

可重构智能表面辅助通信系统时变级联信道估计

邵凯^{1,2,3}, 鲁奔¹, 王光宇^{1,2}

(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;
3. 移动通信教育部工程研究中心, 重庆 400065)

摘 要: 针对可重构智能表面 (RIS) 辅助通信系统时变级联信道的估计中需解决的级联信道稀疏表示、时变信道参数跟踪和信号重构等关键问题, 提出了一种结合 Khatri-Rao 积的分层贝叶斯卡尔曼滤波 (KR-HBKF) 算法。该算法首先利用信道的稀疏特性, 通过 Khatri-Rao 积和克罗内克积变换得到 RIS 级联信道的稀疏表示, 将 RIS 级联信道估计问题转化为低维度的稀疏信号恢复问题。然后, 根据 RIS 级联信道的状态演化模型, 在 HBKF 算法的预测模型中引入了时间相关性参数, 应用改进的 HBKF 解决时变信道参数跟踪和信号重构问题, 完成时变级联信道的估计。KR-HBKF 算法综合利用了信道的稀疏性和时间相关性, 能以较小的导频开销获得更好的估计精度。仿真结果表明, 与传统压缩感知算法相比, 所提算法具有约 5 dB 的估计性能提升, 且在不同的时变信道条件下具有更好的鲁棒性。

关键词: 可重构智能表面; 信道估计; 贝叶斯压缩感知; 卡尔曼滤波

中图分类号: TN928

文献标志码: A

DOI: 10.11959/j.issn.1000-436x.2024028

Time-varying channel estimation in reconfigurable intelligent surface assisted communication system

SHAO Kai^{1,2,3}, LU Ben¹, WANG Guangyu^{1,2}

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
3. Engineering Research Center of Mobile Communications of the Ministry of Education, Chongqing 400065, China

Abstract: Aiming at the key problems need to be solved, such as cascade channel sparse representation, time-varying channel parameter tracking and signal reconstruction, for time-varying cascade channels estimation of reconfigurable intelligent surface (RIS) assisted communication system, a Khatri-Rao and hierarchical Bayesian Kalman filter (KR-HBKF) algorithm was proposed. Firstly, the Khatri-Rao product and Kronecker product transformations were used to obtain the sparse representation of RIS cascaded channels based on the sparse characteristics of channels, thus the RIS cascaded channel estimation problem was transformed into a low-dimensional sparse signal recovery problem. Then, according to the state evolution model of RIS cascaded channel, the time correlation parameter was introduced into the prediction model of HBKF algorithm, and the improved HBKF was applied to solve the problem of time-varying channel parameter tracking and signal reconstruction for completing the time-varying cascaded channels estimation. The sparsity and time correlation of the channel were comprehensively considered in the KR-HBKF algorithm, thus better estimation accuracy could be obtained with small pilot overhead. Compared with the traditional compressed sensing algorithm, the simulation results show that the proposed algorithm has about 5 dB estimated performance improvement, and better robustness performance under different time-varying channel conditions.

Keywords: reconfigurable intelligent surface, channel estimation, Bayesian compressed sensing, Kalman filter

收稿日期: 2023-08-16; 修回日期: 2023-11-01

基金项目: 国家自然科学基金资助项目 (No.U23A20279)

Foundation Item: The National Natural Science Foundation of China (No.U23A20279)

0 引言

作为无线通信环境智能化的关键使能技术^[1],可重构智能表面(RIS, reconfigurable intelligent surface)一经提出就引起业界的广泛关注。RIS 由大量的无源反射元件构成,每个元件都可被独立实时控制以改变入射信号的振幅和相位,进而达到重塑无线电磁环境的目的^[2]。RIS 与毫米波、大规模多输入多输出等技术相结合组成 RIS 辅助系统,能以较低的功耗实现更高的频谱效率和更大的覆盖范围,已成为实现下一代通信系统的关键解决方案^[3-4]。要充分发挥 RIS 辅助系统的性能,精确的信道状态信息(CSI, channel state information)不可或缺。然而,RIS 的引入不仅急剧增加信道矩阵维度,还导致必须在基站(BS, base station)或用户设备(UE, user equipment)进行 BS-RIS-UE 链路的级联信道的估计。这些特点都会增加信道估计的导频开销和处理复杂度,为 RIS 辅助系统的 CSI 获取带来极大挑战。

业界对 RIS 辅助系统下的信道估计方案已开展了广泛研究,例如基于最小二乘/最小均方误差、基于深度学习(DL, deep learning)、基于压缩感知(CS, compressed sensing)等信道估计方案。最小二乘/最小均方误差作为一种逼近超定线性模型解的经典方法,由于其在实际实现中的低复杂度,被广泛应用于 RIS 辅助系统中基于导频的信道估计^[5-8]。但此类方法要求用于估计的导频数量不少于要估计的信道参数数量,在具有大量参数的 RIS 系统下存在频谱效率低的问题。DL 方法学习从训练数据到级联 CSI 之间的近似映射函数,可以有效地提取信道特征^[9-11],将其应用于 RIS 信道估计可以获得良好的估计性能。但是 DL 方法需要大量数据集进行长时间的离线训练,且泛化能力较差,这限制了其实际应用。

CS 方法在 RIS 辅助系统中得到广泛研究,其可显著降低用于信道估计的导频开销。利用 CS 实现 BS-RIS-UE 级联信道的估计,关键在于选取合适的级联信道稀疏表示方案和信号重构算法。为得到级联信道的稀疏表示,文献[12]开创性地将级联信道参数解耦为 RIS 侧和 BS/UE 侧信道相关参数,将高维级联信道估计问题转换为两阶段的低维稀疏信号恢复问题。文献[13]进一步提出了一种两步级联信道估计协议实现对 RIS 级联信道的高分辨率估计。然而,此类两阶段稀疏表示方案存在估计误差

放大问题,即第一阶段的估计误差会严重降低第二阶段的估计性能。为解决这一问题,文献[14]提出了一种新颖的单阶段估计框架,通过克罗内克积和 Khatri-Rao 积变换直接得到级联信道的稀疏表示,只需执行一次重构算法就可得到级联信道的估计,可以有效避免误差放大问题。但文献[14]忽略了 Khatri-Rao 积所导致的信道稀疏表示中存在大量重复项的问题^[15],使后续重构算法的运算量显著增加。另一方面,通过利用 RIS 相关信道的稀疏性,研究者已经开发出各种用于 RIS 级联信道估计的信号重构算法。例如,文献[12]利用正交匹配追踪(OMP, orthogonal matching pursuit)寻找接收的观测向量的最佳匹配投影来实现信号重构。文献[15-16]应用近似消息传递算法通过迭代方式对图模型执行推理来解决级联信道估计问题。其他基于压缩感知的算法,如自适应网格匹配追踪^[13]、迭代重加权^[17]等也已被广泛应用于 RIS 级联信道估计。然而上述算法用于信道估计时均需要先验信息,例如信道的稀疏度、信道的稳定性等,导致此类重构算法仅适用于静态或准静态信道条件。

