

DOI:10.20079/j.issn.1001-893x.220517005

基于 AI 通信的大规模 MIMO 信道状态信息反馈网络^{*}

刘为波, 颜彪, 沈麟, 丁宇舟

(扬州大学 信息工程学院, 江苏 扬州 225009)

摘要:在大规模多输入多输出系统中,由于天线数量的增加导致信道状态信息反馈带宽开销增大。为了减少反馈开销,提出了一种基于深度学习的反馈网络。该网络将卷积注意力模块和快速迭代收缩阈值算法(Fast Iterative Shrinkage Thresholding Algorithm, FISTA)进行了结合。为了贴合实际应用,考虑到了噪声情况,分析了阈值敏感度。仿真结果表明,该网络在不同环境下其性能和鲁棒性可以得到进一步提高。

关键词:大规模多输入多输出;信道状态信息;反馈网络;AI 通信;深度学习

开放科学(资源服务)标识码(OSID):



微信扫描二维码
听独家语音释文
与作者在线交流
享本刊专属服务

中图分类号:TN911.72 文献标志码:A 文章编号:1001-893X(2024)01-0029-07

Massive MIMO Channel State Information Feedback Network Based on AI Communication

LIU Weibo, YAN Biao, SHEN Lin, DING Yuzhou

(College of Information Engineering, Yangzhou University, Yangzhou 225009, China)

Abstract:In a massive multiple-input multiple-output (MIMO) system, the increase of the number of antennas leads to the increase of the channel state information (CSI) feedback bandwidth overhead. To reduce the feedback overhead, a feedback network based on deep learning (DL) is proposed. The network combines a convolutional attention module with a Fast Iterative Shrinkage Thresholding Algorithm (FISTA). In order to fit the practical application, the noise situation is considered and the threshold sensitivity is analyzed. The simulation results show that the performance and robustness of the network can be further improved in different environments.

Key words:massive MIMO; channel state information; feedback network; AI communication; deep learning

0 引言

作为第 5 代无线通信系统的关键技术,大规模多输入多输出(Multiple-Input Multiple-Output, MIMO)是当前最具有吸引力的未来无线接入技术之一^[1-2]。但为了能获得大规模多输入多输出带来的容量增益,基站端(Base Station, BS)需要准确地接收到来自移动端(User Equipment, UE)的信道状

态信息(Channel State Information, CSI)反馈。在时分双工(Time Division Duplex, TDD)模式下,下行信道状态信息可以根据信道的互易性从上行链路获得,而在频分双工(Frequency Division Duplex, FDD)模式下,信道不存在互易性,信道状态信息必须通过 UE 端进行信道估计然后反馈给基站端。尽管 TDD 模式为当前工作主流模式,但 FDD 模式下的低延迟

^{*} 收稿日期:2022-05-17;修回日期:2022-06-27
基金项目:国家自然科学基金资助项目(61601403)
通信作者:刘为波 Email:18506176503@163.com

特性在未来许多场景中可以得到充分的应用。天线数量的增加带来反馈开销的急剧上升,因此减少反馈开销的研究也随之展开。

传统的信道反馈技术^[3-5]只考虑到了信道的稀疏性,却忽略了低秩的性质。近年来,机器学习方法在不同领域的成功证明了其强大的学习能力。CsiNet^[6]的出现说明了深度学习在无线通信的物理层能够得到成功的应用,开创了 CSI 反馈新方法的先河。此方法采用 encoder-decoder 结构,进行端到端神经网络参数训练,通过编码器压缩一定大小的码字来进行反馈以达到减少负载开销的目的。随后的研究都是以 CsiNet 为基础进行的改进^[7-20],大多数以数据驱动来设计网络,端到端的黑匣子设计方式其网络结构与性能难以解释。模型驱动^[21-24]的方式能够减少对计算资源和训练时间的需求,也易于设计和解释网络结构。采用结合深度学习(Deep Learning, DL)的方法能够加快迭代速度,进一步提高性能。

