

基于深度学习的频分复用大规模多输入多输出下行信道状态信息获取技术

桂冠, 王洁, 杨洁, 刘淼, 孙金龙

(南京邮电大学通信与信息工程学院, 南京 210003)

摘要: 大规模多输入多输出 (Multiple input multiple output, MIMO) 技术的演进是第 6 代 (The sixth generation, 6G) 无线通信系统性能进一步提升的重要支撑。随着天线阵列规模的持续扩大, 频分复用 (Frequency division duplexing, FDD) 大规模 MIMO 系统获取下行信道状态信息 (Channel state information, CSI) 面临着严峻挑战。深度学习具有强大的学习及处理高维数据的能力, 能够为解决这一挑战提供新的方案。本文综述了基于深度学习的 FDD 大规模 MIMO 下行 CSI 获取技术, 包括 CSI 反馈和预测技术。首先给出了基于深度学习的 CSI 反馈和预测的原理框架, 其次分析比较了国内外相关研究成果的优越性能, 为解决面向 6G 的 FDD 大规模 MIMO 系统获取下行 CSI 问题提供了可行的参考方案。最后讨论了 FDD 大规模 MIMO 下行 CSI 获取的有待进一步解决的开放性问题以及所对应的潜在研究方案。

关键词: 信号与信息处理; 频分复用; 大规模 MIMO; 信道状态信息; 深度学习

中图分类号: TN929.5 **文献标志码:** A

Frequency Division Duplex Massive Multiple-input Multiple-output Downlink Channel State Information Acquisition Techniques Based on Deep Learning

GUI Guan, WANG Jie, YANG Jie, LIU Miao, SUN Jinlong

(College of Information and Telecommunications Engineering, Nanjing University of Posts and Telecommunications, Nanjing 210003, China)

Abstract: The evolution of massive multiple-input multiple-output (MIMO) techniques is an important support for further improving the performance of six-generation (6G) wireless communication systems. However, with the continuous expansion of large-scale antenna arrays, frequency division duplex (FDD) massive MIMO systems are facing severe challenges in acquiring downlink channel state information (CSI). Deep learning has a powerful ability to learn and process high-dimensional data, which provides a potential solution to this challenge. In this paper, we survey FDD massive MIMO downlink CSI acquisition techniques based on deep learning, including CSI feedback and prediction techniques. Firstly, the theoretical frameworks of CSI feedback and prediction based on deep learning are presented. Then, the superior performance of relevant research results at home and abroad is analyzed, providing a reference scheme for solving the problem of acquiring downlink CSI in FDD massive MIMO systems towards 6G.

Finally, unsolved open problems of FDD massive MIMO downlink CSI acquisition are discussed, followed by potential solutions correspondingly.

Key words: signal and information processing; frequency division; massive MIMO; channel state information; deep learning

引 言

大规模多输入多输出(Multiple input multiple output, MIMO)技术在2010年由Marzetta教授提出^[1],其能够显著提高无线通信系统的频谱效率和系统容量。经过10余年的研究,大规模MIMO技术已成功应用在第5代(The fifth generation, 5G)移动通信系统中。通过持续增大天线阵列规模,超大规模MIMO技术将是未来第6代(The sixth generation, 6G)移动通信系统进一步提升网络性能的关键技术之一^[2-3]。但是,基站能够获取精确的下行信道状态信息(Channel state information, CSI)是大规模MIMO技术实现系统增益的前提^[4]。目前,大规模MIMO系统通常工作在时分双工(Time division duplexing, TDD)通信模式下,通过利用上下行信道的互易性,可以由上行链路的CSI估计直接获取下行链路CSI,避免了巨大的下行CSI获取开销。与TDD通信模式相比,频分双工(Frequency division duplexing, FDD)通信模式具有传输速率高、可连续通信以及适用于高速移动场景等优势。同时,现有大量通信系统仍采用FDD通信模式。为利用FDD通信模式的先天优势并减少更换通信模式所带来的资源浪费和性能损耗,FDD大规模MIMO系统近期得到了广泛关注和研究。在FDD模式下,上下行信道不具有严格的互易性,基站获取下行CSI需要用户进行下行CSI估计和反馈^[5]。由于下行CSI估计的导频开销和反馈的链路开销与基站端天线数成正比,使FDD大规模MIMO系统面临的巨大挑战之一是下行CSI获取的巨大导频和反馈开销。目前,FDD系统通常使用基于码本和基于压缩感知的CSI反馈技术。但随着基站端天线阵列规模不断扩大,码本的设计非常困难,使基于码本的CSI反馈技术不再适用于FDD大规模MIMO系统。高维度CSI矩阵也使基于压缩感知的CSI反馈技术具有较高的计算复杂度和较低的反馈精度。近年来,深度学习(Deep learning, DL)被应用于各个领域,并表现出了卓越的性能,如零部件缺陷检测^[6]、推荐系统^[7]等。已有大量工作有效使用DL解决无线通信问题,包括波束赋形^[8]、信道估计^[9]等。由此可见,DL具有学习、处理高维数据的强大能力,能够为解决FDD大规模MIMO系统获取高维下行CSI问题提供了潜在解决方案。

