

基于深度学习的大规模 MIMO 信道状态信息反馈

陈慕涵, 郭佳佳, 李潇, 金石

(东南大学移动通信国家重点实验室, 江苏 南京 210096)

摘要: 大规模多输入多输出 (MIMO, multiple-input multiple output) 技术被认为是下一代移动通信的核心技术之一, 其系统增益建立在基站能够精确获知信道状态信息 (CSI, channel state information) 的基础上。由于天线数量显著增长, 传统基于码本或矢量量化的反馈方案面临较大的技术挑战, 而深度学习 (DL, deep learning) 为解决大规模 MIMO 系统的 CSI 反馈问题提供了新思路。围绕大规模 MIMO 系统 CSI 反馈关键技术展开调研, 首先阐述了 CSI 反馈的研究背景和意义, 接着构建大规模 MIMO 系统模型并分析 CSI 的稀疏特性, 然后详细介绍和比较了国内外将 DL 技术引入 CSI 反馈机制中的方案, 最后对基于 DL 的 CSI 反馈的未来发展趋势做了进一步展望。

关键词: 大规模 MIMO; 深度学习; CSI 反馈

中图分类号: TN929.5

文献标识码: A

doi:10.11959/j.issn.2096-3750.2020.00157

An overview of the CSI feedback based on deep learning for massive MIMO systems

CHEN Muhan, GUO Jiajia, LI Xiao, JIN Shi

National Mobile Communications Research Laboratory, Southeast University, Nanjing 210096, China

Abstract: The massive multiple-input multiple-output (MIMO) technology is considered to be one of the core technologies of the next generation communication system. To fully utilize the potential gains of MIMO systems, the base station should accurately acquire the channel state information (CSI). Due to the significant increase in the number of antennas, the traditional feedback schemes based on the codebook or vector quantization are faced with great technical challenges. Recently, deep learning (DL) has provided a new idea for solving CSI feedback problems in massive MIMO systems. It was focused on the key technologies of the CSI feedback for massive MIMO systems. Firstly, the background and significance of the CSI feedback were expounded. Then, a model for the massive MIMO system was established and the sparse nature of CSI was analyzed. Several schemes of introducing DL into the CSI feedback mechanism were introduced and compared in detail. Finally, a further prospect on the development trend of the CSI feedback based on DL was made.

Key words: massive MIMO, deep learning, CSI feedback

1 引言

自 20 世纪 80 年代 1G 移动通信系统被提出后, 移动通信技术以 10 年一代的速度迅速发展, 广泛

渗透到社会的方方面面, 对各行各业都产生了深远影响。随着智能终端的普及以及物联网、车联网、虚拟现实等无线新业务的不断涌现, 对未来移动通信系统的性能指标提出了更高的要求, 由此推动全

收稿日期: 2020-02-17; 修回日期: 2020-03-05

通信作者: 金石, jinshi@seu.edu.cn

基金项目: 国家自然科学基金资助项目 (No.61941104)

Foundation Item: The National Science Foundation of China (No. 61941104)

球学术界和工业界投入到 5G 移动通信系统标准化研究的工作中。现如今, 5G 的标准化研究已经基本完成, 大规模多输入多输出 (MIMO, multiple-input multiple output) 技术、超密集异构小蜂窝网络以及毫米波通信被认为是 5G 的三大核心关键技术^[1]。随着 5G 商用时代的到来, 6G 移动通信系统^[2]的研发工作也已经正式启动, 6G 移动通信系统将具备全覆盖、全应用、全频谱、强安全等显著特征, 而作为 6G 潜在使能技术的大规模 MIMO 技术仍有较大的发展空间。

大规模 MIMO 技术具备空间复用增益、分集增益以及波束成形能力, 通过在发射端和接收端配置多根天线实现多收多发, 能够充分利用空间资源, 在不增加频谱资源和发射功率的前提下, 成倍提高信道容量并减少多用户干扰, 展现出显著的性能优势, 但这些增益建立在基站能够精确获知上行链路和下行链路信道状态信息 (CSI, channel state information) 的前提下。上行链路的 CSI 获取较容易, 只需用户端发送训练导频, 再由基站根据接收到的信号估计每个用户终端的信道响应; 下行链路的 CSI 获取则较困难, 也是当前大规模 MIMO 技术中需要重点解决的难题。在时分双工 (TDD, time division duplex) 制式下, 基站可通过上行链路发送的训练导频进行信道估计, 再利用信道互易性获取下行链路的 CSI; 在频分双工 (FDD, frequency division duplex) 制式下, 上行链路和下行链路工作在不同的频点上, 信道互易性很弱, 因此, 下行链路的 CSI 需要先由用户端通过下行导频估计获得, 再通过反馈链路传回基站端。完整的 CSI 回传需要消耗大量的链路开销, 所以通常采用矢量量化 (VQ, vector quantization) 或基于码本的方法^[3]来减少反馈开销, 但这些方法在一定程度上损失了信道信息, 且其产生的反馈量会随着发射天线数量线性缩放。大规模 MIMO 系统中基站端使用大量天线, 使得码本设计复杂度和相应的反馈量显著增长, 因此, 传统反馈方案在大规模 MIMO 系统中是不可取的。

鉴于 FDD 是目前蜂窝系统中应用最广泛的双工制式, 如何在 FDD 大规模 MIMO 系统中精确获取下行链路 CSI 成为研究的热点和难点。实验表明, 随着基站天线数量增加, 用户端在空频域的信道矩阵因基站有限的局部散射体可被表示成一种稀疏形式^[4-5]。因此, 基于压缩感知 (CS, compressive sensing) 的 CSI 反馈方案^[6-7]被提出, 这也是目前较

先进的信道反馈方案。理论上, 具有相关性的 CSI 在某些基底上可以变换为不相关的稀疏向量, 然后利用 CS 方法对其进行随机投影来获得降维的测量值; 该测量值在占用少量资源开销的情况下通过反馈链路传回基站, 基站再根据 CS 算法从低维压缩测量值中恢复出原始的稀疏信道向量。通过利用 CSI 的空时相关性, CS 方法不依赖于统计数据, 简化了压缩过程且在一定程度上减少了反馈开销。然而, 传统基于 CS 的方法仍然存在以下 3 个问题:

1) CS 方法严重依赖于信道结构的先验假设, 即信道在某些变换基上满足稀疏性, 而实际信道在任何基底上都不是完全稀疏的, 甚至可能没有可解释的结构; 2) CS 方法使用随机投影来获得低维压缩信号, 并没有充分利用信道的结构特征; 3) 现有的用于 CSI 恢复的 CS 算法多为迭代算法, 具有较大的计算开销和较慢的运行速度, 不满足实际系统的实时性要求。因此, 一种可以从低压缩率的反馈信息中快速、准确地恢复 CSI 的大规模 MIMO 反馈机制亟待提出, 突破性新技术的引入迫在眉睫。

