

## 基于流形学习的RIS辅助大规模MIMO系统的CSI反馈研究

钱慕君<sup>1,2</sup>, 虞舜驰<sup>1</sup>, 刘陈<sup>1,2</sup>, 宋云超<sup>1,2</sup>, 陆峰<sup>1,2</sup>

- (1. 南京邮电大学电子与光学工程学院、柔性电子(未来技术)学院, 江苏 南京 210023;  
2. 南京邮电大学射频集成与微组装技术国家地方联合工程实验室, 江苏 南京 210023)

**摘要:** 针对频分双工(FDD, frequency-division duplexing)模式下可重构智能反射面(RIS, reconfigurable intelligent surface)辅助的多用户大规模多输入多输出(MIMO, multiple-input multiple-output)系统信道反馈开销大的问题, 提出了一种基于流形学习的信道状态信息(CSI, channel state information)反馈框架。该框架首先通过简化CSI反馈过程实现初步的反馈开销降低, 然后结合流形学习思想训练两组字典, 从而实现增量CSI的降维和重构, 最后在基站端恢复原始信道。仿真结果表明, 在多用户和有限散射环境下, 所提的CSI反馈方案与现有的方法相比具有更低的开销和复杂度, 而且重构质量得到显著提高。

**关键词:** 大规模MIMO; 频分双工; 智能反射面; 信道反馈; 流形学习

**中图分类号:** TN929.5

**文献标志码:** A

**doi:** 10.11959/j.issn.2096-3750.2024.00374

## Research on CSI feedback of RIS-assisted massive MIMO system based on manifold learning

QIAN Mujun<sup>1,2</sup>, YU Shunchi<sup>1</sup>, LIU Chen<sup>1,2</sup>, SONG Yunchao<sup>1,2</sup>, LU Feng<sup>1,2</sup>

1. School of Electronic and Optical Engineering & School of Flexible Electronics (Future Technology), Nanjing University of Posts and Telecommunications, Nanjing 210023, China  
2. National and Local Joint Laboratory of RF Integration and Micro-Assembly Technology, Nanjing University of Posts and Telecommunications, Nanjing 210023, China

**Abstract:** To solve the problem of high feedback overhead in a multi-user massive multiple-input multiple-output (MIMO) system assisted by a reconfigurable intelligent surface (RIS) in frequency-division duplexing (FDD) mode, a channel state information (CSI) feedback framework based on manifold learning was proposed. Firstly, the framework achieved initial feedback overhead reduction by simplifying the CSI feedback process. Then, the framework combined the manifold learning to train two set of dictionaries to achieve dimension reduction and reconstruction of incremental CSI. Finally, the original channel was restored at the base station. The simulation results show that the CSI feedback scheme proposed in this paper has lower overhead and complexity than the existing methods in the multi-user and limited scattering environment, and the reconstruction quality is significantly improved.

**Key words:** massive MIMO, FDD, RIS, channel feedback, manifold learning

### 0 引言

大规模多输入多输出 (MIMO, multiple-input

multiple-output) 技术是第五代移动通信系统的关键技术之一<sup>[1]</sup>, 在基站 (BS, base station) 处部署大量天线可显著提高通信系统的性能<sup>[2-3]</sup>。随着科技的

收稿日期: 2023-07-26; 修回日期: 2024-08-19

通信作者: 钱慕君, qianmj@njupt.edu.cn

基金项目: 国家自然科学基金资助项目 (No. 62371249, No. 62101282, No. 61901232)

**Foundation Items:** The National Natural Science Foundation of China (No. 62371249, No. 62101282, No. 61901232)

进步,可重构智能反射面(RIS, reconfigurable intelligent surface)技术逐步成为未来6G通信的一种有前景的新技术<sup>[4]</sup>。此外,RIS辅助的大规模MIMO通信系统通过采用大量无源反射元件,以较低的成本提高了频谱效率(SE, spectrum efficiency)和能量效率(EE, energy efficiency)<sup>[5-6]</sup>。

大规模MIMO系统的性能增益依赖于基站可以获得精确的信道状态信息(CSI, channel state information)。在时分双工(TDD, time division duplex)系统中,由于上下行信道具有互易性,通过上行信道估计可以轻易地获得下行信道CSI。现有的RIS辅助通信系统的研究中,都是考虑了TDD模式。然而,TDD模式要求收发两端具有非常精确的时间同步,否则会产生严重的干扰,频分双工(FDD, frequency division duplexing)技术通过在上下行间设置保护频段实现了更强的抗干扰,是目前移动通信网络中广泛采用的双工模式。但在FDD模式下,上下行信道互易性不成立,BS要获得CSI需用户设备(UE, user equipment)反馈。

FDD模式下RIS辅助的大规模MIMO系统中,主要障碍是反馈开销随着BS天线数量和RIS反射单元数量的增加而增加。因此,相关研究致力于降低反馈开销,同时在BS端实现高精度的CSI重构。

目前,国内外学者针对FDD大规模MIMO系统降低CSI反馈开销并保持反馈性能的目标,进行了大量研究。文献[7]采用码本减少反馈开销,但决定反馈质量的码本大小随BS天线数的增加呈指数增长。因此,文献[8]结合信道矩阵在空间域的稀疏性<sup>[9-10]</sup>与压缩感知(CS, compressive sensing),提出了一种低开销的反馈机制,但由于计算复杂度高,优势并不明显。

随着RIS的普及,部分学者也开始针对RIS辅助的无线通信系统,研究如何降低CSI反馈开销并保证反馈精度。文献[11-12]提出了利用到达角(AoA, angle of arrival)和出发角(AoD, angle of departure)信息对BS-RIS-UE级联信道进行降维、重构的CSI反馈方案,虽然降低了反馈开销,但是反馈精度并不理想。在此基础上,文献[13]提出了使用CS对每个非零列向量进行压缩,采用聚类算法生成的码本来减少量化误差带来的速率损失,BS再通过正交匹配追踪算法恢复稀疏向量。这种方法对码本的精度要求很高,需要根据增量CSI不断建立新的时变

码本,并共享到BS,产生了较大的开销<sup>[14]</sup>。

近年来,深度学习(DL, deep learning)技术发展迅速,已有研究人员采用DL方法实现CSI反馈<sup>[15-19]</sup>。文献[20]提出了一种CsiNet神经网络,用编码器在UE上将信道矩阵转换为码字,并用解码器在BS上恢复信道矩阵,该方法性能上优于CSI方法,但重建质量仍需进一步优化。文献[21]介绍和比较了一些国内外将DL技术引入CSI反馈机制的方案,提出基于DL的CSI反馈设计具有低反馈开销、高恢复精度的优点。文献[22]提出一种基于DL的CSI反馈网络用来反馈CSI,使用卷积神经网络提取信道特征矢量,在最大池化层通过降维来达到压缩CSI的目的,然后解压、恢复原始信道。文献[23]在文献[22]的基础上,提出了一种展开迭代阈值收缩算法的可解释的模型驱动网络,具有更好的信道恢复性能,且在用户处具有更低的复杂度。然而,上述算法在高压压缩比下的重建质量是有限的。

为了解决上述问题,研究者将流形学习的思想应用于CSI反馈,试图在保持数据固有流形结构的同时,从高维空间恢复低维流形,从而降低高维数据的维数。文献[24-25]针对大规模MIMO系统,介绍了一种基于流形学习的CSI反馈框架,从而实现了反馈量的减少和性能的提高。本文进一步研究流形学习在RIS辅助的FDD大规模MIMO系统中CSI反馈的适用性,结合毫米波的稀疏特性与流形学习思想,在降低CSI反馈开销的同时保证BS端重构CSI的质量。

本文考虑FDD模式下RIS辅助的大规模MIMO系统,以CSI反馈作为研究对象,针对降低反馈开销并保证反馈精度的设计目标,提出了一种基于流形学习框架的降维CSI反馈方案。本文的主要贡献如下。

1) 考虑毫米波传播环境的稀疏特性,将下行增量CSI转换到混合域(角域-空间域)表示,从而将CSI的反馈分解为非零列索引和非零列信道向量的反馈,实现了反馈开销的初步降低。

