

## 一种基于深度自编码器的大规模MIMO系统室外CSI反馈方法

陈锰, 钱蓉蓉, 朱雨佳, 黄振国

### 引用本文

陈锰, 钱蓉蓉, 朱雨佳, 黄振国. 一种基于深度自编码器的大规模MIMO系统室外CSI反馈方法[J]. 计算机科学, 2024, 51(11A): 231000191-6.

CHEN Meng, QIAN Rongrong, ZHU Yujia, HUANG Zhenguo. [Method of Outdoor CSI Feedback for Massive MIMO Systems Based on Deep Autoencoder](#) [J]. Computer Science, 2024, 51(11A): 231000191-6.

---

### 相似文章推荐 (请使用火狐或 IE 浏览器查看文章)

#### Similar articles recommended (Please use Firefox or IE to view the article)

#### [多用户大规模LDPC-SM-MIMO联合分层消息传递检测](#)

Joint Layered Message Passing Detection for Multi-user Large-scale LDPC-SM-MIMO System  
计算机科学, 2023, 50(11): 327-332. <https://doi.org/10.11896/jsjcx.220900103>

#### [存在CSI估计错误的增强型ELM叠加CSI反馈方法](#)

Enhanced ELM-based Superimposed CSI Feedback Method with CSI Estimation Errors  
计算机科学, 2022, 49(6A): 632-638. <https://doi.org/10.11896/jsjcx.210800036>

#### [一种新的基于子连接结构的混合预编码算法](#)

New Hybrid Precoding Algorithm Based on Sub-connected Structure  
计算机科学, 2022, 49(5): 256-261. <https://doi.org/10.11896/jsjcx.210300138>

#### [单类支持向量机融合深度自编码器的异常检测模型](#)

Anomaly Detection Model Based on One-class Support Vector Machine Fused Deep Auto-encoder  
计算机科学, 2022, 49(3): 144-151. <https://doi.org/10.11896/jsjcx.210100142>

#### [大规模MIMO室外无线光通信系统中基于分段高斯近似的最大似然盲检测算法](#)

Maximum Likelihood Blind Detection Algorithm Based on Piecewise Gaussian Approximation for Massive MIMO Outdoor Wireless Optical Communication Systems  
计算机科学, 2020, 47(3): 255-260. <https://doi.org/10.11896/jsjcx.190200310>

# 一种基于深度自编码器的大规模 MIMO 系统室外 CSI 反馈方法

陈 锰 钱蓉蓉 朱雨佳 黄振国

云南大学信息学院 昆明 650500

(chairman\_cm@163.com)

**摘 要** 在室外场景高倍压缩下,针对大规模多输入多输出(Multiple-Input Multiple-Output, MIMO)系统中大多数现有信道状态信息(Channel State Information, CSI)反馈方法重建精度低、复杂度较高的问题,提出了一种基于深度自编码器的 CSI 压缩反馈方法。该方法首先在编码器采用卷积神经网络提取原始 CSI 的特征信息;然后将全连接网络压缩为低维码字反馈回解码器;最后考虑到室外环境的 CSI 空间模式复杂、高倍压缩下信息损失较多,在解码器的残差网络中使用并行多分辨率卷积网络与具有丰富神经元的全连接网络对接收到的特征码字进行重建,以此增强所提方法的重建能力与泛化能力。实验结果表明,所提方法的重建质量在不同压缩比下均有显著提升。

**关键词:** 大规模 MIMO; CSI 反馈; 深度自编码器; 室外场景; 高倍压缩

**中图分类号** TN925

## Method of Outdoor CSI Feedback for Massive MIMO Systems Based on Deep Autoencoder

CHEN Meng, QIAN Rongrong, ZHU Yujia and HUANG Zhenguo

School of Information, Yunnan University, Kunming 650500, China

**Abstract** In outdoor scenarios with high compression, aiming at the problems of low accuracy and high complexity of reconstruction of most existing channel state information (CSI) feedback methods in massive multiple-input multiple-output (MIMO) systems, a deep autoencoder-based CSI compression feedback method is proposed. The method firstly uses a convolutional neural network in the encoder to extract the feature information of the original CSI, and then uses a fully connected network to compress it into a low-dimensional codeword for feedback to the decoder. Considering that the spatial pattern of CSI in outdoor environments is more complicated, and the loss of information is more at high compression, the decoder employs parallel multi-resolution convolutional networks and fully connected networks in a residual structure to reconstruct the received feature codewords. This design enhances the reconstruction and generalization capabilities of the proposed method. Experimental results show that the reconstruction quality of the proposed method is significantly improved at different compression ratios.