针对 BS-RIS-UE 级联时变信道估计,需解决信道参数跟踪问题。已有研究表明,时变无线信道在相邻时间实例上具有相似的角度功率分布,并且相应的路径增益在时间上具有相关性^[18-19]。文献[20]提出了一种基于贝叶斯压缩感知(BCS, Bayesian compressed sensing)的时变级联信道估计方案。BCS 利用观测数据自动推导出信道的稀疏度信息,因此不需要已知信号的稀疏度信息也可取得良好的估计性能。然而,BCS 算法不能利用级联信道的时变相关性实现对信道的实时跟踪。文献[21]将 BS-RIS-UE 级联信道建模为状态空间模型以捕获信道的时变相关性,然后利用卡尔曼滤波(KF, Kalman filter)跟踪级联信道的变化。文献[22]进一步提出了一种两阶段 KF 框架,实现了对 BS-RIS-UE 级联信道和 BS-UE 视距信道的跟踪,有效地提高了时变信道的估计性能。联合时变信道的参数跟踪和信号重构问题,实际是 CS 领域动态稀疏信号恢复问题,文献[23-25]尝试用 KF 方法提取时变信号的时间相关性。而文献[26]中所提出的分层贝叶斯卡尔曼滤波(HBKF, hierarchical Bayesian Kalman filter)算法利用 KF 捕获动态信号的时间相关性,同时将 BCS 算法提供的关于稀疏信号完整后验概率分布集成到 KF 算法中。该方

案既克服了 BCS 估计方案的不足，又解决了 KF 算法无法保证信号稀疏估计的问题。

综上，要获得 BS-RIS-UE 级联时变信道的估计，需解决级联信道稀疏表示、时变信道参数跟踪和信号重构等关键问题。为此，本文基于 HBKF 算法提出了结合 Khatri-Rao 积的分层贝叶斯卡尔曼滤波（KR-HBKF, Khatri-Rao and HBKF）算法。所提方案首先利用信道的稀疏特性，通过 Khatri-Rao 积和克罗内克积变换得到 RIS 级联信道的稀疏表示，并将 RIS 级联信道估计问题转化为低维度的稀疏信号恢复问题。然后应用 HBKF 解决时变信道参数跟踪和信号重构问题。本文主要贡献如下。1) 利用 Khatri-Rao 积和克罗内克积的性质得到级联信道的稀疏表示，为解决级联信道稀疏表示中存在大量重复项的问题，进一步利用 Khatri-Rao 积和字典矩阵的性质对级联信道的稀疏表示进行降维；然后将级联信道估计问题转化为稀疏信号恢复问题，并得到了信道增益的角域空间状态演化模型。2) HBKF 算法中稀疏信号演化模型无法拟合 RIS 辅助通信系统时变级联信道的时变相关性，本文提出的 KR-HBKF 算法根据 RIS 级联信道的状态演化模型，在 HBKF 算法的预测模型中引入了时间相关性参数，重点分析了超参数估计问题，因此能够有效捕获级联信道的时变相关和稀疏特性。

符号说明如下：标量用小写字母 a 表示，小写粗体字母 \mathbf{a} 和大写粗体字母 \mathbf{A} 分别表示向量和矩阵， \mathbf{A}^T 、 \mathbf{A}^* 、 \mathbf{A}^H 以及 $\text{vec}(\mathbf{A})$ 以及 $\text{diag}(\mathbf{a})$ 分别表示转置、共轭、共轭转置、矩阵向量化和向量对角化运算符。 $\hat{\mathbf{A}}$ 表示 \mathbf{A} 的估计值。 \otimes 和 \bullet 分别表示克罗内克积和转置 Khatri-Rao 积运算符。

1 RIS 辅助通信系统模型

图 1 为 RIS 辅助系统模型。假设 RIS 是由 $N = N_1 \times N_2$ 个反射元件构成的均匀平面阵列，基站由配备了 M 个天线的均匀线性阵列构成。RIS 到 BS 侧的信道用 $\mathbf{G} \in \mathbb{C}^{M \times N}$ 表示，UE 到 RIS 侧信道用 $\mathbf{h}_r \in \mathbb{C}^N$ 表示。基站与用户之间采用毫米波通信，当视线线路径 \mathbf{h}_d 被阻塞时，数据传输通过 RIS 构建的 \mathbf{h}_r -RIS- \mathbf{G} 虚拟视距链路实现。本文假设块衰落信道，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。在导频

训练阶段，UE 通过 RIS 向 BS 发送 Q 个已知的导频符号用于上行链路级联信道估计。

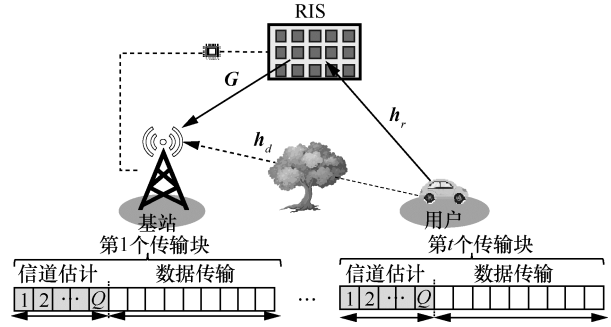


图 1 RIS 辅助系统模型

1.1 级联信道模型

根据毫米波的特性，可以采用窄带几何信道模型来对信道 \mathbf{G} 和 \mathbf{h}_r 进行表征。具体来说， \mathbf{G} 和 \mathbf{h}_r 可以分别表示为

$$\mathbf{G} = \sqrt{\frac{MN}{L_G}} \sum_{i=1}^{L_G} \alpha_i \mathbf{b}(\phi_i) \mathbf{a}(\vartheta_i, \psi_i)^T \quad (1)$$

$$\mathbf{h}_r = \sqrt{\frac{N}{L_h}} \sum_{j=1}^{L_h} \alpha_j \mathbf{a}(\vartheta_j, \psi_j) \quad (2)$$

其中， L_G 表示 RIS-BS 信道的路径数量， α_i 、 ϕ_i 和 $\vartheta_i(\psi_i)$ 分别表示 RIS-BS 信道第 i 条路径对应的路径损耗、BS 处的方位角和 RIS 侧的方位角（仰角）。同样地， L_h 表示 UE-RIS 信道的路径数量， α_j 和 $\vartheta_j(\psi_j)$ 分别表示 UE-RIS 信道第 j 条路径的路径损耗和 RIS 侧的方位角（仰角）。此外， $\mathbf{b}(\phi)$ 和 $\mathbf{a}(\vartheta, \psi)$ 分别表示与 BS 和 RIS 相关的归一化阵列响应矢量，即

$$\mathbf{b}(\phi) = \frac{1}{\sqrt{M}} \left[e^{-\frac{j2\pi d \sin(\phi) m}{\lambda}} \right] \quad (3)$$

$$\mathbf{a}(\vartheta, \psi) = \frac{1}{\sqrt{N}} \left[e^{-\frac{j2\pi d \sin(\vartheta) \cos(\psi) n_1}{\lambda}} \right] \otimes \left[e^{-\frac{j2\pi d \sin(\psi) n_2}{\lambda}} \right] \quad (4)$$