受模型驱动的启发,本文提出 AMFISTANet (Attention Module Fast Iterative Shrinkage Thresholding Algorithm Network),通过注意力机制与 FISTANet 结合,在网络层设计上可解释性强,嵌入式的注意力模块其复杂性极低,通过加入噪声模块更加贴合实际应用。仿真结果证明 AMFISTANet 的性能得到了进一步的提升,其鲁棒性也更好。

1 系统模型

考虑一个单蜂窝 FDD 大规模 MIMO 系统模型,其中 BS 端和 UE 端分别包含 N_t 和 N_r 根发射天线,其中 $N_r \ll N_t$ 。为了简化模型,设置 $N_r = 1$,整个 FDD 系统使用 N_c 个子载波。假设 UE 端获得的下行信道为

$$\tilde{\mathbf{H}} = \begin{bmatrix} \tilde{h}_{0,0} & \tilde{h}_{0,1} & \cdots & \tilde{h}_{0,N_t-1} \\ \tilde{h}_{1,0} & \tilde{h}_{1,1} & \cdots & \tilde{h}_{1,N_t-1} \\ \vdots & \vdots & & \vdots \\ \tilde{h}_{N_c-1,0} & \tilde{h}_{N_c-1,1} & \cdots & \tilde{h}_{N_c-1,N_t-1} \end{bmatrix} \quad (1)$$

式中: $\tilde{\mathbf{H}} \in \mathbb{C}^{N_c \times N_t}$ 可以在 BS 端通过波束成形以提升通信质量。在实际反馈中需要总共反馈 $2N_c N_t$ 个元素,这包括 CSI 的实部和虚部。很明显可以看出,天线数量的增加导致反馈数量也随之增加。通过二维离散傅里叶变换^[25](Two Dimension Discrete Fourier

Transform, 2D-DFT) 转换到角延迟域能够得到稀疏结构:

$$\mathbf{H}' = \mathbf{T}_c \tilde{\mathbf{H}} \mathbf{T}_t \quad (2)$$

式中: $\mathbf{T}_c$ 和 $\mathbf{T}_t$ 的大小分别为 $N_c \times N_c$ 和 $N_t \times N_t$ 。角延迟矩阵 $\mathbf{H}'$ 中每个元素对应着一定的路径延迟和到达角,并且前 N_a 行包含了大部分的非零值,取其前 N_a 行的截断矩阵为 $\mathbf{H}$ 。尽管稀疏结构能够减少一大部分元素,但其反馈的负载开销依旧巨大,这就需要通过编译码器进一步地压缩才能反馈。设压缩比 $\eta = 2N_c N_t / s$, s 为压缩后码字的长度,表示为

$$s = f_e(\mathbf{H}, \theta_e) \quad (3)$$

式中: f_e 和 θ_e 分别代表编码处理和编码器参数。码字 s 通过上行链路反馈到 BS 端通过解码器恢复 $\hat{\mathbf{H}}$:

$$\hat{\mathbf{H}} = f_d(s, \theta_d) \quad (4)$$

式中: f_d 和 θ_d 分别代表编码处理和编码器参数。

随后通过补零操作恢复 $\hat{\mathbf{H}}'$,通过逆二维离散傅里叶变换(Two Dimensional Inverse Discrete Fourier Transformation, 2D-IDFT)恢复 $\hat{\mathbf{H}}$ 。CSI 的压缩恢复网络结构为端到端训练,通过均方误差(Mean Square Error, MSE)作为其优化方式,通过设计和训练 θ_e 和 θ_d 最小化 $\mathbf{H}$ 和 $\hat{\mathbf{H}}$ 之间的距离来达到提高性能的目的:

$$(\hat{\theta}_e, \hat{\theta}_d) = \underset{\theta_e, \theta_d}{\operatorname{argmin}} \|\mathbf{H} - f_d(f_e(\mathbf{H}, \theta_e), \theta_d)\|_2^2 \quad (5)$$