**Keywords** Massive MIMO, CSI feedback, Deep autoencoder, Outdoor scenario, High compression

## 1 引言

作为无线通信系统中关键的技术之一,大规模 MIMO 技术不仅可以显著地提高信道容量,而且能提供更好的能量效率<sup>[1]</sup>。然而,这些优势要求基站(Base Station, BS)准确地获取下行 CSI,以便能够消除用户间的干扰。在频分双工(Frequency Division Duplexing, FDD)模式下,由于信道之间不像时分双工模式存在互易性,为了在 BS 上实现预编码的设计,用户设备(User Equipment, UE)必须精确地把下行 CSI 反馈给 BS。对于大规模 MIMO 系统,反馈开销随着天线数量的增加呈指数性增长,故需在 CSI 矩阵反馈前进行压缩处理来减少系统的开销。

深度学习技术的蓬勃发展有效克服了传统压缩感知方法(LASSO, BM3D-AMP 和 TVAL3)<sup>[2-3]</sup>依赖信道稀疏性假设和迭代重构效率低的缺点,为 FDD 大规模 MIMO 系统中 CSI

的高效反馈提供了另一种可能的解决方案。CsiNet<sup>[4]</sup>首次将深度学习(Deep Learning, DL)方法应用到 CSI 压缩与重构领域,其通过数据驱动的方式,端到端训练由神经网络(Neural Network, NN)搭建的自编码器,编码器从训练样本中学习信道结构特征并压缩成低维码字反馈回解码器,接收到码字后进行 CSI 的重构操作。

自 DL 应用于大规模 MIMO 系统的 CSI 反馈以来,国内外学者提出各种各样的 NN 架构来进行高精度的重构任务。在 CsiNet 的基础上, CsiNet+<sup>[5]</sup>采用规模更大的卷积核来提高网络的反馈性能。CRNet<sup>[6]</sup>提出使用多分辨率来提高模型适应不同特征粒度的能力。CLNet<sup>[7]</sup>认为 CSI 是具有物理意义的复杂值形式,因此使用  $1 \times 1$  卷积运算作为网络的第一层来处理 CSI 的实部和虚部;引入了长短期记忆(Long Short-Term Memory, LSTM)网络的 CsiNet-LSTM<sup>[8]</sup>,关注到 CSI 反馈的时间相关性。ACCsiNet<sup>[9]</sup>使用非对称卷积块对 Con-

基金项目:国家自然科学基金青年科学基金(61701433);云南省科技厅面上项目(2018FB099)

This work was supported by the Young Scientists Fund of the National Natural Science Foundation of China(61701433) and Yunnan Provincial Department of Science and Technology General Project(2018FB099).

通信作者:钱蓉蓉(r.qiang@ynu.edu.cn)

vCsiNet<sup>[10]</sup>进行改进,增强了卷积的特征提取能力。也有一些工作引入其他模块的CSI反馈网络架构,如通过抵御噪声的影响来提高重构精度的DNNNet<sup>[11]</sup>,增加通道注意力的Attention-CsiNet<sup>[12]</sup>和空间注意力的CLPNet<sup>[13]</sup>等。以上研究在原始CsiNet的基础上做了大量改进,反馈精度和重建质量得到了很大改善。但是,这些网络模型在室外场景大压缩比(Compression Ratio, CR)下的CSI重建效果不理想。采用深度神经网络(Deep Neural Network, DNN)的CsiNet + DNN<sup>[14]</sup>关注到了这一问题,通过采用大卷积和增加全连接网络(Fully Connected Network, FCN)的方法提高了模型的重建能力,但较多的网络训练参数使得模型计算复杂度高,牺牲了CSI反馈的实时性。

在以上研究的启发下,本文针对室外高倍压缩CSI已有反馈方法计算复杂度高、反馈精度低的问题,提出了一种基于深度自编码器的神经网络模型。所提方法包括对CSI进行压缩处理的编码器和解压缩处理的解码器。编码器采用卷积神经网络来学习信道分布知识,通过FCN对提取到的CSI特征信息进行整合并降维生成码字矢量。解码器采用多分辨率并行卷积网络恢复CSI的不同特征,并在残差结构中添加具有强大拟合能力的FCN,这一改进使得所提方法即使在高倍压缩下仍能精确地重建出原始CSI。本文对比了所提方法与一些已有的CSI反馈方法的复杂度与重建性能,仿真结果表明,所提方法具有低开销和高精度的优势,在重建质量上有显著提升。

## 2 系统模型

本文在FDD大规模MIMO正交频分复用(Orthogonal Frequency Division Multiplexing, OFDM)系统中,考虑一个简单的单蜂窝小区下行链路的情形。BS端使用半波长间距的均匀线性阵列,配置 $N_t \gg 1$ 根发射天线,UE端配置单根接收天线,子载波的数量设置为 $\tilde{N}_c$ ,频域中第 $n$ 个子载波的接收信号可以表示为:

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

其中, $\tilde{\mathbf{h}}_n \in \mathbb{C}^{\tilde{N}_c \times 1}$ ,  $\mathbf{v}_n \in \mathbb{C}^{\tilde{N}_c \times 1}$ ,  $x_n \in \mathbb{C}$ ,  $z_n \in \mathbb{C}$ ,分别表示频域信道向量、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矩阵为所有子载波信息的堆叠,可以表示为:

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

其中, $\tilde{\mathbf{H}} \in \mathbb{C}^{\tilde{N}_c \times N_t}$ 。该CSI矩阵 $\tilde{\mathbf{H}}$ 包括实部和虚部,此时UE需要反馈的参数总量为 $2N_t\tilde{N}_c$ 。