近年来, 以深度学习 (DL, deep learning) 技术为代表的人工智能发展迅速, 与计算机视觉、自然语言处理、语音识别等领域深度融合, 取得了突破性进展, 被认为是 6G 强有力的潜在使能技术。DL 算法可根据大量训练数据有效逼近或拟合任意复杂的函数, 提取并处理隐含的特征, 所以融入了 DL 的智能通信有望打破传统通信系统的设计瓶颈, 降低建模难度, 在物理层基础理论与关键技术上有所突破, 得到整体性能最优的新架构, 因此, 智能通信也被 3GPP、ITU 等国际化标准组织作为通信技术演进的主流方向。鉴于 DL 在通信系统各个领域中的成功应用^[8-11], 国内外研究者试图将 DL 技术引入大规模 MIMO 反馈方案中, 为解决 FDD 制式下 CSI 反馈难题提供新的设计思路, 并取得了一些成果。

2 系统模型

国内外现有基于 DL 的 CSI 反馈方案都是借鉴 CS 理论设计的。从 FDD 大规模 MIMO 系统模型出发, 分析 CSI 在角度时延域的稀疏性以及 CS 理论的应用局限性, 为后续引入 DL 技术进行改进奠定基础。

在 FDD 大规模 MIMO 系统中, 考虑一个简单的单一蜂窝小区下行链路的情形。基站端使用半波

长间距的均匀线性阵列 (ULA, uniform linear antenna array), 配置 $N_t \gg 1$ 根发射天线, 用户端配置单一接收天线。考虑在 \tilde{N}_c 个正交子载波上传输信息的正交频分复用 (OFDM, orthogonal frequency division multiplexing) 系统, 则第 n 个子载波上的接收信号可表示为

$$y_n = \tilde{\mathbf{h}}_n^H \mathbf{v}_n x_n + z_n \quad (1)$$

其中, $\tilde{\mathbf{h}}_n \in \mathbb{C}^{N_t \times 1}$, $\mathbf{v}_n \in \mathbb{C}^{N_t \times 1}$, $x_n \in \mathbb{C}$, $z_n \in \mathbb{C}$ 分别表示第 n 个子载波上的频域信道向量、预编码向量、下行发送数据符号和加性高斯白噪声。若以空频域为基底, 则下行链路的 CSI 矩阵为所有子载波上信道向量的堆叠, 即

$$\tilde{\mathbf{H}} = [\tilde{\mathbf{h}}_1, \tilde{\mathbf{h}}_2, \dots, \tilde{\mathbf{h}}_{\tilde{N}_c}]^H \quad (2)$$

其中, $\tilde{\mathbf{H}} \in \mathbb{C}^{\tilde{N}_c \times N_t}$ 。当基站获取下行链路 CSI 矩阵 $\tilde{\mathbf{H}}$ 后, 就可以据此设计预编码向量 $\{\mathbf{v}_n, n=1, \dots, \tilde{N}_c\}$, 从而消除用户间干扰, 改善通信质量。然而在 FDD 制式下, 用户端需要通过反馈链路将 CSI 矩阵 $\tilde{\mathbf{H}}$ 反馈回基站, 所需反馈的参数总量为 $N_t \tilde{N}_c$ 个复数。由于基站配置大量天线, 反馈完整的 CSI 矩阵需要消耗大量的反馈资源, 在实际应用中是不可取的, 因此, 研究如何减少反馈开销的有限信道 CSI 反馈技术至关重要。

为了分析 CSI 矩阵的性质, 可将式(2)中空频域的 CSI 矩阵展开为

$$\tilde{\mathbf{H}} = \begin{bmatrix} h_{11} & h_{12} & \dots & h_{1N_t} \\ h_{21} & h_{22} & \dots & h_{2N_t} \\ \vdots & \vdots & \ddots & \vdots \\ h_{\tilde{N}_c 1} & h_{\tilde{N}_c 2} & \dots & h_{\tilde{N}_c N_t} \end{bmatrix}_{\tilde{N}_c \times N_t} \quad (3)$$

其中, 矩阵的每个列向量均为一个频域信道向量, 每个行向量均为一个空间域信道向量。

在时延域中, 由于信道的时延扩展有限, 即多径到达之间的时延是在一定时间段内的, 因此, 信道向量在时延域上表现出稀疏性。时延域对应于频域的离散傅里叶变换 (DFT, discrete Fourier transform), 而 CSI 矩阵的每个列向量均为一个频域信道向量, 所以可以对其每个列向量进行 DFT, 得到时延域稀疏的信道矩阵, 即

$$\mathbf{H}_d = \mathbf{F}_d \tilde{\mathbf{H}} \quad (4)$$

其中, $\mathbf{F}_d \in \mathbb{C}^{\tilde{N}_c \times \tilde{N}_c}$ 为 DFT 矩阵, \mathbf{H}_d 为变换得到的

时延域稀疏信道矩阵。

由文献[12]可知, 第 i 个子载波上的空间域信道向量可以表示为

$$\mathbf{h}_i^T = \mathbf{R}_{UE}^{1/2} \mathbf{v}_i \mathbf{R}_{BS}^{1/2} \quad (5)$$

其中, $\mathbf{h}_i^T = [h_{i1}, h_{i2}, \dots, h_{iN_t}] \in \mathbb{C}^{1 \times N_t}$ 为式(3)中 CSI 矩阵的第 i 个行向量, \mathbf{v}_i 是均值为 0、方差为 1 的高斯复向量, \mathbf{R}_{BS} 和 \mathbf{R}_{UE} 分别为基站端和用户端由散射条件决定的半正定信道协方差矩阵。由于本文考虑单天线用户端, 其对应的 \mathbf{R}_{UE} 为单位矩阵, 则式(5)可简化为

$$\mathbf{h}_i^T = \mathbf{v}_i \mathbf{R}_{BS}^{1/2} \quad (6)$$

基站端使用配置 N_t 根天线的 ULA 阵列, 则 \mathbf{R}_{BS} 可以表示成到达角 θ 的函数。实验表明, 当基站天线数 $N_t \rightarrow \infty$ 时, 基站端 ULA 阵列的导矢量可作为 DFT 的基底, 角度功率谱 $p(\theta)$ 可作为相应的特征值, 将 \mathbf{R}_{BS} 表示为

$$\mathbf{R}_{BS} = \mathbf{F} \mathbf{A}_{BS} \mathbf{F}^H \quad (7)$$

其中, \mathbf{F} 为 $N_t \times N_t$ 的 DFT 矩阵, \mathbf{A}_{BS} 是对角线元素为 $\{p(n/N_t)\}_{n \in \{0, 1, \dots, N_t-1\}}$ 的对角矩阵。文献[12]仿真表明, 该特征值具有稀疏性, 即只在少量 θ 处有值, 其余部分均接近于 0。由此可定义角度域的信道向量为

$$\tilde{\mathbf{h}}_i^T = \mathbf{h}_i^T \mathbf{F} \quad (8)$$

将式(6)和式(7)代入式(8)得

$$\tilde{\mathbf{h}}_i^T = \mathbf{v}_i \mathbf{F} \mathbf{A}_{BS}^{1/2} \quad (9)$$