2) 运用流形学习的思想,建立基于流形学习的反馈框架(MLF, manifold learning-based CSI feedback framework),训练了一对降维、重构字典组,对于增量CSI,一方面利用降维字典在用户端以保留局部流形结构的方式进行降维,另一方面利用重构字典在基站端进行低维到高维的数据重构,实现了反馈开销的进一步降低。

3) 通过交替迭代的方式对降维、重构字典组进行了优化, 得到两组最优字典, 实现了较高精度的CSI重构。

## 1 系统模型

本文考虑一个RIS辅助的多用户毫米波大规模MIMO系统, RIS辅助多用户MIMO系统模型如图1所示, 包含一个具有 $M$ 根天线的BS、一个具有 $N$ 个均匀平面阵列(UPA, uniform planar array)单元的RIS和 $K$ 个单天线UE。

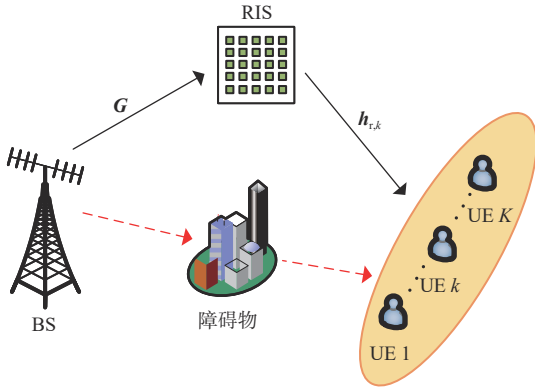


图1 RIS辅助多用户MIMO系统模型

由图1可知, 第 $k$ 个UE ( $k = 1, 2, \dots, K$ ) 接收的信号表示为<sup>[26]</sup>

$$y_k = \mathbf{h}_{r,k}^T \Phi \mathbf{G} \mathbf{x} + n_k \quad (1)$$

其中,  $y_k$  为第 $k$ 个UE的接收信号,  $\mathbf{h}_{r,k}^T$  为从RIS到第 $k$ 个UE的RIS-UE信道,  $\mathbf{x} \in \mathbf{C}^{M \times 1}$  是在BS处预编码的传输信号,  $\mathbf{G} \in \mathbf{C}^{N \times M}$  为从BS到RIS的BS-RIS信道矩阵,  $n_k \sim \text{CN}(0, \sigma_n^2)$  为第 $k$ 个UE处的加性高斯白噪声,  $\Phi = \text{diag}(\mathbf{v}) \in \mathbf{C}^{N \times N}$  为RIS反射元件相移值的对角矩阵, 并且  $\mathbf{v} = [\beta_1 e^{j\phi_1}, \beta_2 e^{j\phi_2}, \dots, \beta_N e^{j\phi_N}] \in \mathbf{C}^{N \times 1}$ ,  $\beta_n \in [0, 1]$  和  $\phi_n \in [0, 2\pi]$  分别表示第 $n$ 个反射元素的幅值和相位系数。考虑到反射增益和硬件复杂度, 现有的RIS研究中广泛假设  $\beta_n = 1$ <sup>[5]</sup>。

由于 $\Phi$ 是对角矩阵, 因此  $\mathbf{h}_{r,k}^T \Phi \mathbf{G} = \mathbf{v}^T \text{diag}(\mathbf{h}_{r,k}^T) \mathbf{G}$ , 第 $k$ 个UE的等效下行信道  $\mathbf{h}_{DL,k}^T \in \mathbf{C}^{1 \times M}$  可表示为

$$\mathbf{h}_{DL,k}^T = \mathbf{v}^T \text{diag}(\mathbf{h}_{r,k}^T) \mathbf{G} \quad (2)$$

于是空间域中第 $k$ 个UE的BS-RIS-UE级联信道可表示为

$$\mathbf{H}_k = \text{diag}(\mathbf{h}_{r,k}^T) \mathbf{G} \quad (3)$$

其中,  $\mathbf{H}_k \in \mathbf{C}^{N \times M}$  仅依赖于下行CSI。若直接反馈  $\mathbf{H}_k$ , 则用户需反馈  $M \times N$  个信道衰落系数。在大规

模MIMO系统中,  $M$  通常较大, 若反射单元数  $N$  也较大, 则反馈开销巨大。

本文采用Saleh Valenzuela几何信道模型对毫米波信道进行建模<sup>[27]</sup>。在该模型下, BS-RIS信道  $\mathbf{G}$  可表示为

$$\mathbf{G} = \sqrt{\frac{MN}{L_1}} \sum_i^{L_1} g_i^{(1)} \mathbf{b}_i(\phi_{r,i}^{(1)}, \theta_{r,i}^{(1)}) \mathbf{a}_i^T(\phi_{r,i}^{(1)}) \quad (4)$$

其中,  $\sqrt{MN/L_1}$  是归一化因子,  $L_1$  为BS和RIS之间的路径数,  $g_i^{(1)} \sim \text{CN}(0, 1)$  是第 $i$ 条路径的复增益,  $\mathbf{b}_i(\phi_{r,i}^{(1)}, \theta_{r,i}^{(1)}) \in \mathbf{C}^{N \times 1}$ ,  $\mathbf{a}_i^T(\phi_{r,i}^{(1)}) \in \mathbf{C}^{M \times 1}$  分别表示与RIS和BS相关的阵列响应向量。  $\phi_{r,i}^{(1)}$ 、 $\theta_{r,i}^{(1)}$ 、 $\phi_{t,i}^{(1)}$  分别为方位角AoA、俯仰角AoA和方位角AoD。阵列响应向量具有如下形式<sup>[28]</sup>

$$\mathbf{b}(\phi, \theta) = \frac{1}{\sqrt{N}} \left[ 1, \dots, e^{j\frac{2\pi}{\lambda} d_r (n_1 \cos(\theta) \sin(\phi) + n_2 \sin(\theta))}, \dots, e^{j\frac{2\pi}{\lambda} d_r ((N_1 - 1) \cos(\theta) \sin(\phi) + (N_2 - 1) \sin(\theta))} \right]^T \quad (5)$$

$$\mathbf{a}(\phi) = \frac{1}{\sqrt{M}} \left[ 1, \dots, e^{j\frac{2\pi}{\lambda} d_a (m \sin(\phi))}, \dots, e^{j\frac{2\pi}{\lambda} d_a ((M-1) \sin(\phi))} \right]^T \quad (6)$$

其中,  $d_r$ 、 $d_a$  分别为RIS元件与BS天线的间距,  $\lambda$  为信号波长,  $n_1$ 、 $n_2$  ( $0 \leq n_1 < N_1$ ,  $0 \leq n_2 < N_2$ ) 分别表示RIS元件的水平索引和垂直索引,  $N = N_1 \times N_2$ , BS天线的索引为  $m$  ( $0 \leq m < M$ )。

式(3)中RIS与第 $k$ 个UE之间的信道向量  $\mathbf{h}_{r,k}^T$  可表示为

$$\mathbf{h}_{r,k}^T = \sqrt{\frac{M}{L_2}} \sum_j^{L_2} g_j^{(2)} \mathbf{b}_j^H(\phi_{t,r,j}^{(2)}, \theta_{t,r,j}^{(2)}) \quad (7)$$

其中,  $L_2$  为RIS与第 $k$ 个UE之间的主要路径数,  $\sqrt{M/L_2}$  为归一化因子,  $g_j^{(2)} \sim \text{CN}(0, 1)$  为第 $j$ 个路径的复增益,  $\theta_{t,k,j}^{(2)}$ 、 $\phi_{t,k,j}^{(2)}$  分别为方位角和俯仰角AoD。  $\mathbf{b}_i^H(\phi_{t,k,j}^{(2)}, \theta_{t,k,j}^{(2)})$  处的阵列响应向量可以用式(5)表示。

