

一种轻量化低复杂度的FDD大规模MIMO系统CSI反馈方法

廖 勇,李玉杰

(重庆大学微电子与通信工程学院,重庆 400044)

摘 要: 针对频分双工大规模多输入多输出(Multiple-Input Multiple-Output, MIMO)通信系统中信道状态信息(Channel State Information, CSI)反馈方法复杂度高、精度低和开销大的问题,本文提出了一种基于深度学习的低复杂度CSI反馈方法.该方法通过端到端的方式构建了一种从用户设备编码器到基站解码器相结合的网络结构.编解码器利用连续的平均池化层和上采样层完成特征图的降维和升维,同时引入深度可分离卷积神经网络减少网络参数量.在解码器部分,本文利用残差网络构建连续的拥有大卷积核的残差块逼近原始CSI矩阵.仿真结果表明,和已有的代表性方法相比,本文所提方法在归一化均方误差上有2 dB~5 dB的性能提升,在余弦相似度上也有2%~5%的提升,并且在时间复杂度和空间复杂度上均有更好的表现.

关键词: 频分双工;大规模MIMO;信道状态信息;深度学习;深度可分离卷积神经网络;残差网络

中图分类号: TN911.72

文献标识码: A

文章编号: 0372-2112(2022)05-1211-07

电子学报 URL: <http://www.ejournal.org.cn>

DOI: 10.12263/DZXB.20210723

Lightweight and Low Complexity CSI Feedback Method for FDD Massive MIMO Systems

LIAO Yong, LI Yu-jie

(School of Microelectronics and Communication Engineering, Chongqing University, Chongqing 400044, China)

Abstract: Aiming at the problems of high complexity, low precision and high overhead of the channel state information(CSI) feedback method in frequency division duplexing massive multiple input multiple output(MIMO) communication system, this paper proposes a low complexity CSI feedback method based on deep learning. This method constructs a network structure from the encoder of user equipment to the decoder of base station in an end-to-end way. The codec uses a continuous average pooling layers and up sampling layers to complete the dimensionality reduction and dimensionality increase of the feature map, and introduces a depthwise separable convolutional neural network to reduce the amount of network parameters. In the decoder part, this paper uses the residual network to construct continuous residual blocks with large convolution kernel to approximate the original CSI matrix. Simulation results show that, compared with the existing representative methods, the method proposed in this paper has 2 dB~5 dB improvement in normalized mean square error, and 2%~5% improvement in cosine similarity, and it has better performance in time complexity and space complexity.

Key words: frequency division duplexing; massive MIMO(Multiple-Input Multiple-Output); channel state information; deep learning; depthwise separable convolution neural network; residual network

1 引言

大规模多输入多输出(Multiple-Input Multiple-Output, MIMO)作为下一代无线通信系统的一项关键技术,通过在基站(Base Station, BS)配备数十根甚至数百根天线,可以大幅度提高频谱效率和能量效率^[1].为了充

分利用空间分集和复用增益,大规模MIMO系统需要获取足够精确的下行链路信道状态信息(Channel State Information, CSI)^[2].在频分双工(Frequency Division Duplexing, FDD)大规模MIMO系统中,用户设备(User Equipment, UE)必须首先估计下行链路CSI,再通过反

链路反馈回 BS^[3]. 当收发端天线数量不大时, 基于码本的反馈方法可以有效地解决反馈开销问题, 如文献[4, 5]提出的通过网格解码和低纬度矢量量化码本的方法. 不过随着天线数的增加, 码本变得非常巨大, 码字搜索也变得异常困难.

在大规模 MIMO 系统中, 信道间具有很强的空间相关性^[6]. 一方面, 由于真实环境中有限的散射环境, 时域无线多径信道大部分路径的能量为零, 这使得多径信道呈现出稀疏性; 另一方面, 由于 BS 周围的散射体有限, 大规模 MIMO 信道在角度域内呈现稀疏性^[7]. 因此研究人员将压缩感知 (Compressed Sensing, CS)^[8] 应用在 CSI 反馈中. 不过现有的 CS 方法存在两个问题: 一个是严重依赖信道的稀疏特性. 然而真实信道并非严格稀疏; 另一个是现存 CS 算法大多都依靠迭代完成信号的重建, 在低压缩率时其重建性能差, 重建速度较慢.

近年来, 深度学习 (Deep Learning, DL) 方法逐渐在 CSI 反馈中得到应用, 已有研究学者提出了一些基于 DL 的 CSI 反馈框架. 如文献[9~11]提出的一系列基于 DL 的信道恢复框架, 即在 UE 使用编码器将信道矩阵转换为码字, 在 BS 解码器使用 ResNet 或双向长短期记忆网络来恢复信道矩阵. 另外, 为了降低网络的复杂度, 也有研究学者提出了 CS 联合 DL 的框架^[12], 先在 UE 利用高斯随机矩阵将 CSI 矩阵压缩为测量向量, 接着在 BS 利用金字塔池化网络和 ResNet 来恢复信道矩阵, 但其性能并未有明显提升.

