为

$$\mathbf{y}(t) = \sum_{k=1}^K \alpha_k \mathbf{h}_k s_k(t) + \mathbf{n}(t) \quad (1)$$

式中: α_k 表示第 k 个用户是否被激活($\alpha_k = 1$ 表示被激活, $\alpha_k = 0$ 表示未被激活), $s_k(t)$ 表示第 k 个用户在 t 时刻发送的信号, T 为快拍数, $\mathbf{h}_k \in \mathbb{C}^{M \times 1}$ 表示第 k 个用户的信道响应, $\mathbf{n}(t) = [n_1(t), n_2(t), \dots, n_M(t)]^T \in \mathbb{C}^{M \times 1}$ 表示均值为零,方差为 v 的复高斯白噪声。对于一个均匀线性阵列(Uniform linear array, ULA),其近场阵列流型可表示为^[17]

$$\mathbf{a}(\vartheta_k, d_k) = \left[1, e^{\frac{j2\pi(r_{k,2} - d_k)}{\lambda}}, e^{\frac{j2\pi(r_{k,3} - d_k)}{\lambda}}, \dots, e^{\frac{j2\pi(r_{k,M} - d_k)}{\lambda}} \right]^T \in \mathbb{C}^{M \times 1} \quad (2)$$

式中: d_k 表示第 k 个用户的距离, $r_{k,m} = \sqrt{d_k^2 + \Delta_m^2 - 2d_k\Delta_m \sin \vartheta_k}$ 表示第 k 个用户到第 m 根天线之间的距离, Δ_m 表示第 m 根天线到参考天线之间的距离, ϑ_k 表示第 k 个用户的到达角, λ 表示波长。此时, $\mathbf{y}(t)$ 可重写为

$$\mathbf{y}(t) = \sum_{k=1}^K \alpha_k g_k \mathbf{a}(\vartheta_k, d_k) s_k(t) + \mathbf{n}(t) = \mathbf{A}(\vartheta, \tilde{\mathbf{d}}) \mathbf{\Lambda} \mathbf{G} \mathbf{s}^T(t) + \mathbf{n}(t) \quad (3)$$

式中: g_k 表示第 k 个用户的复增益, $\mathbf{A}(\vartheta, \tilde{\mathbf{d}}) = [\mathbf{a}(\vartheta_1, d_1), \mathbf{a}(\vartheta_2, d_2), \dots, \mathbf{a}(\vartheta_K, d_K)] \in \mathbb{C}^{M \times K}$, $\mathbf{\Lambda} =$




图1 近场激活用户场景示意图

Fig.1 Illustration of the activated user scenario in the near-field region

$\text{diag}(\alpha_1, \alpha_2, \dots, \alpha_K), G = \text{diag}(g_1, g_2, \dots, g_K)$ 。若定义 $Y = [y(1), y(2), \dots, y(T)]$, 有

$$Y = A(\vartheta, \tilde{d}) \Lambda G S^T + N \quad (4)$$

式中: $S = [s(1), s(2), \dots, s(T)]^T \in \mathbb{C}^{T \times K}$, $s(t) = [s_1(t), s_2(t), \dots, s_K(t)]^T \in \mathbb{C}^{K \times 1}$, $N = [n(1), n(2), \dots, n(T)] \in \mathbb{C}^{M \times T}$ 。

近场阵列流型矩阵 $A(\vartheta, \tilde{d})$ 中 ϑ 和 $\tilde{d}$ 无法分离, 极大增加了信道参数估计的难度和计算复杂度。此外, 由于 $A(\vartheta, \tilde{d})$ 、激活矩阵 Λ 、 G 及 S^T 相互耦合, 进一步加剧了近场模型信道估计问题的复杂性。现有解耦 S^T 的方法中, 最小二乘法 (Least squares, LS) 通过直接对式 (4) 求解, 获得解耦后的信道估计。但为了保证 S^T 伪逆的存在, 必须满足 $T \geq K$ 的条件。另一类方法如文献 [15] 所述, 将整体阵列视为多个子阵列的集合, 从而将全局性的近场问题转化为一列子阵列层面的远场问题处理。该方法首先利用少量激活用户的稀疏性, 使用 OMP 算法先解耦 S^T , 再基于估计得到的信道矩阵, 采用多信号分类 (Multiple signal classification, MUSIC) 算法估计角度参数。然而, 该方法将近场模型近似为远场模型, 会引入模型失真, 且仅利用了激活用户稀疏性而未充分挖掘角度域稀疏特性。此外, 由于该方法采用分步估计的策略, 可能会导致误差累积, 进而影响估计精度。

2 精确近场双重稀疏信道估计与多用户检测

为避免模型失真并充分利用极域和激活用户域的稀疏特性, 本文提出一种基于近场精确模型的双重稀疏表示信道估计方法。首先, 给出了精确近场双重稀疏模型的离网稀疏表示来克服网格失配, 其次, 利用独立向量 VBI 技术促进稀疏贝叶斯推断, 通过二维离网对参数估计结果进行校正, 最后, 对所提方法进行了参数初始化与计算复杂度分析。

2.1 精确近场双重稀疏模型

针对信道模型失真以及稀疏性问题, 本文通过联合极域和激活用户域的双重稀疏结构, 构建了一种基于离网稀疏表示的近场信道精确模型。该模型需借助二维网格表征, 为了有效缩减字典规模、降低计算复杂度, 同时减少相邻基之间的相关性, 从而提升稀疏恢复的性能, 本文采用了一种与文献 [17] 相似的非均匀采样的二维网格 $[\theta, d] = \{\theta_l, d_l\}_{l=1}^L$ 对角度域和距离域进行采样, 其中 L 为采样点数, 将式 (3) 进行稀疏展开得

$$y(t) = \sum_{l=1}^L \sum_{k=1}^K \alpha_k w_{l,k} a(\theta_l, d_l) s_k(t) + n(t) = \sum_{k=1}^K \alpha_k A(\theta, d) w_k s_k(t) + n(t) \quad (5)$$