基于DL的FDD大规模MIMO下行CSI获取技术主要分为两类,分别是基于DL的下行CSI反馈技术和基于DL的下行CSI预测技术。基于DL的下行CSI反馈技术利用神经网络充分学习CSI矩阵的内在特征,实现对CSI矩阵的自动压缩与重建,在降低CSI反馈开销的同时提高CSI反馈精度。然而,基于DL的下行CSI反馈技术无法避免FDD大规模MIMO系统中下行CSI估计开销。针对这一问题,基于DL的下行CSI预测技术能够利用DL强大的学习能力和FDD系统中上下行链路之间的部分互易性,由上行CSI直接映射出下行CSI。为促进FDD大规模MIMO系统的实际部署及面向6G的技术演进,本文首先给出了两种基于DL的FDD大规模MIMO下行CSI获取技术的原理框架,然后对国内外相关研究进展进行了分析比较,最后对基于DL的FDD大规模MIMO下行CSI获取技术的未来发展做出进一步展望。

1 基于DL的FDD大规模MIMO下行CSI反馈技术

1.1 基于DL的CSI反馈技术框架

假设用户通过信道估计算法从基站发送的导频信号中已经估计出了下行CSI矩阵 H_d ,只关注下行

CSI的反馈过程。如图1所示,在基于DL的CSI反馈技术中,用户和基站分别配备基于神经网络的编码器和解码器。首先,部署在用户端的编码器会实现对CSI矩阵 H_d 的压缩,压缩得到的向量将由均匀或非均匀量化器进行量化,得到最终需要反馈的码字 s_d^{cq} 。令 $f_{en}(\cdot)$ 和 $f_Q(\cdot)$ 分别代表压缩函数和量化函数,则经过零误差反馈,基站端接收到的用户反馈的下行CSI可以表达为

$$s_d^{cq} = f_Q\left(f_{en}\left(H_d, \Phi_1\right)\right) \quad (1)$$

式中 Φ_1 表示编码器中神经网络的权重参数。

当基站接收到 s_d^{cq} 后,部署在基站的解码器会对其进行量化译码及重建以恢复出原始的下行CSI。令 $f_{de}(\cdot)$ 和 $f_Q^{-1}(\cdot)$ 分别代表重建函数和量化译码函数,则基站端恢复出的下行CSI可以表示为

$$\hat{H}_d = f_{de}\left(f_Q^{-1}\left(s_d^{cq}\right), \Phi_2\right) \quad (2)$$

式中 Φ_2 表示解码器中神经网络的权重参数。整个基于DL的CSI反馈过程可以表示为

$$\hat{H}_d = f_{de}\left(f_Q^{-1}\left(f_Q\left(f_{en}\left(H_d, \Phi_1\right)\right)\right), \Phi_2\right) \quad (3)$$

编码器和解码器一起进行端到端训练,根据代价函数和梯度下降法训练得到权重参数 Φ_1 和 Φ_2 。

1.2 相关研究进展

Wen等^[10]首次提出了一种基于DL的下行CSI反馈技术(称为CsiNet),其网络结构如图2所示。在用户端,CsiNet使用1个卷积层和2个全连接层构成编码器,实现对下行CSI的压缩,输出压缩后未量化的浮点型码字 s_d^c 。在基站端,CsiNet首先利用1个全连接层恢复出下行CSI的原始维度,然后利用2个残差网络对初始恢复的下行CSI进行更精确的恢复,最后再经过1个卷积层输出下行CSI的估计。压缩后向量 s_d^c 的元素个数与原始CSI矩阵中元素个数的比值称为压缩率 γ 。

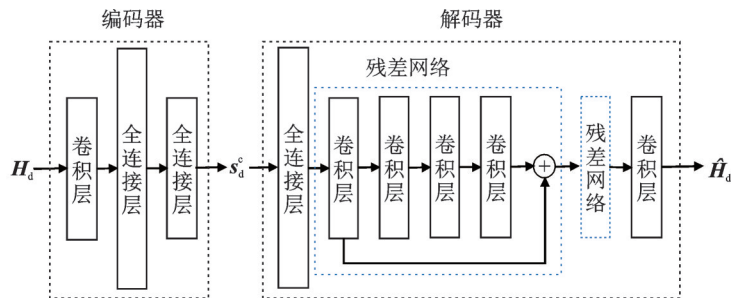


图2 CsiNet的网络结构

Fig.2 Network structure of CsiNet

CsiNet在COST 2100信道模型上进行性能验证,包括频率为5.3 GHz的室内微蜂窝场景和频率为300 MHz的乡村户外场景。以归一化均方误差(Normalized mean square error, NMSE)作为衡量下行CSI反馈精度的性能指标,并与3个基于压缩感知的CSI反馈方案(BM3D-AMP^[11]、TVAL3^[12]以及LASSO^[13])进行性能比较,各方案的下行CSI反馈性能如表1所示。从表1中可以看出,基于CsiNet的