针对高复杂度和反馈开销大的问题, 本文提出了一种轻量化低复杂度的 CSI 反馈网络 LCsiNet, 该网络在 UE 采用连续的平均池化层 (Average Pooling, AP)、卷积网络 (Convolution Neural Network, CNN) 和深度可分离卷积网络 (Depthwise Separable Convolution Neural Network, DSCNN)^[13] 所组成的结构逐步缩小原始的 CSI 矩阵得到压缩后的码字矩阵, 其中 AP 是利用了一种计算量较小的池化技术来缩小矩阵的尺度, 而 DSCNN 是一种通过减少网络参数量来降低计算密度的改进型 CNN, 在加深网络的同时提升其性能. BS 首先采用连续的上采样层 (Up Sampling, US)、CNN 和 DSCNN 所组成的结构逐步扩大压缩的码字矩阵, 重建初始 CSI 矩阵; 接着, 利用残差网络^[14] (Residual Network, ResNet) 这种可以逐步微调的结构构建了一种双路的残差卷积块, 将初始 CSI 逐渐逼近原始 CSI. 我们在复杂度和重建质量指标对比了目前主流的 CSI 反馈框架 CsiNet、CS-ReNet 和 CsiNetPlus. 分析与仿真结果表明, 相较于这些代表性方法, 本文所提方法在复杂度、重构质量以及运行时间上均有更好的性能表现.

2 系统模型

2.1 大规模 MIMO 系统

我们考虑一种单小区大规模 MIMO 通信系统, 该通信系统在基站端有 N_t ($N_t \gg 1$) 根发射天线, 用户端有单根接收天线, 采用正交频分复用 (Orthogonal Frequency Division Multiplexing, OFDM), 并有 N_s 个子载波. 接收端信号 \mathbf{y} 可以被描述为

$$\mathbf{y} = \tilde{\mathbf{H}}^H \mathbf{F} \mathbf{x} + \mathbf{n} \quad (1)$$

其中, $\mathbf{y} \in \mathbb{C}^{N_s \times 1}$ 表示为 N_s 维接收向量; $\mathbf{x} \in \mathbb{C}^{N_s \times 1}$ 表示为 N_s 维发射向量; $\tilde{\mathbf{H}} = [\mathbf{h}_1, \mathbf{h}_2, \dots, \mathbf{h}_{N_s}] \in \mathbb{C}^{N_s \times N_t}$ 表示为 $N_s \times N_t$ 维度的信道矩阵, 其中的 $\mathbf{h}_i \in \mathbb{C}^{N_t \times 1}$ 表示为第 i 个子载波上的信道向量; $\mathbf{F} = [\mathbf{u}_1, \mathbf{u}_2, \dots, \mathbf{u}_{N_s}] \in \mathbb{C}^{N_s \times N_t}$, 其中 \mathbf{u}_i 表示第 i 个子载波的预编码向量; $\mathbf{n} \in \mathbb{C}^{N_s \times 1}$ 表示为 N_s 维的加性高斯白噪声向量.

为更好地设计预编码向量 \mathbf{u}_i , 在 CSI 反馈流程中, 需要在基站端得到一个足够精确的 $\tilde{\mathbf{H}}$, 而这正是 CSI 反馈当中最需要解决的问题, 通过更低的反馈量获得更好的重建效果. 在 FDD 大规模 MIMO 系统中, CSI 反馈即是在 UE 经信道估计得到的信道矩阵 $\tilde{\mathbf{H}}$ 通过反馈链路发送到 BS. 此时我们需要反馈的数据量可以被表示为 $N_s \times N_t$ 个复数值, 在反馈链路中, 这个数据量是非常大的, 需要占据大量珍贵的带宽资源. 由于 CSI 矩阵在虚拟角度域是稀疏的, 该虚拟角度域矩阵可通过两个离散傅里叶变换 (Discrete Fourier Transform, DFT) 矩阵求得

$$\mathbf{H} = \mathbf{D}_s \tilde{\mathbf{H}} \mathbf{D}_t^H \quad (2)$$

其中, \mathbf{D}_s 是一个 $N_s \times N_s$ 的 DFT 矩阵, \mathbf{D}_t 是一个 $N_t \times N_t$ 的 DFT 矩阵. 在真实的信道环境中, 信号的多径时延只集中在几条路径上, 因此导致角度域中大多数元素是为 0 的, 仅前 N_s' 行中包含非零元素, 因此我们将原始的 $N_s \times N_t$ 矩阵截断为 $N_s' \times N_t$ ($N_s' < N_s$) 的截断矩阵. 在本文当中, 我们所涉及的 CSI 流程中需要反馈的矩阵即为上述的截断矩阵 $\mathbf{H} \in \mathbb{C}^{N_s' \times N_t}$.