式中: $A(\theta, d) = [a(\theta_1, d_1), a(\theta_2, d_2), \dots, a(\theta_L, d_L)] \in \mathbb{C}^{M \times L}$ 表示导向矢量矩阵, $a(\theta_l, d_l) =$

$$\begin{bmatrix} 1, e^{\frac{j2\pi(r_{l,2}-d_l)}{\lambda}}, e^{\frac{j2\pi(r_{l,3}-d_l)}{\lambda}}, \dots, e^{\frac{j2\pi(r_{l,M}-d_l)}{\lambda}} \end{bmatrix}^T \in \mathbb{C}^{M \times 1} \text{ 表示导向矢量, } w_k = [w_{1,k}, w_{2,k}, \dots, w_{L,k}]^T \in \mathbb{C}^{L \times 1}$$

表示稀疏列向量。式 (4) 可重新定义为

$$Y = A(\theta, d) \tilde{W} S^T + N \quad (6)$$

式中: $\tilde{w}_k = \alpha_k w_k$ 表示复合稀疏列向量, 由于仅有少量激活用户被激活, 因此, $\tilde{W} = [\tilde{w}_1, \tilde{w}_2, \dots, \tilde{w}_K] \in \mathbb{C}^{L \times K}$ 是点稀疏矩阵。

在实际应用中, 并非所有真正的角度和距离都能精确定位在预定义的网格上, 这导致了方向不匹配问题^[18]。为了避免网格失配带来的影响, 式 (6) 利用离网模型可表示为^[19]

$$Y = A(\theta + \beta^{\text{ang}}, d + \beta^{\text{dist}}) \tilde{W} S^T + N \quad (7)$$

式中: $\beta^{\text{ang}} = [\beta_1^{\text{ang}}, \beta_2^{\text{ang}}, \dots, \beta_L^{\text{ang}}]^T \in \mathbb{C}^{L \times 1}$ 表示角度间隙, $\beta^{\text{dist}} = [\beta_1^{\text{dist}}, \beta_2^{\text{dist}}, \dots, \beta_L^{\text{dist}}]^T \in \mathbb{C}^{L \times 1}$ 表示距离间隙。 $A(\theta + \beta^{\text{ang}}, d + \beta^{\text{dist}})$ 用一阶泰勒展开近似表示为^[20]

$$A(\theta + \beta^{\text{ang}}, d + \beta^{\text{dist}}) \approx A(\theta, d) + B^{\text{ang}} \text{diag}(\beta^{\text{ang}}) + B^{\text{dist}} \text{diag}(\beta^{\text{dist}}) \quad (8)$$

式中: $B^{\text{ang}} = [b^{\text{ang}}(\theta_1, d_1), b^{\text{ang}}(\theta_2, d_2), \dots, b^{\text{ang}}(\theta_L, d_L)]$, $B^{\text{dist}} = [b^{\text{dist}}(\theta_1, d_1), b^{\text{dist}}(\theta_2, d_2), \dots, b^{\text{dist}}(\theta_L, d_L)]$,

$$b^{\text{ang}}(\theta_l, d_l) = \frac{\partial a(\theta', d')}{\partial \theta'} \Big|_{\theta'=\theta_l, d'=d_l}, b^{\text{dist}}(\theta_l, d_l) = \frac{\partial a(\theta', d')}{\partial d'} \Big|_{\theta'=\theta_l, d'=d_l} \quad \text{式(7)为联合激活用户和信道估计}$$

提供了精确的离网稀疏表示,从而为实现二者的精确估计奠定了基础。

2.2 稀疏贝叶斯推断

直接对式(7)解耦面临双重挑战性,主要体现在总用户数远大于快拍数($K \gg T$),导致传统的LS方法无法有效地解耦 S^T , 无法保证 S^T 的伪逆存在。另一方面,尽管可通过向量化操作重构式(7),但随之产生的高维矩阵会引发巨大的计算复杂度,难以实现。为此,本文采用稀疏贝叶斯框架实现信道与多用户激活检测。在复高斯白噪声的假设下,式(7)的条件似然函数为

$$p(Y|\tilde{W}, v; \beta^{\text{ang}}, \beta^{\text{dist}}) = \prod_{t=1}^T \text{CN}(\mathbf{y}(t)|A(\theta + \beta^{\text{ang}}, d + \beta^{\text{dist}})\tilde{W}s^T(t), v^{-1}I) \quad (9)$$

式中: $\text{CN}(\cdot)$ 为复高斯分布, 噪声精度 v 服从伽马分布^[21]

$$p(v) = \Gamma(v|a, b) \quad (10)$$

式中: a 和 b 为趋于0的常量^[20]。假设矩阵 $\tilde{W}$ 各个元素相互独立, 且每个元素 $w_{l,k}$ 服从由超参数 $\gamma_{l,k}$ 控制方差的复高斯分布

$$p(\tilde{W}|\mathbf{r}, \Phi) = \prod_{l=1}^L \prod_{k=1}^K \text{CN}(\tilde{w}_{l,k}|0, \tau_k \gamma_{l,k}) \quad (11)$$

式中: τ_k 表示激活超参数, 当第 k 个用户被激活时, 其趋于一个正值, 否则为0; $\mathbf{r}$ 为超参数; $[\Phi]_k \triangleq \tau_k$ 。假设每个超参数遵循独立的伽马分布, 可得

$$p(\tau_k|\xi_k) = \Gamma\left(\tau_k \middle| \frac{3}{2}, \frac{\xi_k^2}{4}\right) \quad (12)$$

式中: $3/2$ 和 $\xi_k^2/4$ 源自文献[22], ξ_k 进一步建模为

$$p(\xi_k) = \Gamma(\xi_k|h, h) \quad (13)$$

式中: h 是一个非常小的正值。类似地, $\mathbf{r}$ 的伽马分布可表示为

$$p(\mathbf{r}) = \prod_{k=1}^K p(\gamma_k) = \prod_{l=1}^L \prod_{k=1}^K \Gamma(\gamma_{l,k}|a, b) \quad (14)$$

式(12~14)的分层先验模型可以进一步提高稀疏性, 在获取激活用户信息方面表现出显著优势。综合上述概率模型(式(9~14)), 联合概率密度函数可表示为

$$p(Y, \tilde{W}, v, \mathbf{r}, \Phi, \Omega; \beta^{\text{ang}}, \beta^{\text{dist}}) = p(Y|\tilde{W}, v; \beta^{\text{ang}}, \beta^{\text{dist}}) p(\tilde{W}|\mathbf{r}, \Phi) p(v) p(\mathbf{r}) p(\Phi|\Omega) p(\Omega) \quad (15)$$