可以发现, 式(9)为一个稀疏向量, 说明信道向量在角度域上也表现出稀疏性。由式(8)可知, 通过对 $\tilde{\mathbf{H}}$ 的每个行向量进行 DFT 可以得到角度域稀疏的信道矩阵, 即

$$\mathbf{H}_a = \tilde{\mathbf{H}} \mathbf{F}_a \quad (10)$$

其中, $\mathbf{F}_a \in \mathbb{C}^{N_t \times N_t}$ 为 DFT 矩阵, \mathbf{H}_a 为变换得到的角度域稀疏信道矩阵。但在实际系统中, 基站的天线数量 N_t 是个有限值, 使得角度域的信道矩阵只是近似稀疏。

结合式(4)和式(10), 可以对空频域的 CSI 矩阵 $\tilde{\mathbf{H}}$ 做二维 DFT, 即左乘一个 $\tilde{N}_c \times \tilde{N}_c$ 的 DFT 矩阵, 右乘一个 $N_t \times N_t$ 的 DFT 矩阵, 得到在角度时延域近似稀疏的 CSI 矩阵 \mathbf{H} , 表示为

$$\mathbf{H} = \mathbf{F}_d \tilde{\mathbf{H}} \mathbf{F}_a^H \quad (11)$$

由于信道时延扩展的有限性， \mathbf{H} 只有前 N_c ($N_c < \tilde{N}_c$) 行具有非零值，因此，只需保留 \mathbf{H} 的前 N_c 行并去除剩余行，得到截断矩阵 $\mathbf{H} \in \mathbb{C}^{N_c \times N_t}$ ，从而将反馈量减少至 $N = 2N_c N_t$ ，但这在大规模 MIMO 系统中仍然是个很大的数目。

借鉴 CS 理论思想，可利用信道矩阵的稀疏特性，将上述 N 维信号压缩成 M 维 ($M \ll N$) 测量值，进一步减少反馈开销。然而，传统的 CS 算法 (如 LASSO^[13]和 AMP^[14]) 严重依赖于信道结构的先验假设，而 CSI 矩阵在角度时延域只是近似稀疏，且大多数相邻元素间的变化存在关联，需要复杂的先验假设且无法保证恢复性能。另外，有部分先进算法 (如 TVAL3^[15]和 BM3D-AMP^[16]) 研究利用更精细的先验假设对压缩测量值进行恢复，但人为设计的先验假设仍然无法符合实际信道的复杂模型。因此，国际学术界致力于利用 DL 技术强大的优化拟合能力，通过神经网络充分学习信道结构知识，获得更好的重建性能。

3 相关研究进展

基于 CS 算法的反馈方案在一定程度上减少了大规模 MIMO 系统的反馈开销，但其重建性能受限于先验假设，且存在计算开销大、运行速度慢等问题，仍有较大的性能提升空间。由此考虑引入 DL 技术对 CS 方案进行优化，接下来详细介绍 5 种现有的基于 DL 的 CSI 反馈方案及其性能。

3.1 基于自动编码器的信道反馈网络

受卷积神经网络在 CS 图像重建^[17]以及结构信号感知重建^[18]上取得重大突破的启发，文献[19]首次提出了一种基于 DL 的大规模 MIMO 信道状态信息反馈架构 CsiNet。CsiNet 的结构类似于自动编码器^[20]，包括编码器和译码器两部分。编码器属于用户端，用于 CSI 压缩，即利用信道矩阵的稀疏特性将原先

N 维的信道矩阵 \mathbf{H} 压缩成 M 维的码字 \mathbf{s} ，其原理可表示为

$$\mathbf{s} = f_{\text{en}}(\mathbf{H}) \quad (12)$$

此时，称 $\gamma = M / N$ 为数据压缩率 ($M < N$)；译码器属于基站端，用于 CSI 重建，即将接收到的码字 \mathbf{s} 恢复成原始的信道矩阵 $\hat{\mathbf{H}}$ ，其原理可表示为

$$\hat{\mathbf{H}} = f_{\text{de}}(\mathbf{s}) \quad (13)$$

在此基础上参考 CS 算法，CsiNet 的工作机制可归纳如下：用户端在接收到空频域的信道矩阵 $\tilde{\mathbf{H}}$ 后，通过式(11)进行二维 DFT 获得截断矩阵 \mathbf{H} ，然后使用编码器(12)生成一个压缩码字 \mathbf{s} ；接着码字 \mathbf{s} 通过反馈链路被回传到基站，基站接收到码字 \mathbf{s} 后，用译码器(13)来重建角度时延域的信道矩阵 $\hat{\mathbf{H}}$ ；最后，通过逆 DFT 得到空频域的恢复信道矩阵。

CsiNet 网络结构如图 1 所示，其中，Conv 表示卷积层，Dense 表示全连接层，Reshape 表示在不改变输入数据总维度的前提下重塑输出数据的结构，卷积层中的数字表示卷积核大小，重塑和全连接层中的数字表示输出向量维度，每层上方所标的数字表示生成通道数。具体来说，编码器包括一个卷积层和一个全连接层，卷积层使用 3×3 卷积核分别对输入信道矩阵的实部和虚部进行特征提取，生成两通道特征图。之后再两通道特征图合并，重塑成一个向量并输入全连接层进行压缩。译码器包括一个全连接层、两个 RefineNet 单元和一个卷积层，第一层全连接层将接收到的码字解压缩成两个和编码器输入维度相同的矩阵作为信道矩阵实部、虚部的初始估计值。再经由两个 RefineNet 单元不断改善重建的信道矩阵，每个 RefineNet 单元由 4 层卷积层构成，第一层作为输入层，后 3 层分别生成 8、16、2 通道特征图，并通过引入残差网络思想，将第一层和最后一层的输出相加后作为整个单元的输出，有效避免了梯度消失问题。最后一层

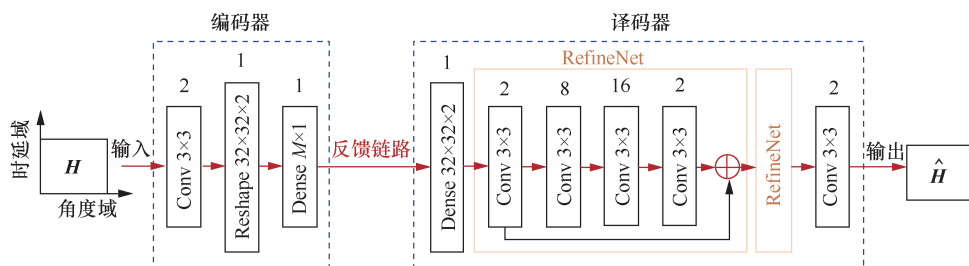


图 1 CsiNet 网络结构

卷积层使用 Sigmoid 激活函数对输出信道矩阵的元素进行归一化。所有卷积层均使用 same padding 方式在输入周围填充 0，使输出始终保持原始信道矩阵的维度。除了最后一层卷积层外，其余卷积层均使用泄漏修正线性单元 (Leaky ReLU, leaky rectified linear unit) 作为激活函数，且在激活函数前使用批标准化 (BN, batch normalization) 降低训练难度。网络训练采用的代价函数为均方误差 (MSE, mean square error)，并使用端到端学习和 Adam 优化算法更新参数集。