2 网络设计

2.1 注意力模块

整体网络的设计主要由编码器的 CBAM (Convolutional Block Attention Module)^[26]和译码器的 FISTA 网络组成,如图 1 所示。编码器处的 CBAM 模块包含通道注意力和空间注意力两个子模块,分别进行通道和空间上的 attention。轻量化网络在残差结构做到轻松嵌入,节省了大量的参数和算力。神经网络只能实值训练,因此信道复系数需要虚实分开输入到网络中。




图 1 AMFISTANet 整体结构

Fig. 1 Overall structure of AMFISTANet

编码器实现如图 2 所示。首先, 受 CLNet 的启发, 笔者使用了 1×1 的卷积核进行虚实结合, 产生 c 个通道, c 为卷积核的数量, 这样便能充分利用到复系数的相位关系。随后连接通道注意力模块, 输入的特征图 ($H \times W \times C$) 通过残差进行分支, 分别进行全局平均池化 (avg) 和全局最大池化 (max), 大小为 $1 \times 1 \times C$, 然后送入到参数共享的多层感知机 (Multilayer Perceptron, MLP) 中, 生成的特征进行逐点相加, 通过 sigmoid 激活函数的结果与主干进行一个相乘即可完成通道注意。通道注意力操作可表示为

$$\text{mask}_c = s[\text{mlp}(\text{avg}(F)) + \text{mlp}(\text{max}(F))] \quad (6)$$

式中: F 为输入特征图; avg 和 max 分别表示全局平均池化和全局最大池化; s 为激活函数操作。




图 2 编码器结构

Fig. 2 Structure of the encoder

空间注意机制通过最大池化和平均池化分别生成一个 $H \times W \times 1$ 的特征图, 随后进行拼接操作, 通过卷积层生成 $H \times W \times 1$ 的特征图与主干相乘, 可表示为

$$\text{mask}_s = s[f(\text{avg}(F); \text{max}(F))] \quad (7)$$

式中: F 为特征图; avg 为平均池化; max 为最大池化; f 为变成 1 通道的卷积操作; s 为激活函数操作。最后 CBAM 经过一个 3×3 的卷积核输出到全连接层进行码字压缩, 通过上行链路反馈给 BS 端的译码器进行重构。

2.2 FISTANet

软阈值迭代算法 (ISTA) 采用 Nesterov 加速技

术得到快速迭代收缩阈值算法 (FISTA), 两种方法都是稀疏恢复的经典算法。FISTA 用一种更为聪明的办法选择序列 $\{x_k\}$, 使得其基于梯度下降思想的迭代过程更加快速地趋近问题函数 $F(x)$ 的最小值。通过深度学习神经网络参数化能够进一步提高计算速度^[22]。通过向量化 H , 得到 $h = \text{vec}(H)$, 解码器端的 CSI 重构问题可以表示为

$$\min_h \frac{1}{2} \|s - W_{\text{en}} h\|_2^2 + \tau \|\lambda(h)\|_1 \quad (8)$$

式中: 第二项为重构问题的约束项; l_1 范数作为正则化项, 可以产生一个稀疏模型用于特征选择; W_{en} 为编码器全连接层的权重; λ 为稀疏变换; τ 为惩罚系数。针对上式的凸优化问题, 可以选择基于梯度下降的方法来求解, 如 FISTA 算法。FISTA 算法通过阈值收缩来更新 h 。首先设 $y_1 = h_0$, 在第 k 次迭代中,

$$m_k = y_k - \alpha_k W_{\text{en}}^T (W_{\text{en}} y_k - s) \quad (9)$$

$$h_k = \lambda^{-1}(\text{soft}(\lambda(m_k), \tau)) \quad (10)$$

$$y_{k+1} = h_k + \frac{t_k - 1}{t_{k+1}} (h_k - h_{k-1}) \quad (11)$$

式(8)~(11)中: k 为迭代索引; s 为码字; α_k 为重构步长; t_k 代表收缩伪系数, 其更新方式为 $t_{k+1} = \frac{1 + \sqrt{1 + 4t_k^2}}{2}$; $\text{soft}(g, \tau)$ 为收缩函数, 表示为