根据式(3)、式(4)和式(7), 第 $k$ 个UE的级联信道矩阵  $\mathbf{H}_k$  可表示为

$$\mathbf{H}_k = \sqrt{\frac{M^2 N}{L_1 L_2}} \sum_i^{L_1} \sum_j^{L_2} \left\{ g_i^{(1)} g_j^{(2)} \text{diag}(\mathbf{b}_i^H(\phi_{t,k,j}^{(2)}, \theta_{t,k,j}^{(2)})) \times \mathbf{b}_i(\phi_{r,i}^{(1)}, \theta_{r,i}^{(1)}) \mathbf{a}_i^T(\phi_{r,i}^{(1)}) \right\} \quad (8)$$

将  $\sqrt{M^2 N / (L_1 L_2)}$  记为  $q$ , 并令  $g_{i,k,j} = g_i^{(1)} g_j^{(2)}$ , 则式(8)可简化为

$$\mathbf{H}_k = q \sum_i^{L_1} \sum_j^{L_2} \left\{ g_{i,k,j} \text{diag} \left( \mathbf{b}_i^H(\phi_{i,k,j}^{(2)}, \theta_{i,k,j}^{(2)}) \right) \times \mathbf{b}_i(\phi_{i,d}^{(1)}, \theta_{i,d}^{(1)}) \mathbf{a}_i^T(\phi_{i,d}^{(1)}) \right\} \quad (9)$$

下一节将阐述所提的基于流形学习框架的CSI降维和重构方法。

## 2 基于流形学习的反馈框架

本节首先利用BS-RIS-UE级联信道的稀疏性，将下行链路CSI分解为两部分，即所有用户共享的非零列索引和非零列向量，并在此基础上提出一种基于流形学习的信道反馈方案，从而降低信道反馈开销和计算复杂度，提高反馈精度。

### 2.1 BS-RIS-UE级联信道的结构稀疏性

本文假设通过下行信道估计可以获得每个UE的完美下行CSI。由于在RIS辅助的无线通信系统中，BS和RIS通常被有限的散射体包围，所以BS-RIS-UE级联信道在角域具有稀疏性<sup>[29]</sup>。利用毫米波传播环境中角域有限的信道特性，将级联信道矩阵 $\mathbf{H}_k$ 转换为混合域（角域—空间域）级联信道矩阵 $\mathbf{H}_k^{\text{ang}} \in \mathbf{C}^{N \times G}$ ，该转换可表示为<sup>[12]</sup>

$$\mathbf{H}_k^{\text{ang}} = \mathbf{H}_k \boldsymbol{\Theta}_M \quad (10)$$

其中， $\boldsymbol{\Theta}_M \in \mathbf{C}^{M \times G}$ 是在BS处AoD的角分辨率 $G$ 的字典矩阵。利用字典矩阵，将BS处的AoD量化为 $G$ 网格，字典矩阵表示为

$$\boldsymbol{\Theta}_M = \left[ \mathbf{a}_1(\phi_1), \dots, \mathbf{a}_1(\phi_p), \dots, \mathbf{a}_1(\phi_G) \right] \quad (11)$$

其中， $\phi_p$ 表示量化AoD的角度。第 $p$ 个网格的离散角度值，也就是字典矩阵 $\boldsymbol{\Theta}_M$ 的第 $p$ 列中的阵列响应向量的角度，可以表示为 $\phi_p = -\pi/2 + \pi(p-1)/G$ 。因此 $\boldsymbol{\Theta}_M$ 的每一列可根据式(6)生成。

已知 $\mathbf{G}$ 是多个UE共享的从BS到RIS的信道矩阵，通过角域变换得到的 $\mathbf{H}_k^{\text{ang}}$ 具有少量有优势信道增益的非零列<sup>[13]</sup>，且非零列数就是路径数 $L_1$ ， $\mathbf{H}_k^{\text{ang}}$ 中的第 $l$ 个非零列可表示为

$$\mathbf{h}_{k,l} = \mathbf{H}_{k,(:,p_l)} = \sum_{j=1}^{L_2} g_{i,k,j} \text{diag} \left( \mathbf{b}_i^H(\phi_{i,j,k}^{(2)}, \theta_{i,j,k}^{(2)}) \right) \mathbf{b}_i(\phi_{i,d}^{(1)}, \theta_{i,d}^{(1)}) \quad (12)$$

其中， $\mathbf{h}_{k,l} \in \mathbf{C}^{N \times 1}$ ， $l = 1, 2, \dots, L_1$ ， $p_l$ 为 $\mathbf{H}_k^{\text{ang}}$ 中非零列的索引。

至此，本文将下行增量CSI反馈的问题转化为混合域中的非零列索引和非零列的反馈问题。由于每个用户的非零列索引在一个较长的角度相干时间

内是不变的，所以其反馈开销可以忽略不计，只需对 $\mathbf{h}_{k,l}$ 进行反馈处理。

### 2.2 基于流形学习的反馈与重构

本节提出MLF方案：先从下行导频中获得训练数据集；BS端利用样本集构建降维、重构字典组，每个字典组都包含一个高维字典和一个低维字典，且BS端保留重构字典组，将降维字典组共享给UE；UE使用降维字典组来降维增量 $\mathbf{h}_{k,l}$ 并将其反馈给BS，BS通过重构字典组进行重构。

首先，使用经典的流形学习算法局部切空间排列(LTSA, local tangent space alignment)训练数据集<sup>[30]</sup>。LTSA是基于“局部拟合和全局排列”框架的局部保持嵌入方法，通过逼近每一个样本点邻域的切空间表示低维流形的局部几何特性，排列所有的局部切空间来构建全局唯一的低维坐标系<sup>[31]</sup>。

将原始信道矩阵采样所在的高维空间命名为“输入空间”，将原始信道矩阵嵌入所在的低维空间命名为“特征空间”。

从下行导频中获得 $\mathbf{h}_{k,l}$ 的 $S$ 个样本，将这 $S$ 个样本作为高维训练数据，样本具体为

$$\mathbf{X} = [\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_i, \dots, \mathbf{x}_S] \in \mathbf{C}^{N \times S} \quad (13)$$

其中， $\mathbf{x}_i$ 为对 $\mathbf{h}_{k,l}$ 的第 $i$ 次采样。换言之，从 $N$ 维输入空间采样的信道矩阵包含一个数据集 $\mathbf{X}$ ，它表征了输入空间的流形结构。然后，利用LTSA计算 $\mathbf{X}$ 的低维嵌入

$$\mathbf{Y} = f_{\text{LTSA}}(\mathbf{X}) \quad (14)$$

其中， $\mathbf{Y} = [\mathbf{y}_1, \mathbf{y}_2, \dots, \mathbf{y}_S] \in \mathbf{R}^{d \times S}$ 是由 $d$ 维特征空间中的样本组成的， $\mathbf{y}_i$ 是 $\mathbf{x}_i$ 的嵌入，维数 $d$ 远小于 $N$ ，压缩比定义为

$$\gamma = \frac{d}{N} \quad (15)$$

对多个UE进行随机采样形成一个无组织数据集的方法简单直观，但会带来冗余且样本集不具有代表性。所以，本文尝试从训练数据集 $\mathbf{X}$ 中训练出更具代表性的高维字典，该字典不仅尺寸更小，而且可以很好地近似数据集 $\mathbf{X}$ 的流形。同样，从 $\mathbf{Y}$ 中训练低维字典来表征特征空间的流形。

#### 1) 降维字典组

从上文可知降维可以描述为从输入空间到特征空间的映射问题，即寻找数据集 $\mathbf{X}$ 到 $\mathbf{Y}$ 的映射关系 $f: \mathbf{y}_i = f(\mathbf{x}_i)$ 。

本文引入字典而不是无组织的数据集来描述高

非零列向量的采样或低维嵌入所在的流形结构。设  $\mathbf{D}_H^{\text{rd}} = [\mathbf{d}_1, \mathbf{d}_2, \dots, \mathbf{d}_{\text{DM}}] \in \mathbf{R}^{N \times \text{DM}}$  是表征输入空间流形结构的高维字典，其中，DM ( $\text{DM} \ll S$ ) 是字典的大小， $\mathbf{d}_i$  是  $\mathbf{D}_H^{\text{rd}}$  的第  $i$  列。为了保留局部流形结构， $\mathbf{x}_i$  需满足在字典  $\mathbf{D}_H^{\text{rd}}$  的所有列都能被它的最近邻居线性逼近，因此  $\mathbf{x}_i$  近似为

$$\mathbf{x}_i \approx \sum_{j=1}^{\text{DM}} c_{ji}^{\text{rd}} \mathbf{d}_j \quad (16)$$