其中， λ 为载波波长， d 为天线间距。 $\mathbf{m} = [0, 1, \dots, M-1]^T$ ， $\mathbf{n}_1 = [0, 1, \dots, N_1-1]^T$ ， $\mathbf{n}_2 = [0, 1, \dots, N_2-1]^T$ 。由于毫米波信道的稀疏散射特性，信道的路径数远小于信道矩阵 \mathbf{G} 和 \mathbf{h}_r 的维数，表现出强稀疏性。基于式(1)和式(2)，信道 \mathbf{G} 和 \mathbf{h}_r 可进一步表示为

$$\mathbf{G} = \mathbf{U}_B \mathbf{A}_G \mathbf{U}_R^H \quad (5)$$

$$\mathbf{h}_r = \mathbf{U}_R \mathbf{A}_{h_r} \quad (6)$$

其中, $\mathbf{U}_R \in \mathbb{C}^{N \times N_g}$ 和 $\mathbf{U}_B \in \mathbb{C}^{M \times M_g}$ 分别表示 RIS 和 BS 侧的过完备字典矩阵; $\mathbf{A}_G \in \mathbb{C}^{M_g \times N_g}$ 和 $\mathbf{A}_{h_r} \in \mathbb{C}^{N_g}$ 分别为具有 L_G 和 L_h 个非零项的稀疏矩阵, 对应于信道 \mathbf{G} 和 \mathbf{h}_r 的角度域表示, M_g 和 N_g 表示相应字典矩阵的分辨率。

定义 $\mathbf{H}_c = \mathbf{G} \text{diag}(\mathbf{h}_r)$ 表示 \mathbf{h}_r -RIS- \mathbf{G} 链路级联信道。为了描述信道的时变特性, 根据式(1)和式(2), 第 t 个传输块的级联信道矩阵 $\mathbf{H}_c[t]$ 可表示为

$$\begin{aligned} \mathbf{H}_c[t] &= \mathbf{G}[t] \text{diag}(\mathbf{h}_r[t]) = \\ & \sqrt{\frac{MN^2}{L_G L_h}} \sum_{i=1}^{L_G} \sum_{j=1}^{L_h} \alpha_i[t] \alpha_j[t] \cdot \\ & \mathbf{b}(\phi_i) \mathbf{a}(\vartheta_i, \psi_i)^T \text{diag}(\mathbf{a}(\vartheta_j, \psi_j)) = \\ & \sqrt{\frac{MN^2}{L_G L_h}} \sum_{i=1}^{L_G} \sum_{j=1}^{L_h} \alpha_{i,j}[t] \cdot \\ & \mathbf{b}(\phi_i) \mathbf{a}(\vartheta_i + \vartheta_j, \psi_i + \psi_j)^T \end{aligned} \quad (7)$$

其中, $\alpha_{i,j}[t] = \alpha_i[t] \alpha_j[t]$ 表示第 t 个传输块的级联路径增益。根据文献[19,21], $\alpha_{i,j}[t]$ 的时间演化模型可通过一阶自回归过程近似表示为

$$\alpha_{i,j}[t] = \rho \alpha_{i,j}[t-1] + \sqrt{1-\rho^2} u_{i,j}[t] \quad (8)$$

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 分别表示最大多普勒频移和传输块持续时间。此外, $u_{i,j}[t] \sim (0, \sigma_u^2)$ 表示模型误差, 并且假设与 $\alpha_{i,j}[t]$ 独立。

1.2 问题建立

假设 $\boldsymbol{\theta} = [\beta_1 e^{j\theta_1}, \beta_2 e^{j\theta_2}, \dots, \beta_N e^{j\theta_N}]$ 表示 RIS 的反射系数, 其中 $\theta_n \in [0, 2\pi]$ 和 $\beta_n \in [0, 1]$ 分别表示 RIS 第 n 个反射元件的相移和振幅反射系数。简单起见, 本文假设 $\beta_n = 1, \forall n$ 。为表述方便, 下文中不同传输块用下标 t 来描述, 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 $\mathbf{y}_{t,q} \in \mathbb{C}^M$ 可以表示为

$$\begin{aligned} \mathbf{y}_{t,q} &= \mathbf{G}_t \text{diag}(\boldsymbol{\theta}_q) \mathbf{h}_{r,t} s_q + \mathbf{w}_{t,q} = \\ & \mathbf{G}_t \text{diag}(\mathbf{h}_{r,t}) \boldsymbol{\theta}_q s_q + \mathbf{w}_{t,q} = \\ & \mathbf{H}_{c,t} \boldsymbol{\theta}_q s_q + \mathbf{w}_{t,q} \end{aligned} \quad (9)$$

其中, s_q 表示导频信号, $\mathbf{w}_{t,q} \sim (0, \sigma^2 \mathbf{I}_M)$ 表示接收

机产生的噪声, σ^2 表示噪声能量。假设导频信号为 $s_q = 1, \forall q$, 则在 Q 个导频传输完成后, 根据式(9)可得测量矩阵 $\mathbf{Y}_t = [\mathbf{y}_{t,1}, \dots, \mathbf{y}_{t,Q}]$ 为

$$\mathbf{Y}_t^T = \boldsymbol{\Theta}^T \mathbf{H}_{c,t}^T + \mathbf{W}_t^T \quad (10)$$

其中, $\boldsymbol{\Theta} = [\boldsymbol{\theta}_1, \dots, \boldsymbol{\theta}_Q]$, $\mathbf{W}_t = [\mathbf{w}_{t,1}, \dots, \mathbf{w}_{t,Q}]$ 。本文目标是根据测量矩阵 \mathbf{Y}_t 和式(8)描述的增益演化模型得到级联信道 $\mathbf{H}_{c,t}$ 的估计。对式(10)进行向量化操作, 可得到 $\mathbf{y}_t = \mathbf{Y} \mathbf{h}_{c,t}^T + \mathbf{w}_t$, 其中, $\mathbf{Y} = \boldsymbol{\Theta}^T \otimes \mathbf{E}$, $\mathbf{y}_t = \text{vec}(\mathbf{Y}_t^T)$, $\mathbf{h}_{c,t} = \text{vec}(\mathbf{H}_{c,t}^T)$, $\mathbf{w}_t = \text{vec}(\mathbf{W}_t^T)$ 。根据最小二乘算法, 信道矩阵矢量 $\mathbf{h}_{c,t}$ 的估计可表示为 $\hat{\mathbf{h}}_{c,t} = \mathbf{Y}^\dagger \mathbf{y}_t$, 其中 \mathbf{Y}^\dagger 为 \mathbf{Y} 的伪逆。但是, 此类线性估计方案需要至少 $Q > N$ 个导频去获得精确的信道估计, 在具有大量元件的 RIS 场景下不切实际。为降低用于信道估计的导频开销, 本文考虑利用高频信道固有的稀疏性, 提出一种基于 CS 的低导频开销信道估计方案。

2 KR-HBKF 估计方案

2.1 级联信道稀疏表示

基于式(5)和式(6), 结合 Khatri-Rao 积和克罗内克积的性质, 级联信道 \mathbf{H}_c 可以表示为

$$\begin{aligned} \mathbf{H}_c^T &= \text{diag}(\mathbf{h}_r) \mathbf{G}^T = \mathbf{h}_r \bullet \mathbf{G}^T \stackrel{\text{a}}{=} \\ & (\mathbf{U}_R \mathbf{A}_{h_r}) \bullet (\mathbf{U}_B \mathbf{A}_G \mathbf{U}_R^H)^T \stackrel{\text{b}}{=} \\ & (\mathbf{U}_R \bullet \mathbf{U}_R^*) (\mathbf{A}_{h_r} \otimes (\mathbf{A}_G^T \mathbf{U}_B^T))^c \\ & (\mathbf{U}_R \bullet \mathbf{U}_R^*) (\mathbf{A}_{h_r} \otimes \mathbf{A}_G^T) (\mathbf{I} \otimes \mathbf{U}_B^T) \stackrel{\text{d}}{=} \\ & \mathbf{U} (\mathbf{A}_{h_r} \otimes \mathbf{A}_G^T) \mathbf{U}_B^T \end{aligned} \quad (11)$$