$$\text{soft}(g, \tau) = \text{sign}(g) \max\{|g| - \tau, 0\} \quad (12)$$

式中: $\text{sign}(\cdot)$ 为符号函数。

FISTA 算法中超参数需要经验设置, 如 α , τ 。不当的设置就会带来许多不确定性。本文对 FISTA 算法在神经网络中展开为 FISTANet, 将 K 次迭代到深度神经网络层中, 对部分超参数设置为可训练参数来减少这种不确定性。具体如图 3 所示, 使用可学习的参数和 ST-Net 来代替人工设置的超参数; 重构步长 α_k 和收缩系数 $\frac{t_k - 1}{t_{k+1}}$ 为可学习参数, 分别设为 $\tilde{\alpha}_k$ 和 γ_k , 则式(9)和式(10)中推导出新的公式为

$$m_k = y_k - \tilde{\alpha}_k W_{\text{en}}^T (W_{\text{en}} y_k - s) \quad (13)$$

$$y_{k+1} = h_k + \gamma_k (h_k - h_{k-1}) \quad (14)$$

经过式(13)的操作后, m_k 重塑成两通道的 M_k 方便输入到下一个卷积层。为了使 λ 能够得到更加稀疏的表示, 添加了一个包括 1×1 卷积和 5×5 卷积以及一个线性修正单元 (ReLU) 非线性变换

$v(\cdot)$ 和逆稀疏变换 $v^{-1}(\cdot)$, 以此替换掉 λ 和 λ^{-1} 。同时 3×3 的卷积层用 1×1 卷积替代作为头部卷积, 并在逆稀疏变换层后也进行添加。最后为了防止过拟合和梯度爆炸, 添加了残差结构。式 (9) 推导出新公式:

$$h_k=M_k+f(v^{-1}(\text{soft}(v(f(M_k)),\tau))) \quad (15)$$

式中: f 为 5×5 卷积操作。

阈值的选择对 FISTA 的性能也会有很大的影

响。ST-Net^[24] 作为子网络去寻找阈值 τ , ST-Net 网络也是基于注意力机制, 结构如图 3 下方所示。稀疏变换后的特征图去绝对值得到 $|v(f(M_k))|$, 经过全局平均池化 (Global Average Pooling, GAP) 后变成 $1\times 1\times C, C=16$, 随后经过多层感知机先降维再升维到原来的维度, 产生一个缩放因子 σ_k , 最后进行 soft 收缩操作。FISTANet 包含了 K 次迭代, 其中需要训练的参数包括 $\theta=\{\tilde{\alpha}_k,\gamma_k,v,v^{-1},f,W_{\text{en}}\}$ 。




图 3 第 K 次迭代的 FISTANet
Fig. 3 The K th iteration of FISTANet

训练过程中的损失函数可以重新定义为

$$L(\theta)=l_{\text{mse}}+\mu l_{\text{iter}}+\zeta l_{\text{sym}}=\\ \|\hat{h}_K-h\|_2^2+\mu\sum_{k=1}^K\|\hat{h}_k-h\|_2^2+\\ \zeta\sum_{k=1}^K\|v^{-1}(v(\hat{h}_k)-h)\|_2^2 \quad (16)$$

式中: μ 和 ζ 是平衡参数; 第一项为标准的均方误差; 第二项是第 K 阶段下真实值和迭代值的差异, 第三项是为了让非线性变换 v 和其逆变换 v^{-1} 通过哈达玛积相乘尽可能为单位矩阵, 即 $v\circ v^{-1}=I$ 。

3 实验仿真

为了能够得到统一对比, 使用了 COST2100 信道模型产生的数据进行对比。更进一步讲, 采用了 CsiNet^[6] 中的预处理好的数据。室内和室外范围分别设置为 20 m 和 400 m 的方形区域, UE 端在方形区域内随机采样, 频段分别在 5.3 GHz 和 300 MHz。使用了均匀线阵 (Uniform Linear Array, ULA) 天线方案, BS 端部署 32 根天线, $N_c=1\,024$, UE 端配备单天线, 通过 2D 离散傅里叶变换转换到角延迟域, 保留前 32 行作为最后的 H , 大小为 32×32 。