图1 基于DL的CSI反馈技术框架

Fig.1 Theoretical framework of CSI feedback based on DL

下行CSI反馈精度在2个场景中的所有压缩率下都高于3个基于压缩感知的CSI反馈技术。同时,CsiNet的计算时间远小于上述3个压缩感知算法的计算时间。上述实验结果证明了基于DL的CSI反馈技术的有效性。

CsiNet的网络结构相对比较简单,通过设计更复杂、更合理的神经网络结构可以更加充分提取CSI数据内部特征,进一步提高CSI反馈精度。Lu等^[14]将多分辨率网络引入到CSI反馈技术中,提出了信道重建网络(Channel reconstruction network, CRNet),取得了比CsiNet更高的CSI反馈精度,其网络结构如图3所示。其中 $a \times b$ 表示卷积层的卷积核大小,每个卷积层后面都连接了1个批归一化(Batch normalization, BN)层。在用户端,CRNet用多个具有不同卷积核大小的卷积层学习CSI数据的内部特征,然后用全连接层将学习到的特征压缩为未量化的浮点型码字 s_d^c 。在基站端,CRNet首先通过1个全连接层恢复出下行CSI的原始维度,然后送入1个卷积层,最后通过2个信道重建模块(Channel reconstruction block, CRBlock)对下行CSI进行精确恢复,并输出下行CSI的估计结果。

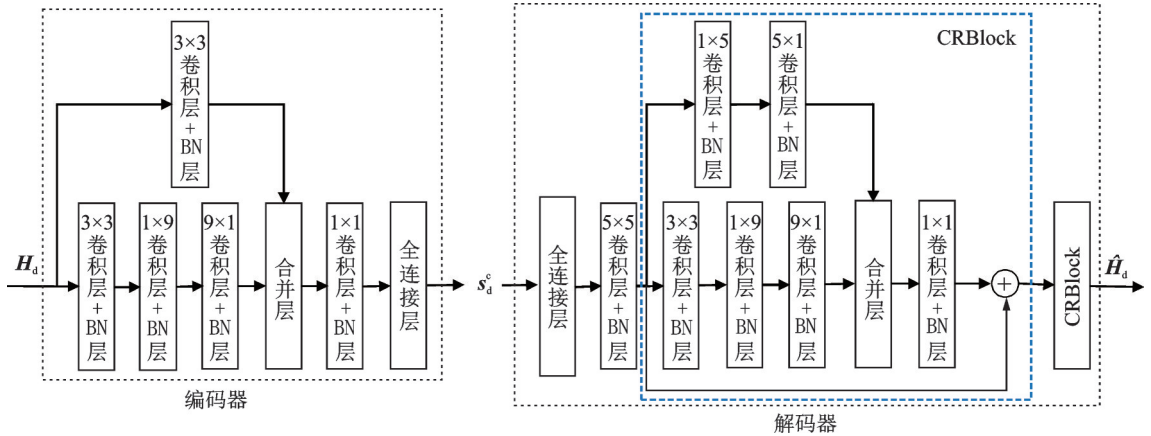


图3 CRNet的网络结构

Fig. 3 Network structure of CRNET

CRNet的核心设计是采用了2个CRBlock,每个CRBlock各由两路具有不同卷积核大小的卷积层并行组成,然后用1个卷积核大小为 1×1 的卷积层合并两路输出特征。通过给神经网络添加并行的、具有不同卷积核大小的卷积层,可以让神经网络自己学习到合适的不同卷积核大小的组合,提高了神经网络提取数据特征的能力。同时,当CRNet以动态的学习速率训练神经网络时,它与CsiNet在COST 2100信道模型上的NMSE性能对比如表2所示。从表2中可以看出,CRNet在室内、室外两

表1 CsiNet与压缩感知算法的NMSE性能对比

Table 1 NMSE performance comparison between Csi-Net and compressed sensing algorithms

场景	γ	NMSE/dB			
		BM3D-AMP	TVAL3	LASSO	CsiNet
室内	1/4	-4.33	-14.87	-7.59	-17.36
	1/16	0.26	-2.61	-2.72	-8.65
	1/32	24.72	-0.27	-1.03	-6.24
	1/64	26.22	0.63	-0.14	-5.84
室外	1/4	-1.33	-6.9	-5.08	-8.75
	1/16	0.55	-0.43	-1.01	-4.51
	1/32	22.66	0.46	-0.24	-2.81
	1/64	25.45	0.76	-0.06	-1.93

表2 CRNet与CsiNet的NMSE性能对比

Table 2 NMSE performance comparison between CRNet and CsiNet

场景	γ	dB			
		1/4	1/16	1/32	1/64
室内	CsiNet	-17.36	-8.65	-6.24	-5.84
	CRNet	-26.99	-11.35	-8.93	-6.49
室外	CsiNet	-8.75	-4.51	-2.81	-1.93
	CRNet	-12.71	-5.44	-3.51	-2.22