式中

$$p(\Phi|\Omega) = \prod_{k=1}^K p(\tau_k|\xi_k) \quad (16)$$

$$p(\Omega) = \prod_{k=1}^K p(\xi_k) \quad (17)$$

为了便于贝叶斯推理, 本文将 β^{ang} 和 β^{dist} 视为参数而不是随机变量, 其更新规则将会在2.3节给出。

由于最大后验概率 $p(\tilde{\mathbf{W}}, v, r, \Phi, \Omega | Y; \beta^{\text{ang}}, \beta^{\text{dist}})$ 难以获得闭式解, 通常使用独立向量 VBI 技术来寻找 $p(\tilde{\mathbf{W}}, v, r, \Phi, \Omega | Y; \beta^{\text{ang}}, \beta^{\text{dist}})$ 的近似, 即

$$p(\tilde{\mathbf{W}}, v, r, \Phi, \Omega | Y; \beta^{\text{ang}}, \beta^{\text{dist}}) \approx q(\tilde{\mathbf{W}}, v, r, \Phi, \Omega) \triangleq q(\tilde{\mathbf{W}})q(v)q(r)q(\Phi)q(\Omega) \quad (18)$$

可以观察到 $\tilde{\mathbf{W}}$ 与 $\mathbf{S}^T$ 之间存在高度耦合, 因此很难直接获得 $q(\tilde{\mathbf{W}})$, 可以注意到下式能解耦每一个 $\tilde{\mathbf{w}}_k$

$$A(\theta + \beta^{\text{ang}}, d + \beta^{\text{dist}}) \tilde{\mathbf{W}} \mathbf{S}^T = \sum_{k=1}^K A(\theta + \beta^{\text{ang}}, d + \beta^{\text{dist}}) \tilde{\mathbf{w}}_k \mathbf{s}_k^T \quad (19)$$

并且

$$\begin{aligned} \text{tr} \left\{ A(\theta + \beta^{\text{ang}}, d + \beta^{\text{dist}}) \tilde{\mathbf{w}}_k \mathbf{s}_k^T (A(\theta + \beta^{\text{ang}}, d + \beta^{\text{dist}}) \tilde{\mathbf{w}}_k \mathbf{s}_k^T)^H \right\} = \\ \mathbf{s}_k^T \mathbf{s}_k^* \text{tr} \left\{ A(\theta + \beta^{\text{ang}}, d + \beta^{\text{dist}}) \tilde{\mathbf{w}}_k \tilde{\mathbf{w}}_k^H (A(\theta + \beta^{\text{ang}}, d + \beta^{\text{dist}}))^H \right\} \end{aligned} \quad (20)$$

式中 $\mathbf{s}_k^T \mathbf{s}_k^*$ 为标量。本文采用 VBI 技术, 将式 (18) 进一步因式分解可以表示为^[23]

$$q(\Theta) = \underbrace{\prod_{k=1}^K q(\tilde{\mathbf{w}}_k) q(v) q(r) q(\Phi) q(\Omega)}_{q(\tilde{\mathbf{W}})} \quad (21)$$

式中: $\Theta \triangleq \{\tilde{\mathbf{w}}_1, \tilde{\mathbf{w}}_2, \dots, \tilde{\mathbf{w}}_K, v, r, \Phi, \Omega\}$ 。独立向量 VBI 思想体现在 $q(\tilde{\mathbf{W}}) = \prod_{k=1}^K q(\tilde{\mathbf{w}}_k)$, 其进一步将 $\tilde{\mathbf{W}}$ 进行列向量近似分解, 引入该操作的原因在于降低计算复杂度 (详见 2.3 节分析)。满足上述分解形式的概率密度函数并不唯一, 最优的分解形式应与真实后验概率分布的 Kullback-Leibler (KL) 散度最小^[24], 即

$$q^*(\Theta) = \arg \min_{q(\Theta)} D_{\text{KL}}(q(\Theta) // p(\Theta | Y; \beta^{\text{ang}}, \beta^{\text{dist}})) \triangleq \arg \min_{q(\Theta)} \int q(\Theta) \ln \frac{q(\Theta)}{p(\Theta | Y; \beta^{\text{ang}}, \beta^{\text{dist}})} d\Theta \quad (22)$$

式 (22) 的最优解满足

$$\ln q^*(\Theta_j) \propto \left\langle \ln p(Y, \Theta; \beta^{\text{ang}}, \beta^{\text{dist}}) \right\rangle_{\prod_{i \neq j} q^*(\Theta_i)} \quad \forall j \quad (23)$$

式中: “ $\propto$ ” 表示正比于, Θ_j 表示 Θ 中的第 j 个元素, $\langle \cdot \rangle_{\prod_i q(X_i)}$ 表示对乘积变分分布 $\prod_i q(X_i)$ 的期望。根据推导过程, 可得如下更新规则

$$q^{\text{new}}(\tilde{\mathbf{w}}_k) = \text{CN}(\tilde{\mathbf{w}}_k | \mu_k, \Sigma_k) \quad \forall k \quad (24)$$

$$q^{\text{new}}(v) = \Gamma(v | TM + a, b_a) \quad (25)$$

$$q^{\text{new}}(\gamma_{l,k}) = \Gamma(\gamma_{l,k} | 1 + a, b_{\gamma_{l,k}}) \quad \forall l, k \quad (26)$$

式中: $\mu_k = \hat{v} \Sigma_k (A(\theta + \beta^{\text{ang}}, d + \beta^{\text{dist}}))^H Y_{-k} \mathbf{s}_k^*$, $Y_{-k} = Y - \sum_{j \neq k} A(\theta + \beta^{\text{ang}}, d + \beta^{\text{dist}}) \mu_j \mathbf{s}_j^T$, $\hat{\gamma}_k = [\hat{\gamma}_{1,k}, \hat{\gamma}_{2,k}, \dots, \hat{\gamma}_{L,k}]^T$, $\Sigma_k = \left(\hat{v} \mathbf{s}_k^H \mathbf{s}_k (A(\theta + \beta^{\text{ang}}, d + \beta^{\text{dist}}))^H A(\theta + \beta^{\text{ang}}, d + \beta^{\text{dist}}) + \text{diag}(\hat{\gamma}_k) \right)^{-1}$, $b_{\gamma_{l,k}} = b + [\mu_k \mu_k^H + \Sigma_k]_{l,l}$, $\hat{\gamma}_{l,k} = (1 + a) / b_{\gamma_{l,k}}$, $b_a = b + \left\| Y - \sum_{k=1}^K A(\theta + \beta^{\text{ang}}, d + \beta^{\text{dist}}) \mu_k \mathbf{s}_k^T \right\|_{\text{F}}^2 + \sum_{k=1}^K \mathbf{s}_k^H \mathbf{s}_k \text{tr} \left\{ A(\theta + \beta^{\text{ang}}, d + \beta^{\text{dist}}) \Sigma_k (A(\theta + \beta^{\text{ang}}, d + \beta^{\text{dist}}))^H \right\}$, $\hat{v} = \frac{TM + a}{b_a}$, $[\cdot]_{l,l}$ 表示矩阵的第 l 个对角元素。