2.2 CSI 反馈流程

通过 2.1 节中的分析, 我们在得到即截断矩阵 $\mathbf{H} \in \mathbb{C}^{N_s' \times N_t}$ 后, 所需反馈的元素数量是 $N_s' \times N_t$. 这对于通信系统来说, 依然是巨大的系统开销. 因此, 我们提出了一种基于 DL 的反馈框架, 采用 UE 编码器将 \mathbf{H} 编码为码字矩阵. 这个编码过程可以表示为

$$\mathbf{S}_{\text{en}} = f_{\text{en}}(\mathbf{H}) \quad (3)$$

其中, \mathbf{S}_{en} 是编码器的输出结果, \mathbf{S}_{en} 在不同的压缩率下有不同的矩阵大小, $f_{\text{en}}(\cdot)$ 表示为编码器函数. 接着, 我们将得到的码字矩阵 \mathbf{S}_{en} 反馈回 BS 端. 一旦 BS 得到压

缩后的 CSI 矩阵 \mathbf{S}_{en} , 就可以通过 BS 基于 DL 框架实现的解码器重建矩阵 \mathbf{H} , 这个重建过程可以被表述为

$$\hat{\mathbf{H}} = f_{dc}(\mathbf{S}_{en}) \quad (4)$$

其中, $\hat{\mathbf{H}}$ 为重建后的截断矩阵, $f_{dc}(\cdot)$ 表示为解码器函数. 由于我们采用的是基于 DL 的方法, 因此, 编码器与解码器采用端到端的训练方式. 整个 CSI 反馈流程的结构可以被表述为以下函数:

$$\hat{\mathbf{H}} = f_{dc}(f_{en}(\mathbf{H})) \quad (5)$$

3 CSI 反馈框架设计

卷积神经网络本身所具有的对“图像”进行特征提取的特性, 因此在面对 CSI 反馈领域中的大量 CSI 矩阵时, 二维卷积神经网络可以提取其中的特征信息, 实现 UE 处 CSI 矩阵的压缩以及 BS 处 CSI 矩阵的重建. 现行的基于 DL 的 CSI 反馈框架基本为 CNN 和全连接层 (Full Connected layer, FC) 相结合的形式所构建, 然而这种形式所构建的网络其网络参数量和计算密度都被 FC 所占据, 复杂度较高. 因此, 本文提出一种轻量化 LCsi-Net, 目的是为了降低网络的复杂度, 同时提高网络的重建性能.

3.1 编码器结构设计

在本文中, 我们所提的基于 DL 的网络 LCsiNet 是一种完全基于卷积神经网络的结构, 相比如今较新的基于 DL 的 CSI 反馈框架广泛使用 FC 和 CNN 结合而言, 拥有更低的复杂度, 网络参数量也更少. 降低网络的参数量和复杂度其目的是为了更低的模型存储占用和计算复杂度. 这样一来, UE 通信终端计算负载更低, 存储占用更小.

为了压缩 CSI 矩阵同时降低网络参数量和计算复杂度, 我们引入了 AP、DSCNN 和 US. 前文中, 对于 CSI 复数截断矩阵 $\mathbf{H} \in \mathbb{C}^{N_s' \times N_t}$, 为了方便数据的处理和训练, 我们将其转化为 $N_s' \times N_t \times 2$ (即将实部和虚部分为两个不同的通道). 在针对不同的天线配置时, 矩阵的大小可根据 DFT 变换之后确定, 此时我们改动网络的输入输出大小即可. 理由是在天线配置加大的情况下, 角度域矩阵会逐渐增大, 但是信号的能量依然只是集中在部分路径上, 整个角度域矩阵的稀疏程度也会增大.

具体细节可见图 1 中的 UE encoder 部分, 将 \mathbf{H} 作为 UE 编码器的输入, 首先经过一个 ConvBN (它由一个 3×3 卷积核的 CNN、批量归一化层 (Batch Normalization, BN) 和激活函数 LeakyReLU 组成), 输出特征图数目为 64. 接着, 通过连续四个 AP-SEConvBN (SEConvBN 与 ConvBN 不同的是, 其中的 CNN 被更换为 3×3 卷积核的 DSCNN) 和一个 AP-ConvBN, 得到经过压缩后的码字矩阵 \mathbf{S}_{en} , 特征图数目的变换为 $64 \rightarrow 128 \rightarrow 256 \rightarrow M/4$. 每个 AP-SEConvBN 都由一个池化窗口大小为 2×2 的 AP 和一个 SEConvBN 构成, 每个 AP-ConvBN 由一个池化窗口大小为 2×2 的 AP 和一个 ConvBN 构成. DSCNN 相比 CNN, 参数量更少. DSCNN 和 CNN 的参数量计算的具体细节描述如: 假设输入两个卷积层的矩阵规格为 (w, l, c) , 卷积核心大小 (k, k) 并且不计算偏置项, 最后的输出通道数为 m . 对于 CNN 来说, 有多少个输入通道, 就有多少个卷积核. CNN 的参数量为 $m \times k \times k \times c$. 对于 DSCNN, 首先进行通道卷积 (即可以得到与输入通道数相等的特征图数目) 接着, 在对每个输出特征图进行 1×1 的逐点卷积, 参数量计算得到 $(k \times k + m) \times c$. 与 CNN 相比, DSCNN 参数量得到减少.