为了减少反馈开销,本文采用文献[5]的方案将空间频率矩阵 $\tilde{\mathbf{H}}$ 通过离散傅里叶变换(Discrete Fourier Transform, DFT)映射到具有稀疏性的角度时域域:

$$\hat{\mathbf{H}} = \mathbf{F}_d \tilde{\mathbf{H}} \mathbf{F}_a^H \quad (3)$$

其中, $\mathbf{F}_d \in \mathbb{C}^{\tilde{N}_c \times \tilde{N}_c}$ 与 $\mathbf{F}_a^H \in \mathbb{C}^{N_t \times N_t}$ 是DFT矩阵。由于信道时延扩展的有限性,矩阵 $\hat{\mathbf{H}}$ 只有前几行有非零值,其余行表示传播延迟较大的路径由接近零的值组成。因此,可以在不造成太多信息损失的情况下只保留 $\hat{\mathbf{H}}$ 的前 $N_c$  ( $N_c < \tilde{N}_c$ )行并去掉其余行,得到截断矩阵 $\mathbf{H}_a \in \mathbb{C}^{N_c \times N_t}$ 。此时反馈量减少为 $N = 2N_c N_t$ ,然而这在大规模MIMO系统中仍是一个很大的数目,接下来借鉴自编码器思想对CSI矩阵进一步压缩。




图1 大规模MIMO系统CSI反馈工作流程

Fig. 1 Workflow of CSI feedback in massive MIMO system

在本文中,考虑下行CSI反馈的编解码网络,如图1所示。首先把截断矩阵 $\mathbf{H}_a$ 输入UE端的编码器并根据给定CR将矩阵 $\mathbf{H}_a$ 压缩成长度为 $M$ 的短特征码字矢量;然后在BS端的解码器接收到码字后将其重建为信道矩阵 $\hat{\mathbf{H}}_a$ ,其中 $\text{CR} = M/N$ ,  $N$ 是 $\mathbf{H}_a$ 的大小;最后通过IDFT和零填充得到空频域的重构信道矩阵。整个反馈过程的数学形式可以归纳为:

$$\hat{\mathbf{H}}_a = f_{de}(f_{en}(\mathbf{H}, \Theta_{en}), \Theta_{de}) \quad (4)$$

其中, $f_{en}(\cdot)$ 和 $f_{de}(\cdot)$ 分别表示压缩过程和解压缩过程, $\Theta_{en}$ 和 $\Theta_{de}$ 表示对应网络的训练参数。反馈方法的目标是最小化 $\mathbf{H}_a$ 和重建的 $\hat{\mathbf{H}}_a$ 之间的差异,可以将其描述为所提模型需要找到满足式(5)的编解码器参数集。

$$(\hat{\Theta}_{en}, \hat{\Theta}_{de}) = \arg \min_{\Theta_{en}, \Theta_{de}} \|\mathbf{H}_a - f_{de}(f_{en}(\mathbf{H}, \Theta_{en}), \Theta_{de})\|_2^2 \quad (5)$$

## 3 网络设计

### 3.1 研究动机

基于CNN的自编码器可以有效地提取CSI矩阵中的空间局部相关<sup>[15]</sup>,本文在其基础上扩展设计了能够适用于室外场景大压缩比的CSI反馈NN架构。

与已有的一些CSI反馈工作不同,所提方法更专注于解决室外CSI的重建问题,特别是在高压缩情况下,大部分已有的CSI反馈方法在室内场景中都有良好的重建质量,但在室外场景中并不能很好地重建出原始CSI,其原因在于室外CSI矩阵更加复杂<sup>[16]</sup>。图2通过伪灰度图可视化的方式,对比了COST2100 MIMO信道模型<sup>[17]</sup>生成的室内微蜂窝场景<sup>[18]</sup>与室外乡村场景<sup>[19]</sup>CSI矩阵。具体而言,图2(a)场景对应5.3 GHz下行链路,覆盖范围为 $20\text{m} \times 20\text{m}$ ,UE移动速度为 $0.0036\text{km/h}$ ;图2(b)对应300 MHz下行链路,覆盖范围为 $400\text{m} \times 400\text{m}$ ,UE移动速度为 $3.24\text{km/h}$ 。