其中， $c_{ji}^{\text{rd}}$  需满足  $\sum_{j=1}^{\text{DM}} c_{ji}^{\text{rd}} = 1, i = 1, \dots, S$ 。设  $\chi(\mathbf{x}_i)$  是  $\mathbf{x}_i$  在  $\mathbf{D}_H^{\text{rd}}$  中  $K_n$  个最近邻居的集合，若  $\mathbf{d}_j \notin \chi(\mathbf{x}_i)$ ，则  $c_{ji}^{\text{rd}} = 0$ 。本节将字典  $\mathbf{D}_H^{\text{rd}}$  上  $\mathbf{x}_i$  的编码向量表示为  $\mathbf{c}_i^{\text{rd}} = [c_{1i}^{\text{rd}}, c_{2i}^{\text{rd}}, \dots, c_{\text{DM}i}^{\text{rd}}]^T \in \mathbf{R}^{\text{DM} \times 1}$ ， $\mathbf{X}$  的编码矩阵定义为  $\mathbf{C}_{\text{rd}} = [c_1^{\text{rd}}, c_2^{\text{rd}}, \dots, c_S^{\text{rd}}] \in \mathbf{R}^{\text{DM} \times S}$ 。

同时，在特征空间中的  $\mathbf{y}_i$  与低维字典  $\mathbf{D}_L^{\text{rd}} = [f(\mathbf{d}_1), f(\mathbf{d}_2), \dots, f(\mathbf{d}_{\text{DM}})] \in \mathbf{R}^{d \times \text{DM}}$  之间的线性近似成立，即

$$\mathbf{y}_i \approx \sum_{j=1}^{\text{DM}} c_{ji}^{\text{rd}} f(\mathbf{d}_j) \quad (17)$$

其中， $c_{ji}^{\text{rd}}$  和  $K_n$  个最近邻的集合与式(16)中的相同。

为了保持输入空间和特征空间的邻居关系和编码关系不变，将编码向量  $\mathbf{c}_i^{\text{rd}}$  和字典  $\mathbf{D}_H^{\text{rd}}$  的代价函数最小化问题描述为

$$\min_{c_i^{\text{rd}}, \mathbf{D}_H^{\text{rd}}} \left\| \mathbf{x}_i - \sum_{j=1}^{\text{DM}} c_{ji}^{\text{rd}} \mathbf{d}_j \right\|^2 + \lambda \left\| f(\mathbf{x}_i) - \sum_{j=1}^{\text{DM}} c_{ji}^{\text{rd}} f(\mathbf{d}_j) \right\|^2 \quad (18a)$$

$$\text{s.t.} \quad \sum_{j=1}^{\text{DM}} c_{ji}^{\text{rd}} = 1, i = 1, 2, \dots, S \quad (18a)$$

$$c_{ji}^{\text{rd}} = 0, \mathbf{d}_j \notin \chi(\mathbf{x}_i) \quad (18b)$$

其中， $\lambda$  是一个常数，用于调整代价函数中最后一项的比例<sup>[25]</sup>。本文采用交替优化法求解上述优化问题，首先固定字典  $\mathbf{D}_H^{\text{rd}}$ ，利用拉格朗日乘子法计算最优  $\mathbf{c}_i^{\text{rd}}$ ，再保持  $\mathbf{c}_i^{\text{rd}}$  不变来求解字典  $\mathbf{D}_H^{\text{rd}}$ ，重复此过程，直到代价函数收敛<sup>[24-25]</sup>，具体求解过程如下。

首先，假设  $\mathbf{D}_H^{\text{rd}}$  在上一次迭代中被初始化或更新，即此刻  $\mathbf{D}_H^{\text{rd}}$  固定。利用欧氏距离度量  $\mathbf{x}_i$  和  $\mathbf{d}_j$  之间的相似度为

$$\rho_{ij} = \left\| \mathbf{x}_i - \mathbf{d}_j \right\|_2^2, j = 1, 2, \dots, \text{DM} \quad (19)$$

选取  $\mathbf{x}_i$  的  $K_n$  个最近邻，即从  $\{\mathbf{d}_1, \mathbf{d}_2, \dots, \mathbf{d}_{\text{DM}}\}$  中选取  $K_n$  个与  $\mathbf{x}_i$  的相似度最高的元素，对应元素的索引形成一个索引向量  $\mathbf{A} = [a_1, a_2, \dots, a_{K_n}] \in \mathbf{R}^{1 \times K_n}$ 。所有近邻列组成矩阵  $\mathbf{N}(\mathbf{x}_i) = [\mathbf{d}_{a_1}, \mathbf{d}_{a_2}, \dots, \mathbf{d}_{a_{K_n}}] \in \mathbf{R}^{N \times K_n}$ 。

实际上，编码向量  $\mathbf{c}_i^{\text{rd}}$  只包含  $K_n$  个非零项，可以将非零项组成的向量记为  $\hat{\mathbf{c}}_i^{\text{rd}} = [\hat{c}_{1i}^{\text{rd}}, \hat{c}_{2i}^{\text{rd}}, \dots, \hat{c}_{K_n i}^{\text{rd}}]^T \in \mathbf{R}^{K_n \times 1}$ ，其中， $\hat{c}_{ji}^{\text{rd}} = c_{(a_j)i}^{\text{rd}}, j = 1, 2, \dots, K_n$ 。在式(18)中，用  $\hat{\mathbf{c}}_i^{\text{rd}}$  替换  $\mathbf{c}_i^{\text{rd}}$ ，固定  $\mathbf{D}_H^{\text{rd}}$ ，引入拉格朗日乘子法，对式(18)中的问题求解，得编码向量为

$$\hat{\mathbf{c}}_i^{\text{rd}} = \frac{(\mathbf{R}_{\text{rd}} + \lambda \varphi(\mathbf{R}_{\text{rd}}))^{-1} \mathbf{e}}{\mathbf{e}^T (\mathbf{R}_{\text{rd}} + \lambda \varphi(\mathbf{R}_{\text{rd}}))^{-1} \mathbf{e}} \quad (20)$$

其中，约束条件为  $\mathbf{e}^T \hat{\mathbf{c}}_i^{\text{rd}} = 1$ ，且  $\mathbf{R}_{\text{rd}} = (\mathbf{N}(\mathbf{x}_i) - \mathbf{x}_i \mathbf{e}^T)^T (\mathbf{N}(\mathbf{x}_i) - \mathbf{x}_i \mathbf{e}^T) \in \mathbf{R}^{K_n \times K_n}$ ， $\varphi(\mathbf{R}_{\text{rd}}) = \text{diag}(r_{11}, r_{22}, \dots, r_{K_n K_n})$ ， $r_{mm}$  为  $\mathbf{R}_{\text{rd}}$  中的对角元素。重复式(20)  $S$  次，使用  $\hat{\mathbf{c}}_i^{\text{rd}} = \mathbf{c}_{(a_j)i}^{\text{rd}}$  更新编码矩阵  $\mathbf{C}_{\text{rd}}$  的第  $i$  列，其余元素为零。

然后，通过固定编码矩阵  $\mathbf{C}_{\text{rd}}$ ，利用式(18)对  $\mathbf{d}_j$  的一阶导数为0时存在的一个极值，获得高维字典  $\mathbf{D}_H^{\text{rd}}$  第  $j$  列的解为

$$\mathbf{d}_j = \frac{(\mathbf{X} - \sum_{m \neq j} \mathbf{d}_m \mathbf{C}_m) \mathbf{C}_j^T + \lambda \mathbf{X} (\tilde{\mathbf{C}}_j)^T}{(1 + \lambda) \mathbf{C}_j \mathbf{C}_j^T} \quad (21)$$

其中， $\mathbf{C}_j \in \mathbf{R}^{1 \times S}$  为  $\mathbf{C}_{\text{rd}}$  的第  $j$  行， $\tilde{\mathbf{C}}_j$  表示  $\mathbf{C}_j$  中每个元素的平方构成的矩阵。重复计算式(21) DM 次，更新整个字典  $\mathbf{D}_H^{\text{rd}}$ 。