信道模型产生的 120 000 样本, 10 000 作为训练集, 20 000 为测试集。epoch = 300, 迭代次数 $K=20$, 每次训练的批次为 64。学习率采用衰减学习率, 初始学习率为 0.001, 每 100 个 epoch 学习率乘 0.1。

使用归一化均方误差 (Normalized Mean Square Error, NMSE) 作为评价 CSI 反馈性能的标准来测量原始 H 和重建的 $\hat{H}$ 的距离:

$$E_{\text{NMS}}=E\{\|\mathbf{H}-\hat{\mathbf{H}}\|_2^2/\|\mathbf{H}\|_2^2\} \quad (17)$$

比较了几个最新的方法, 包括 CLNet^[12]、FISTANet^[24] 以及 CsiNet, 在不同压缩比下室内室外环境的 NMSE 如表 1 所示。表 1 中性能最好的情况用加粗字体标出, 可以看出, AMFISTANet 在不同压缩比和不同环境下均表现出了更优异的性能。AMFISTANet 和 FISTANet 在参数上的差距尤其是编码器部分几乎没有增加, 衡量网络标准的复杂度 MACC 只有在基站的译码器部分有了一小部分的增加。值得注意的是, 尽管复杂度高于目前最新的网络, 但在实际部署中, 新引入的信道样本训练往往不需要那么多次迭代, 50 个 epoch 以内的迭代即可达到总迭代性能的 97%, 而其他方法则需要更多的迭

代数才能达到方法的极限性能。

表 1 不同方法 NMSE 对比						
Tab. 1 Comparison of NMSE among different methods						
压缩 比 CR	方法	NMSE/dB		参数 量/10 ⁶	MACC/10 ⁶	
		室内	室外		编码器	解码器
1/4	CsiNet	-17.36	-8.75	2.10	1.09	4.39
	CLNet	-29.16	-12.88	2.10	1.34	2.71
	FISTANet	-36.76	-22.4	1.09	1.05	74.71
	AMFISTANet	-38.14	-22.83	1.09	1.99	76.15
1/8	CsiNet	-12.7	-7.61	1.05	0.56	3.86
	CLNet	-15.6	-8.29	1.05	1.01	3.80
	FISTANet	-26.5	-13.65	0.56	0.52	53.74
	AMFISTANet	-27.66	-13.9	0.56	1.01	55.18
1/16	CsiNet	-8.65	-4.51	0.53	0.30	3.60
	CLNet	-11.15	-5.56	0.56	0.38	3.50
	FISTANet	-17.51	-7.57	0.30	0.26	43.26
	AMFISTANet	-18.35	-7.78	0.30	1.16	44.70
1/32	CsiNet	-6.24	-2.81	0.27	0.17	3.47
	CLNet	-8.95	-3.49	0.26	0.13	3.42
	FISTANet	-12.01	-4.41	0.17	0.13	38.01
	AMFISTANet	-12.64	-4.75	0.17	0.62	39.45
1/64	CsiNet	-5.84	-1.93	0.14	0.11	3.40
	CLNet	-6.34	-2.19	0.16	0.07	0.07
	FISTANet	-8.54	-2.6	0.10	0.07	35.39
	AMFISTANet	-8.67	-2.78	0.10	0.56	36.83

文中提到阈值的选择会对恢复结果有很大影响,因此,针对 ST-Net 子网络的全连接层进行了消融研究,对 MLP 中间的全连接层设置不同的压缩比,实验分别设置通道压缩比为 1/8,1/4,1/2。因为在网络训练期间前 50 个 epoch 就能达到很好的性能,因此,网络在 epoch = 50, SNR = 20, CR = 4 时测试不同通道压缩比的性能,如图 4 所示,比较了室内和室外环境下性能差异。可以看出,通道压缩比为 1/2 时室内外环境表现最好,压缩比为 1/4 情况下表现较差。室内环境下不同 MLP 通道压缩比对阈值的选择有较大的影响,而室外环境几乎没有太大差异,原因可能在于室内环境相对于室外的 CSI 更具有有一定的规律性,超参数的选择对有规律的 CSI 影响更大。