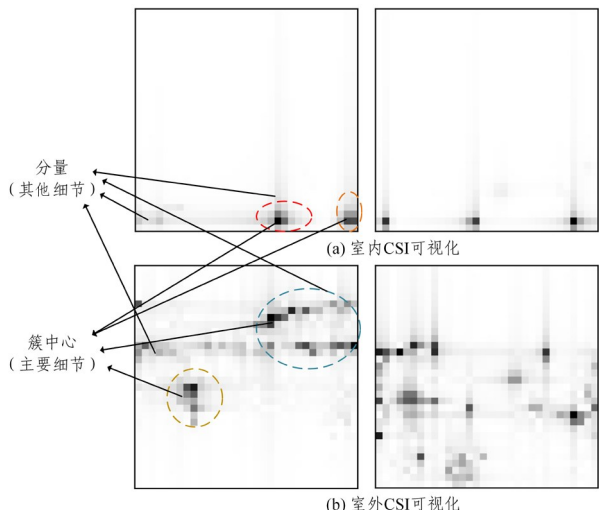


图2 室内外CSI可视化对比

Fig. 2 Comparison of indoor and outdoor CSI visualization

通常,信道特性参数相似的多径分量集合为一个簇,角度时延域下的 CSI 一般为有限个簇构成。图 2 中每个虚线圆圈表示一个簇(其中灰度值越深表示该点信号越强),也就是簇的中心,对应多径传播中的可分辨路径,其功率通常都会高于其他分量路径,因此可以将这些簇中心视为 CSI 图像的主要细节。簇中心附近颜色较浅的地方对应多径传播中的不可分辨路径,其功率相对较低,一般视为 CSI 图像的其他细节。另外,在 CSI 图像中,簇区域外也含有其他信息分量,虽然不是主要信息,但也不可以完全忽视。从室内室外来看,图 2(a)中几乎没有非零点,且因为延迟较低,非零点集中分布于图像的底部;而在图 2(b)中,由于多径衰落和用户位置的随机性,非零点变得分散和模糊,使得 CSI 矩阵的空间模式相对复杂。

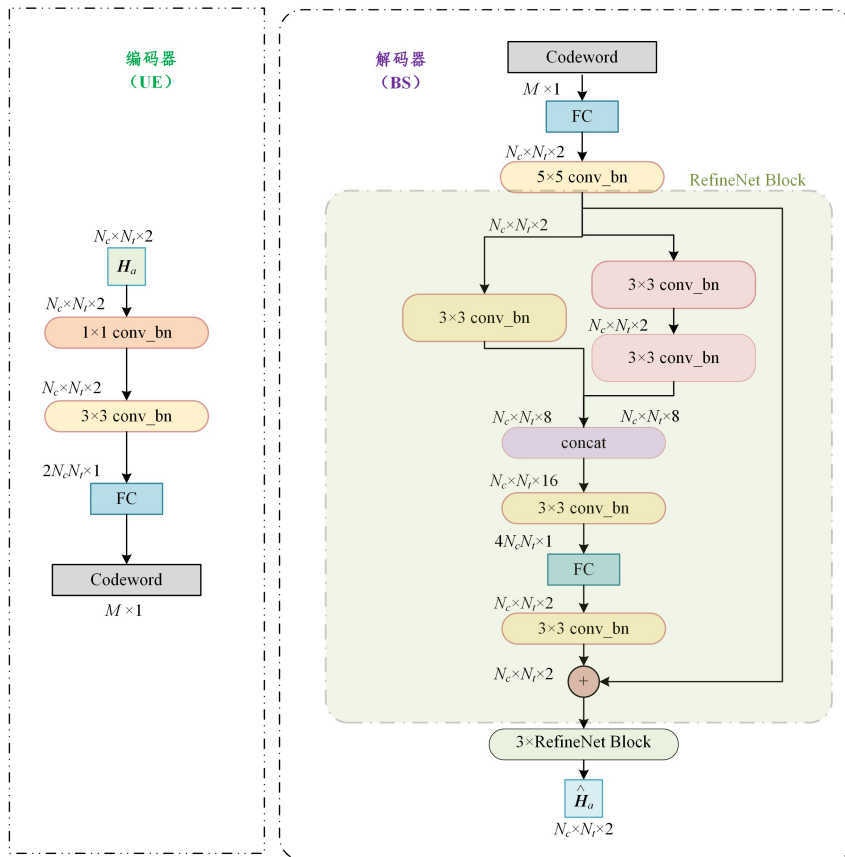


图 3 网络架构

Fig. 3 Network architecture

图 3 描述了所提模型的总架构,模型分为编码器和解码器,图中网络各层上的标识(如  $N_c \times N_r \times 2$ )为该层输入张量的大小。因本文更关注 CSI 压缩反馈策略,故假设下行信道估计和上行反馈过程是理想的,即解码器收到的码字是编码器的输出<sup>[13]</sup>。

### 3.2 编码器

在编码器端,由于 UE 的计算能力和存储空间有限,网络的设计必须简单高效,又因为信道数据开始是复数信号,如下式:

$$\mathbf{H}(t) = \sum_{n=1}^N a_n(t) e^{-j\theta_n(t)} \quad (6)$$

其中,  $N$  表示信号路径总数,  $a_n(t)$  为  $t$  时刻第  $n$  条路径的衰减度,  $\theta_n(t)$  代表对应的相位变化。若只是将 CSI 简单地视为图像的两个独立通道并作为输入,直接进行卷积会破坏 CSI 的原始物理性质,这不利于解码器的 CSI 重建。所以本文所提

已有基于 DL 的 CSI 反馈方法大多将 CSI 视为图像,对于室外 CSI 图像来说,更多的特征需要更强大的网络来丰富模型的表达能力<sup>[20]</sup>。然而 UE 的存储空间和计算资源受限,即深度编码器是难以部署的,而解码器部署在 BS 且有足够的计算资源,这促使所提方法设计学习能力更强的解码器,以弥补简单编码器的性能不足。由于普通的 CNN 很难捕捉室外 CSI 的共享空间模式,CSI 角落或者边缘区域的数据与卷积核进行卷积的次数较少,数据边缘的大部分信息丢失了,因此本文在解码器的残差块中引入表达能力更强的 FCN,以恢复 CSI 压缩过程中的信息损失并重建这些缺乏明确规则的 CSI 空间模式,也正是因为解码器具有强大的重构能力,所以简单编码器更能专注于 CSI 特征的提取<sup>[21]</sup>。