通过交替优化编码矩阵  $\mathbf{C}_{\text{rd}}$  和字典  $\mathbf{D}_H^{\text{rd}}$ ，使代价函数逐渐趋于收敛，获得最优编码矩阵  $\mathbf{C}_{\text{rd}}$ ，之后，可通过最小化如下代价函数

$$\| \mathbf{Y} - \mathbf{D}_L^{\text{rd}} \mathbf{C}_{\text{rd}} \|_F^2 = \sum_{i=1}^S \left\| f(\mathbf{x}_i) - \sum_{j=1}^{\text{DM}} c_{ji}^{\text{rd}} f(\mathbf{d}_j) \right\|^2 \quad (22)$$

得到低维字典  $\mathbf{D}_L^{\text{rd}}$ ，式(22)的最小二乘解为

$$\mathbf{D}_L^{\text{rd}} = \mathbf{Y} \mathbf{C}_{\text{rd}}^T (\mathbf{C}_{\text{rd}} \mathbf{C}_{\text{rd}}^T)^{-1} \quad (23)$$

此时 BS 已知用于降维的高维字典  $\mathbf{D}_H^{\text{rd}}$  和低维字典  $\mathbf{D}_L^{\text{rd}}$ ，共享给 UE 端，用于计算增量的嵌入。

## 2) 重构字典组

与上一小节相反，从低维嵌入中重构增量是一个降维的逆问题，其映射关系为  $f^{-1}: \mathbf{x}_i = f^{-1}(\mathbf{y}_i)$ 。

同样，特征空间中的低维字典设置为  $\mathbf{D}_L^{\text{rc}} = [\mathbf{b}_1, \mathbf{b}_2, \dots, \mathbf{b}_{\text{DM}}] \in \mathbf{R}^{d \times \text{DM}}$ ，输入空间中对应的高维字典为  $\mathbf{D}_H^{\text{rc}} = [f^{-1}(\mathbf{b}_1), f^{-1}(\mathbf{b}_2), \dots, f^{-1}(\mathbf{b}_{\text{DM}})] \in \mathbf{R}^{N \times \text{DM}}$ 。将字典  $\mathbf{D}_H^{\text{rc}}$  上  $\mathbf{y}_i$  的编码向量表示为  $\mathbf{c}_i^{\text{rc}} = [c_{1i}^{\text{rc}}, c_{2i}^{\text{rc}}, \dots, c_{\text{DM}i}^{\text{rc}}]^T \in \mathbf{R}^{\text{DM} \times 1}$ ， $\mathbf{Y}$  的编码矩阵定义为  $\mathbf{C}_{\text{rd}} = [c_1^{\text{rc}}, c_2^{\text{rc}}, \dots, c_S^{\text{rc}}] \in \mathbf{R}^{\text{DM} \times S}$ 。为保持邻居关系和编码关系，对如下目标函数进行最小化

$$\min_{\mathbf{c}_i^{\text{rc}}, \mathbf{D}_L^{\text{rc}}} \left\| \mathbf{y}_i - \sum_{j=1}^{\text{DM}} \mathbf{c}_{ji}^{\text{rc}} \mathbf{b}_j \right\|^2 + \lambda \left\| f^{-1}(\mathbf{y}_i) - \sum_{j=1}^{\text{DM}} \mathbf{c}_{ji}^{\text{rc}} f^{-1}(\mathbf{b}_j) \right\|^2 \quad (24)$$

获取最优字典  $\mathbf{D}_L^{\text{rc}}$  和最优编码向量  $\mathbf{c}_i^{\text{rc}}$ 。

与获得降维字典组的过程类似, 首先通过交替优化得到低维字典  $\mathbf{D}_L^{\text{rc}}$  和编码矩阵  $\mathbf{C}_{\text{rc}}$ , 再通过最小二乘法, 得到高维字典解为

$$\mathbf{D}_H^{\text{rc}} = \mathbf{X} \mathbf{C}_{\text{rc}}^{\text{T}} (\mathbf{C}_{\text{rc}} \mathbf{C}_{\text{rc}}^{\text{T}})^{-1} \quad (25)$$

至此, 重构字典组  $\mathbf{D}_H^{\text{rc}}$  和  $\mathbf{D}_L^{\text{rc}}$  已知, 预存于 BS 端用于重建高维增量。基于流形学习的降维字典和重构字典的生成如算法1所示。

**算法1** 基于流形学习的降维字典和重构字典的生成

**输入:** 高维数据集  $\mathbf{X}$ , 字典 DM 的大小,  $\lambda$

**输出:** 降维字典组 ( $\mathbf{D}_H^{\text{rd}}, \mathbf{D}_L^{\text{rd}}$ ), 重构字典组 ( $\mathbf{D}_H^{\text{rc}}, \mathbf{D}_L^{\text{rc}}$ )

**第一步:** 求解降维字典组 ( $\mathbf{D}_H^{\text{rd}}, \mathbf{D}_L^{\text{rd}}$ )

通过从  $\mathbf{X}$  中随机选择 DM 列样本初始化  $\mathbf{D}_H^{\text{rd}}$

利用式(16)和式(17)中流形学习的性质, 建立目标函数式(18)

利用交替优化, 使代价函数式(18)收敛

由式(20)计算  $\mathbf{C}_{\text{rd}}$  的第  $i$  列, 由式(21)计算  $\mathbf{D}_H^{\text{rd}}$  的第  $j$  列

由式(14)计算数据集  $\mathbf{X}$  的低维嵌入  $\mathbf{Y}$

由式(23)计算低维字典  $\mathbf{D}_L^{\text{rd}}$

**第二步:** 求解重构字典组 ( $\mathbf{D}_H^{\text{rc}}, \mathbf{D}_L^{\text{rc}}$ )

通过从  $\mathbf{Y}$  中随机选择 DM 列样本初始化  $\mathbf{D}_L^{\text{rc}}$

利用流形学习的性质, 建立目标函数式(24)

利用交替优化, 使代价函数式(24)收敛, 获得  $\mathbf{D}_L^{\text{rc}}$  和  $\mathbf{C}_{\text{rc}}$

由式(25)计算高维字典  $\mathbf{D}_H^{\text{rc}}$

### 2.3 增量非零列向量的降维和重构

前文中, 已获得两组字典。以单用户为例, 用  $\mathbf{H}_{\text{new}}$  表示该用户的增量信道矩阵, 利用式(10)获得角域级联信道矩阵  $\mathbf{H}_{\text{new}}^{\text{ang}}$ , 得非零列向量构成的矩阵  $\mathbf{H}'$  为

$$\mathbf{H}' = [\mathbf{h}'_1, \mathbf{h}'_2, \dots, \mathbf{h}'_{L_1}] \in \mathbf{R}^{N \times L_1} \quad (26)$$

其中,  $\mathbf{h}'_i$  ( $i = 1, 2, \dots, L_1$ ) 是  $\mathbf{H}_{\text{new}}^{\text{ang}}$  中的非零列。

本节的任务是在 BS 端重构下行链路增量 CSI, 并尽量减少来自 UE 端的反馈。UE 采用预存的降维字典组, 即  $\mathbf{D}_H^{\text{rd}}$  和  $\mathbf{D}_L^{\text{rd}}$ , 来计算  $\mathbf{h}'_i$  的低维嵌入。设  $\mathbf{h}'_i$  在字典  $\mathbf{D}_H^{\text{rd}}$  上的编码向量为  $\mathbf{c}_i^{(1)} = [c_{1i}^{(1)}, c_{2i}^{(1)}, \dots, c_{\text{DM}i}^{(1)}]^{\text{T}} \in \mathbf{R}^{\text{DM} \times 1}$ ,  $\mathbf{H}'$  的编码矩阵定义为  $\mathbf{C}'_{\text{rd}} = [\mathbf{c}_1^{(1)}, \mathbf{c}_2^{(1)}, \dots, \mathbf{c}_{L_1}^{(1)}] \in \mathbf{R}^{\text{DM} \times L_1}$ 。为了保证  $\mathbf{H}'$  的输入空间与特征空间具有相