图 4 MLP 内不同通道压缩比性能比较
Fig. 4 Comparison of compression ratio performance among different channels within MLP

为了能够贴合实际应用,添加了加性高斯白噪声进行了比较,在 CR=4 的室内环境^[26]下进行了对比,结果如图 5 所示,可见在大信噪比下 AMFISTANet 依旧能够保持很优异的性能。




图 5 CR=4 室内环境下的性能比较
Fig. 5 Comparison of performance in an indoor environment with CR = 4

在网络训练的过程中,编码器网络还尝试加入不同的注意力机制,包括 ECANet^[27]、CANet^[28]和 Transformer^[13]。图 6 比较了在 CR = 4 下室内和室外的结果,尽管 CANet、ECANet 在室内表现的更佳,但在室外环境下其性能与 FISTANet 相比反而有所下降,因此选择了性能折中方法。在高压缩比 (CR = 64) 的户外情况下,Transformer 嵌入的编码器网络测试性能可以达到 -3.0 dB,证明了 Transformer 对更加注重整体特征图而模糊细节部分。




图 6 各种注意力嵌入比较
Fig. 6 Comparison under various attention embeddings

受以上注意力机制的启发,在实际环境部署中,可以考虑针对特定环境下设计反馈网络,以此进一步提高性能。

良好的 CSI 可以对下游工作如功率分配、天线选择、方案切换等带来益处,不仅可以提高通信质量,还可以降低系统整体的复杂度。

4 结束语

本文针对 FDD 模式下大规模 MIMO 的 CSI 反馈问题,提出了一种基于 DL 的网络结构 AMFISTANet。在整个网络中,编码器端嵌入注意力机制并串联卷积层进行设计,其轻量化设计在实际部署也更容易实现;译码器端的 FISTA 网络其结构不仅具有可解释性,通过神经网络参数化,学习能力也得到增强。消融实验验证了在大信噪比的情况下其性能也进一步提升,多种注意力机制对比验证了 AMFISTANet 的优势。

在实际应用中需要考虑量化等步骤来提高整体性能,在未来工作中将考虑从信道本身特性出发去设计更易实现的高效网络。

参考文献:

[1] ADHIKARY A, NAM J, AHN J Y, et al. Joint spatial division and multiplexing—the large-scale array regime [J]. IEEE Transactions on Information Theory, 2013, 59 (10) : 6441–6463.

[2] ADHIKARY A, SAFADI E A, SAMIMI M K, et al. Joint spatial division and multiplexing for mm-wave channels [J]. IEEE Journal of Selected in Areas Communication, 2014, 32 (6) : 1239–1255.

[3] METZLER C A, MALEKI A, BARANIUK R G. From denoising to compressed sensing [J]. IEEE Transactions on Information Theory, 2016, 62 (9) : 5117–5144.

[4] DAUBECHIES I, DEFRISE M, MOL C D J C O P, et al. An iterative thresholding algorithm for linear inverse problems with a sparsity constraint [J]. Communications on Pure and Applied Mathematics, 2010, 57 (11) : 1413–1457.

[5] RAO X B, LAU V K N. Distributed compressive CSIT estimation and feedback for FDD multi-user massive MIMO systems [J]. IEEE Transactions on Signal Processing, 2014, 62 (12) : 3261–3271.

[6] WEN C K, SHIH W T, JIN S. Deep learning for massive MIMO CSI feedback [J]. IEEE Wireless Communication Letters, 2018, 7 (5) : 748–751.

[7] HU Z, GUO J, LIU G, et al. MRFNet: a deep learning-based CSI feedback approach of massive MIMO systems [J]. IEEE Communications Letters, 2021, 25 (10) : 3310–3314.

[8] WANG T, WEN C, 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.

[9] GUO J, WEN C, JIN S, 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.

[10] LU Z, WANG J, SONG J. Multi-resolution CSI feedback with deep learning in massive MIMO system [C] // Proceedings of 2020 IEEE International Conference on Communications. Dublin: IEEE, 2020: 1–6.