模型的编码器头卷积采用 CLNet<sup>[7]</sup>提出的  $1 \times 1$  逐点卷积来耦合 CSI 的实部和虚部,以保存 CSI 的物理信息。通过权衡精度和模型大小,本文采用 32 个可学习卷积核。之后经过  $3 \times 3$  卷积核进行特征提取,其通过滑窗对数据卷积求和,可以表示为:

$$\mathbf{H}_o = f_c(\mathbf{H}_l * \mathbf{W}_c) \quad (7)$$

其中,  $\mathbf{H}_l \in \mathbb{R}^{N_c \times N_r \times K}$  和  $\mathbf{H}_o \in \mathbb{R}^{N_c \times N_r \times K}$  分别为卷积的输入和输出,  $K$  为卷积核的数量,  $\mathbf{W}_c$  为卷积核权重矩阵,  $*$  表示卷积,  $f_c(\cdot)$  为激活函数。卷积层统一使用带参数的修正线性单元(Parametric Rectified Linear Unit, PReLU)激活函数,且在激活前进行批归一化(Batch Normalization, BN)处理,用于防止梯度消失和加速模型的收敛。经  $3 \times 3$  卷积层特征提取后的输出为  $\mathbf{H}_o' \in \mathbb{R}^{N_c \times N_r \times 2}$ , 重新排列为二维向量  $\mathbf{c}_l \in \mathbb{R}^{2N_c \times N_r \times 1}$ , 然后使用 FCN 将学到的特征空间映射到样本标记空间表示,可以归纳为:

$$\mathbf{c}_0 = \mathbf{c}_l \mathbf{W}_L + \mathbf{b} \quad (8)$$

其中,  $\mathbf{c}_l$  和  $\mathbf{c}_0$  分别为全连接的输入和输出,  $\mathbf{W}_L$  为全连接权重矩阵,  $\mathbf{b}$  为偏置。得到低维码字  $\mathbf{c}_0$  后反馈到解码器。

### 3.3 解码器

在解码器端, 首先将接收到的码字  $\mathbf{c}_0$  通过 FC 层恢复, 重塑为  $\hat{\mathbf{H}}_0' \in \mathbb{R}^{N_r \times N_t \times 2}$ , 然后通过  $5 \times 5$  的头部卷积层 (CRNet<sup>[6]</sup> 已表明该内核大小作为头部卷积层的优势), 最后通过适当设计的优化块重构 CSI。

优化块是解码器的主要成分, 首先输入数据经过 2 条具有不同感受野的并行卷积路径, 卷积核大小分别为  $3 \times 3$  和  $5 \times 5$ , 所提方法使用 2 个串联的  $3 \times 3$  卷积核来替代  $5 \times 5$  大卷积, 保持感受野范围的同时降低了不必要的复杂性, 且增加的非线性函数可以增强模型的拟合能力。并行路径可以视为从输入中进行再提取操作, 这样处理的原因是单一分辨率的网络不能很好地适应特征粒度的变化, 可能会导致网络性能和鲁棒性变差。使用不同感受野大小的卷积核使得模型不局限于局部信息, 更能关注到全局信息, 这对 CSI 的重建是有利的。2 条并行路径将通道统一扩展至 8 通道, MRFNet<sup>[20]</sup> 已证明多个卷积通道可以有效恢复 CSI 的不同特征, 此时得到 2 条路径的输出维度为  $\hat{\mathbf{H}}_0'' \in \mathbb{R}^{N_r \times N_t \times 8}$ , 进行通道拼接激活后的维度为  $\hat{\mathbf{H}}_0''' \in \mathbb{R}^{N_r \times N_t \times 16}$ 。由于拼接后的维度是模型输入的 8 倍, 因此需要降低维度使得模型的输出与输入维度一致。所提方法采用 FCN 对拼接输出进行处理, 这是因为当压缩倍数较大时, 压缩过程将会有较多的信息损失, 而解码器的优化块必须将丢失的信息重建出来, 这对于 CNN 来说是比较困难的。但由于此时输出维度较大, 直接作为 FCN 的输入会造成模型参数量过于庞大, 所以在传递给 FCN 之前采用了额外的  $3 \times 3$  卷积层进行维度变换至  $\hat{\mathbf{H}}_0'''' \in \mathbb{R}^{N_r \times N_t \times 4}$ , 这是一个更合理的水平, 然后将其重塑为 FCN 的输入  $\mathbf{c}_l' \in \mathbb{R}^{4N_r \times N_t \times 1}$ , 经式(8)整合映射得到  $\mathbf{c}_0' \in \mathbb{R}^{2N_r \times N_t \times 1}$ , 将其再重塑为输入大小维度。优化块最后采用了一个  $3 \times 3$  卷积层, 并将其输出与跳跃连接相加后进行激活操作, 这一步的目的在于增强特征之间的交叉能力。考虑到不同层次的特征信息存在差异, 通过逐元素相加两个特征向量的相应元素来实现这一目标, 这样做可以使不同层次之间的特征更好地相互影响, 生成更丰富的特征表示, 从而提高模型的性能<sup>[22]</sup>。