其中, 变换 a 由式(5)和式(6)得到; 变换 b 和变换 c 由变换性质 $(\mathbf{A} \bullet \mathbf{C})(\mathbf{B} \mathbf{D}) = (\mathbf{A} \bullet \mathbf{B})(\mathbf{C} \otimes \mathbf{D})$ 和 $(\mathbf{A} \mathbf{B}) \otimes (\mathbf{C} \mathbf{D}) = (\mathbf{A} \otimes \mathbf{C})(\mathbf{B} \otimes \mathbf{D})$ 得到; 令 $\mathbf{U} = (\mathbf{U}_R \bullet \mathbf{U}_R^*)$, 得到变换 d。矩阵 $\mathbf{U} \in \mathbb{C}^{N \times N_g^2}$ 中的转置 Khatri-Rao 积运算使 \mathbf{U} 产生了大量的冗余项, 根据文献[15]的推论, \mathbf{H}_c 可以进一步简化为

$$\mathbf{H}_c^T = \mathbf{U} (\mathbf{A}_{h_r} \otimes \mathbf{A}_G^T) \mathbf{U}_B^T = \mathbf{U}_D \mathbf{A} \mathbf{U}_B^T \quad (12)$$

其中, $\mathbf{U}_D = \mathbf{U}(:, 1:N_g)$ 表示 \mathbf{U} 的前 N_g 列; $\mathbf{A}(i,:) = \sum_{n \in S_i} \mathbf{J}(n,:)$, $\mathbf{A}(i,:)$ 表示 \mathbf{A} 的第 i 行, S_i 表示 \mathbf{U} 中与 \mathbf{U}_D 的第 i 列相关联列的索引集;

$J = \mathbf{A}_h \otimes \mathbf{A}_G^T$ 。同时, \mathbf{A} 最多含有 $L_G \times L_h$ 个非零项。将式(12)代入式(10)可得

$$\mathbf{Y}_t^T = \boldsymbol{\Theta}^T \mathbf{U}_D \mathbf{A}_t \mathbf{U}_B^T + \mathbf{W}_t^T \quad (13)$$

令 $\mathbf{y}_t = \text{vec}(\mathbf{Y}_t^T)$, 根据克罗内克积的性质, 进一步可得

$$\mathbf{y}_t = (\mathbf{U}_B \otimes \boldsymbol{\Theta}^T \mathbf{U}_D) \mathbf{h}_{t,b} + \text{vec}(\mathbf{W}_t^T) = \boldsymbol{\Phi} \mathbf{h}_{b,t} + \text{vec}(\mathbf{W}_t^T) \quad (14)$$

其中, $\boldsymbol{\Phi} = \mathbf{U}_R \otimes \boldsymbol{\Theta}^T \mathbf{U}_D \in \mathbb{C}^{QM \times M_g N_g}$ 表示感知矩阵; $\mathbf{h}_{b,t} = \text{vec}(\mathbf{A}_t)$ 为级联信道的等效角域空间表示, $\mathbf{h}_{b,t}$ 的非零元素与级联信道的路径增益相对应。根据文献[27]的推论, 为得到精确的信道估计, CS 方案需要的导频数量 $Q \approx \frac{L_G L_h}{M} \log \frac{M_g N_g}{\sqrt{L_G L_h}}$ 。通常情况下, L_G 和 L_h 在高频信道下很小, 对训练开销的贡献很小。此外, 由于对数函数的存在, $M_g N_g$ 引起的训练开销也很低。因此可以看出, 相较于最小二乘方案, CS 方案能以较低的导频开销得到级联信道的估计。

基于式(8), 信道增益的角域状态演化模型可进一步表示为

$$\mathbf{h}_{b,t} = \rho \mathbf{h}_{b,t-1} + \sqrt{1 - \rho^2} \mathbf{u}_t \quad (15)$$

其中, $\mathbf{h}_{b,t}$ 和 \mathbf{u} 共享相同的稀疏性轮廓。进一步假设 $\mathbf{h}_{b,t}$ 和 \mathbf{u} 的非零元素独立同分布, 相应元素分别服从分布 $\mathcal{CN}(0, \sigma_h^2)$ 和 $\mathcal{CN}(0, \sigma_v^2)$ 。

2.2 参数跟踪和信号重构

文献[26]中提出的 HBKF 算法可以分为 3 个阶段: 预测估计阶段、超参数估计阶段和滤波估计阶段。HBKF 在预测估计阶段中假设 $\hat{\mathbf{h}}_{b,t|t-1} = \hat{\mathbf{h}}_{b,t-1|t-1}$, 不能有效拟合式(15)所描述的 RIS 级联时变信道的相关性, 导致预测模型存在参数不匹配问题。因此本文基于式(14)中的稀疏观测模型和式(15)描述的增益演化模型, 在 HBKF 的预测估计阶段引入了时间相关性参数 ρ 来捕获级联信道的相关性。首先, 采用 KF 算法实现对时变信道的估计, 具体流程如下。

预测估计为

$$\hat{\mathbf{h}}_{b,t|t-1} = \rho \hat{\mathbf{h}}_{b,t-1|t-1} \quad (16)$$

$$\mathbf{y}_{t|t-1} = \boldsymbol{\Phi}_t \hat{\mathbf{h}}_{b,t|t-1} \quad (17)$$

更新预测 MSE 为

$$\boldsymbol{\Sigma}_{t|t-1} = \rho^2 \boldsymbol{\Sigma}_{t-1|t-1} + (1 - \rho^2) \boldsymbol{\Gamma}_t \quad (18)$$

卡尔曼增益计算为

$$\mathbf{K}_t = \boldsymbol{\Sigma}_{t|t-1} \boldsymbol{\Phi}_t^T (\sigma^2 \mathbf{I} + \boldsymbol{\Phi}_t \boldsymbol{\Sigma}_{t|t-1} \boldsymbol{\Phi}_t^T)^{-1} \quad (19)$$

滤波估计为

$$\hat{\mathbf{h}}_{b,t|t} = \hat{\mathbf{h}}_{b,t|t-1} + \mathbf{K}_t (\mathbf{y}_t - \mathbf{y}_{t|t-1}) \quad (20)$$

更新估计 MSE 为

$$\boldsymbol{\Sigma}_{t|t} = (\mathbf{I} - \mathbf{K}_t \boldsymbol{\Phi}_t) \boldsymbol{\Sigma}_{t|t-1} \quad (21)$$

其中, $\hat{\mathbf{h}}_{b,t|t-1}$ 和 $\boldsymbol{\Sigma}_{t|t-1}$ 分别表示在第 t 个传输块的预测估计和预测误差协方差矩阵, $\hat{\mathbf{h}}_{b,t|t}$ 和 $\boldsymbol{\Sigma}_{t|t}$ 为在第 t 个传输块中得到的滤波估计和滤波误差协方差矩阵。KF 算法中式(18)假设信道增益模型误差项 \mathbf{u}_t 的协方差矩阵 $\boldsymbol{\Gamma}_t$ 为给定的满秩矩阵, 无法实现对信道角域空间矢量 $\mathbf{h}_{b,t}$ 的稀疏估计, 因此在 RIS 辅助通信场景下存在严重的性能损失。