同编码和邻居关系, 通过解决以下优化问题来实现降维

$$\min_{\mathbf{c}_i^{(1)}} \left\| \mathbf{h}'_i - \sum_{j=1}^{\text{DM}} \mathbf{c}_{ji}^{(1)} \mathbf{d}_j \right\|^2 + \lambda \left\| f(\mathbf{h}'_i) - \sum_{j=1}^{\text{DM}} \mathbf{c}_{ji}^{(1)} f(\mathbf{d}_j) \right\|^2 \quad (27)$$

$$\text{s.t.} \sum_{j=1}^{\text{DM}} \mathbf{c}_{ji}^{(1)} = 1, i = 1, 2, \dots, L_1 \quad (27a)$$

$$\mathbf{c}_{ji}^{(1)} = 0, \mathbf{d}_j \notin \chi(\mathbf{x}_i) \quad (27b)$$

其中,  $\lambda$  是一个常数, 用于调整代价函数中最后一项的比例<sup>[25]</sup>。上述优化问题与最小化问题式(18)类似, 不同之处在于此时高维字典  $\mathbf{D}_H^{\text{rd}}$  已知, 无须再进行两变量的交替优化。通过已知的字典  $\mathbf{D}_H^{\text{rd}}$ , 直接利用式(20)求解  $\mathbf{C}'_{\text{rd}}$  的第  $i$  列  $\mathbf{c}_i^{(1)}$ 。

得到编码矩阵  $\mathbf{C}'_{\text{rd}}$  后, 利用式(17)的矩阵形式进一步计算  $\mathbf{H}'$  的低维嵌入为

$$\mathbf{Y}' = \mathbf{D}_L^{\text{rd}} \mathbf{C}'_{\text{rd}} \quad (28)$$

然后由 UE 反馈给 BS。

一旦 BS 接收到低维嵌入, 即可重构高维  $\mathbf{H}'$ 。先利用预先存储的重构字典  $\mathbf{D}_H^{\text{rc}}$  和  $\mathbf{D}_L^{\text{rc}}$ , 求解以下最小化目标函数得到编码向量

$$\min_{\mathbf{c}_i^{(2)}} \left\| \mathbf{y}'_i - \sum_{j=1}^{\text{DM}} \mathbf{c}_{ji}^{(2)} \mathbf{b}_j \right\|^2 + \lambda \left\| f^{-1}(\mathbf{y}'_i) - \sum_{j=1}^{\text{DM}} \mathbf{c}_{ji}^{(2)} f^{-1}(\mathbf{b}_j) \right\|^2 \quad (29)$$

其中,  $\mathbf{c}_i^{(2)}$  是编码矩阵  $\mathbf{C}'_{\text{rc}}$  的第  $i$  列,  $\mathbf{y}'_i$  是  $\mathbf{Y}'$  的第  $i$  列。基于字典  $\mathbf{D}_H^{\text{rc}}$  和编码矩阵  $\mathbf{C}'_{\text{rc}}$ , 通过下式进行重构

$$\hat{\mathbf{H}}' = \mathbf{D}_H^{\text{rc}} \mathbf{C}'_{\text{rc}} \quad (30)$$

至此, 增量非零列向量的降维与重构任务已经完成。很明显 MLF 具有反馈量少、重构质量高等优点。CSI 的降维和重构只需要矢量运算和矩阵计算, 无须多次迭代。

最后, 利用已知的非零列向量和非零列索引, 通过下式恢复出下行 CSI

$$\hat{\mathbf{H}}_{\text{new}} = \hat{\mathbf{H}}_{\text{new}}^{\text{ang}} \mathbf{O}_M^{\text{H}} \quad (31)$$

增量降维和重构及下行 CSI 恢复如算法2所示。

**算法2** 增量降维和重构及下行 CSI 恢复

**输入:** 增量  $\mathbf{H}'$ , 字典 DM 的大小 ( $\mathbf{D}_H^{\text{rd}}, \mathbf{D}_L^{\text{rd}}$ ), ( $\mathbf{D}_H^{\text{rc}}, \mathbf{D}_L^{\text{rc}}$ )

**输出:** 重构级联信道  $\hat{\mathbf{H}}_{\text{new}}$

**第一步:** 降维

利用流形学习性质, 建立代价函数式(27)

通过交替优化, 使其收敛, 从式(28)得到  $\mathbf{H}'$  的低维嵌入  $\mathbf{Y}'$




图2 信道反馈的框架结构

## 第二步：重构

利用预储存的  $\mathbf{D}_c^c$ ，建立最小化目标函数式(29)

通过交替优化和  $\mathbf{D}_{\text{ff}}^c$ ，从式(30)重构出  $\hat{\mathbf{H}}'$

## 第三步：恢复下行 CSI

结合索引和  $\hat{\mathbf{H}}'$  得到  $\hat{\mathbf{H}}_{\text{new}}^{\text{ang}}$

利用式(31)恢复下行 CSI  $\hat{\mathbf{H}}_{\text{new}}$

综上所述，信道反馈的框架结构如图2所示，具体可分为如下3步。

**步骤1** 利用级联信道的单结构稀疏性，将级联信道矩阵从空间域映射到混合域（角域—空间域），将下行链路CSI分解为索引和非零列向量。

**步骤2** 通过流形学习框架建立两组字典用来降维和重构非零列向量，分别为BS端的重构字典组和UE端的降维字典组。

**步骤3** 对于增量CSI，先在UE端利用降维字典获取非零列的低维嵌入，并将其发送给BS，然后在BS处进行重构，最后恢复信道矩阵。

图2中为一段时间内本文所提出的CSI反馈框架的反馈过程，其中，步骤1只需要在较长的角度相干时间内执行一次；步骤2在整个通信过程中只需执行一次；步骤3需在信道相干时间内执行一次。在不同的角度相干时间里，步骤1需要再次执行。

本文信道反馈方案的每个用户开销由两部分组成：与用户独立的非零列索引的反馈开销和非零列元素的反馈开销。每个用户开销  $v_{\text{MLF}}$  可以计算为

$$v_{\text{MLF}} = \frac{L_1 \text{lb} G}{\chi K} + \frac{2dL_1 L_2}{\chi} \quad (32)$$

其中，系数  $\chi$  表示角度相干时间与信道相干时间之比<sup>[32]</sup>。

若直接反馈  $\mathbf{H}_k$ ，则反馈开销为  $v_1 = M \times N$ 。若将现有的降维信道反馈（DRFB, dimension reduction feedback）方案<sup>[12]</sup>运用到本文考虑的系统，则开销  $v_{\text{DRFB}}$  可表示为

$$v_{\text{DRFB}} = \frac{L_1 \text{lb} G}{\chi K} + \frac{2B_0 L_1 L_2}{\chi} + BL_1 \quad (33)$$

其中， $B_0$  为AoA的量化位，且通常  $B_0 > d$ ， $B$  为动态码本尺寸。将基于CS的信道反馈（CSFB, compressed sensing-based feedback）方案<sup>[13]</sup>运用到本文考虑的系统时，由于CSFB在DRFB的基础上进行码本优化，利用CS降低了码本复杂度，反馈开销并没有变化，所以  $v_{\text{CSFB}} = v_{\text{DRFB}}$ 。显然， $v_{\text{MLF}} - v_{\text{DRFB}} = 2(d - B_0)L_1 L_2 / \chi - BL_1 < 0$ ，即本文方案的反馈开销远低于DRFB和CSFB方案。

## 3 仿真与分析

本节对采用MLF方案的RIS辅助的无线通信系统进行了仿真，并将其与DRFB方案<sup>[12]</sup>、CSFB方案<sup>[13]</sup>、CsiNet方案<sup>[20]</sup>、DLFB方案<sup>[21]</sup>和基于发射机信道状态信息（CSIT, channel state information at the transmitter）的方案进行了比较。