设置基站天线数 $N_t = 32$ ，子载波数 $\tilde{N}_c = 1024$ ，利用 COST 2100 信道模型^[21]生成室内和室外两种场景下的数据集，其中，训练集、校验集和测试集分别包含 100 000、30 000 和 20 000 个样本，训练迭代次数、初始学习率和批量大小分别设为 1 000、0.001 和 200。为了评估网络的重建性能，使用归一化均方误差 (NMSE, normalized mean square error) 作为衡量标准，定义为

$$\text{NMSE} = \mathbb{E} \left\{ \frac{\| \mathbf{H} - \hat{\mathbf{H}} \|_2^2}{\| \mathbf{H} \|_2^2} \right\} \quad (14)$$

其中， $\hat{\mathbf{H}}$ 表示恢复的信道矩阵， \mathbf{H} 表示原始的信道矩阵， $\| \cdot \|_2$ 表示欧几里得范数。在两个场景的不同压缩率 γ 下进行重建性能测试，将 CsiNet 与 3 种最先进的 CS 算法 (LASSO、TVAL3 和 BM3D-AMP) 进行比较，CsiNet 与 CS 算法的 NMSE 性能比较如表 1 所示，其中，最好的结果进行了加粗显示。仿真结果表明，相比于传统的 CS 算法，CsiNet 在不同场景的不同压缩率下均具有更好的 CSI 重建性能。这是因为 CsiNet 通过数据驱动方式端到端地训练由神经网络构成的基于自动编码器的架构，直接从训练数据中学习如何有效地利用信道结构特征，不依赖于信道分布的先验知识，且算法非迭代，比 CS 的迭代算法快几个数量级，有效解决了传统 CS 方法存在的局限性。在传统 CS 算法无法工作的低压缩率下，CsiNet 仍然具有良好的重建性能并能降低时间复杂度，显示出极大的性能优势，是一种极具潜力的新型 CSI 反馈机制。

3.2 引入 LSTM 的时变信道反馈网络

CsiNet 给研究者们提供了一种针对 CSI 反馈的设计思路和用于扩展的基础架构，但其在低压缩率下的重建精度会显著降低，仍有较大的性能提升空间。在许多典型的大规模 MIMO 应用场景下信道变化缓慢，采集的一帧信道数据具有时间相关性，可

以利用这种时间相关性对信道矩阵进行更高效的压缩。

表 1 CsiNet 与 CS 算法的 NMSE 性能比较/dB

场景	γ	LASSO	TVAL3	BM3D-AMP	CsiNet
室内	1/4	-7.59	-14.87	-4.33	-17.36
	1/16	-2.72	-2.61	0.26	-8.65
	1/32	-1.03	-0.27	24.72	-6.24
	1/64	-0.14	0.63	26.22	-5.84
室外	1/4	-5.08	-6.90	-1.33	-8.75
	1/16	-1.01	-0.43	0.55	-4.51
	1/32	-0.24	0.46	22.66	-2.81
	1/64	-0.06	0.76	25.45	-1.93

受用于高帧速率视频 CS 实时架构^[22]的启发，文献[23]将相干时间内的 T 个角度时延域的信道矩阵作为一个信道组，其信道矩阵间的相关性类似于视频信号中的帧间相关性。因此，文献[23]用长短期记忆网络 (LSTM, long short-term memory) 对 CsiNet 架构进行扩展，提升网络在压缩率和恢复质量间的折中，CsiNet-LSTM 网络结构如图 2 所示。在 CsiNet-LSTM 网络结构中，CsiNet 编码器和 CsiNet 译码器两个模块沿用了 CsiNet 中的网络结构。在对信道矩阵进行角度时延域特征提取和恢复重建时，CsiNet-LSTM 采用了两种不同的压缩率。第一个 CsiNet 模块采用高压压缩率，从而能够保留第一个信道矩阵足够的结构信息以进行后续的高分辨率恢复。由于剩余信道与第一个信道间存在相关性，包含的有效信息量较少，因此，之后的 $T-1$ 个信道矩阵均可执行低压缩率的编码。在进行恢复重建前，将第一个高压压缩率编码的码字串联到所有低压缩率码字的前面，充分利用信道相关性信息进行译码。将译码后的输出构成长度为 T 的序列送入 3 层 LSTM 中，LSTM 通过前一时刻的输入能够隐式地学习时间相关性，再与当前时刻的输入合并，从而提高低压缩率的重建质量。

同样地，CsiNet-LSTM 也采用 MSE 作为代价函数，使用端到端学习和 Adam 优化算法训练网络。在 COST 2100 信道模型的两场景下，设置基站天线数 $N_t = 32$ ，子载波数 $\tilde{N}_c = 256$ ，生成的训练集、校验集和测试集分别包含 75 000、12 500 和 12 500 个样本。训练网络的部分参数预先从 CsiNet 中加载来进行初始化。训练迭代次数根据收敛情况在 500 和

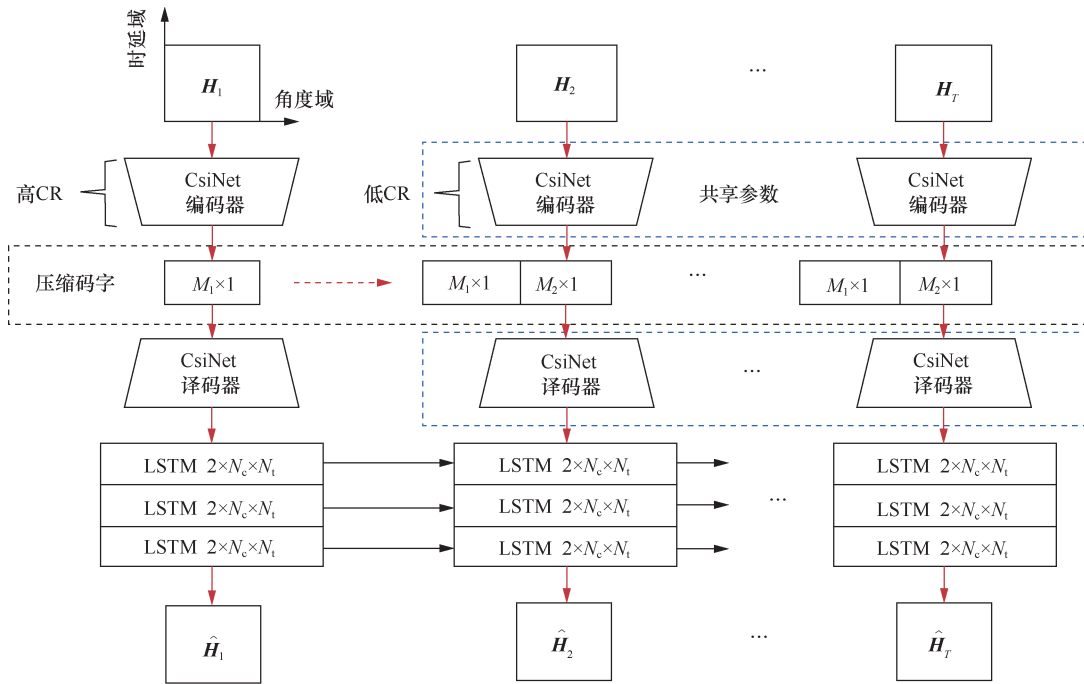


图2 CsiNet-LSTM网络结构

1 000 之间进行调整, 相应的学习率分别为 0.001 和 0.000 1, 批量大小设为 100。使用不同压缩率 γ 测试 CsiNet-LSTM、3 种 CS 算法 (LASSO、TVAL3 和 BM3D-AMP) 以及 CsiNet 的重建性能与运行时间, CsiNet-LSTM 与 CsiNet、CS 算法比较如表 2 所示, 其中, 最好的结果进行了加粗显示。仿真结果表明, 在所有压缩率下, CsiNet-LSTM 的 NMSE