为克服 KF 算法的不足, 根据 HBKF 利用 BCS 算法的稀疏估计思想, 假设式(15)中模型误差项 \mathbf{u}_t 服从分层结构的高斯先验分布来促进稀疏性^[26], 具体表示如下

$$p(\mathbf{u}_t; \boldsymbol{\Gamma}_t) = \prod_{i=1}^{M_g N_g} (\pi \gamma_{i,t})^{-1} \exp\left(-\frac{|\mathbf{u}_t(i)|^2}{\gamma_{i,t}}\right) \quad (22)$$

其中, 超参数 $\gamma_{i,t}, \forall 1 \leq i \leq M_g N_g$ 表示模型误差项 \mathbf{u}_t 第 i 个元素 $\mathbf{u}_t(i)$ 的先验方差, $\boldsymbol{\Gamma}_t = \text{diag}(\boldsymbol{\gamma}_t) = \text{diag}[\gamma_{1,t}, \dots, \gamma_{i,t}, \dots, \gamma_{M_g N_g,t}]$ 表示超参数的对角矩阵。在 HBKF 框架下, $\boldsymbol{\gamma}_t$ 为未知但确定的参数, 通常使用期望最大化 (EM, expectation maximization) 算法最大化贝叶斯证据 $p(\mathbf{y}_{e,t} | \boldsymbol{\gamma}_t)$ 来得到超参数 $\boldsymbol{\gamma}_t$ 的估计, 其中预测误差向量 $\mathbf{y}_{e,t} = \mathbf{y}_t - \mathbf{y}_{t|t-1}$ 。得到 $\boldsymbol{\gamma}_t$ 的估计后, 可以发现与模型误差项 \mathbf{u}_t 的零元素相对应的 $\gamma_{i,t}$ 都趋于零。又由于 $\mathbf{h}_{b,t}$ 和 \mathbf{u} 共享相同的稀疏性轮廓, 因此在收敛后获得的 $\boldsymbol{\Gamma}_t$ 能够很好地捕获 $\mathbf{h}_{b,t}$ 的稀疏特性^[28]。将收敛后获得的 $\boldsymbol{\Gamma}_t$ 代入 KF 算法的更新阶段, 即可得到 KR-HBKF 算法, 实现对级联信道的稀疏估计。

接下来将详细分析 KR-HBKF 中利用 EM 算法获取超参数 $\boldsymbol{\gamma}_t$ 的过程。EM 算法通过最大化似然函数 $p(\mathbf{y}_{e,t} | \boldsymbol{\gamma}_t)$ 来得到超参数 $\boldsymbol{\gamma}_t$ 的估计。根据式(14)、式(16)和式(17), 可得到增益演化模型误差项 \mathbf{u}_t 关于信道预测误差向量 $\mathbf{y}_{e,t}$ 的表达式为

$$\begin{aligned} \mathbf{y}_{e,t} &= \mathbf{y}_t - \mathbf{y}_{t|t-1} = \\ &\Phi_t \left(\mathbf{h}_{b,t-1} + \sqrt{1-\rho^2} \mathbf{u}_t \right) + \mathbf{w}_t - \rho \Phi_t \hat{\mathbf{h}}_{b,t-1|t-1} \approx \\ &\sqrt{1-\rho^2} \Phi_t \mathbf{u}_t + \mathbf{w}_t \end{aligned} \quad (23)$$

噪声的概率分布为 $\mathbf{w}_t \sim \mathcal{CN}(0, \sigma^2 \mathbf{I}_M)$, 根据贝叶斯理论, 可得到 $\mathbf{y}_{e,t}$ 的似然分布为

$$\begin{aligned} p(\mathbf{y}_{e,t} | \mathbf{u}_t, \sigma^2) &= (2\pi\sigma^2)^{-\frac{M_g N_g}{2}} \\ &\exp \left(-\frac{\|\mathbf{y}_{e,t} - \sqrt{1-\rho^2} \Phi_t \mathbf{u}_t\|^2}{2\sigma^2} \right) \end{aligned} \quad (24)$$

基于式(22)和式(24), 可得超参数 γ_t 的对数似然函数为

$$\begin{aligned} \mathcal{L}(\gamma_t) &= \log p(\mathbf{y}_{e,t} | \gamma_t) = \\ &\log \int p(\mathbf{y}_{e,t} | \mathbf{u}_t, \sigma^2) p(\mathbf{u}_t; \Gamma_t) d\mathbf{u}_t = \\ &-\frac{1}{2} \left\{ M_g N_g \log 2\pi + \log |\Sigma_{\mathbf{y}_{e,t}}| + \mathbf{y}_{e,t}^T \mathbf{C}^{-1} \mathbf{y}_{e,t} \right\} \end{aligned} \quad (25)$$

其中, $\Sigma_{\mathbf{y}_{e,t}} = \sigma^2 \mathbf{I} + \sqrt{1-\rho^2} \Phi_t \Gamma_t^{-1} \Phi_t^T$ 表示预测误差向量 $\mathbf{y}_{e,t}$ 的协方差矩阵。假设 $\hat{\Gamma}_t^{(k)}$ 为 EM 算法第 k 次迭代时产生的估计值。根据式(25), EM 算法期望阶段 (E-step) 产生的平均对数似然函数可表示为

$$\begin{aligned} \mathcal{L}(\Gamma | \hat{\Gamma}_t^{(k)}) &= \mathbb{E}_{\mathbf{u}_t | \mathbf{y}_t; \hat{\Gamma}_t^{(k)}} \{ \log p(\mathbf{y}_{e,t} | \gamma_t) \} = \\ &\mathbb{E}_{\mathbf{u}_t | \mathbf{y}_t; \hat{\Gamma}_t^{(k)}} \{ \log p(\mathbf{y}_{e,t} | \mathbf{u}_t, \sigma^2) + \log p(\mathbf{u}_t; \Gamma_t) \} \end{aligned} \quad (26)$$

式(26)中第一项与超参数 γ_t 无关, 因此在后续最大化阶段 (M-Step) 中可以忽略。此外, 结合式(22)和式(23)可以进一步得到 \mathbf{u}_t 的后验概率分布为 $p(\mathbf{u}_t | \mathbf{y}_{e,t}; \gamma_t) \sim \mathcal{CN}(\boldsymbol{\mu}_t, \Sigma_t)$, 其中, 均值 $\boldsymbol{\mu}_t$ 和方差 Σ_t 分别为

$$\Sigma_t = \left((1-\rho^2) \Phi_t^H \mathbf{R}_w^{-1} \Phi_t + \Gamma_t^{-1} \right)^{-1} \quad (27)$$

$$\boldsymbol{\mu}_t = \sqrt{1-\rho^2} \Sigma_t \Phi_t^H \mathbf{R}_w^{-1} \mathbf{y}_{e,t} \quad (28)$$

其中, \mathbf{R}_w 表示噪声 \mathbf{w} 的协方差矩阵。基于此, 式(26)中的第二项可化简为

$$\begin{aligned} \mathbb{E}_{\mathbf{u}_t | \mathbf{y}_t; \hat{\Gamma}_t^{(k)}} \{ \log p(\mathbf{u}_t; \Gamma_t) \} &= \\ &\left\{ \sum_{i=1}^{M_g N_g} -\log(\pi \gamma_{i,t}) - \frac{\mathbb{E}_{\mathbf{u}_t | \mathbf{y}_t; \hat{\Gamma}_t^{(k)}} \{ |\mathbf{u}_{i,t}|^2 \}}{\gamma_{i,t}} \right\} \end{aligned} \quad (29)$$