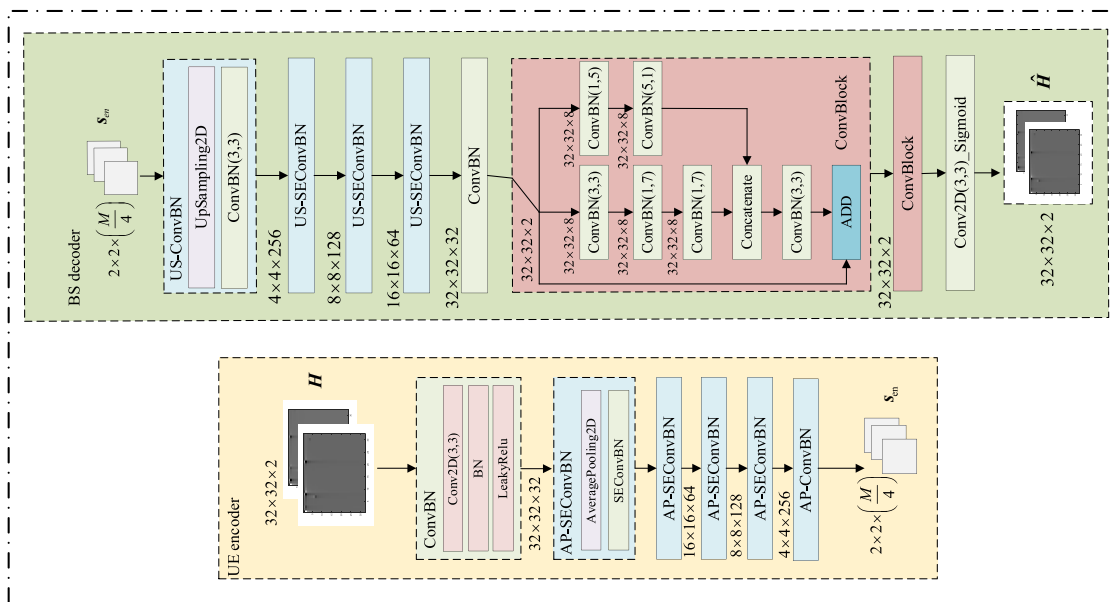


图 1 编解码器结构设计

3.2 解码器结构设计

图 1 中的 BS decoder 部分,对于解码器结构设计,相比于编码器结构设计而言要更复杂,网络层数更深.我们将 UE 编码器(encoder)输出得到码字矩阵 \mathbf{S}_{en} 输入 BS 解码器(decoder),编码器首先是 1 个 US-ConvBN 和 3 个连续的 US-SEConvBN,每个 US-ConvBN 由一个数据插值窗口大小为 2×2 的 US 和一个 ConvBN 构成,每个 US-SEConvBN 由一个 US 和一个 SEConvBN 构成. US 可以使得输入的数据维度提升,其原理是通过特征图数据的行和列进行重复的插值过程完成升维.连续的 4 个 US-ConvBN 和 US-SEConvBN 的特征图数目变换过程为 $M/4 \rightarrow 256 \rightarrow 128 \rightarrow 64$.接着,通过一个 ConvBN 得到 $N_s' \times N_t' \times 2$ 的输出后,再输入到连续的两个 ConvBlock,每个 ConvBlock 都是根据残差网络的形式所构建的一种参数量较少的双路残差卷积块.首先将 $N_s' \times N_t' \times 2$ 的输入分为两支路,每条支路均由 CNN 构成.上边的支路采用卷积核 1×5 和 5×1 的两个 CNN,输出特征图数目都为 8.下边的支路采用 3×3 、 1×7 和 7×1 的卷积核的 CNN 构成,输出特征图数目也都为 8.接着,将两支路的输出特征图进行合并,即输出特征图数目为两支路之和为 16.通过一个 ConvBN 后的输出与整个 ConvBlock 的输入的和作为 ConvBlock 的输出.最后将 $N_s' \times N_t' \times 2$ 的输出通过一个 3×3 卷积核的 CNN(激活函数 Sigmoid,可以将数据调整至 0~1)得到最终的重建结果 $\hat{\mathbf{H}}$.