下面分别给出 $q(\tau_k)$ 和 $q(\xi_k)$ 的更新规则, 可得

$$\ln q(\tau_k)^{\text{new}} = \left\langle \ln p(\tilde{\mathbf{W}}|\mathbf{r}, \boldsymbol{\Phi}) \right\rangle_{q(\tilde{\mathbf{W}})q(\tau)} + \left\langle \ln p(\boldsymbol{\Phi}|\boldsymbol{\Omega}) \right\rangle_{q(\boldsymbol{\Omega})} \quad (27)$$

将式(11,16)代入式(27), 可得

$$\ln q(\tau_k)^{\text{new}} = \left(\frac{1}{2} - L \right) \ln \tau_k - \frac{\hat{\xi}_k^2}{4} \tau_k - \tau_k^{-1} \sum_{l=1}^L \hat{\gamma}_{l,k} [\boldsymbol{\mu}_k \boldsymbol{\mu}_k^H + \boldsymbol{\Sigma}_k]_{l,l} \quad (28)$$

式中 $\hat{\xi}_k$ 表示 ξ_k 的期望值, 这将在后面给出。由于满足广义逆高斯分布, 只需获得 $\ln q(\tau_k)^{\text{new}}$ 的期望, 即

$$\hat{\tau}_k = \frac{K_{z+1}(\sqrt{u_k v_k})}{K_z(\sqrt{u_k v_k})} \sqrt{\frac{v_k}{u_k}} \quad (29)$$

式中: $K_z(\cdot)$ 是 $z = \left(\frac{3}{2} \right) - L$ 的第 2 类修正贝塞尔函数, $u_k = \frac{[\hat{\xi}_k^2]}{2}$, $v_k = 2 \sum_{l=1}^L \hat{\gamma}_{l,k} [\boldsymbol{\mu}_k \boldsymbol{\mu}_k^H + \boldsymbol{\Sigma}_k]_{l,l}$ 。更新 $q(\xi_k)$ 可得

$$\ln q(\xi_k)^{\text{new}} = \left\langle \ln p(\boldsymbol{\Phi}|\boldsymbol{\Omega}) + \ln p(\boldsymbol{\Omega}) \right\rangle_{q(\boldsymbol{\Omega})} \quad (30)$$

将式(16,17)代入式(30), 可得

$$\ln q(\xi_k)^{\text{new}} = (h+2) \ln \xi_k - h \xi_k - \frac{\xi_k^2}{4} \hat{\tau}_k \quad (31)$$

令式(31)的导数为 0, 可得

$$\hat{\xi}_k = \frac{-h + \sqrt{h^2 + 2\hat{\tau}_k(h+2)}}{\hat{\tau}_k} \quad (32)$$

2.3 二维离网参数更新

本小节采用期望最大化(Expectation-maximization, EM)算法, 获取角度间隙 $\boldsymbol{\beta}^{\text{ang}}$ 和距离间隙 $\boldsymbol{\beta}^{\text{dist}}$ 的更新规则^[25]。最佳的 $\boldsymbol{\beta}^{\text{ang}}$ 和 $\boldsymbol{\beta}^{\text{dist}}$ 应当最小化式(22)中的目标函数, 即

$$\{\boldsymbol{\beta}^{\text{ang}}, \boldsymbol{\beta}^{\text{dist}}\} = \arg \max_{\boldsymbol{\beta}^{\text{ang}}, \boldsymbol{\beta}^{\text{dist}}} \left\langle \ln p(Y|\tilde{\mathbf{W}}, v; \boldsymbol{\beta}^{\text{ang}}, \boldsymbol{\beta}^{\text{dist}}) \right\rangle_{q(v) \prod_{k=1}^K q(\tilde{\mathbf{w}}_k)} \quad (33)$$

将式(9)代入式(33), 得

$$\begin{aligned} \left\langle \ln p(Y|\tilde{\mathbf{W}}, v; \boldsymbol{\beta}^{\text{ang}}, \boldsymbol{\beta}^{\text{dist}}) \right\rangle_{q(v) \prod_{k=1}^K q(\tilde{\mathbf{w}}_k)} &= \left\| Y_{-k} - \left(A(\boldsymbol{\theta}, d) + \mathbf{B}^{\text{ang}} \text{diag}(\boldsymbol{\beta}^{\text{ang}}) + \mathbf{B}^{\text{dist}} \text{diag}(\boldsymbol{\beta}^{\text{dist}}) \right) \tilde{\mathbf{w}}_k \mathbf{s}_k^T \right\|_{\text{F}}^2 = \\ &= (\boldsymbol{\beta}^{\text{ang}})^T \mathbf{P}^{\text{ang}} \boldsymbol{\beta}^{\text{ang}} + (\boldsymbol{\beta}^{\text{dist}})^T \mathbf{P}^{\text{dist}} \boldsymbol{\beta}^{\text{dist}} - 2(\boldsymbol{\eta}^{\text{ang}})^T \boldsymbol{\beta}^{\text{ang}} - 2(\boldsymbol{\eta}^{\text{dist}})^T \boldsymbol{\beta}^{\text{dist}} + 2(\boldsymbol{\beta}^{\text{ang}})^T \boldsymbol{\Psi} \boldsymbol{\beta}^{\text{dist}} \end{aligned} \quad (34)$$