在 M-step 中, 通过最大化 $\mathcal{L}(\Gamma | \hat{\Gamma}_t^{(k)})$ 得到超参

数 γ_t 的估计为

$$\begin{aligned} \hat{\gamma}_t^{(k)} &= \arg \max_{\gamma_t} \mathbb{E}_{\mathbf{u}_t | \mathbf{y}_t; \hat{\Gamma}_t^{(k)}} \{ \log p(\mathbf{y}_{e,t} | \mathbf{u}_t, \sigma^2) \} + \\ \log p(\mathbf{u}_t; \Gamma_t) &= \sum_{i=1}^{M_g N_g} -\log(\pi \gamma_{i,t}) - \frac{\mathbb{E}_{\mathbf{u}_t | \mathbf{y}_t; \hat{\Gamma}_t^{(k)}} \{ |\mathbf{u}_{i,t}|^2 \}}{\gamma_{i,t}} \end{aligned} \quad (30)$$

其中, 超参数向量 γ_t 的估计对每个元素 $\gamma_{i,t}$ 是解耦的, 因此对 $\hat{\gamma}_{i,t}^{(k+1)}$ 的估计可以化简为

$$\hat{\gamma}_{i,t}^{(k+1)} = \mathbb{E}_{\mathbf{u}_t | \mathbf{y}_t; \hat{\Gamma}_t^{(k)}} \{ |\mathbf{u}_{i,t}|^2 \} = \Sigma_{i,t}^{(k)} + |\boldsymbol{\mu}_{i,t}^{(k)}|^2 \quad (31)$$

其中, $\Sigma_{i,t}$ 和 $\boldsymbol{\mu}_{i,t}$ 分别为 Σ_t 和 $\boldsymbol{\mu}_t$ 对角线上的第 i 个元素。观察式(27)、式(28)和式(31)可以发现, γ_t 是 Σ_t 和 $\boldsymbol{\mu}_t$ 的函数, 同时 Σ_t 和 $\boldsymbol{\mu}_t$ 是 γ_t 的函数。因此, 执行迭代算法直到满足收敛标准, 即可得到 KR-HBKF 算法中超参数 γ_t 的估计值。

为得到信道预测误差向量 $\mathbf{y}_{e,t}$ 的似然分布, 式(23)

中假设上一时刻信道的估计值 $\hat{\mathbf{h}}_{b,t-1|t-1}$ 和信道真实值 $\mathbf{h}_{b,t-1}$ 近似相等。HBKF 算法在初始时刻假设信道估计值 $\mathbf{h}_{b,-1|1} = \mathbf{0}$ 进行初始化, 这一方案虽然实现简单, 但会导致式(23)产生较大的近似误差, 需要经过大量的传输块后才能收敛到较小 MSE。为此, 本文采用 BCS 算法来对 KR-HBKF 算法进行初始化。在初始时刻, 首先利用 BCS 算法得到 \mathbf{h}_b 的估计值 $\hat{\mathbf{h}}_{b,\text{bcs}}$ 和收敛后的超参数矩阵 Γ_{bcs} , 然后将 KR-HBKF 方案的参数初始化为

$$\mathbf{h}_{b,-1|1} = \hat{\mathbf{h}}_{b,\text{bcs}}, \Sigma_{-1|1} = \Gamma_{\text{bcs}}, \Gamma_t^{(0)} = \mathbf{I} \quad (32)$$

其中, $\Gamma_t^{(0)}$ 表示第 t 个传输块时的初始化超参数矩阵。基于 BCS 的初始化方案可以有效减小式(23)产生的近似误差, 因此经过少量的传输块就可实现收敛。所提 KR-HBKF 信道估计算法的完整流程如算法 1 所示。

算法 1 KR-HBKF 算法

输入 测量矢量 \mathbf{y} , 感知矩阵 Φ , 相关系数 ρ , 噪声协方差 \mathbf{R}_w , 停止阈值 ε 和最大迭代次数 k_{max}

输出 级联信道 $\hat{\mathbf{H}}_{c,t}$

- 1) 初始化参数 $\mathbf{h}_{b,-1|1} = \hat{\mathbf{h}}_{b,\text{bcs}}$, $\Sigma_{-1|1} = \Gamma_{\text{bcs}}, \Gamma_t^{(0)} = \mathbf{I}, t = 0$
for $t = 0, 1, \dots, T$ do
- 2) 预测估计 $\hat{\mathbf{h}}_{b,t|t-1} = \rho \hat{\mathbf{h}}_{b,t-1|t-1}$
- 3) 预测误差 $\mathbf{y}_{e,t} = \mathbf{y}_t - \rho \Phi_t \hat{\mathbf{h}}_{b,t-1|t-1}$

- 4) 超参数估计迭代次数 $k = 0$
while $\|\hat{\gamma}_t^{(k)} - \hat{\gamma}_t^{(k-1)}\| > \varepsilon$ and $k < k_{\max}$
- 5) $\hat{\gamma}_{i,t}^{(k+1)} = \mathbb{E}_{u_i|y; \hat{\Gamma}_t^{(k)}} \{ |u_{i,t}|^2 \} =$
 $\Sigma_{i,t}^{(k)} + |\mu_{i,t}^{(k)}|^2$
- 6) $\Sigma_t^{(k+1)} = \left((1 - \rho^2) \Phi_t^H R_w^{-1} \Phi_t + \right.$
 $\left. (\Gamma_t^{(k+1)})^{-1} \right)^{-1}$
- 7) $\mu_t^{(k+1)} = \sqrt{1 - \rho^2} \Sigma_t^{(k+1)} \Phi_t^H R_w^{-1} y_{e,t}$
- 8) 更新迭代次数 $k++$
end while
- 9) 更新超参数矩阵
 $\Gamma_t = \text{diag}([\gamma_{t,1}, \dots, \gamma_{t,i}, \dots, \gamma_{t,M_g N_g}])$
- 10) 更新预测 MSE
 $\Sigma_{t|t-1} = \rho^2 \Sigma_{t-1|t-1} + (1 - \rho^2) \Gamma_t$
- 11) 卡尔曼增益
 $K_t = \Sigma_{t|t-1} \Phi_t^T (\sigma^2 I + \Phi_t \Sigma_{t|t-1} \Phi_t^T)^{-1}$
- 12) 滤波更新
 $\hat{h}_{b,t|t} = \hat{h}_{b,t|t-1} + K_t (y_t - y_{t|t-1})$
- 13) 滤波后 MSE
 $\Sigma_{t|t} = (I - K_t \Phi_t) \Sigma_{t|t-1}$
- 14) 计算级联信道
 $\hat{H}_{c,t} = U_D \text{vec}^{-1}(\hat{h}_{b,t|t}) U_B^T$
- 15) 更新传输块 $t++$
end for