对于 LCsiNet 的训练,我们采用端到端的训练方式(编码器与解码器作为一个网络进行训练),这样不仅能够方便地对我们所设计的网络进行训练和调试,同时也能更好地学习调整网络结构中的权重和偏置参数.假设我们输入 LCsiNet 的数据为 \mathbf{H}_i ,那么整个编码器的输入输出可表示为 $\hat{\mathbf{H}}_i = f_{\text{all}}(\mathbf{H}_i) \triangleq f_{\text{de}}(f_{\text{en}}(\mathbf{H}_i))$,其中的 i 是第 i 个样本.在训练过程中,我们采用自适应矩估计(Adaptive moment estimation, Adam)算法优化器,计算表达式见式(6).

$$\mathbf{L}_{(\mathbf{H}, \hat{\mathbf{H}})} = \frac{1}{T} \sum_{i=1}^T \left\| f_{\text{all}}(\mathbf{H}_i) - \mathbf{H}_i \right\|_2^2 \quad (6)$$

其中, $\|\cdot\|_2$ 表示为欧几里得范数, T 为训练样本的总量.

损失函数采用均方误差(Mean Square Error, MSE),其计算方式如式(7).

$$\text{MSE}_{(\mathbf{H}, \hat{\mathbf{H}})} = \frac{1}{T} \sum_{i=1}^T (\mathbf{H}_i - \hat{\mathbf{H}}_i)^2 \quad (7)$$

4 复杂度分析

时间和空间复杂度是衡量一个算法复杂度的两个重要指标.同样的在 DL 中,也有两个具体的复杂度指标,即对应时间复杂度的浮点运算数(FLOating Point

operations, FLOPs),对应空间复杂度的模型参数量(Model Parameters, MP).本文所提的 LCsiNet 其目的是为了降低模型的复杂度,提升 CSI 重建精度.由于本文所提的模型以及与之对比已提出的模型使用的网络结构主要是全连接层和卷积层.因此对全连接层和卷积层的浮点运算数和网络参数量进行计算分析.

全连接层的复杂度计算:假设输入的数据维度 (N, D) ,隐藏层权重维度 (D, out) ,输出 (N, out) ,那么它的 FLOPs 和 MP 见式(8)和(9).

$$\text{FLOPs} = (2 \times D - 1) \times \text{out} \quad (8)$$

$$\text{MP} = D \times \text{out} + \text{out} \quad (9)$$

卷积层的复杂度计算:假设输出特征图的宽高分别为 W 和 H ,卷积核大小为 $K_1 \times K_2$, C_{in} 为输入通道数(卷积核的层数), C_{out} 为输出通道数(卷积核的个数),那么它的 FLOPs 和 MP 见式(10)和(11).

$$\text{FLOPs} = W \times H \times K_1 \times K_2 \times C_{\text{in}} \times C_{\text{out}} \quad (10)$$

$$\text{MP} = K \times K \times C_{\text{in}} \times C_{\text{out}} \quad (11)$$

根据上述计算方式,我们分别得到了 CsiNet、CsiNetPlus 和 LCsiNet 的 MP 和 FLOPs.由于 CS-ReNet 中其编码器是由随机投影矩阵构成,并不是基于 DL 所搭建的深度自编码器,因此不纳入该对比中.从表 1 我们可以看出,单纯在编码器中,FC 所占有的参数量是极多数的,即便是更大的卷积核更多的卷积层的 CsiNetPlus,FC 依然占据其模型参数量的大多数.我们所提的网络结构也正是针对该问题所提,通过去除 FC,大大降低 UE 端编码器的复杂度之外,转而利用参数量,计算密度都较小的 DSCNN 和 AP 结合来达到降低特征图大小,完成矩阵压缩过程.

表 1 编码器结构中 FC 层对参数量的占用

CR	方法	Total	FC	百分比
1/16	A	262318	262272	99.99%
	B	262478	262272	99.92%
1/32	A	131182	131136	99.99%
	B	131342	131136	99.84%

(A: CsiNet B: CsiNetPlus)

另外,从表 2 对三种方法的整体结构 MP 和 FLOPs 对比来看,LCsiNet 在 AP、US、DSCNN 和 CNN 相结合的形式下,MP 和 FLOPs 相比其余的网络都要小, NMSE 和 ρ 也都有明显的提升,说明所提网络 LCsiNet 在能够提升性能之外,也降低了网络的复杂度.

5 仿真结果和分析

在 Matlab 仿真平台中采用 COST2100^[15]信道模型产生训练集、验证集和测试集数据,该信道模型是一种基于几何的随机信道模型,产生两类数据集:(1)工作

表 2 三种方法的 MP 和 FLOPs 的对比

CR	指标	CsiNet	CsiNetPlus	LCsiNet
1/4	MP	2103224	2121928	510516
	FLOPs	4201024	4238397	1015505
1/8	MP	1054392	1073096	289012
	FLOPs	2103872	2141245	572881
1/16	MP	529976	548680	178260
	FLOPs	1055296	1092699	351569
1/32	MP	267768	286472	122884
	FLOPs	530008	568381	240913
1/64	MP	136664	155368	95196
	FLOPs	268864	306237	199825