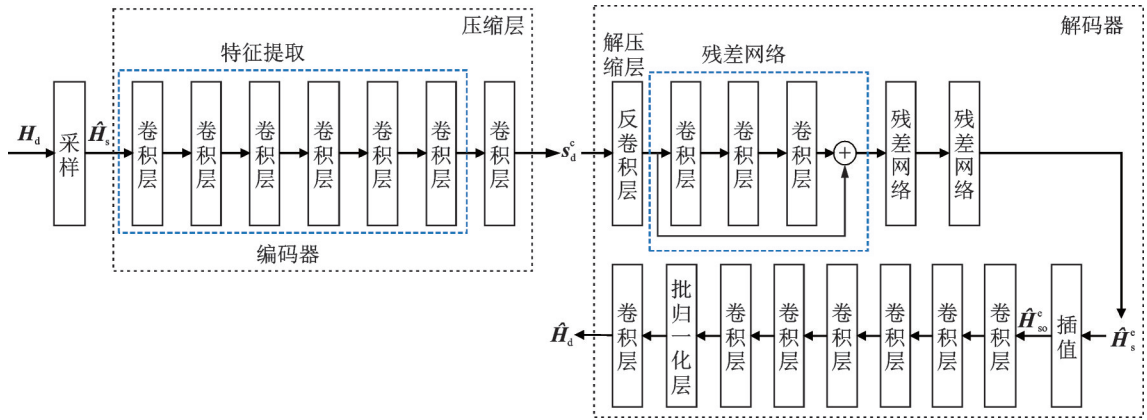


图4 SampleDL技术中整个CSI反馈流程

Fig.4 Entire CSI feedback process in sampleDL

个场景下的所有压缩率上的性能都优于CsiNet,这说明通过设计更复杂、更合理的神经网络结构可以进一步提高基于DL的CSI反馈精度。

不同于上述基于数据驱动的方案,通过引入其他特定的网络结构,另一类基于DL的高精度CSI反馈技术被提出^[15-17],即将CSI数据的先验知识引入到基于DL的CSI反馈中,通过知识和数据双驱动的神经网络及深度学习实现更高的CSI反馈精度。基于此,Wang等^[18]提出了基于采样与DL的CSI反馈技术(称为SampleDL),通过采样将信道在时间、频率两个维度上具有相关性这一先验知识引入深度学习,在降低神经网络计算复杂度的同时提高了CSI反馈精度。基于SampleDL的整个CSI反馈流程如图4所示。在用户端,SampleDL技术首先对下行CSI的 H_d 进行采样,得到采样后的CSI数据 \tilde{H}_s ,然后将 \tilde{H}_s 送入编码器中进行特征提取,并用卷积层实现对 \tilde{H}_s 的压缩,输出压缩后的码字 s_d^c 。在SampleDL方案中,CSI矩阵的总压缩率 R_T 定义为采样压缩率 R_s 与空间压缩率 R_c 的乘积,其中 R_s 为 \tilde{H}_s 中元素个数与 H_d 中元素个数的比值, R_c 为 s_d^c 中元素个数与 \tilde{H}_s 中元素个数的比值。在基站端,SampleDL技术首先用一个反卷积层将压缩码字 s_d^c 恢复到与 \tilde{H}_s 一样的维度;然后用3个残差网络对其精确恢复,并输出对 \tilde{H}_s 的恢复值 \tilde{H}_s^c ,再对 \tilde{H}_s^c 进行插值操作,使其恢复到与原始CSI H_d 一样的维度,记为 $\tilde{H}_{s_0}^c$;最后通过7个卷积层对 $\tilde{H}_{s_0}^c$ 进行精确恢复,并输出下行CSI的最终估计值 \hat{H}_d 。

SampleDL技术在符合3GPP TR 38.901标准的nrCDLChannel信道模型^[19]上进行性能评估,并与CRNet的性能进行比较。SampleDL技术和CRNet中的卷积层均采用三维卷积层,且均通过卷积层实现对CSI的压缩与重建,对压缩层和重建层设置不同的卷积步长可实现不同的压缩率。通过结合采样和DL,基于SampleDL的CSI反馈技术在提高CSI反馈精度的同时具有更低的计算复杂度。表3给出了SampleDL和CRNet中神经网络的总浮点运算数(Floating point operations, FLOPs)。从表3中可以看出,SampleDL的FLOPs数比CRNet的FLOPs数少了 6.2037226×10^9 次,这将降低整个CSI反馈过程的计算复杂度与开销。SampleDL技术具有较低时间复杂度的原理在于,编码器的输入和3个残差网络的输入及输出是采样后的CSI矩阵,大大减小了编码器和残差网络中各网络层的数据张量维度。文献[18]采用NMSE作为衡量CSI反馈精度的评价指标,并对下行CSI反馈过程中引

表3 SampleDL与CRNet的FLOPs比较

Table 3 Comparison of FLOPs between SampleDL and CRNet

R_T	CRNet	SampleDL
1/84	$2.14039570 \times 10^{10}$	$1.52002344 \times 10^{10}$
1/168	$2.14038740 \times 10^{10}$	$1.52001514 \times 10^{10}$
1/336	$2.14038325 \times 10^{10}$	$1.52001099 \times 10^{10}$
1/672	$2.14038117 \times 10^{10}$	$1.52000892 \times 10^{10}$