[11] YE H, GAO F, QIAN J, et al. Deep learning-based denoise network for CSI feedback in FDD massive MIMO systems [J]. IEEE Communications Letters, 2020, 24 (8) : 1742–1746.

[12] JI S, LI M. CLNet: complex input lightweight neural network designed for massive MIMO CSI feedback [J]. IEEE Wireless Communications Letters, 2021, 10 (10) : 2318–2322.

[13] CUI Y, GUO A, SONG C. TransNet: full attention network for CSI feedback in FDD massive MIMO system [J]. IEEE Wireless Communications Letters, 2022, 11 (5) : 903–907.

[14] XU Y, YUAN M, PUN M O. Transformer empowered CSI feedback for massive MIMO Systems [C] // Proceedings of 2021 30th Wireless and Optical Communications Conference. Taipei, China: IEEE, 2021: 157–161.

[15] WANG J, GUI G, 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.

[16] LIAO Y, YAO H, HUA Y, et al. CSI feedback based on deep learning for massive MIMO systems [J]. IEEE Access, 2019, 7: 10–20.

[17] 王月, 段红光, 郑兴林. 大规模 MIMO 系统中基于 CNN 的延迟 CSI 反馈改进算法 [J]. 电讯技术, 2020, 60 (7) : 833–838.

[18] ZENG J, SUN J, GUI G, et al. Downlink CSI feedback algorithm with deep transfer learning for FDD massive MIMO systems [J]. IEEE Transactions on Cognitive Communications and Networking, 2021, 7 (4) : 1253–1265.

[19] LIU Z, ZHANG L, DING Z. An efficient deep learning framework for low rate massive MIMO CSI reporting [J]. IEEE Transactions on Communications, 2020, 68 (8) : 4761–4772.

[20] LIN Y C, LIU Z, LEE T S, et al. Deep learning phase compression for MIMO CSI feedback by exploiting FDD channel reciprocity [J]. IEEE Wireless Communications Letters, 2021, 10 (10) : 2200–2204.

[21] HE H, JIN S, WEN C K, et al. Model-driven deep learning for physical layer communications [J]. IEEE Wireless Communications, 2019, 26(5) : 77–83.

[22] ZHANG J, GHANEM B. ISTA-Net: interpretable optimization-inspired deep network for image compressive sensing [C] // Proceedings of 2018 IEEE/ CVF Conference on Computer Vision and Pattern Recognition. Salt Lake: IEEE, 2018: 1828–1837.

[23] LIU Z, ROSARIO M D, 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.

[24] GUO J, WANG L, LI F, et al. CSI feedback with model-driven deep learning of massive MIMO systems [J]. IEEE Communications Letters, 2022, 26(3) : 547–551.

[25] LI X, FANG J, LI H, et al. Millimeter wave channel estimation via exploiting joint sparse and low-rank structures [J]. IEEE Transactions on Wireless Communications, 2018, 17(2) : 1123–1133.

[26] WOO S, PARK J, LEE J Y, KWEON I S. CBAM: convolutional block attention module [C] // Proceedings

of European Conference on Computer Vision. Munich: IEEE, 2018: 3–19.

[27] WANG Q, WU B, ZHU P, et al. ECA-Net: efficient channel attention for deep convolutional neural networks [C] // Proceedings of the 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Seattle: IEEE, 2020: 11531–11539.

[28] HOU Q, ZHOU D, FENG J. Coordinate attention for efficient mobile network design [C] // Proceedings of 2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Nashville: IEEE, 2021: 13713–13722.

作者简介:

刘为波 男, 1996 年生于江苏徐州, 硕士研究生, 主要研究方向为无线通信、深度学习。

颜 彪 男, 1962 年生于江苏扬州, 博士, 教授、硕士生导师, 主要研究方向为无线通信。

沈 麟 男, 1996 年生于江苏常州, 硕士研究生, 主要研究方向为滤波器组多载波系统的关键技术。

丁宇舟 男, 1999 年生于江苏宜兴, 硕士研究生, 主要研究方向为无线通信。