均低于传统 CS 算法及改进前的 CsiNet, 说明其具有更高的重建精度, 且随着压缩率降低, CsiNet-LSTM 的 NMSE 性能下降不明显, 解决了 CsiNet 在低压缩率下重建质量差的问题。由于引入了 LSTM, CsiNet-LSTM 的运行时间略长于 CsiNet, 但相比于传统 CS 算法仍然快几个数量级。归纳来说, 通过利用 LSTM 提取信道矩阵间的时间相关性,

表 2 CsiNet-LSTM 与 CsiNet、CS 算法比较

场景	γ	LASSO	TVAL3	BM3D-AMP	CsiNet	CsiNet-LSTM	
室内	NMSE/dB	1/16	-2.96	-3.20	0.25	-10.59	-23.06
		1/32	-1.18	-0.46	20.85	-7.35	-22.33
		1/64	-0.18	0.60	26.66	-6.09	-21.24
	运行时间/s	1/16	0.247 1	0.314 8	0.345 4	0.000 1	0.000 3
		1/32	0.213 7	0.314 8	0.555 6	0.000 1	0.000 3
		1/64	0.247 9	0.286 0	0.604 7	0.000 1	0.000 3
室外	NMSE/dB	1/16	-1.09	-0.53	0.40	-3.60	-9.86
		1/32	-0.27	0.42	18.99	-2.14	-9.18
		1/64	-0.06	0.74	24.42	-1.65	-8.83
	运行时间/s	1/16	0.212 2	0.314 5	0.421 0	0.000 1	0.000 3
		1/32	0.240 9	0.298 5	0.603 1	0.000 1	0.000 3
		1/64	0.016 6	0.285 0	0.598 0	0.000 1	0.000 3

CsiNet-LSTM 能够在不显著增加开销的情况下提供实时且精确的 CSI 重建，在压缩速率、重建质量以及复杂度之间进行了很好的权衡，在低压缩率和信道较为复杂的环境中具有更明显的性能优势。

文献[24]也在 CsiNet 的基础上引入 LSTM，充分利用无线信道的时延相关性提高网络的重建性能，提出了 RecCsiNet 架构，RecCsiNet 网络结构如图 3(a)所示。RecCsiNet 的编码器包括特征提取和特征压缩两个模块，译码器包括特征解压缩和信道恢复两个模块，其中，特征提取和信道恢复模块与 CsiNet 中的结构相同，而在特征压缩和解压缩模块中使用了 LSTM 网络。特征压缩模块的输入分为两个并行流，分别为 LSTM 网络和线性全连接网络 (FCN, fully-connected network)。LSTM 用于提取时变信道的时延相关性，FCN 用于跳跃连接，可以加速收敛并减少梯度消失问题。相应地，解压缩模块也包括 LSTM 网络和线性 FCN，压缩和解压缩模块的输入和输出大小是对称的。类似于残差网络，在线性 FCN 的连接作用下，LSTM 网络可以学习残差特性，而不是直接学习时间相关性，使得网络学习更稳健。比较可知，同样是使用 LSTM 提取时间相关性，文献[24]侧重于特征压缩和解压缩模块的优化，而文献[23]侧重于信道恢复模块的优化。

然而，RecCsiNet 存在训练参数过于庞大的问题，因此，文献[24]对压缩和解压缩模块的结构

进行调整，进一步提出了 PR-RecCsiNet 架构，PR-RecCsiNet 的压缩和解压缩模块如图 3(b)所示。比较图 3(a)和图 3(b)可知，RecCsiNet 以并行结构连接 FCN 和 LSTM，FCN 作为 LSTM 输入和输出之间维度变换的跳转连接；而 PR-RecCsiNet 以串行结构连接 FCN 和 LSTM，LSTM 的输入和输出因为具有相同的维度可以直接连接，FCN 映射则用于降低 LSTM 的输入维度，从而减少了整体网络的训练参数。以压缩模块将 N 维信道矩阵压缩成 M 维码字 ($M \ll N$) 为例，RecCsiNet 的网络参数为 $(NM) + (4N^2 + 4NM + 4N)$ ，而 PR-RecCsiNet 中的 LSTM 的输入维度为 M ，相应的网络参数变为 $(NM) + (4M^2 + 4M^2 + 4M)$ ，网络参数显著减少。在不同压缩率 γ 下，比较 CsiNet、CsiNet-LSTM、RecCsiNet 以及 PR-RecCsiNet 的参数复杂度和重建性能，4 种 CSI 压缩反馈网络的参数比较如表 3 所示，4 种网络在 COST 2100 信道模型的室内场景下进行测试的 NMSE 性能如图 4 所示。由图 4 的仿真结果可以看出，RecCsiNet 在各压缩率下的 NMSE 均低于 CsiNet，说明利用信道矩阵的时间相关性优化压缩和解压缩模块能够获得更高的重建精度。结合表 3 可以看出，虽然 CsiNet-LSTM 在某些压缩率下性能优于 RecCsiNet，但 CsiNet-LSTM 的参数大小几乎是 RecCsiNet 的 5 倍，而改进后的 PR-RecCsiNet 的参数复杂度显著降低。




图 3 RecCsiNet 及其变体网络结构

表 3 4 种 CSI 压缩反馈网络的参数比较

方法	γ		
	1/16	1/32	1/64
CsiNet	530 656	268 448	137 344
CsiNet-LSTM	102 009 892	101 354 404	101 026 660
RecCsiNet	19 478 584	18 118 392	17 450 584
PR-RecCsiNet	793 144	333 816	153 304




图 4 4 种网络在 COST 2100 信道模型的室内场景下进行测试的 NMSE 性能

3.3 利用双向信道互易性的信道反馈网络

在 TDD MIMO 系统中，基站可利用信道互易性获取下行链路的 CSI，而 FDD 系统由于上行链路和下行链路工作在不同频段上，信道互易性不明显，因此，需要用户端将下行链路 CSI 反馈回基站。由于上、下行链路的信道都可表示成由多径和散射体等组成的物理环境的函数，现有研究表明，FDD 系统的双向信道间存在一定的相关性，因此，文献[25]侧重于研究 FDD 系统中上、下行链路 CSI 的相关性，利用上行链路 CSI 提高下行链路 CSI 的恢复精度。