入量化后的性能进行验证和分析。

通过采用均匀量化技术,表4给出了在量化位数为8位和6位时,SampleDL和CRNet在不同压缩率下的NMSE性能对比。从表4中可以得到,SampleDL的NMSE性能在不同的量化位数和不同的压缩率下都优于CRNet。SampleDL的性能增益来自两个方面:一方面是当使用相同结构的神经网络对数据进行相同操作时,小维度数据能够取得比大维度数据更好的性能;另一方面是

在时间和频率维度上的采样和插值过程向神经网络引入了信道在时间和频率上具有相关性的先验知识,使得SampleDL技术在CSI恢复精度上高于仅仅使用三维卷积层学习CSI内在结构的性能。

随着研究的深入,在未来实际部署中存在的量化问题、多压缩率问题、安全性问题以及网络轻量化问题也已经开始被提出和研究^[20-22]。Guo等^[20]首次在基于DL的端到端CSI反馈框架中引入量化操作,并提出了2个在单次训练下可实现多压缩率的编码器框架(SM-CsiNet+和PM-CsiNet+)。与通过训练不同的编码器实现不同的压缩率相比,SM-CsiNet+和PM-CsiNet+分别使用户端的参数数量减少了38.0%和46.7%。量化和多压缩率的引入使基于DL的CSI反馈技术向实际部署又迈进了一步。通过引入自注意力机制和密集连接,Song等^[21]提出了一种新的多压缩率网络结构,实现了比SM-CsiNet+更高反馈精度。Fan等^[22]使用卷积层实现CSI的压缩与解压缩,在提高CSI反馈精度的同时大幅度降低了神经网络的训练参数和计算复杂度。针对相对固定的通信场景,Guo等^[23]提出了以用户为中心进行在线学习的端到端CSI反馈框架,讨论了3种在线学习方法,仿真结果表明该框架能够在低训练开销下提高特定场景下的CSI反馈精度。

上述基于DL的CSI反馈技术证明了用DL降低下行CSI反馈开销、提高反馈精度的有效性。相关研究针对DL在实际部署中所面临的问题和特定通信场景下CSI反馈精度提升问题提出了研究方案和性能验证,为FDD大规模MIMO系统获取下行CSI提供了潜在解决方案。

2 基于DL的FDD大规模MIMO下行CSI预测技术

2.1 基于DL的CSI预测技术框架

在基于DL的下行CSI预测技术中,通常将CSI矩阵作为图像数据进行处理。图像数据是具有1个或多个通道的二维实数矩阵。上行CSI和下行CSI均是1个复数矩阵,其数据形式与图像数据非常相似,可以将复数CSI矩阵考虑为1个具有两通道的实数值矩阵,复数矩阵的实部作为第1通道,复数矩阵的虚部作为第2通道。如图5所示,在基于DL的CSI预测技术中,将上行CSI数据作为神经网络的输入,下行CSI数据作为神经网络的输出,通过学习上下行链路之间的信道相关性,由上行CSI直接预测出下行CSI的 H_d 。用 Φ_{pre} 表示神经网络的权重参数, $f_{pre}(\cdot)$ 表示神经网络的拟合函数,则基于DL的下行CSI预测过程可以表示为

$$H_d = f_{pre}(H_u, \Phi_{pre}) \quad (4)$$

表4 SampleDL与CRNet的NMSE性能比较
Table 4 NMSE performance comparison between SampleDL and CRNet

量化位数	R_T	1/84	1/168	1/336	1/672
8位	CRNet	-22.60	-20.22	-18.03	-11.80
	SampleDL	-31.11	-30.01	-27.15	-18.10
6位	CRNet	-22.22	-19.21	-15.40	-11.78
	SampleDL	-29.14	-28.49	-19.08	-15.32




图5 基于DL的CSI预测技术框架

Fig.5 Theoretical framework of CSI prediction based on DL

2.2 相关研究进展

Safari等^[24]首次提出用神经网络从上行CSI直接预测下行CSI的思想,并提出了基于卷积神经网络(Convolutional neural network, CNN)的下行CSI预测技术,该技术用7个卷积层实现了由上行CSI的 H_u 预测下行CSI的 \hat{H}_d ,如图6所示,其中每1层上的数字为该层的卷积核个数。仿真结果证明了该方案的有效性,为未来FDD大规模MIMO系统获取下行CSI提供了可参考的低开销方案。

为充分学习上下行CSI之间在时隙、频率和空间3个维度上的相关性,提高下行CSI预测精度,Wang等^[25]将由上行CSI预测下行CSI建模为一个时空图像预测问题,并用卷积长短期记忆网络(Convolutional long short term memory network, ConvLSTM-Net)解决该问题。ConvLSTM-Net由5个卷积长短期记忆(ConvLSTM)层和1个3维卷积层(Conv3D)构成,如图7所示。其中,每一层旁边的数字为该层的卷积核个数,每一个ConvLSTM层都使用“tanh”作为激活函数,且都串联一个批归一化层,最后一个Conv3D层使用线性激活函数。