经模型性能与复杂度的权衡之后(见 4.3 节), 所提方法在解码器采用 4 个残差优化块进行 CSI 的重建, 最后通过 Sigmoid 函数激活得到重建 CSI 矩阵  $\hat{\mathbf{H}}_a \in \mathbb{R}^{N_r \times N_t \times 2}$ 。

## 4 仿真结果及性能分析

### 4.1 实验设置

#### 4.1.1 数据集

为公平比较不同方法的性能, 在训练所提模型时使用了 CsiNet 等模型中的基本系统设置和数据集, 这些方法在 COST2100 MIMO 信道模型下进行了测试<sup>[22]</sup>, 所提方法重点关注在 300 MHz 频段的室外乡村场景。BS 被放置在一个边长为 400 m 的正方形区域中心, 在 BS 端使用  $N_t = 32$  根天线和  $\tilde{N}_c = 1024$  个子载波, 带宽为 20 MHz, 截断矩阵时取  $N_c = 32$ <sup>[4]</sup>。通过 COST2100 MIMO 信道生成共 150 000 条

数据矩阵, 训练集、验证集和测试集分别包含 100 000, 30 000 和 20 000 个样本, 所有的测试样本均被排除在训练和验证样本之外。

#### 4.1.2 实验环境

实验使用 Windows10 系统, 模型基于 PyTorch 框架以 Python 作为开发语言, 计算机处理器为 Intel(R) Xeon(R) W-2102 CPU @ 2.90 GHz, 并利用 NVIDIA GeForce RTX 3090 显卡加速模型推理。

#### 4.1.3 训练超参数设置

模型训练过程中, 目标函数为均方误差 (Mean Square Error, MSE), 学习率调整方案采用余弦退火算法, 初始学习率和最终学习率分别设置为 0.002 和 0.00005, 前 30 个迭代轮次用于热身。使用 Kaiming 初始化生成每个 CNN 和 FCN 的权值, 采用 Adam 优化器更新权值。所提方法进行了 500 个迭代轮次的训练, 批处理大小设置为 200。随机种子固定为 12345。

#### 4.1.4 评估指标

网络整体是一个端到端的编解码框架, 目的是训练式(5)中的  $\Theta_m$  和  $\Theta_d$ , 使得  $\mathbf{H}_a$  与  $\hat{\mathbf{H}}_a$  之间的距离最小。为评估网络的重建性能, 所提方法使用归一化均方误差 (NMSE) 作为标准来衡量测试值与真实值之间的差异, 其定义为:

$$\text{NMSE} = \mathbf{E} \left\{ \frac{\| \mathbf{H}_a - \hat{\mathbf{H}}_a \|_2^2}{\| \mathbf{H}_a \|_2^2} \right\} \quad (9)$$

其中,  $\mathbf{E}\{\cdot\}$  表示求期望,  $\|\cdot\|_2$  表示欧几里得范数。此外, 使用余弦相似度来衡量反馈 CSI 的质量<sup>[13]</sup>, 其定义为:

$$\rho = \mathbf{E} \left\{ \frac{1}{N_c} \sum_{n=1}^{\tilde{N}_c} \frac{|\hat{\mathbf{h}}_n^H \tilde{\mathbf{h}}_n|}{\| \hat{\mathbf{h}}_n \|_2 \| \tilde{\mathbf{h}}_n \|_2} \right\} \quad (10)$$

其中,  $\tilde{\mathbf{h}}_n$  和  $\hat{\mathbf{h}}_n$  分别表示第  $n$  个子载波的原始和重建的信道向量。

### 4.2 对比分析

所提方法与已有的几种基于 DL 的 CSI 反馈方法进行了比较。在室外场景下, 不同压缩比的 NMSE 性能和余弦相似度对比如表 1 所列, 本文更关注模型在室外场景高倍压缩情况下的表现, 所以实验在 8~64 倍压缩之间进行。表 1 中, CsiNet 是第一个基于深度学习的方法, 被作为后续研究的基线, 其他方法均在其基础上做出不同方面的改进工作。本文通过这些比较评估所提方法在高倍压缩情况下的性能优势。

表 1 各方法不同压缩比的性能表现

Table 1 Performance of each method at different compression ratios

方法	CR=1/8		CR=1/16		CR=1/32		CR=1/64	
	NMSE/dB	$\rho$	NMSE/dB	$\rho$	NMSE/dB	$\rho$	NMSE/dB	$\rho$
CsiNet	-7.26	0.88	-4.68	0.80	-2.81	0.67	-1.93	0.59
CsiNet+	-8.34	0.90	-5.64	0.84	-3.53	0.73	-2.09	0.61
ConvCsiNet	-	-	-6.00	0.85	-5.21	0.82	-4.48	0.79
ACCsiNet	-	-	-11.76	0.94	-9.14	0.92	-7.11	0.88
CsiNet+ DNN	-17.88	0.97	-14.70	0.96	-14.42	0.96	-11.34	0.94
所提方法	<b>-18.69</b>	<b>0.97</b>	<b>-17.33</b>	<b>0.97</b>	<b>-16.88</b>	<b>0.97</b>	<b>-14.60</b>	<b>0.96</b>