频率为 5.3 GHz 频段的室内微蜂窝场景。(2)工作频率 300 MHz 频段的室外场景。发射接收天线数 32、1,线性天线阵列,波长为 1/2 天线间距,子载波数 1024。原始信道矩阵在角度域是稀疏的,DFT 变换之后,只取前 $N_s'=32$ 行。采用的深度学习开源框架为 Keras。数据集分布:训练\验证\测试:100000\30000\20000。批次数据大小(batch size)为 200,训练轮次(epoch)1500,学习率(learning rate)0.001。仿真设备配置 CPU: Intel(R)Xeon (R)E5-2678,内存:64 GB,GPU: RTX 2080Ti。

将 LCsiNet 网络与现行 CS 算法和 DL 算法进行比较。CS 算法有 TVAL3^[16]、OMP^[17]方法。DL 算法有 CsiNet、CsiNetPlus 和 CS-ReNet。TVAL3 是一种非常快速的基于全变量的恢复算法,它考虑了越来越复杂的先验知识。OMP 是一种需要知道稀疏度先验的贪婪迭代算法。CsiNet 是最早使用 DL 的自编码器方法,它引入了残差结构增强恢复效果。CsiNetPlus 则是在 CsiNet 的基础上采用更大卷积核并且使用更多的残差结构来提升 CSI 重建质量。CS-ReNet 引入金字塔池化层 SPP-Net 的

概念来消除 CsiNet 出现的过拟合现象,同时利用随机投影矩阵压缩信号减轻 UE 端的计算存储压力。

以下分析性能优劣采用两个指标:计算 \mathbf{H} 和 $\hat{\mathbf{H}}$ 之间的归一化均方误差(Normalized Mean Square Error, NMSE),见式(12)。

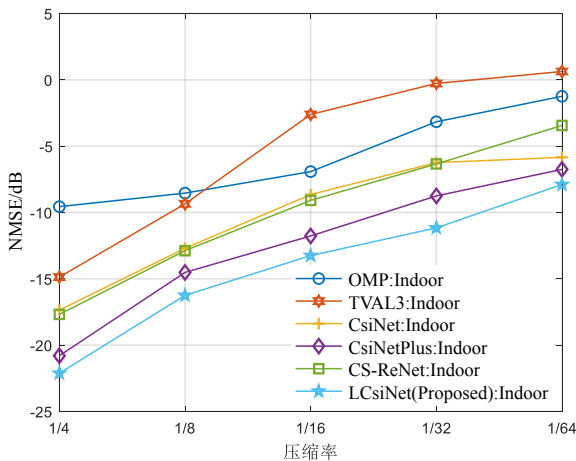
$$NMSE = 10 \times \log_{10} E \left\{ \left\| \frac{\mathbf{H} - \hat{\mathbf{H}}}{\|\mathbf{H}\|_2} \right\|_2^2 \right\} \quad (12)$$

计算重建子载波向量与原始子载波向量之间的余弦相似度,见式(13)。

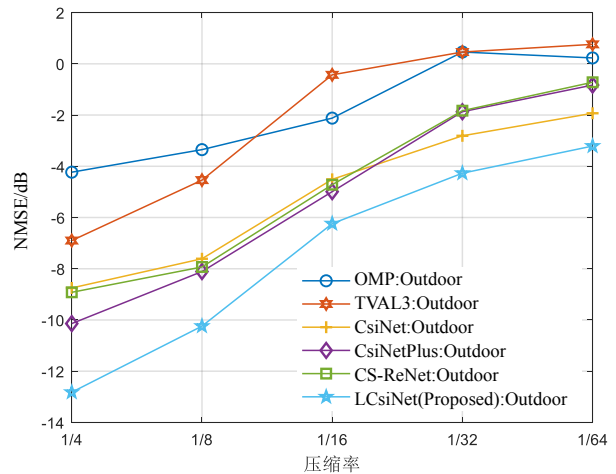
$$\rho = E \left\{ \frac{1}{T} \frac{1}{N_s} \sum_{t=1}^T \sum_{n=1}^{N_s} \frac{|\hat{\mathbf{h}}_{n,t}^H \mathbf{h}_{n,t}|}{\|\hat{\mathbf{h}}_{n,t}\|_2 \|\mathbf{h}_{n,t}\|_2} \right\} \quad (13)$$

其中 $\hat{\mathbf{h}}_{n,t}$ 是时刻 t 处的第 n 个子载波重建信道向量, $\mathbf{h}_{n,t}$ 是时刻 t 处的第 n 个子载波的信道向量。