仿真中，BS配备  $M = 256$  根天线，RIS配备  $N = 64$  个反射单元，UE数为4，BS与RIS之间、RIS与各UE之间的信道路径数分别为  $L_1 = 4$ 、 $L_2 = 2$ 。BS-RIS信道为视距信道，莱斯因子为15 dB，RIS-UE信道为非视距信道。均匀线性阵列（ULA, uniform linear array）配置的BS天线间距和UPA配置的RIS单元间距均为半波长，压缩比为  $\gamma = d/N$ ，AoD量化网格设为  $G = 1024$ ，收敛阈值设为  $\xi = 1.0 \times 10^{-4}$ ，角度相干时间与信道相干时间之比为  $\chi = 10$ 。

首先，对4个UE的信道矩阵处理后获取的非零列向量进行了  $S$  次采样，每个UE采样  $S/4$  次。样本数据被随机划分为75%的训练数据集和25%的测试数据集。此外，利用欧几里得距离确定最近邻。常数  $\lambda$ 、最近邻居的数量  $K$  和字典的大小  $DM$  分别选择为0.001、20和400。

为了评估重构  $\mathbf{H}_{\text{new}}$  性能，使用归一化均方误差（NMSE, normalized mean square error）测量重构信道与原始信道之间的误差如下

$$\text{NMSE} = 10\lg \left\{ \mathbb{E} \frac{\| \mathbf{H}_{\text{new}} - \hat{\mathbf{H}}_{\text{new}} \|_{\text{F}}^2}{\| \mathbf{H}_{\text{new}} \|_{\text{F}}^2} \right\} \quad (34)$$

在不同压缩比  $\gamma$  下，将本文所提方法 MLF 与两种基于 CS 的算法 (DRFB 和 CSFB)，以及两种基于 DL 的算法 (CsiNet 和 DLFB) 的重建性能与运行时间进行了比较。比较中涉及的所有算法都采用本文的系统模型。各种方案的 NMSE 与运行时间对比如表 1 所示，其中，最优结果进行了加粗显示。仿真结果表明，在所有压缩比下，MLF 方案的 NMSE 均低于 CS 算法和 DL 算法，说明其具有更高的重建精度，且随着压缩比降低，MLF 方案的 NMSE 性能下降不明显，解决了其他方案在低压缩比下重建质量差的问题。虽然 MLF 方案的运行时间略长于 DL 算法，但仍然比 CS 算法快许多。总的来说，MLF 方案能够在不显著增加开销的情况下提供更高的重建精度，在压缩比、重建质量和复杂度之间进行了很好的权衡，具有更明显的性能优势。

表 1 各种方案的 NMSE 与运行时间对比

	$\gamma$	DRFB	CSFB	CsiNet	DLFB	MLF
NMSE/dB	1/8	-19.93	-23.01	-12.13	-25.06	<b>-35.47</b>
	1/16	-7.44	-16.72	-8.61	-21.66	<b>-32.24</b>
	1/32	-2.24	-12.42	-6.15	-15.16	<b>-20.87</b>
运行时间/s	1/8	0.155	0.128	<b>0.004</b>	0.009	0.035
	1/16	0.138	0.120	<b>0.004</b>	0.009	0.022
	1/32	0.141	0.121	<b>0.004</b>	0.009	0.022

归一化均方误差与数据集大小的关系如图 3 所示。该图展示了不同压缩比时训练数据集  $\mathbf{X}$  的大小  $S$  对重构性能的影响，描述了  $S$  与重构 NMSE 之间的关系。对于一定的  $\gamma$ ，随着  $S$  值的增大，NMSE 逐渐变小，最终收敛。此外，算法 1 的计算复杂度与  $S$  成正比，计算复杂度决定了字典学习所需的时间。




图 3 归一化均方误差与数据集大小的关系

当  $S$  达到 4 000 后，重构 NMSE 逐渐收敛，当  $\gamma=1/8$  时，收敛效果最好。训练集越大，字典学习的计算复杂度越高，基于这种现象，可以在 NMSE 和  $S$  之间进行权衡。当压缩比  $\gamma=1/8$  和  $S=4 000$  时，重构性能最好，下面的仿真以此为例。

本文还对系统的可达和速率进行了仿真。不同压缩比  $\gamma$  的可达和速率与信噪比的关系如图 4 所示。其中，基站预编码与 RIS 反射系数均根据本文所提反馈方案所获得的 CSI 进行了优化。横轴“信噪比”为基站发射功率与用户端加性高斯白噪声功率之比。“完美 CSI”曲线为此时系统获得的可达和速率的上限。可以观察到，当  $\gamma=1/8$  时，可达和速率性能接近理想情况，说明重构信道与原始信道之间的误差小。然而，随着  $\gamma$  的降低，性能会下降。




图 4 不同压缩比  $\gamma$  的可达和速率与信噪比的关系

不同方案的可达和速率对比如图 5 所示，展示了根据不同反馈方案所获得的 CSI 进行基站预编码与 RIS 相移优化时系统可获得的可达和速率。图 5 比较了 MLF 方案、CSFB 方案、DRFB 方案、CsiNet 方案和 DLFB 方案在不同信噪比下的可达和速率，很明显 MLF 方案要优于其他方案。在高信噪比场景下，用户间干扰是相较于系统噪声的主要影响，为了获得好的性能，通常会造成较大的开销，但是本文方案在较长的一段时间不需要多次进行字典学习，开销明显低于另外两种方案，很好地平衡了系统的反馈开销和性能。

不同方案的可达和速率随 UE 数的变化如图 6 所示，展示了 UE 数对可达和速率性能的影响。仿真结果表明，本文提出的 MLF 方案比 CSFB 方案、DRFB 方案、CsiNet 方案和 DLFB 方案具有更好的性能。由图 6 可以发现，在完美 CSIT 环境和不完美 CSIT 环境下，UE 数量大于 4 时，可达和速率会

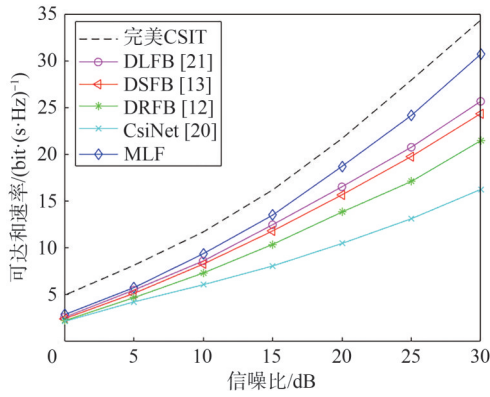


图5 不同方案的可达和速率对比




图6 不同方案的可达和速率随UE数的变化

呈现降低趋势。这一现象源于信道矩阵  $\mathbf{H}_{\text{total}}$  的低秩性，特别是在毫米波通信系统中，低秩是在有限散射环境下的大规模MIMO信道的共同特性。

#### 4 结束语

本文针对RIS辅助的大规模MIMO系统在FDD模式下信道反馈负担沉重的问题，提出了一种基于流形学习的低开销、高精度的CSI反馈方案。该方案充分利用信道的稀疏性特征降低了CSI反馈量，并利用基于流形学习的反馈框架降低了反馈维度、提升了重构性能。仿真结果表明，本文所提方案的性能优于现有的反馈方案，能够在保证CSI重建精度的同时，减少反馈开销。后续将从优化流形结构、降低复杂度方面对算法进一步改进，并将流形学习方法应用于RIS辅助的大规模MIMO通信场景中的信道估计。