3 仿真与分析

3.1 仿真参数设置

本节通过仿真验证所提出的 KR-HBKF 信道估计算法在 RIS 辅助毫米波通信系统下的有效性。仿真数据设置 BS 侧和 RIS 侧天线数分别为 16 和 64，天线间距固定为 0.5λ ，RIS 的每个反射元件的相移从 $\left\{ -\frac{1}{\sqrt{N}}, \frac{1}{\sqrt{N}} \right\}$ 中随机选择^[16]。角度空间的量化网格点数分别为 $N_g = 128$ ， $M_g = 16$ ，且假设所有空间角度都位于网格点上。假设 BS-RIS 信道和 RIS-UE 信道路径数分别为 $L_G = 4$ 和 $L_h = 8$ ，且所有传播路径增益遵循复高斯分布 $\mathcal{CN}(0,1)$ 。假设该通信系统部署在 Q 波段，载波频率为 28 GHz，移动速度 $v = 5 \text{ km/h}$ ，导致的多普勒频移 $f_d = 130 \text{ Hz}$ 。相干时间设置为 $T_c = 5 \text{ ms}$ ，传输块长度设置为

$T_B = \frac{T_c}{10}$ ^[21]。则对于式(15)描述的时间选择性信道模型的相关系数 $\rho \approx 0.89$ 。仿真过程采用归一化均方误差 (NMSE, normalized mean square error) 作为信道估计算法的性能度量，计算式如下

$$\text{NMSE} = \frac{\mathbb{E}\{\|\mathbf{H}_c - \hat{\mathbf{H}}_c\|_2^2\}}{\mathbb{E}\{\|\mathbf{H}_c\|_2^2\}} \approx \frac{1}{J} \sum_{j=1}^J \frac{\|\mathbf{H}_{c,j} - \hat{\mathbf{H}}_{c,j}\|_2^2}{\|\mathbf{H}_{c,j}\|_2^2} \quad (33)$$

其中，期望近似于 J 次随机实现的平均值， J 表示蒙特卡罗仿真次数， $\hat{\mathbf{H}}_{c,j}$ 和 $\mathbf{H}_{c,j}$ 表示第 j 次仿真级联信道的估计结果和实际信道信息。若无特殊说明，本文仿真实验中取 $J=100$ 。

3.2 性能分析

本节将对 KR-HBKF 算法进行综合评估，并与经典 OMP 算法^[12]、单时间实例 BCS 信道估计算法^[20]以及基于 KF 的信道估计算法^[21]进行比较，其中 OMP 算法仿真时假设已知信道的稀疏度。实验首先对比了各算法在不同信噪比和导频开销下的估计性能，随后给出了 KR-HBKF 算法的跟踪性能的实验分析。

3.2.1 估计性能分析

在信噪比为 5 dB 情况下，不同传导频数量下 NMSE 对比如图 2 所示。由图 2 可知，随着导频开销的增加，所有算法的 NMSE 都在减小，意味着更大的导频开销能带来更好的信道估计效果。相较于 OMP 和 BCS 算法，KF 算法无法利用高级级联信道的稀疏性，因此需要更多的导频开销才能达到同样的性能。KR-HBKF 算法综合考虑了级联信道的稀疏性和时间相关性，因此性能最好。

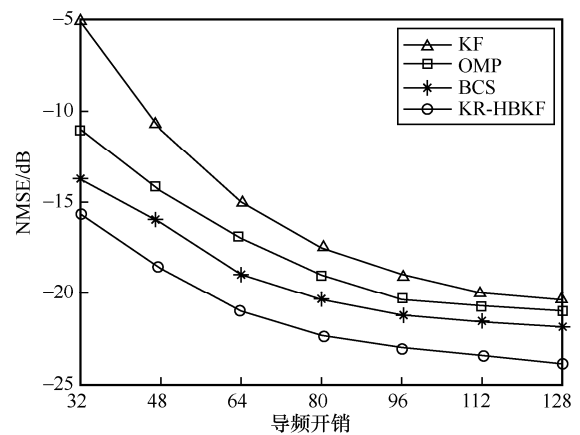


图 2 不同传导频数量下 NMSE 对比

图 3 展示了在导频开销 $Q = 48$ 情况下, 各信道估计方案 NMSE 与信噪比之间的关系。随着信噪比的增大, 噪声的影响逐步减弱, 所有算法的 NMSE 随之降低。KR-HBKF 算法的性能最佳, 在 5 dB 条件下可以达到与经典 OMP 算法在 10 dB 条件下相媲美的性能。结合图 2 和图 3 可以发现, 得益于其能同时捕获信道相关性和稀疏性的能力, KR-HBKF 算法在不同信道条件下的估计性能均优于其他算法, 因此更能适应实际通信系统中复杂多变的信道条件。




图 3 各信道估计方案 NMSE 与信噪比之间的关系

3.2.2 跟踪性能分析

在信噪比 SNR=5 dB、导频开销 $Q = 48$ 的条件下, 图 4 给出了各算法在信道时间相关系数 $\rho = 0.89$ 时, 不同传输块下的 NMSE。根据仿真结果可知, 相比于 BCS 和 OMP, KR-HBKF 算法有明显的性能提升。由于考虑了信道的稀疏特性, 收敛后的 KR-HBKF 算法比 KF 算法具有更优越的估计性能。得益于时间相关性参数 ρ 的引入, KR-HBKF 算法相较于 HBKF 算法有约 2 dB 的性能提升。从图 4 还可以看出, 通过对初始化方案进行改进, KR-HBKF 算法相比于 HBKF 具有更快的收敛速度。

为进一步分析 KR-HBKF 算法的鲁棒性, 基于前文的仿真参数设置, 图 5 进一步仿真了 $J=1$ 、 $v=10$ km/h、信道时间相关系数 $\rho \approx 0.75$ 时各算法的性能。对比图 4 可以看出, 相较于 $\rho \approx 0.89$ 信道条件, HBKF 算法由于无法正确拟合 RIS 信道变化的速度, 因此在 $\rho \approx 0.75$ 时估计性能下降严重。KR-HBKF 算法由于能够正确拟合 RIS 信道的相关性, 在不同信道变化场景下估计性能较稳定。此外,

仿真时在传输块 $t = 50$ 时设置 RIS-UE 信道 h_r 消失 2 条路径, 可以发现虽然 KR-HBKF 算法由于信道预测模型欠拟合估计性能暂时下降, 但是经过大约 10 个传输块的迭代检测到突变后, 估计性能再次趋于稳定。OMP 方案在已知信道稀疏度的情况下估计性能仍然不如 KR-HBKF 算法。




图 4 $\rho \approx 0.89$ 时不同传输块的 NMSE




图 5 $\rho \approx 0.75$ 时不同传输块下性能对比

3.3 复杂度分析

本文提出的 KR-HBKF 算法的计算量主要来自 KF 算法跟踪阶段和超参数 γ_i 的估计阶段。在 KF 算法跟踪阶段, 每次估计 5 个步骤产生的计算量分别为 $O(QMM_g N_g)$ 、 $O(M_g^2 N_g^2)$ 、 $O(M_g^2 N_g^2 QM)$ 、 $O(QMM_g N_g)$ 和 $O(M_g^2 N_g^2 QM)$ 。超参数 γ_i 的估计阶段的计算复杂度为 $O(M_g^3 N_g^3)$ [29]。在实际实现时, 字典矩阵的网格数 M_g 与 N_g 略大于天线维数 M 与 N , 所以本文 KR-HBKF 估计算法整体复杂度约为 $O(M_g^3 N_g^3)$ 。若没有式(12)的矩阵降维过程, 算法的