式中: $\mathbf{P}^{\text{ang}} = \mathbf{R} \left\{ \left((\mathbf{B}^{\text{ang}})^H \mathbf{B}^{\text{ang}} \right)^* \odot \sum_{k=1}^K \left[\mathbf{s}_k^H \mathbf{s}_k (\boldsymbol{\mu}_k \boldsymbol{\mu}_k^H + \boldsymbol{\Sigma}_k) \right] \right\}$, $\mathbf{P}^{\text{dist}} = \mathbf{R} \left\{ \left((\mathbf{B}^{\text{dist}})^H \mathbf{B}^{\text{dist}} \right)^* \odot \sum_{k=1}^K \left[\mathbf{s}_k^H \mathbf{s}_k (\boldsymbol{\mu}_k \boldsymbol{\mu}_k^H + \boldsymbol{\Sigma}_k) \right] \right\}$, $\boldsymbol{\eta}^{\text{ang}} = \sum_{k=1}^K \left\{ -\mathbf{s}_k^H \mathbf{s}_k \mathbf{R} \left\{ \text{diag} \left((\mathbf{B}^{\text{ang}})^H A(\boldsymbol{\theta}, d) \boldsymbol{\Sigma}_k \right) \right\} + \mathbf{R} \left\{ (\text{diag}(\boldsymbol{\mu}_k))^* (\mathbf{B}^{\text{ang}})^H (Y_{-k} - A(\boldsymbol{\theta}, d) \boldsymbol{\mu}_k \mathbf{s}_k^T) \mathbf{s}_k^* \right\} \right\}$, $\boldsymbol{\eta}^{\text{dist}} = \sum_{k=1}^K \left\{ -\mathbf{s}_k^H \mathbf{s}_k \mathbf{R} \left\{ \text{diag} \left((\mathbf{B}^{\text{dist}})^H A(\boldsymbol{\theta}, d) \boldsymbol{\Sigma}_k \right) \right\} + \mathbf{R} \left\{ (\text{diag}(\boldsymbol{\mu}_k))^* (\mathbf{B}^{\text{dist}})^H (Y_{-k} - A(\boldsymbol{\theta}, d) \boldsymbol{\mu}_k \mathbf{s}_k^T) \mathbf{s}_k^* \right\} \right\}$, $\boldsymbol{\Psi} = \mathbf{R} \left\{ \left((\mathbf{B}^{\text{ang}})^H \mathbf{B}^{\text{dist}} \right)^* \odot \sum_{k=1}^K \left[\mathbf{s}_k^H \mathbf{s}_k (\boldsymbol{\mu}_k \boldsymbol{\mu}_k^H + \boldsymbol{\Sigma}_k) \right] \right\}$, $\mathbf{R}\{\cdot\}$ 表示取实数, “ $(\cdot)^*$ ” 表示共轭, “ $\odot$ ” 表示哈达玛积。分别计算式(34)关于 $\boldsymbol{\beta}^{\text{ang}}$ 和 $\boldsymbol{\beta}^{\text{dist}}$ 的偏导数, 并令其等于零, 得

$$(\boldsymbol{\beta}^{\text{ang}})^{\text{new}} = (\boldsymbol{P}^{\text{ang}})^+ (\boldsymbol{\eta}^{\text{ang}} - \boldsymbol{\Psi} \boldsymbol{\beta}^{\text{dist}}) \quad (35)$$

$$(\boldsymbol{\beta}^{\text{dist}})^{\text{new}} = (\boldsymbol{P}^{\text{dist}})^+ (\boldsymbol{\eta}^{\text{dist}} - \boldsymbol{\Psi}^T \boldsymbol{\beta}^{\text{ang}}) \quad (36)$$

式中 $(\cdot)^+$ 表示伪逆。由于真实的角度和距离与最近的网格点距离不变,为了避免这个问题,本文将采样网格点视为可调参数,并将其更新得^[26]

$$\boldsymbol{\theta}^{\text{new}} = \boldsymbol{\theta} + (\boldsymbol{\beta}^{\text{ang}})^{\text{new}} \quad (37)$$

$$\boldsymbol{d}^{\text{new}} = \boldsymbol{d} + (\boldsymbol{\beta}^{\text{dist}})^{\text{new}} \quad (38)$$

经过数次迭代后,更新后的采样网格将最终趋于真实的角度和距离。

本文方法的具体步骤为:

(1) 输入:接收信号 $\boldsymbol{Y}$, 导频信号 $\boldsymbol{S}$;

(2) 参数初始化:由于基于 VBI 方法对初始化有很强的鲁棒性,可以令: $a = b = 10^{-10}$, $v^{(0)} = 1$, $\gamma_{l,k} = 1$, $\boldsymbol{\beta}^{\text{ang}} = \boldsymbol{\beta}^{\text{dist}} = \mathbf{0}_{L \times 1}$;

(3) 参数迭代及离网细化:通过式(24~26, 35~36, 37~38)分别计算 $\boldsymbol{\mu}_k, \boldsymbol{\Sigma}_k, \hat{v}, \hat{\gamma}_{l,k}, (\boldsymbol{\beta}^{\text{ang}})^{\text{new}}, (\boldsymbol{\beta}^{\text{dist}})^{\text{new}}, \boldsymbol{\theta}^{\text{new}}$ 和 $\boldsymbol{d}^{\text{new}}$;

(4) 收敛判定:当 $\frac{\|\boldsymbol{r}^{(i)} - \boldsymbol{r}^{(i-1)}\|_2}{\|\boldsymbol{r}^{(i-1)}\|_2} \leq \epsilon$, 其中, $\boldsymbol{r}^{(i)}$ 表示第 i 次迭代后的估计值, $\epsilon = 10^{-6}$ 为预设的收敛

阈值,当迭代次数 i 达到 300 时,即使收敛条件未满足,同样终结算法运行,其依据在于仿真实验中所提算法一般在 200 次迭代内收敛,否则返回步骤(3);

(5) 输出:估计的信道响应 $\hat{\boldsymbol{h}}_k = \boldsymbol{A}(\boldsymbol{\theta} + \boldsymbol{\beta}^{\text{ang}}, \boldsymbol{d} + \boldsymbol{\beta}^{\text{dist}}) \boldsymbol{\mu}_k, \forall k$, 估计激活用户指标 $\hat{a}_k, \forall k$ 。