#### 参考文献：

[1] LARSSON E G, EDFORS O, TUFVESSON F, et al. Massive MIMO for next generation wireless systems[J]. IEEE Communications Magazine, 2014, 52(2): 186-195.  
 [2] MARZETTA T L. Noncooperative cellular wireless with unlim-

ited numbers of base station antennas[J]. IEEE Transactions on Wireless Communications, 2010, 9(11): 3590-3600.  
 [3] WANG B L, GAO F F, JIN S, et al. Spatial- and frequency-wideband effects in millimeter-wave massive MIMO systems[J]. IEEE Transactions on Signal Processing, 2018, 66(13): 3393-3406.  
 [4] ZHANG Z Q, XIAO Y, MA Z, et al. 6G wireless networks: vision, requirements, architecture, and key technologies[J]. IEEE Vehicular Technology Magazine, 2019, 14(3): 28-41.  
 [5] WU Q Q, ZHANG S W, ZHENG B X, et al. Intelligent reflecting surface-aided wireless communications: a tutorial[J]. IEEE Transactions on Communications, 2021, 69(5): 3313-3351.  
 [6] WIJEKOON D, MEZGHANI A, HOSSAIN E. Beamforming optimization in RIS-aided mimo systems under multiple-reflection effects[C]//Proceedings of the ICASSP 2023 - 2023 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP). Piscataway: IEEE Press, 2023: 1-5.  
 [7] RAGHAVAN V, HEATH R W, SAYEED A M. Systematic codebook designs for quantized beamforming in correlated MIMO channels[J]. IEEE Journal on Selected Areas in Communications, 2007, 25(7): 1298-1310.  
 [8] KUO P H, KUNG H T, TING P G. Compressive sensing based channel feedback protocols for spatially-correlated massive antenna arrays[C]//Proceedings of the 2012 IEEE Wireless Communications and Networking Conference (WCNC). Piscataway: IEEE Press, 2012: 492-497.  
 [9] WANG Y R, LIU A J, XIA X C, et al. Learning the structured sparsity: 3-D massive MIMO channel estimation and adaptive spatial interpolation[J]. IEEE Transactions on Vehicular Technology, 2019, 68(11): 10663-10678.  
 [10] KYRITSI P, COX D C, VALENZUELA R A, et al. Correlation analysis based on MIMO channel measurements in an indoor environment[J]. IEEE Journal on Selected Areas in Communications, 2003, 21(5): 713-720.  
 [11] SHEN D C, DAI L L. Channel feedback for reconfigurable intelligent surface assisted wireless communications[C]//Proceedings of the GLOBECOM 2020 - 2020 IEEE Global Communications Conference. Piscataway: IEEE Press, 2020: 1-5.  
 [12] SHEN D C, DAI L L. Dimension reduced channel feedback for reconfigurable intelligent surface aided wireless communications[J]. IEEE Transactions on Communications, 2021, 69(11): 7748-7760.  
 [13] SHIN B S, OH J H, YOU Y H, et al. Limited channel feedback scheme for reconfigurable intelligent surface assisted MU-MIMO wireless communication systems[J]. IEEE Access, 2022, 10: 50288-50297.  
 [14] LOVE D J, HEATH R W, LAU V K N, et al. An overview of limited feedback in wireless communication systems[J]. IEEE Journal on Selected Areas in Communications, 2008, 26(8): 1341-1365.  
 [15] LIU Z Y, DEL ROSARIO M, DING Z. A Markovian model-driven deep learning framework for massive MIMO CSI feedback[J]. IEEE Transactions on Wireless Communications, 2022, 21(2): 1214-1228.  
 [16] CUI Y D, GUO A H, SONG C L. TransNet: full attention network

- for CSI feedback in FDD massive MIMO system[J]. IEEE Wireless Communications Letters, 2022, 11(5): 903-907.
- [17] ZENG J, HE Z R, SUN J L, et al. Deep transfer learning for 5G massive MIMO downlink CSI feedback[C]//Proceedings of the 2021 IEEE Wireless Communications and Networking Conference (WCNC). Piscataway: IEEE Press, 2021: 1-5.
- [18] JI S J, LI M. CLNet: complex input lightweight neural network designed for massive MIMO CSI feedback[J]. IEEE Wireless Communications Letters, 2021, 10(10): 2318-2322.
- [19] CAO Z, SHIH W T, GUO J J, et al. Lightweight convolutional neural networks for CSI feedback in massive MIMO[J]. IEEE Communications Letters, 2021, 25(8): 2624-2628.
- [20] WEN C K, SHIH W T, JIN S. Deep learning for massive MIMO CSI feedback[J]. IEEE Wireless Communications Letters, 2018, 7(5): 748-751.
- [21] 陈慕涵, 郭佳佳, 李潇, 等. 基于深度学习的大规模MIMO信道状态信息反馈[J]. 物联网学报, 2020, 4(1): 33-44.  
CHEN M H, GUO J J, LI X, et al. An overview of the CSI feedback based on deep learning for massive MIMO systems[J]. Chinese Journal on Internet of Things, 2020, 4(1): 33-44.
- [22] 廖勇, 姚海梅, 花远肖. 一种基于深度学习的物联网信道状态信息获取算法[J]. 物联网学报, 2019, 3(1): 8-13.  
LIAO Y, YAO H M, HUA Y X. Channel state information acquisition algorithm based on deep learning for IoT[J]. Chinese Journal on Internet of Things, 2019, 3(1): 8-13.
- [23] 张阳阳, 张席畅, 刘毅. 面向大规模MIMO信道信息反馈的模型驱动轻量化神经网络[J]. 信号处理, 2023, 39(3): 381-389.  
ZHANG Y Y, ZHANG X C, LIU Y. Model-driven lightweight network for CSI feedback in massive MIMO[J]. Journal of Signal Processing, 2023, 39(3): 381-389.
- [24] CAO Y D, YIN H F, HE G N, et al. Manifold learning-based CSI feedback in massive MIMO systems[C]//Proceedings of the ICC 2022-IEEE International Conference on Communications. Piscataway: IEEE Press, 2022: 225-230.
- [25] ZHAO Z, FENG G C, ZHU J H, et al. Manifold learning: dimensionality reduction and high dimensional data reconstruction via dictionary learning[J]. Neurocomputing, 2016, 216: 268-285.
- [26] SEJAN M A S, RAHMAN M H, SHIN B S, et al. Machine learning for intelligent-reflecting-surface-based wireless communication towards 6G: a review[J]. Sensors, 2022, 22(14): 5405.
- [27] MEIJERINK A, MOLISCH A F. On the physical interpretation of the Saleh-Valenzuela model and the definition of its power delay profiles[J]. IEEE Transactions on Antennas and Propagation, 2014, 62(9): 4780-4793.
- [28] EL AYACH O, RAJAGOPAL S, ABU-SURRA S, et al. Spatially sparse precoding in millimeter wave MIMO systems[J]. IEEE Transactions on Wireless Communications, 2014, 13(3): 1499-1513.
- [29] WEI X H, SHEN D C, DAI L L. Channel estimation for RIS assisted wireless communications: Part I: fundamentals, solutions, and future opportunities[J]. IEEE Communications Letters, 2021, 25(5): 1398-1402.

- [30] DJEBRA Y, MARIN T, HAN P K, et al. Manifold learning via linear tangent space alignment (LTSA) for accelerated dynamic MRI with sparse sampling[J]. IEEE Transactions on Medical Imaging, 2023, 42(1): 158-169.
- [31] ZHANG Z Y, ZHA H Y. Principal manifolds and nonlinear dimensionality reduction via tangent space alignment[J]. Journal of Shanghai University (English Edition), 2004, 8(4): 406-424.
- [32] SHEN W Q, DAI L L, SHIM B, et al. Channel feedback based on AoD-adaptive subspace codebook in FDD massive MIMO systems[J]. IEEE Transactions on Communications, 2018, 66(11): 5235-5248.

## [作者简介]



钱慕君 (1986– ) 女, 博士, 南京邮电大学电子与光学工程学院、柔性电子 (未来技术) 学院讲师, 主要研究方向为物理层安全技术、无线携能通信、智能反射面等。



虞舜驰 (1998– ) 男, 南京邮电大学电子与光学工程学院、柔性电子 (未来技术) 学院硕士生, 主要研究方向为毫米波大规模MIMO通信、智能反射面等。



刘陈 (1963– ) 男, 博士, 南京邮电大学电子与光学工程学院、柔性电子 (未来技术) 学院教授、博士生导师, 主要研究方向为无线通信中的空时信号传输与处理算法、大规模MIMO通信、流形学习与流形优化等。



宋云超 (1988– ) 男, 博士, 南京邮电大学电子与光学工程学院、柔性电子 (未来技术) 学院副教授、硕士生导师, 主要研究方向为5G/6G无线通信信号处理。



陆峰 (1978– ) 男, 博士, 南京邮电大学电子与光学工程学院、柔性电子 (未来技术) 学院副教授, 主要研究方向为通信信号处理。