根据图 2 和图 3 所示,压缩率(Compression Ratio, CR)的取值根据式子 $CR = M/(N_s' \times N_t \times 2)$ 进行确定。 M 的取值为 32、64、128、256、512,对应的 CR 值为 1/4、1/8、1/16、1/32、1/64。在 1/4 到 1/16 压缩率之间,基于 CS 的方法还是有效的,但是在更低压缩率时,高斯随机矩阵采样无法提取有效信息,因此基于 CS 的方法是无法重建信号的。如 TVAL3 在 1/16 压缩率时, NMSE 和余弦相似度骤降。因此我们可以得出一个结论,低压压缩率下,CS 算法的重构是无效的。反观基于 DL 的方法,虽然也受压缩率大小的影响,但是其在更低压缩率的表现显然是优于 CS 算法,在应对更低压缩率时,网络所能学习到的原始信号的信息更多,重建效果也就更好。本文所提的 LCsiNet 在 1500 轮的训练条件下,也表现出了更好的 NMSE 和余弦相似度。从图中可以看到 CsiNetPlus 较之 CsiNet 有不小性能提升,其本质上是增加了网络的深度,改用了更大的卷积核。而本文所提的 LCsiNet 则是



(a) 室内场景的 NMSE



(b) 室外场景的 NMSE

图 2 不同压缩率下的 NMSE

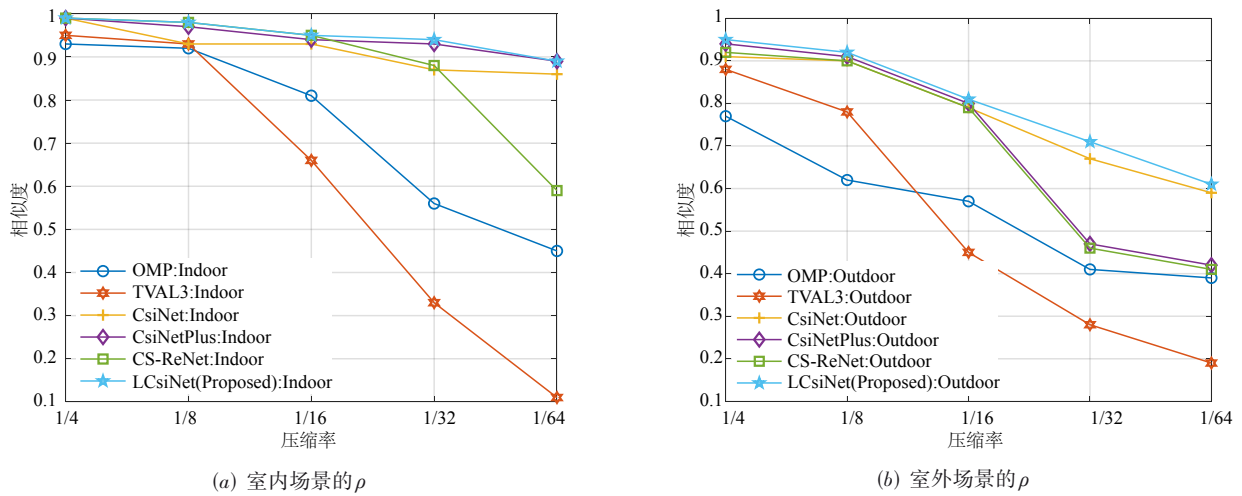


图3 不同压缩率下的 ρ

在保证良好的NMSE和余弦相似度下,达到更低的复杂度,更少的网络参数量.

除此之外,由于CSI矩阵获取的精确性往往会影响到BS对预编码向量的设计.预编码向量设计的好坏又会决定整个系统的性能表现,因此我们这里选取两个具有代表性的室内场景下的压缩率1/4和1/32进行误码

率的仿真.仿真结果如图4,从图中可以看出,本文所提出的LCsiNet在恢复精度更高的情况下,给误码率也带来一定程度的增益.其次,在执行测试集的单个样本的平均运行时间上,CsiNet:0.18 ms,CsiNetPlus:0.23 ms,LCsiNet:0.15 ms,基于DL的方法相比基于CS的算法,会快几十倍到上百倍.