本文方法的计算复杂度为:(1) 每次迭代计算 $\boldsymbol{\mu}_k$ 和 $\boldsymbol{\Sigma}_k$ 的计算复杂度均为 $O(KML^2)$;(2) 每次迭代计算 $\hat{v}$ 和 $\hat{\gamma}_{l,k}$ 的计算复杂度分别为 $O(KML^2)$ 和 $O(KL)$;(3) 每次迭代计算 $(\boldsymbol{\beta}^{\text{ang}})^{\text{new}}$ 和 $(\boldsymbol{\beta}^{\text{dist}})^{\text{new}}$ 的计算复杂度为 $O(KML^2)$ 。因此,所提出的方法每次迭代的计算复杂度为 $O(KML^2)$ 。尽管远场变分贝叶斯(Far-field variational Bayesian inference, FF-VBI)方法与本文提出的方法计算复杂度相同,但是本文方法建立了精确的信道估计模型,在估计性能上具有明显优势。若采用对式(6)进行向量化的 SBL 方法,其计算复杂度为 $O(MTL^2K^2)$ 。因此,所提方法与向量化 SBL 方法相比降低了计算复杂度。

3 仿真结果与分析

为验证本文方法的性能,将所提方法与 LS、OMP、SBL、FF-VBI 及两阶段稀疏贝叶斯(Two-step sparse Bayesian learning, TS-SBL^[17,27])算法进行对比分析:(1) LS:直接对式(6)求伪逆解耦 $\boldsymbol{S}^T$;(2) OMP:对式(6)进行转置,解耦 $\boldsymbol{S}$;(3) SBL:对式(6)进行转置,直接解耦 $\boldsymbol{S}$,没有用到极域的稀疏性;(4) FF-VBI:将所提出方法的阵列流型换成远场场景下的阵列流型,用 VBI 技术解耦导频 $\boldsymbol{S}^T$;(5) TS-SBL:该方法采用分步处理策略。具体而言,首先对式(6)进行转置,利用 SBL 对 $\boldsymbol{S}$ 进行解耦,随后,基于阵列流型在极域的稀疏性,再次运用 SBL 解耦 $\boldsymbol{A}(\boldsymbol{\theta}, \boldsymbol{d})$ 得到稀疏矩阵 $\tilde{\boldsymbol{W}}$ 。考虑天线间距为 $\Delta = \frac{\lambda}{2}$, 其设信号波长 $\lambda = \frac{c}{f} = 0.03 \text{ m}$, c 为光速,信号频率 $f = 10 \text{ GHz}$,信号的角度和距离分别随机在 $[-60^\circ, 60^\circ]$ 和 10 m 之内生成。信道估计的精度采用归一化均方误差(Normalized mean square error, NMSE)作为评估指标

$$\text{NMSE} = \frac{1}{I} \sum_{i=1}^I \frac{\sum_{k=1}^K \|\hat{\mathbf{h}}_k(i) - \alpha_k(i) \mathbf{h}_k(i)\|_2^2}{\sum_{k=1}^K \|\mathbf{h}_k(i)\|_2^2} \quad (39)$$

式中: I 为 Monte Carlo 实验的总次数, 设置为 200, $\hat{\mathbf{h}}_k(i)$ 为第 i 次 Monte Carlo 实验的估计值响应, $\mathbf{h}_k(i)$ 为第 i 次 Monte Carlo 实验的真实值, $\alpha_k(i)$ 为第 i 次 Monte Carlo 实验的激活指标。激活用户的成功率 (Active-user success rate, AUSR) 可以表示为

$$\text{AUSR} = \frac{1}{I} \sum_{i=1}^I \left(1 - \frac{\sum_{k=1}^K |\hat{\alpha}_k(i) - \alpha_k(i)|}{K} \right) \quad (40)$$

式中 $\hat{\alpha}_k(i)$ 表示第 k 个用户在 i 次 Monte Carlo 实验的估计激活指标。

实验 1 研究信噪比 (Signal-to-noise ratio, SNR) 对信道估计性能的影响。图 2 给出了不同算法的 NMSE 随着 SNR 变化的曲线图, 参数设置 $M = 100, K = 25, K_a = 2, L = 160$ 。在 LS 算法中, 为了保证伪逆 $(\mathbf{S}^T)^+$ 的存在, 快拍数大于用户数, 即设置 $T = 30$, 而对于其他方法 $T = 20$ 。仿真结果可总结如下: (1) 所有方法的 NMSE 都随着 SNR 的增加而减小, 所提的方法始终取得最佳的性能; (2) LS 方法的信道估计性能在所有方法中表现得最差, 因为该方法没有利用到角度域的稀疏性信息; (3) OMP 和 SBL 的性能表现得较差, 因为这两个方法都没有利用阵列流型; (4) FF-VBI 方法性能优于 OMP 和 SBL, 但不及所提方法, 原因在于其虽采用了离网模型以缓解角度误差, 但是存在模型失真; (5) TS-SBL 利用了极域的稀疏性, 其性能优于 SBL, 而劣于 FF-VBI 原因在于 TS-SBL 分步利用极域和用户域的稀疏性, FF-VBI 是联合求解信道, 从而在整体估计精度上更具优势; (6) 本文方法在所有的方法中最优, 是因为提出了精确的信道模型, 并利用了离网模型将网格点视为可调参数, 消除了角度间隙和距离间隙。

实验 2 研究天线数量对信道估计性能的影响。图 3 给出了不同算法的 NMSE 随着 M 变化的曲线图, 参数设置 $T = 20, K = 25, K_a = 2, \text{SNR} = 10 \text{ dB}, L = 160$ 。仿真结果表明: (1) 随着天线的增加, 所提的方法和 FF-VBI 得到了一定的改善, 因为更多的天线可以提供一定的阵列增益, 有助于提升估计精度; (2) LS、SBL 和 OMP 的 NMSE 随着天线数几乎不变, 因为在信道估计中仅用到了用户域的稀疏性, 而没有用到角度域的稀疏特性; (3) TS-SBL 的 NMSE 随天线数增加呈现先下降后趋于平稳的趋势, 因




图 2 不同算法的 NMSE 随 SNR 变化的曲线
Fig.2 NMSE versus SNR for different methods




图 3 不同算法的 NMSE 随天线 M 变化的曲线
Fig.3 NMSE versus M for different methods

为该方法在第1阶段估计的误差会影响最终的信道估计精度;(4)所提出的方法始终保持最优的性能,这得益于其精确的近场信道模型的充分挖掘并利用了距离信息。

实验3 研究快拍对信道估计性能的影响。

图4给出了不同算法的NMSE随着 T 变化的曲线图,参数设置 $M=100, K=25, K_a=2, \text{SNR}=5 \text{ dB}, L=160$ 。仿真结果表明:(1)所有方法的NMSE都随着 T 的增加而降低,因为利用到快拍维度的信息;(2)在快拍数较少的情况下,LS方法的性能很差,因为快拍数小于用户数,使得伪逆 $(S^T)^+$ 不存在;(3)尽管在快拍数较少的情况下,所提的方法始终保持着最优的性能。