复杂度将变为 $O(M_g^3 N_g^6)$ ，导致在实际场景中难以实现。本文还比较了本文场景下不同算法进行信道估计的复杂度，如表 1 所示。

表 1 算法复杂度对比

算法	计算复杂度
OMP 算法	$O(QMM_g N_g)$
KF 算法	$O(QMM_g^2 N_g^2)$
BCS 算法	$O(M_g^3 N_g^3)$
KR-HBKF 算法	$O(M_g^3 N_g^3)$

4 结束语

本文针对信道稀疏表示、时变信道参数跟踪和信号重构等关键问题，为 RIS 辅助通信系统时变级联信道估计提出了 KR-HBKF 算法。由于综合利用信道的时间相关性和稀疏特性，本文提出的 KR-HBKF 算法相较于其他传统信道估计算法有较好的 NMSE 估计性能。KR-HBKF 算法采用了 BCS 算法进行初始化，相比于 KF 算法能够以更快的速度达到收敛，且估计误差更低。下一步工作将考虑：1) 为适应 RIS 辅助的多用户场景，对 KR-HBKF 算法分层结构的先验分布进行改进，以利用多用户共享相同 BS-RIS 信道这一结构特性，实现性能提升；2) 改进 KR-HBKF 算法中超参数 γ_n 的迭代估计过程和卡尔曼滤波增益 \mathbf{K}_k 的计算过程，以降低算法复杂度。

参考文献：


- [1] SHAMASUNDAR B, DARYANAVARDAN N, NOSRATINIA A. Channel training & estimation for reconfigurable intelligent surfaces: exposition of principles, approaches, and open problems[J]. IEEE Access, 2023, 11: 6717-6734.
- [2] SWINDLEHURST A L, ZHOU G, LIU R, et al. Channel estimation with reconfigurable intelligent surfaces—a general framework[J]. Proceedings of the IEEE, 2022, 110(9): 1312-1338.
- [3] ZHENG B X, YOU C S, MEI W D, 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] XUE Q, LIU Y J, SUN Y, et al. Beam management in ultra-dense mmWave network via federated reinforcement learning: an intelligent and secure approach[J]. IEEE Transactions on Cognitive Communications and Networking, 2023, 9(1): 185-197.
- [5] YANG Y F, ZHENG B X, ZHANG S W, et al. Intelligent reflecting surface meets OFDM: protocol design and rate maximization[J]. IEEE Transactions on Communications, 2020, 68(7): 4522-4535.
- [6] ZHENG B X, YOU C S, 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.
- [7] ZHENG B X, ZHANG R. Intelligent reflecting surface-enhanced OFDM: channel estimation and reflection optimization[J]. IEEE Wireless Communications Letters, 2020, 9(4): 518-522.
- [8] JENSEN T L, DE-CARVALHO E. An optimal channel estimation scheme for intelligent reflecting surfaces based on a minimum variance unbiased estimator[C]//Proceedings of 2020 IEEE International Conference on Acoustics, Speech and Signal Processing. Piscataway: IEEE Press, 2020: 5000-5004.
- [9] MA Y Y, BAI Z Q, HE B W, et al. Enhanced deep residual shrinkage network based channel estimation in RIS communication system[C]//Proceedings of the 2023 25th International Conference on Advanced Communication Technology (ICACT). Piscataway: IEEE Press, 2023: 18-22.
- [10] LIU S C, GAO Z, ZHANG J, et al. Deep denoising neural network assisted compressive channel estimation for mmWave intelligent reflecting surfaces[J]. IEEE Transactions on Vehicular Technology, 2020, 69(8): 9223-9228.
- [11] GAO S, DONG P H, PAN Z W, et al. Deep multi-stage CSI acquisition for reconfigurable intelligent surface aided MIMO systems[J]. IEEE Communications Letters, 2021, 25(6): 2024-2028.
- [12] ARDAH K, GHEREKHLOO S, DE ALMEIDA A L F, et al. TRICE: a channel estimation framework for RIS-aided millimeter-wave MIMO systems[J]. IEEE Signal Processing Letters, 2021, 28: 513-517.
- [13] JIA C L, CHENG J Q, GAO H, et al. High-resolution channel estimation for intelligent reflecting surface-assisted MmWave communications[C]//Proceedings of the 2020 IEEE 31st Annual International Symposium on Personal, Indoor and Mobile Radio Communications. Piscataway: IEEE Press, 2020: 1-6.
- [14] MA X Y, CHEN Z, CHEN W J, et al. Joint channel estimation and data rate maximization for intelligent reflecting surface assisted terahertz MIMO communication systems[J]. IEEE Access, 2020, 8: 99565-99581.
- [15] WANG P L, FANG J, DUAN H P, et al. Compressed channel estimation for intelligent reflecting surface-assisted millimeter wave systems[J]. IEEE Signal Processing Letters, 2019, 27: 905-909.
- [16] 曾嵘, 杭潇. 车联网环境下可重构智能反射面辅助无线信道估计算法[J]. 通信学报, 2022, 43(8): 142-150.
- [16] ZENG R, HANG X. Reconfigurable intelligent surface assist wireless channel estimation algorithm in Internet of vehicles environment[J]. Journal on Communications, 2022, 43(8): 142-150.
- [17] HE J G, LEINONEN M, WYMEERSCH H, et al. Channel estimation for RIS-aided mmWave MIMO systems[C]//Proceedings of the IEEE Global Communications Conference. Piscataway: IEEE Press, 2020: 1-6.
- [18] BORADE S, ZHENG L Z. Writing on fading paper, dirty tape with little ink: wideband limits for causal transmitter CSI[J]. IEEE Transac-

- tions on Information Theory, 2012, 58(8): 5388-5397.
- [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.
- [20] JIAN M N, ZHAO Y J. A modified off-grid SBL channel estimation and transmission strategy for RIS-assisted wireless communication systems[C]//Proceedings of the 2020 International Wireless Communications and Mobile Computing (IWCMC). Piscataway: IEEE Press, 2020: 1848-1853.
- [21] CAI P H, ZONG J, LUO X L, et al. Downlink channel tracking for intelligent reflecting surface-aided FDD MIMO systems[J]. IEEE Transactions on Vehicular Technology, 2021, 70(4): 3341-3353.
- [22] MAO Z D, PENG M G, LIU X Q. Channel estimation for reconfigurable intelligent surface assisted wireless communication systems in mobility scenarios[J]. China Communications, 2021, 18(3): 29-38.
- [23] VASWANI N. Kalman filtered Compressed Sensing[C]//Proceedings of the 2008 15th IEEE International Conference on Image Processing. Piscataway: IEEE Press, 2008: 893-896.
- [24] 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.
- [25] 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.
- [26] 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.
- [27] REBOREDO H, RENNA F, CALDERBANK R, et al. Bounds on the number of measurements for reliable compressive classification[J]. IEEE Transactions on Signal Processing, 2016, 64(22): 5778-5793.
- [28] JI S H, XUE Y, CARIN L. Bayesian compressive sensing[J]. IEEE Transactions on Signal Processing, 2008, 56(6): 2346-2356.
- [29] TIPPING M. The relevance vector machine[C]//Proceedings of the 12th International Conference on Neural Information Processing Systems. Massachusetts: MIT Press, 1999: 652-658.

[作者简介]



邵凯（1977-），男，重庆人，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。



鲁奔（1999-），男，河南南阳人，重庆邮电大学硕士生，主要研究方向为智能反射面、信道估计。



王光宇（1964-），男，贵州贵阳人，重庆邮电大学教授、硕士生导师，主要研究方向为数字信号处理、滤波器组理论等。