不同置信区间 (CI, confidence interval) 下 FDD 系统上行链路和下行链路 CSI 间的相关系数分布如图 5 所示^[25]，可以看出原始形式的上、下行链路 CSI 间的相关系数非常不稳定，使得在恢复下行链路 CSI 时无法使用信道互易性。通过将时延域的 CSI 变换为极坐标形式，分别考虑其幅度和相位的相关性，发现上、下行链路的 CSI 幅度表现出极强的相关性，而相位间不存在明显相关性。同样地，将 CSI 实部和虚部的符号进行分离，也发现上、下行链路 CSI 的绝对值具有较强的相关性，而符号间不存在明显的相关性。因此，用户端在对下行链路 CSI 进行压缩反馈时，可以消耗更多资源去反馈下

行链路 CSI 的相位或符号，而将其幅度或绝对值进行高度压缩以降低反馈开销。相应地，基站在对下行链路 CSI 的幅度或绝对值进行解码时，可以联合使用反馈得到的下行链路 CSI 幅度或绝对值以及自行估计获得的上行链路 CSI 幅度或绝对值，充分利用它们之间的相关性以提高下行链路 CSI 的恢复精度。




图 5 不同置信区间下 FDD 系统上行链路和下行链路 CSI 间的相关系数分布

根据上述分析，文献[25]分别利用上、下行链路 CSI 幅度和绝对值间的相关性，提出了两种 CSI 反馈架构 DualNet-MAG 和 DualNet-ABS，减少了 CSI 的反馈开销并提高重建精度。DualNet-MAG 网络结构如图 6 所示，DualNet-ABS 的结构与其类似。从图 6 中可以看出，用户端首先将需要反馈的下行链路 CSI 的幅度和相位进行分离，将幅度通过编码器进行压缩编码后反馈回基站，而相位则直接基于幅度分布进行量化再反馈回基站，因此总反馈开销中的较大比例来自于相位反馈。在进行 CSI 重建时，基站对反馈得到的下行幅度和估计得到的上行幅度进行联合译码，充分利用双向互易性提高幅度的重建精度，再加上反馈得到的量化相位即可恢复出下行 CSI。该方法显著提高了反馈效率和下行链路 CSI 的恢复准确性，并为大规模 MIMO 系统节省了大量带宽。

在训练模型时，采用 MSE 作为代价函数，并使用 Adam 优化算法更新参数。在 COST 2100 信道模型的两种场景下，设置基站天线数 $N_t=32$ ，子载波数 $\tilde{N}_c=1024$ ，生成的训练集和测试集分别包含 70 000 和 30 000 个样本。训练迭代次数、学习率和批量大小分别设为 600、0.001 和 200。使用不同压缩率对 CsiNet、DualNet-MAG 和 DualNet-ABS 进行测试，仿真结果表明，无论是在室内还是室外，

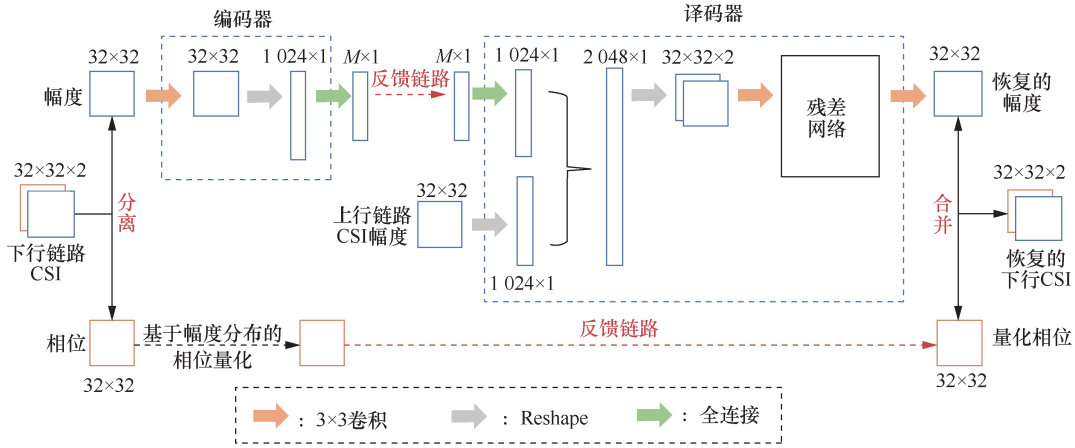


图 6 DualNet-MAG 网络结构

利用了上、下行链路间相关性的两种方法均表现出优于 CsiNet 的重建性能。另一方面，在固定的压缩率下，使用不同信噪比测试 CsiNet、DualNet-MAG 以及 DualNet-ABS 的重建性能，仿真结果表明，DualNet-MAG 和 DualNet-ABS 在所有信噪比条件下均具有比 CsiNet 更低的 NMSE，即具有更高的恢复精度，说明这两种网络对噪声的稳健性更强。此外，在绝大多数测试条件下，DualNet-MAG 都具有比 DualNet-ABS 更优越的性能，这在一定程度上也反映了上、下行链路间 CSI 幅度的相关性强于绝对值的相关性，符合图 5 给出的相关系数分布图。

3.4 基于可学习测量矩阵的 CS 网络

在 CSI 反馈机制中应用 CS 方法的一大技术挑战是对测量矩阵的设计。传统使用的随机映射测量矩阵是从高斯或伯努利分布中生成的，对实际应用中的时变信道等场景并不是最优的，且在压缩测量值不足时无法保证其恢复性能。与随机矩阵相比，确定的测量矩阵能够在更少的测量值条件下工作，在保证恢复精度的同时减少反馈参数，但确定的测量矩阵设计难度较大且无法适用于不同的信道环境。为了解决上述问题，文献[26]提出了一种使用可学习测量矩阵的 CS 方法，通过展开稀疏恢复的迭代过程，构建了数学上可解释的自动编码器

ℓ_1 -AE。

ℓ_1 -AE 神经网络结构如图 7 所示，包含 CS 线性编码器和专用多层非线性译码器。线性编码器简单地实现信道矩阵的压缩采样（编码），将压缩测量值作为译码器的输入；多层非线性译码器是通过展开 ℓ_1 最小化优化的投影子梯度下降迭代得到的，用于实现稀疏恢复。由图 7 中的译码器部分可以看出，不同于传统 DL 的黑盒设计， ℓ_1 -AE 的译码器将稀疏恢复的迭代过程展开为一系列以测量矩阵作为参数的神经网络的堆叠，继承了 DL 的数据驱动特性以及 CS 清晰的数学解释。

考虑基站天线数 $N_t = 256$ 的 MIMO 系统，生成 20 000 个信道样本并以 0.8:0.1:0.1 的比例生成训练集、校验集和测试集。采用 MSE 作为代价函数，并使用随机梯度下降（SGD, stochastic gradient descent）算法训练参数，训练迭代次数、学习率和批量大小分别设为 1 000、0.01 和 128。初始化测量矩阵 Φ 由标准差为 $\sigma=1/\sqrt{512}$ 的截断正态分布生成，译码器的层数设为 10，步长参数 α 初始化为 1.0 且在训练过程中自动更新。设 m 为压缩后的参数维度， m 越小则说明压缩程度越大，对应的反馈开销越小。将文献[26]提出的可学习测量矩阵 Φ^* 与常用的随机高斯矩阵 G 、随机伯努利矩阵 B 、部分