基于ConvLSTM-Net的下行CSI预测技术在扩展车辆(Extended vehicular A, EVA)信道模型上进行性能验证,探索了在频域信道数据和时域信道数据上的性能差异,并与基于CNN的下行CSI预测技术进行对比,在不同数据以及不同卷积核大小下NMSE性能对比如表5所示。通过表5可以看出,CNN在信道的频域数据上具有更好的预测性能,而ConvLSTM-Net在信道的时域数据上具有更好的预测性能,但不同域、不同神经网络以及CSI预测性能之间的关系仍需要进一步探索和研究。此外,在不同的域和不同的卷积核大小下,ConvLSTM-Net都具有比CNN更高的预测精度,这是因为ConvLSTM层将长短期记忆单元中输入与状态之间的全连接操作、状态之间转换的全连接操作全都替换为了卷积操作,使ConvLSTM-Net同时具有很强的学习数据空间特征和时间相关性的能力^[26]。但是,ConvLSTM-Net具有比CNN更高的计算复杂度,因此在工程应用中还需要进一步对预测精度和神经网络的计算复杂度进行权衡。

上述两种基于DL的CSI预测技术的性能证明了使用DL直接预测下行CSI的可行性。针对CSI矩阵的复数结构,Yang等^[27]和Zhang等^[28]提出基于复数神经网络的下行CSI预测技术。仿真实验结果表明,复数神经网络在预测精度方面优于实数神经网络,但也具有比实数神经网络更高的计算复杂度。随着研究的深入,针对实际部署中会遇到的神经网络泛化问题,基于迁移学习^[29]和联邦学习^[30]的下行CSI技术也开始被研究。针对特定环境下




图6 基于CNN的下行CSI预测技术

Fig. 6 Downlink CSI prediction technology based on CNN

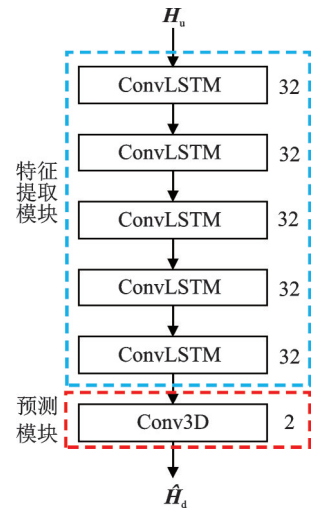


图7 基于ConvLSTM-Net的下行CSI预测技术

Fig. 7 Downlink CSI prediction technology based on ConvLSTM-Net

表5 ConvLSTM-Net与CNN在不同域信道数据以及不同卷积核大小下的NMSE性能对比

Table 5 NMSE performance comparison of ConvLSTM-Net and CNN under different domain channel data and different convolution kernel sizes

信道数据	卷积核大小	NMSE/dB	
		CNN	ConvLSTM-Net
频域信道数据	3 × 3	-17.45	-30.74
	5 × 5	-21.03	-36.22
时域信道数据	3 × 3	-13.77	-31.86
	5 × 5	-18.09	-37.85

训练的神经网络很难直接应用于新环境下用户的问题, Yang等^[29]提出了基于深度迁移学习的CSI预测技术,其提出了元学习算法,实验结果表明该算法可在少量标签数据下使网络适应新环境,验证了迁移思想的有效性。针对微基站训练数据少、集中式训练传输开销大问题, Hou等^[30]提出了基于联邦学习的下行CSI预测框架,并设计了一种新的模型聚合算法,该算法通过考虑局部模型权值和局部梯度对全局模型进行两次更新。实验结果表明,文献[30]提出的联邦学习框架及模型聚合算法能够在大幅度降低传输开销的同时取得接近集中式训练的性能。

此外,针对如何进一步提升下行CSI预测精度问题, Yang等^[9]引入深度多模态学习技术,提出了多源感知数据辅助的下行CSI预测技术,并讨论验证了不同模态组合和特征融合方法的性能。实验结果表明,通过融合过去时刻的下行CSI数据、用户位置数据以及上行CSI数据,多源感知数据辅助的下行CSI预测技术能够获得比已有技术更好的CSI预测精度。在应用场景方面, Yang等^[31]针对混合预编码场景中射频链数目远小于发射天线数目的问题,探索了用部分上行CSI预测整个下行CSI的性能,并结合概率抽样理论,提出了对天线选择和下行CSI预测进行联合优化的端到端训练策略。实验结果表明,基于DL的下行CSI预测技术可以在混合预编码场景下取得可观的下行CSI预测精度。

3 结束语

上述基于DL的下行CSI反馈技术能够在较低压缩率下保持较高的CSI反馈精度,有效降低了CSI反馈开销。而基于DL的下行CSI预测技术能够在彻底消除下行CSI估计和反馈开销的情况下获得可观的下行CSI预测精度。上述两种方案将在不同场景下为未来FDD大规模MIMO系统的部署提供技术支撑,但目前相关研究仍处于初期探索阶段,还面临着许多问题和挑战,需要更深入的研究。

(1)面向特定场景和新技术的深度学习方案设计。一方面,挖掘特定通信场景下的特征,设计个性化深度学习方案将是进一步提升CSI获取精度、加快部署进程的方向之一。例如, Guo等^[23]针对室内通信环境的稳定性,提出了以用户为中心的在线学习CSI反馈框架。另一方面,探索新技术应用下的可行性深度学习方案将是基于DL的下行CSI获取技术应用于未来通信系统的演进方向之一,比如分布式大规模MIMO、全息MIMO等。