从表 1 可以看出, 所提方法在不同压缩比下均表现出较好的性能, 在压缩比为 1/8 时, 模型表现出较佳的性能, NMSE 为 -18.69 dB。随着压缩倍数的增加, 压缩过程中有更多的信息损失, 所有方法的性能都出现了下降, 但所提方法

依然有稳健的性能表现,在压缩比为 1/64 时,其 NMSE 为  $-14.60$  dB,余弦相似度提升到 0.96。这种出色的重建性能即使在高倍压缩下仍然能够实现,其主要原因在于网络拥有更加强大的解码器,特别是在残差优化块中,FCN 的作用至关重要,在第 4.3 节将详细讨论 FCN 的贡献。

CsiNet+DNN 在性能上远远优于 CsiNet 和 CsiNet+,尤其是在 64 倍压缩下,CsiNet 和 CsiNet+ 的 NMSE 值约为  $-2$  dB,几乎无法在实际应用中使用。尽管 CsiNet+DNN 表现出良好的性能,但其复杂度相对较高。为了衡量各模型复杂性,表 2 提供了各方法在压缩比为 1/8 时编码器和解码器的参数量与浮点运算数(Floating Point Operations, FLOPs),其中 ACCsiNet 与 ConvCsiNet 复杂度一样<sup>[9]</sup>。从表 2 中可以观察到,所提方法的编码器复杂度与 CsiNet 相当,而额外的复杂度增加主要集中在解码器部分,但远低于其他几种反馈方法。综合考虑表 1 和表 2 中的数据,可以得出结论:所提方法在较低复杂度下表现出更好的 CSI 重建性能。

表 2 各方法压缩比为 1/8 时的复杂度

Table 2 Complexity of each method at a compression ratio of 1/8

方法	编码器		解码器	
	参数量	FLOPs	参数量	FLOPs
CsiNet	$0.52 \times 10^6$	$1.13 \times 10^6$	$0.53 \times 10^6$	$7.72 \times 10^6$
CsiNet+	$0.52 \times 10^6$	$2.91 \times 10^6$	$0.55 \times 10^6$	$45.46 \times 10^6$
ConvCsiNet	$1.85 \times 10^6$	$59.10 \times 10^6$	$1.78 \times 10^6$	$165.48 \times 10^6$
ACCsiNet	$1.85 \times 10^6$	$59.10 \times 10^6$	$1.78 \times 10^6$	$165.48 \times 10^6$
CsiNet+DNN	$0.52 \times 10^6$	$2.91 \times 10^6$	$45.35 \times 10^6$	$137.30 \times 10^6$
所提方法	$0.52 \times 10^6$	$1.14 \times 10^6$	$34.10 \times 10^6$	$37.27 \times 10^6$

此外,本文提供了所提网络模型的拟合效果。图 4 展示了当  $CR=1/64$  时训练数据集和测试数据集的 MSE 损失曲线,其中每 5 轮训练进行 1 次测试。从图中可以观察到,在前 30 轮热身和之后的训练过程中,损失函数曲线存在一定的差异。这是因为在热身阶段,学习率迅速从小变大,导致损失函数值发生较大的变化。随着迭代次数的增加,模型的损失值逐渐减小,而且训练与测试曲线的变化趋势基本一致。最终,损失函数能够收敛到  $10^{-5}$  左右的较小值,这体现了所提网络模型具有良好的拟合效果。




图 4 网络模型的 MSE 损失

Fig. 4 MSE loss of the proposed model

### 4.3 网络结构讨论

为进一步验证所提出模型的有效性,本文进行了 2 项对比实验。第 1 项讨论了模型深度对性能的影响,实验考察了在压缩比为 1/8 和 1/64 时,通过增加解码器中残差优化块数量分析模型性能发生的变化,仿真结果如图 5 所示。从图中可以看出优化块数量对模型的性能有显著影响,随着优化块数量的增加,模型的 NMSE 性能逐渐提升,但当增加到第 5 个优化块时,性能几乎没有进一步提升,而复杂度却呈线性增加。综合以上分析讨论,所提

方法决定采用 4 个优化块进行 CSI 重构。




图 5 解码器优化块数量对模型性能的影响

Fig. 5 Influence of the number of RefineNet blocks on model performance

第 2 项实验探讨了优化块中 FCN 的作用。通常情况下,参数众多的线性层赋予了神经网络强大的拟合能力,但其对存储空间和计算资源的需求可能令人望而却步。本项实验旨在研究残差结构中增加的 FCN 对所提模型性能的影响,仿真结果如表 3 所列。在  $CR=1/8$  时,通过修改残差优化块中 FCN 的输入张量大小来验证 FCN 在网络中的贡献,具体方法是将上一个卷积层的输出通道数更改为 8 或 16。从表 3 中可以观察到随着增加 FCN 输入张量大小,所提方法的性能有一定提升,然而,这种提升伴随着更多计算资源的消耗。例如输入张量大小为 8192 时,NMSE 性能提升并不显著,而模型的复杂度却成倍增长,这可能是 FCN 中存在较多冗余参数所导致的。在综合考虑模型复杂度与性能后,本文选择将优化块中 FCN 的输入张量大小设置为 4096,这一选择可以在相对较低的复杂度下获得令人满意的重建性能。