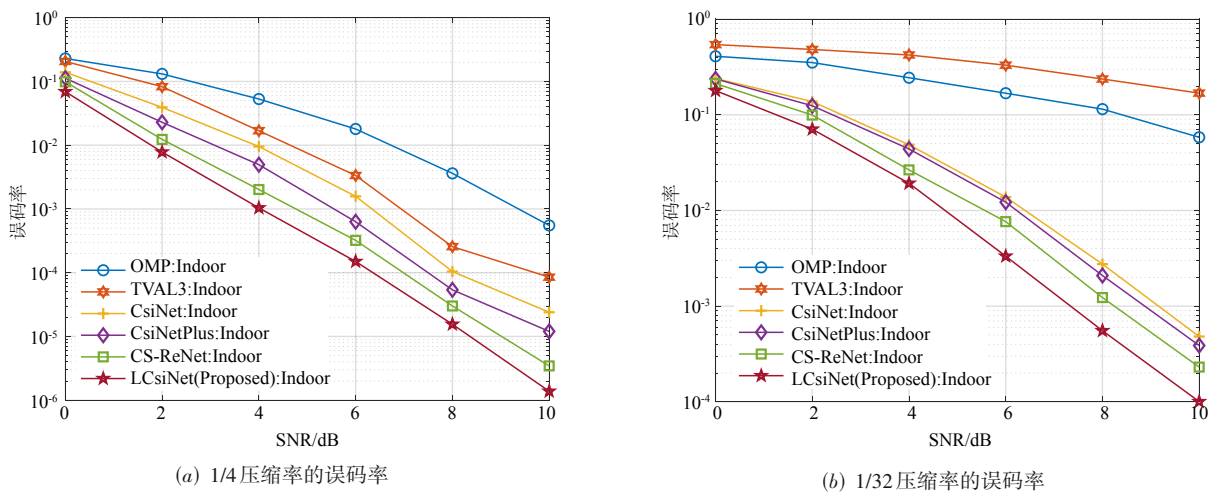


图4 室内场景下的误码率

6 结论

在本文中,我们提出了一种轻量化低复杂度的CSI反馈框架LCsiNet,相比于现有的基于DL的方法和基于CS的方法,其信道矩阵的重建质量更好.更好地利用了AP、US、DSCNN和CNN的特性,合理地将原始CSI进行压缩和重建,采用参数量更小且性能更优的DSCNN加深网络,提升了CSI重建的精度.通过仿真分析对比

发现,LCsiNet在降低网络复杂度的同时也获得了不错的性能表现.

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] BARRIAC G, MADHOW U. Space-time communication

- for OFDM with implicit channel feedback[J]. IEEE Transactions on Information Theory, 2004, 50(12): 3111-3129.
- [3] RAO X, 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.
- [4] CHOI J, CHANCE Z, LOVE D J, et al. Noncoherent trellis coded quantization: a practical limited feedback technique for massive MIMO systems[J]. IEEE Transactions on Communications, 2013, 61(12): 5016-5029.
- [5] MIRZA J, SHAFI M, SMITH P J, et al. Limited feedback massive MISO systems with trellis coded quantization for correlated channels[J]. IEEE Transactions on Vehicular Technology, 2016, 65(10): 8240-8254.
- [6] DAI L, WANG Z, YANG Z. Spectrally efficient time-frequency training OFDM for mobile large-scale MIMO systems[J]. IEEE Journal on Selected Areas in Communications, 2013, 31(2): 251-263.
- [7] RAGHAVAN V, SAYEED A M. Sublinear capacity scaling laws for sparse MIMO channels[J]. IEEE Transactions on Information Theory, 2010, 57(1): 345-364.
- [8] DONOHO D L. Compressed sensing[J]. IEEE Transactions on Information Theory, 2006, 52(4): 1289-1306.
- [9] WEN C K, SHIH W T, JIN S. Deep learning for massive MIMO CSI feedback[J]. IEEE Wireless Communications Letters, 2017, 7(5): 748-751.
- [10] 廖勇, 姚海梅, 花远肖, 等. 一种基于深度学习的 FDD 大规模 MIMO 系统 CSI 反馈方法[J]. 电子学报, 2020, 48(6): 1182-1189.
LIAO Yong, YAO Hai-mei, HUA Yuan-xiao, et al. CSI feedback method based on deep learning for FDD massive MIMO systems[J]. Acta Electronica Sinica, 2020, 48(6): 1182-1189. (in Chinese)
- [11] GUO 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.
- [12] LIANG P, FAN J, SHEN W, et al. Deep learning and compressive sensing-based CSI feedback in FDD massive MIMO systems[J]. IEEE Transactions on Vehicular Technology, 2020, 69(8): 9217-9222.
- [13] FRANOIS C. Xception: Deep learning with depthwise separable convolutions[C]//IEEE International Conference on Computer Vision and Pattern Recognition. Piscataway, New Jersey, USA: IEEE, 2017: 1251-1258.
- [14] HE K M. Deep residual learning for image recognition [C]//ZHANG X Y. IEEE Conference on Computer Vision and Pattern Recognition. Piscataway, New Jersey, USA: IEEE, 2016: 770-778.
- [15] LIU L. The COST 2100 MIMO channel model[J]. IEEE Wireless Communications, 2012, 19(6): 92-99.
- [16] LI C, YIN W, ZHANG Y. User's guide for TVAL3: TV minimization by augmented lagrangian and alternating direction algorithms[R]. Houston: Department of Computational and Applied Mathematics, Rice University, 2009: 46-47.
- [17] NOURI N. A compressed CSI estimation approach for FDD massive MIMO systems[C]//AZUZUPOUR M J. Iranian Conference on Electrical Engineering. Piscataway, New Jersey, USA: IEEE, 2020: 1-6.

作者简介



廖 勇 男, 1982 年 1 月出生于四川自贡. 现为重庆大学副研究员、博士生导师. 主要研究方向为下一代无线通信、人工智能、区块链、量子计算及其在无线通信中的应用.
E-mail: liaoy@cqu.edu.cn



李玉杰 男, 1996 年 7 月出生于河南周口市. 现为重庆大学微电子与通信工程学院研究生. 主要研究方向为无线通信中的 CSI 反馈算法研究.
E-mail: cleeshark@cqu.edu.cn