实验4 研究激活用户数对信道估计性能的影响。图5给出了不同算法的NMSE随着 K_a 变化的曲线图,参数设置 $M=100, K=25, T=20, \text{SNR}=10 \text{ dB}, L=160$ 。仿真结果表明:(1)因为用户间干扰,所有方法的NMSE都随着 K_a 的增加而增加;(2)LS方法因完全忽略信道结构信息,表现最差;(3)OMP与SBL方法没有用到角度域的稀疏性,性能较差;(4)FF-VBI方法因未考虑距离域信息,性能相对较差;(5)TS-SBL比FF-VBI的性能差,因为TS-SBL未联合利用极域和用户域的稀疏性且分步估计会造成误差累积问题;(6)所提的方法总是优于其他方法在于其精确的信道模型和离网估计能力,能更好地应对激活用户增多带来的干扰问题,说明了所提方法稳健的信道估计性能。

实验5 研究快拍数对激活用户成功率的影响。图6给出了不同算法的激活用户成功率随着 T 变化的曲线图,参数设置 $M=100, K=25, K_a=2, \text{SNR}=10 \text{ dB}, L=160$ 。仿真结果表明:(1)所有方法的激活成功率随着 T 的增加呈现出上升的趋势;(2)当 T 较小时,OMP、LS和TS-SBL由于不能获得准确的信道估计结果而遭受一些性能损失,这阻碍了激活用户的成功率;(3)所提出的方法始终保持着相对优越的成功率,这验证了其所采用的近场精确离网信道模型能够更高效地从有限数据中提取信息,具备可靠的信道估计性能。




图4 不同算法的NMSE随快拍 T 变化的曲线
Fig.4 NMSE versus T for different methods




图5 不同算法的NMSE随激活用户数 K_a 变化的曲线
Fig.5 NMSE versus K_a for different methods




图6 不同算法的成功率随快拍 T 变化的曲线
Fig.6 Success rates versus T for different methods

4 结束语

本文针对6G系统XL-MIMO近场信道估计与多用户激活检测所面临的模型失真与误差累积问题,提出了一种基于精确球面波前模型的联合估计框架。该框架通过联合利用极域与用户域的双重稀疏性,并引入独立向量VBI技术,成功将高维耦合的联合估计问题解耦为一系列用户独立的稀疏恢复子问题,进而实现了近场阵列流型与多用户导频的分离。此外,引入离网参数更新机制进一步克服了网格失配带来的性能限制。仿真结果一致表明,本文所提方案在估计精度与检测可靠性方面均优于现有方法。

参考文献:

- [1] 田飞燕,陈晓明,钟财军,等. 6G蜂窝物联网的大规模接入技术[J]. 物联网学报, 2020, 4(1): 92-103.
TIAN Feiyan, CHEN Xiaoming, ZHONG Caijun, et al. Massive access technology in 6G cellular Internet of things network [J]. Chinese Journal on Internet of Things, 2020, 4(1): 92-103.
- [2] FAYAD A, CINKLER T, RAK J. Toward 6G optical fronthaul: A survey on enabling technologies and research perspectives [J]. IEEE Communications Surveys & Tutorials, 2025, 27(1): 629-666.
- [3] XIANG B, HU D, WU J. Deep learning-based downlink channel estimation for FDD massive MIMO systems[J]. IEEE Wireless Communications Letters, 2023, 12(4): 699-702.
- [4] KUAI X, CHEN L, YUAN X, et al. Structured turbo compressed sensing for downlink massive MIMO-OFDM channel estimation[J]. IEEE Transactions on Wireless Communications, 2019, 18(8): 3813-3826.
- [5] YOU Y, XUE Y, ZHANG L, et al. Channel estimation for RIS assisted millimeter wave systems via OMP with optimization [J]. IEEE Transactions on Vehicular Technology, 2023, 72(12): 16783-16787.
- [6] XIAO Z, CAO S, ZHU L, et al. Channel estimation for movable antenna communication systems: A framework based on compressed sensing[J]. IEEE Transactions on Wireless Communications, 2024, 23(9): 11814-11830.
- [7] LI K, HE J, EI-HAJJAR M, et al. Localization in reconfigurable intelligent surface aided mmWave systems: A multiple measurement vector based channel estimation method[J]. IEEE Transactions on Vehicular Technology, 2024, 73(9): 13326-13339.
- [8] GREBIEN S, LEITINGER E, WITRISAL K, et al. Super-resolution estimation of UWB channels including the dense component—An SBL-inspired approach[J]. IEEE Transactions on Wireless Communications, 2024, 23(8): 10301-10318.
- [9] MO J, SCHNITER P, HEATH R W. Channel estimation in broadband millimeter wave MIMO systems with few-bit ADCs [J]. IEEE Transactions on Signal Processing, 2018, 66(5): 1141-1154.
- [10] LU H, ZENG Y, YOU C, et al. A tutorial on near-field XL-MIMO communications toward 6G[J]. IEEE Communications Surveys & Tutorials, 2024, 26(4): 2213-2257.
- [11] CUI M, WU Z, LU Y, et al. Near-field MIMO communications for 6G: Fundamentals, challenges, potentials, and future directions[J]. IEEE Communications Magazine, 2023, 61(1): 40-46.
- [12] PAN Y, PAN C, JIN S, et al. RIS-aided near-field localization and channel estimation for the terahertz system[J]. IEEE Journal of Selected Topics in Signal Processing, 2023, 17(4): 878-892.
- [13] CUI M, DAI L. Channel estimation for extremely large-scale MIMO: Far-field or near-field?[J]. IEEE Transactions on Communications, 2022, 70(4): 2663-2677.
- [14] JI C, DAI J, FU H, et al. Joint device activity detection and channel estimation for mMTC[J]. IEEE Internet of Things Journal, 2024, 11(16): 27232-27244.
- [15] QIAO L, LIAO A, LI Z, et al. Sensing user's activity, channel, and location with near-field extra-large-scale MIMO[J]. IEEE Transactions on Communications, 2024, 72(2): 890-906.
- [16] DAHIYA S, SINGH A. Channel estimation and channel tracking for correlated block-fading channels in massive MIMO systems[J]. Digital Communications and Networks, 2018, 4(2): 138-147.
- [17] 李一, 傅海军, 戴继生. 基于非均匀稀疏贝叶斯学习的近场源定位[J]. 数据采集与处理, 2025, 40(1): 187-196.