表 3 在  $CR=1/8$  时,优化块 FCN 输入大小对模型的影响

Table 3 Influence of input size of FCN on model performance when  $CR=1/8$

输入张量大小	NMSE/dB	$\rho$	参数量	FLOPs
2048	-14.05	0.96	$17.84 \times 10^6$	$20.41 \times 10^6$
4096	-18.69	0.97	$34.61 \times 10^6$	$38.40 \times 10^6$
8192	-20.46	0.97	$68.17 \times 10^6$	$74.38 \times 10^6$
16384	-23.58	0.98	$135.28 \times 10^6$	$136.64 \times 10^6$

**结束语** 对于 FDD 大规模 MIMO-OFDM 系统,目前大多数基于 DL 的 CSI 反馈方法存在室外高倍压缩下重建表现不佳的问题。本文提出了一种新的解决方法,通过使用并行多分辨率 CNN 以及在残差结构中引入具备强大学习能力的 FCN,构建了一个高性能的反馈网络模型。通过仿真实验,验证了所提方法的可行性和有效性,其在复杂度相对较低的情况下实现了高质量的 CSI 重建,与其他基于 DL 的反馈方法相比,所提方法在不同压缩比下均表现出更卓越的性能。随着天线数量的不断增加,反馈开销呈指数增长,实现高倍压缩下良好的 CSI 反馈重建是非常必要的,未来的研究将重点关注更多收发天线的 CSI 反馈问题。

### 参考文献

- [1] ANDREWS J G, BUZZI S, CHOI W, et al. What will 5G be? [J]. IEEE Journal on Selected Areas in Communications, 2014, 32(6): 1065-1082.
- [2] METZLER C A, MALEKI A, BARANIUK R G. From denoising to compressed sensing[J]. IEEE Transactions on Information Theory, 2016, 62(9): 5117-5144.

- [3] 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*, 2004, 57(11): 1413-1457.
- [4] 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.
- [5] GUO J J, WEN C K, 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.
- [6] LU Z L, WANG J T, SONG J. Multi-resolution CSI feedback with deep learning in massive MIMO system[C]// *IEEE International Conference on Communications*. IEEE, 2020: 1-6.
- [7] 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.
- [8] WANG T, 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.
- [9] CAO B, YANG Y, RAN P, et al. ACCsiNet: Asymmetric convolution-based autoencoder framework for massive MIMO CSI feedback[J]. *IEEE Communications Letters*, 2021, 25(12): 3873-3877.
- [10] CAO Z, SHIH W, GUO J J, et al. Lightweight convolutional neural networks for CSI feedback in massive MIMO[J]. *IEEE Communications Letters*, 2021, 25(8): 2624-2628.
- [11] YE H Y, GAO F 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] CAI Q, DONG C, NIU K. Attention model for massive MIMO CSI compression feedback and recovery[C]// *IEEE Wireless Communications and Networking Conference*. IEEE, 2019: 1-5.
- [13] LIU W B, YAN B, SHEN L, et al. CLPNet: CSI feedback network for massive MIMO based on deep learning[J]. *Radio Engineering*, 2022, 52(9): 1660-1665.
- [14] ZHANG Y, ZHANG X, LIU Y. Deep learning-based CSI compression and quantization with high compression ratios in FDD massive MIMO systems[J]. *IEEE Wireless Communications Letters*, 2021, 10(10): 2101-2105.
- [15] GUO J J, WEN C K, JIN S, et al. Overview of deep learning-based CSI feedback in massive MIMO systems[J]. *IEEE Transactions on Communications*, 2022, 70(12): 8017-8045.
- [16] LU Z, ZHANG X, HE H, et al. Binarized aggregated network with quantization: Flexible deep learning deployment for CSI feedback in massive MIMO systems[J]. *IEEE Transactions on Wireless Communications*, 2022, 21(7): 5514-5525.
- [17] LIU L F, OESTGES C, POUTANEN J, et al. The COST2100 MIMO channel model[J]. *IEEE Wireless Communications*, 2012, 19(6): 92-99.
- [18] KOLMONEN V M, ALMERS P, SALMI J, et al. A dynamic dual-link wideband MIMO channel sounder for 5.3 GHz[J]. *IEEE Transactions on Instrumentation and Measurement*, 2010, 59(4): 873-883.
- [19] ZHU M, ERIKSSON G, TUFVESSON F. The COST 2100 channel model: Parameterization and validation based on outdoor MIMO measurements at 300 MHz[J]. *IEEE Transactions on Wireless Communications*, 2013, 12(2): 888-897.
- [20] HU Z Y, GUO J H, LIU G Z, et al. MRFNet: A deep learning-based CSI feedback approach of massive MIMO systems[J]. *IEEE Communications Letters*, 2021, 25(10): 3310-3314.
- [21] HE K M, CHEN X L, XIE S N, et al. Masked autoencoders are scalable vision learners[C]// *2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition*. New Orleans, LA, USA, 2022: 15979-15988.
- [22] 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]. *Internet Things*, 2020, 4(10): 33-44.



**CHEN Meng**, born in 1998, postgraduate. His main research interests include deep learning and channel state information feedback.



**QIAN Rongrong**, born in 1985, Ph. D. Her main research interests include wireless communication, signal processing and so on.