(2)面向CSI的原生神经网络设计。目前已有的基于DL的下行CSI获取技术均采用通用神经网络,基于数据对神经网络进行训练,这将使该技术在未来应用时面临很多问题,包括大量有效数据集的获取问题、神经网络计算复杂度与性能的平衡问题、不同通信场景下神经网络的再训练与再部署开销问题等。即使文献[18]通过引入信道数据的先验知识,在降低神经网络的复杂度的同时提高CSI反馈精度,但仍没有克服通用神经网络本身的缺点。轻量化网络、迁移学习以及联邦学习的研究是解决神经网络计算复杂度、泛化性的方案之一,但基于信道固有特性,提出适用于CSI获取的原生网络是解决上述问题的根本,需要进一步探索和研究。

(3)用于训练的真实化场景分析。目前基于DL的下行CSI获取技术的性能验证大部分基于仿真信道数据,且没有考虑量化误差、反馈误差以及信道估计误差等真实场景,无法保证该技术在实际应用场景的适用性和可靠性。因此,需要基于真实场景数据和原型系统对基于DL的下行CSI获取技术做进一步的探索和研究。

针对FDD大规模MIMO系统面临的下行CSI获取挑战,本文探讨了基于深度学习的下行CSI获取技术,具体包括基于深度学习的下行CSI反馈技术和基于深度学习的下行CSI预测技术。首先给出了两种基于深度学习的CSI获取技术的原理,其次分析了相关研究成果,最后对其未来发展做出了展望。通过上述总结分析可以得出,基于深度学习的FDD大规模MIMO下行CSI获取技术有望成为促进FDD大规模MIMO系统商业部署及面向6G演进的强有力支撑,但尚处于初期探索阶段,面临着许多

亟待解决的问题,包括原生网络的探索与研究、真实场景下的性能验证等。

参考文献:

- [1] MARZETTA T L. Noncooperative cellular wireless with unlimited numbers of base station antennas [J]. *IEEE Transactions on Wireless Communications*, 2010, 9(11): 3590-3600.
- [2] 张平, 牛凯, 田辉, 等. 6G 移动通信技术展望[J]. *通信学报*, 2019, 40(1): 141-148.
ZHANG Ping, NIU Kai, TIAN Hui, et al. Technology prospect of 6G mobile communications[J]. *Journal of Communications*, 2019, 40(1): 141-148.
- [3] 王东明. 面向6G的无蜂窝大规模MIMO无线传输技术[J]. *移动通信*, 2021, 45(4): 10-15.
WANG Dongming. Wireless transmission techniques of cell-free massive MIMO for 6G mobile communications [J]. *Mobile Communications*, 2021, 45(4): 10-15.
- [4] LARSSON E, EDFORS O, TUFVESSON F, et al. Massive MIMO for next generation wireless systems[J]. *IEEE Communications Magazine*, 2014, 52(2): 186-195.
- [5] 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.
- [6] 马晨凯, 吴毅慧, 傅华奇, 等. 基于深度学习的先进陶瓷零件实时缺陷检测系统[J]. *南京航空航天大学学报*, 2021, 53(5): 726-734.
MA Chenkai, WU Yihui, FU Huaqi, et al. Real-time defect detection system for advanced ceramic parts based on deep learning [J]. *Journal of Nanjing University of Aeronautics & Astronautics*, 2021, 53(5): 726-734.
- [7] 余永红, 殷凯宇, 王强, 等. 基于深度学习的欧几里得嵌入的推荐算法[J]. *南京航空航天大学学报*, 2020, 52(5): 729-735.
YU Yonghong, YIN Kaiyu, WANG Qiang, et al. Recommendation algorithm of Euclidean embedding based on deep learning [J]. *Journal of Nanjing University of Aeronautics & Astronautics*, 2020, 52(5): 729-735.
- [8] HUANG Hao, PENG Yang, YANG Jie, et al. Fast beamforming design via deep learning[J]. *IEEE Transactions on Vehicular Technology*, 2020, 69(1): 1065-1069.
- [9] YANG Yuwen, GAO Feifei, XING Chengwen, et al. Deep multimodal learning: merging sensory data for massive MIMO channel prediction [J]. *IEEE Journal on Selected Areas in Communications*, 2021, 39(7): 1885-1898.
- [10] 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.
- [11] METZLER C A, MALEKL A, BARANIUK R G. From denoising to compressed sensing[J]. *IEEE Transactions on Information Theory*, 2016, 62(9): 5117-5144.
- [12] LI C, YIN W, ZHANG Y. TVAL3: TV minimization by augmented Lagrangian and alternating direction algorithms [EB/OL].(2013-11-07)[2022-04-22].<https://www.caam.rice.edu/~optimization/11/tval3/>.
- [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] LU Zhilin, WANG Jintao, SONG Jian. Multi-resolution CSI feedback with deep learning in massive MIMO system[C]// *Proceedings of IEEE International Conference on Communications*. Dublin, Ireland: IEEE, 2020: 1-6.
- [15] WANG Tianqi, WEN C K, JIN Shi, et al. Deep learning-based CSI feedback approach for time-varying massive MIMO channels [J]. *IEEE Wireless Communications Letters*, 2019, 8(2): 416-419.
- [16] LI Xiangyi, WU Huaming. Spatio-temporal representation with deep neural recurrent network in MIMO CSI feedback [J]. *IEEE Wireless Communications Letters*, 2020, 9(5): 653-657.
- [17] YE Hongyuan, GAO Feifei, QIAN Jing, et al. Deep learning-based denoise network for CSI feedback in FDD massive MIMO systems [J]. *IEEE Communications Letters*, 2020, 24(8): 1742-1746.
- [18] WANG Jie, GUI Guan, OHTSUKI T, et al. Compressive sampled CSI feedback method based on deep learning for FDD massive MIMO systems [J]. *IEEE Transactions on Communications*, 2021, 69(9): 5873-5885.
- [19] 3GPP TR 38.901. Study on channel model for frequencies from 0.5 to 100 GHz [S]. Sophia Antipolis Valbonne, France: 3GPP, 2019: 1-101.