- LI Yi, FU Haijun, DAI Jisheng. Near-field sources localization based on non-uniform sparse Bayesian learning[J]. Journal of Data Acquisition and Processing, 2025, 40(1): 187-196.
- [18] DAI J, LIU A, LAU V K. FDD massive MIMO channel estimation with arbitrary 2D-array geometry[J]. IEEE Transactions on Signal Processing, 2018, 66(10): 2584-2599.
- [19] 戴继生, 尚河坤. 一种基于实值变分贝叶斯推断的大规模MIMO系统下行信道估计方法[J]. 数据采集与处理, 2021, 36(6): 1094-1103.
- DAI Jisheng, SHANG Hekun. Downlink channel estimation for massive MIMO system based on real-valued variational Bayesian inference[J]. Journal of Data Acquisition and Processing, 2021, 36(6): 1094-1103.
- [20] YANG Z, XIE L, ZHANG C. Off-grid direction of arrival estimation using sparse Bayesian inference[J]. IEEE Transactions on Signal Processing, 2013, 61(1): 38-43.
- [21] DAI J, SO H C. Real-valued sparse Bayesian learning for DOA estimation with arbitrary linear arrays[J]. IEEE Transactions on Signal Processing, 2021, 69: 4977-4990.
- [22] WANG Q, YU H, LI J, et al. Sparse Bayesian learning using generalized double pareto prior for DOA estimation[J]. IEEE Signal Processing Letters, 2021, 28: 1744-1748.
- [23] MA M, DAI J, JIANG X Q. Fast burst-sparsity learning approach for massive MIMO-OTFS channel estimation[J]. IEEE Wireless Communications Letters, 2025, 14(5): 1546-1550.
- [24] TZIKAS D G, LIKAS A C, GALATSANOS N P. The variational approximation for Bayesian inference[J]. IEEE Signal Processing Magazine, 2008, 25(6): 131-146.
- [25] PARKER J T, SCHNITER P, CEVHER V. Bilinear generalized approximate message passing—Part I: Derivation[J]. IEEE Transactions on Signal Processing, 2014, 62(22): 5839-5853.
- [26] ZHOU L, DAI J, XU W. Joint multi-user channel estimation for RIS-assisted massive MIMO systems[J]. IEEE Transactions on Wireless Communications, 2024, 23(10): 13993-14006.
- [27] CAO J, DU J, HAN M, et al. Efficient sparse Bayesian channel estimation for near-field ultra-scale massive MIMO systems [J]. IEEE Wireless Communications Letters, 2023, 12(12): 2133-2137.

作者简介:



王姣姣(2000-),女,博士研究生,研究方向:信道估计、阵列信号处理、稀疏信号处理,E-mail:2242118@mail.dhu.edu.cn。



戴继生(1982-),通信作者,男,教授,研究方向:信道估计、阵列信号处理、稀疏信号处理,E-mail:jsdai@dhu.edu.cn。

(编辑:陈琨)

Near-Field Doubly-Sparse Channel Estimation and Multi-user Detection Based on Variational Bayesian Inference

WANG Jiaojiao, DAI Jisheng*

(School of Information and Intelligent Science, Donghua University, Shanghai 201620, China)

Abstract: For extremely large-scale multiple-input multiple-output (XL-MIMO) enabled 6G communication systems, the near-field effect poses performance limitations for traditional channel estimation methods based on far-field plane wavefront models. Existing near-field schemes predominantly rely on the Fresnel approximation, which introduces modeling errors, and generally handle channel estimation and multi-user activation detection in separate steps, leading to error accumulation. To address these challenges, this paper proposes a joint near-field channel estimation and multi-user activation detection framework based on an accurate spherical wave channel model. Different from approximation-based near-field schemes, the proposed framework directly characterizes the near-field array manifold without relying on Fresnel approximation, thereby avoiding model mismatch. Furthermore, the proposed method jointly exploits the double sparsity of XL-MIMO channels in both the polar domain and the user domain. Specifically, the polar domain sparsity arises from the limited number of effective propagation paths described by angle and distance parameters, while the user domain sparsity comes from the fact that only a small subset of users is active during a given transmission interval. By leveraging these two types of sparsity simultaneously, the original high-dimensional coupled estimation problem can be transformed into a more structured sparse recovery problem. Moreover, an independent-vector variational Bayesian inference (VBI) technique is introduced to efficiently decouple the complicated joint estimation task into multiple user-wise sparse recovery subproblems. This strategy enables effective separation between the near-field array manifold and multi-user pilot signals, thereby substantially reducing computational complexity while preserving estimation accuracy. In addition, an off-grid parameter update strategy is incorporated to refine the predefined angular and distance grids. By iteratively updating the off-grid parameters, the proposed method alleviates grid mismatch and improves the accuracy of near-field channel reconstruction. Simulation results demonstrate that the proposed method outperforms existing methods in terms of channel estimation accuracy and user activity detection reliability. Under different signal-to-noise ratios, antenna numbers, snapshot lengths, and active user numbers, the proposed algorithm consistently obtains lower normalized mean square error and higher user activity detection success rate. These results verify the effectiveness, robustness, and superiority of the proposed framework. Therefore, the proposed method provides an efficient and accurate solution for near-field XL-MIMO channel acquisition and grant-free massive access in future 6G wireless communication systems.

Highlights:

1. This work develops an accurate spherical-wave near-field channel model for XL-MIMO systems, thereby avoiding the modeling mismatch introduced by the Fresnel approximation.
2. A joint channel estimation and multi-user activity detection framework is proposed by exploiting the double sparsity in both the polar domain and the user domain.
3. This work introduces an independent-vector VBI technique to decouple the high-dimensional coupled sparse recovery problem into user-independent sparse recovery subproblems, thereby enabling the effective separation of the near-field array manifold and multi-user pilot signals.

Key words: 6G; near-field channel estimation; multi-user activation detection; sparse representation; variational Bayesian inference (VBI)

Foundation item: Natural Science Foundation of Shanghai Basic Research Funding (No.25ZR1401002).

Received: 2025-02-24; **Revised:** 2025-10-15

***Corresponding author, E-mail:** jsdai@dhu.edu.cn.