图 7 ℓ_1 -AE 神经网络结构

傅立叶矩阵 F 、随机选择矩阵 S 以及随机移相器矩阵 P 分别用于 CS，不同测量矩阵的精确恢复百分比如表 4 所示。仿真结果表明，在 $m \leq 25$ 时，绝大多数测量矩阵已无法工作，而可学习测量矩阵 Φ^* 仍然保持着较高的精确恢复度。不同测量矩阵进行稀疏恢复的归一化根平均误差(NRSE, normalized root square erro) 性能如图 8 所示，可以看出与随机矩阵相比，可学习测量矩阵 Φ^* 具有最低的 NRSE，即可以通过更少的测量值实现与其他测量矩阵相同水平的恢复精度，这在实际应用中意味着更少的资源开销和更高的频谱效率。归纳来说，相比于传统使用的随机映射，可学习测量矩阵能够更有效地利用信道数据集的隐藏数据结构特征，从而可将信道矩阵压缩成更小维度的压缩测量值，同时获得更高的恢复精度。

表 4 不同测量矩阵的精确恢复百分比

测量矩阵	$m=20$	$m=25$	$m=30$	$m=35$	$m=40$
Φ^*	95.90%	98.70%	99.60%	100%	100%
F	0.90%	7.85%	89.20%	99.80%	99.75%
S	5.30%	30.15%	72.70%	90.00%	98.45%
B	5.90%	26.80%	63.10%	87.70%	99.10%
G	2.15%	13.45%	58.50%	84.75%	97.70%
P	0	0	0.45%	1.00%	6.85%




图 8 不同测量矩阵进行稀疏恢复的 NRSE 性能

3.5 其他改变结构的变体网络

随着文献[19]首次将 DL 技术应用于大规模 MIMO 系统的 CSI 反馈，国内外研究者在如何更好地利用神经网络进一步降低反馈开销、提高恢复精度等性能指标上进行了大量研究，文献[23-24]引入

LSTM 提取 CSI 的时间相关性、文献[25]通过分析信道互易性以利用上行链路 CSI 辅助下行链路 CSI 重建以及文献[26]应用可学习测量矩阵代替传统使用的随机测量矩阵，这些方案都在提升反馈性能的同时提供了开创性的设计思路。另有部分文献^[27-28]在已有反馈方案的基础上，对网络结构进行调整或替换，也在一定程度上提升了网络性能。

文献[27]在 RecCsiNet^[24]的基础上，提出了 ConvLSTMCsiNet 网络架构，进一步在特征提取模块中引入 LSTM，并采用 P3D (Pseudo-3D) 模块对信道矩阵在时间域和空间域的特征进行分开提取。不同于特征压缩模块和特征解压缩模块采用的 LSTM，特征提取模块采用的是 ConvLSTM (convolutional LSTM)，是 LSTM 的一种变体。由于卷积操作比线性操作具有更少的参数，因此，采用 ConvLSTM 有助于减少网络参数，更适用于特征提取。仿真结果表明，ConvLSTMCsiNet 在各压缩比下的性能均优于 RecCsiNet。

文献[28]也在网络结构中引入了 LSTM，但不同于文献[23-24,27]利用 LSTM 提取时间相关性，文献[28]将 CsiNet 编码器和译码器中的全连接层替换成了 LSTM 网络，用于提取 CSI 子载波间的相关性，提高了恢复性能，并显著减少了参数开销。同时，还在译码器中引入了循环神经网络 (RNN, recurrent neural network) 中的 Attention 机制，提出了一种 Attention-CsiNet 网络架构，通过学习对不同的特征图赋予不同的 Attention 权重，充分利用特征信息进行信道恢复。仿真结果表明，Attention-CsiNet 在各压缩比下的重建性能均优于 CsiNet。

这些方案对已有设计思路进行修改完善，进一步推动了基于 DL 的大规模 MIMO 系统的 CSI 反馈相关技术的发展。

4 未来展望

上述所有基于 DL 的 CSI 反馈方案均在一定程度上弥补了传统方法存在的不足，在低压缩率下仍然具有良好的重建性能，在显著减少反馈开销的同时保证了 CSI 重建精度，在未来移动通信系统中具有广阔的应用前景。虽然基于 DL 的 CSI 反馈方案在重建精度、时间复杂度等指标上具有极大的性能优势，但将 DL 技术应用于 CSI 反馈仍然处于探索初期，还面临着许多问题和挑战亟待未来展开进一

步讨论与研究。

1) 网络结构创新：现有基于 DL 的反馈方案均采用基于自动编码器的网络结构。文献[24]将 CS 算法的迭代过程进行展开，虽然具有清晰的数学解释，但这种方法只是对传统 CS 算法的改进，并没有带来本质突破或学习新的算法；而其余方案均用神经网络对传统算法进行完全替换，以数据驱动方式自主学习信道结构特征进行压缩和解压缩，可视为一种黑盒结构，无法解释基于 DL 的方法能够取得优异性能的原因且性能不可控。因此，可以考虑利用已有的信道模型设计新的网络结构，提出模型驱动反馈方案。

2) 量化误差的影响：为了实现高效的存储、传输和处理，在实际应用中编码将在量化后以比特流形式进行发送。在现有方案中，用户端大多直接将浮点型压缩编码通过反馈链路传回基站，在严格的信息论意义上并不是真正的压缩，而是一种降维，忽略了实际无线通信系统中量化误差的影响。引入量化误差会对网络的重建精度产生较大影响，因此，需要设计对量化误差稳健的 CSI 反馈网络。

3) 多速率压缩：不同信道环境下的 CSI 稀疏特性不同，压缩率固定的网络不能很好地适应特征粒度的变化，但现有基于 DL 的反馈方案均只能以固定压缩率对 CSI 矩阵进行压缩。若要根据信道环境调整压缩率，用户端就需要存储若干个网络架构和相应的参数集，这对存储空间有限的用户端显然是不可取的，因此，设计实现多速率压缩的 CSI 反馈架构具有极大的现实意义。

4) 从仿真到实际部署：现有基于 DL 的 CSI 反馈方案均停留在仿真阶段，缺少实际系统支持。同时，这些网络架构采用的数据集均由特定的仿真信道（如 COST 2100 信道模型）生成，而实际信道场景复杂多变，无法保证这些网络还能有较好的重建性能或继续工作。因此，为了在实际部署前进一步完善基于 DL 方案的性能，需要研究者收集实际通信系统的真实数据集，对 DL 网络架构进行训练，评估其在真实信道环境下的性能和适用性，并与现有的 CSI 反馈性能进行比较。此外，现有反馈网络都具有较为庞大的网络参数，不利于实际部署，根据文献[29]对 DL 模型压缩与加速的研究，可设计更轻量化的网络，减少网络参数，为未来部署奠定基础。