- [20] GUO Jiajia, WEN C K, JIN Shi, et al. Convolutional neural network-based multiple-rate compressive sensing for massive MIMO CSI feedback: Design, simulation, and analysis [J]. IEEE Transactions on Wireless Communications, 2020, 19(4): 2827-2840.
- [21] SONG Xuan, WANG Jun, WANG Jie, et al. SALDR: Joint self-attention learning and dense refine for massive MIMO CSI feedback with multiple compression ratio [J]. IEEE Wireless Communications Letters, 2021, 10(9): 1899-1903.
- [22] FAN Guanghui, SUN Jinlong, GUI Guan, et al. Fully convolutional neural network based CSI limited feedback for FDD massive MIMO systems[J]. IEEE Transactions on Cognitive Communications and Networking, 2021. DOI: 10.1109/TCCN.2021.3119945.
- [23] GUO Jiajia, ZUO Yiping, WEN C K, et al. User-centric online gossip training for autoencoder-based CSI feedback [J]. IEEE Journal of Selected Topics in Signal Processing, 2022. DOI: 10.1109/JSTSP.2022.3160268.
- [24] SAFARI M S, POURAHMADI V, SODAGARI S. Deep UL2DL: Data-driven channel knowledge transfer from uplink to downlink [J]. IEEE Open Journal of Vehicular Technology, 2020, 1: 29-44.
- [25] WANG Jie, DING Ying, BIAN Shujie, et al. UL-CSI data driven deep learning for predicting DL-CSI in cellular FDD systems [J]. IEEE Access, 2019, 7: 96105-96112.
- [26] SHI Xingjian, CHEN Zhouong, WANG Hao, et al. Convolutional LSTM network : A machine learning approach for precipitation nowcasting [EB/OL]. (2015-09-19)[2022-04-22]. <https://arxiv.org/abs/1506.04214>.
- [27] YANG Yuwen, GAO Feifei, LI G Y, et al. Deep learning based downlink channel prediction for FDD massive MIMO system [J]. IEEE Communications Letters, 2019, 23(11): 1994-1998.
- [28] ZHANG Yinbin, WANG Jie, SUN Jinlong, et al. CV-3DCNN: Complex-valued deep learning for CSI prediction in FDD massive MIMO systems [J]. IEEE Wireless Communications Letters, 2021, 10(2): 266-270.
- [29] YANG Yuwen, GAO Feifei, ZHONG Zhimeng, et al. Deep transfer learning-based downlink channel prediction for FDD massive MIMO systems [J]. IEEE Transactions on Communications, 2020, 68(12): 7485-7497.
- [30] HOU Weihao, SUN Jinlong, GUI Guan, et al. Federated learning for DL-CSI prediction in FDD massive MIMO systems [J]. IEEE Wireless Communications Letters, 2021, 10(8): 1810-1814.
- [31] YANG Yindi, ZHANG Shun, GAO Feifei, et al. Deep learning based antenna selection for channel extrapolation in FDD massive MIMO [C]//Proceedings of 2020 International Conference on Wireless Communications and Signal Processing. Nanjing, China: IEEE, 2020: 182-187.

作者简介:



桂冠(1982-),男,教授,博士生导师,研究方向:人工智能、深度学习、智能通信、智能物联网等6G技术, E-mail: guiguan@njupt.edu.cn。



王洁(1991-),通信作者,女,博士研究生,研究方向:CSI信道反馈等智能通信关键技术。



杨洁(1980-),女,博士,讲师,研究方向:分布式学习、边缘计算和智能无线通信等。



刘森(1988-),博士,讲师,硕士生导师,研究方向:智能车联网、异构物联网、非正交多址、无人机通信以及基于模型驱动的深度学习技术等。



孙金龙(1988-),博士,讲师,硕士生导师,研究方向:智能通信、智能感知与识别以及基于模型驱动的深度学习技术等。

(编辑:刘彦东)