5 结束语

本文首先介绍了大规模 MIMO 系统下 CSI 反馈的研究背景和研究现状，分析了传统基于码本和矢量量化方法以及 CS 方法在 FDD 大规模 MIMO 系统中进行 CSI 反馈时存在的问题和局限性，然后详细阐述了国内外研究者将 DL 技术引入 CSI 反馈机制中的方案，包括基于自动编码器的信道反馈网络、引入 LSTM 的时变信道反馈网络、利用双向信道互易性的信道反馈网络以及基于可学习测量矩阵的 CS 网络。这 4 种基于 DL 的 CSI 反馈方案从不同角度对传统方法进行了改进，仿真结果表明，上述方法在一定程度上解决了传统方法存在的问题，能够在保证 CSI 重建精度的同时，显著减少大规模 MIMO 系统的反馈开销。目前，基于 DL 的 CSI 反馈设计的相关研究仍然处于初步探索阶段，还面临着许多问题与挑战，但其表现出的性能优势与发展潜力使之成为 FDD 大规模 MIMO 系统的主流研究方向之一。

参考文献：


- [1] WONG V S, SCHOBER R, NG D W K, et al. Key technologies for 5G wireless systems[M]. Cambridge: Cambridge University Press, 2017.
- [2] YANG P, XIAO Y, XIAO M, et al. 6G wireless communications: vision and potential techniques[J]. IEEE Network, 2019, 33(4): 70-75.
- [3] 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.
- [4] ZHOU Y, HERDIN M, SAYEED A M, et al. Experimental study of MIMO channel statistics and capacity via the virtual channel representation[D]. Madison: University of Wisconsin-Madison, 2007.
- [5] KYRITSIS 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.
- [6] KUO P H, KUNG H T, TING P A. Compressive sensing based channel feedback protocols for spatially-correlated massive antenna arrays[C]//2012 IEEE Wireless Communications and Networking Conference (WCNC). IEEE, 2012: 492-497.
- [7] RAO X B, LAU V K. Distributed compressive CSIT estimation and feedback for FDD multi-user massive MIMO systems[J]. IEEE Transactions on Signal Processing, 2014, 62(12): 3261-3271.
- [8] SHEA T O, HOYDIS J. An introduction to deep learning for the physical layer[J]. IEEE Transactions on Cognitive Communications and Networking, 2017, 3(4): 563-575.
- [9] QIN Z J, YE H, LI G Y, et al. Deep learning in physical layer communications[J]. IEEE Wireless Communications, 2019, 26(2): 93-99.
- [10] 张静, 金石, 温朝凯, 等. 基于人工智能的无线传输技术最新研究进展[J]. 电信科学, 2018, 34(8): 46-55.
ZHANG J, JIN S, WEN C K, et al. An overview of wireless transmis-

- sion technology utilizing artificial intelligence[J]. Telecommunications Science, 2018, 34(8): 46-55.
- [11] WANG T Q, WEN C K, WANG H Q, et al. Deep learning for wireless physical layer: opportunities and challenges[J]. China Communications, 2017, 14(11): 92-111.
- [12] WEN C K, JIN S, WONG K K, et al. Channel estimation for massive MIMO using Gaussian-mixture Bayesian learning[J]. IEEE Transactions on Wireless Communications, 2015, 14(3): 1356-1368.
- [13] DAUBECHIES I, DEFRISE M, MOL C D. An iterative thresholding algorithm for linear inverse problems with a sparsity constraint[J]. Communications on Pure and Applied Mathematics, 2003, 57(11): 1413-1457.
- [14] DONOHO D L, MALEKI A, MONTANARI A. Message passing algorithms for compressed sensing[J]. Proceedings of the National Academy of Sciences of the United States of America, 2009, 106(45): 18914-18919.
- [15] LI C, YIN W, ZHANG Y. TVAL3: TV minimization by augmented Lagrangian and alternating direction algorithms[E/OL]. 2013.
- [16] METZLER C A, MALEKI A, BARANIUK R G. From denoising to compressed sensing[J]. IEEE Transactions on Information Theory, 2016, 62(9): 5117-5144.
- [17] LOHIT S, KULKARNI K, KERVICHE R, et al. Convolutional neural networks for non-iterative reconstruction of compressively sensed images[J]. IEEE Transactions on Computational Imaging, 2018, 4(3): 326-340.
- [18] MOUSAVI A, DASARATHY G, BARANIUK R G. DeepCodec: adaptive sensing and recovery via deep convolutional neural networks[J]. arXiv: 1707.03386, 2017.
- [19] 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.
- [20] VINCENT P, LAROCHELLE H, BENGIO Y, et al. Extracting and composing robust features with denoising autoencoders[C]//Proceedings of the 25th International Conference on Machine Learning (ICML). ACM, 2008: 1096-1103.
- [21] LIU L F, OESTGES C, POUTANEN J, et al. The COST 2100 MIMO channel model[J]. IEEE Wireless Communications, 2012, 19(6): 92-99.
- [22] XU K, REN F B. CSVideoNet: a real-time end-to-end learning framework for high-frame-rate video compressive sensing[C]//2018 IEEE Winter Conference on Applications of Computer Vision (WACV). IEEE, 2018: 1680-1688.
- [23] WANG T Q, WEN C K, JIN S, et al. Deep learning-based CSI feedback approach for time-varying massive MIMO channels[J]. IEEE Wireless Communications Letters, 2019, 8(2): 416-419.
- [24] LU C, XU W, SHEN H, et al. MIMO channel information feedback using deep recurrent network[J]. IEEE Communications Letters, 2019, 23(1): 188-191.
- [25] LIU Z Y, ZHANG L, DING Z. Exploiting bi-directional channel reciprocity in deep learning for low rate massive MIMO CSI feedback[J]. IEEE Wireless Communications Letters, 2019, 8(3): 889-892.
- [26] WU P X, LIU Z C, CHENG J L. Compressed CSI feedback with learned measurement matrix for mmWave massive MIMO[J]. arXiv: 1903.02127, 2019.
- [27] LI X Y, WU H M. Spatio-temporal representation with deep neural recurrent network in MIMO CSI feedback[J]. IEEE Wireless Communications Letters, 2020.
- [28] CAI Q Y, DONG C, NIU K. Attention model for massive MIMO CSI compression feedback and recovery[C]//2019 IEEE Wireless Communications and Networking Conference (WCNC). IEEE, 2019.
- [29] GUO J J, WANG J H, WEN C K, et al. Compression and acceleration of neural networks for communications[J]. arXiv: 1907.13269, 2019.

[作者简介]



陈慕涵（1997-），女，江苏南通人，东南大学移动通信国家重点实验室硕士生，主要研究方向为基于深度学习的信道状态信息反馈、机器学习等。



郭佳佳（1993-），男，江苏泰兴人，东南大学移动通信国家重点实验室博士生，主要研究方向为基于深度学习的信道状态信息反馈等。



李潇（1982-），女，安徽蚌埠人，博士，东南大学移动通信国家重点实验室副教授、硕士生导师，主要研究方向为移动通信理论与关键技术、智能通信以及智能反射表面在无线通信中的应用等。



金石（1974-），男，安徽黄山人，博士，东南大学移动通信国家重点实验室教授、博士生导师，主要研究方向为移动通信理论与关键技术、物联网理论与关键技术以及人工智能在无线通信中的应用等。