

# 高速移动环境下基于 RM-Net 的大规模 MIMO CSI 反馈算法

廖勇, 王世义

(重庆大学微电子与通信工程学院, 重庆 400044)

**摘 要:** 针对高速移动环境信道特征复杂多变, 同时存在加性噪声和非线性效应的影响, 提出一种残差混合网络 (RM-Net) 的大规模 MIMO CSI 反馈算法。RM-Net 通过学习高速移动信道的空间结构与时间相关性, 具备去除大规模 MIMO 信道噪声的能力, 能显著提高 CSI 压缩率与恢复质量。系统仿真结果表明, RM-Net 可消除高速移动场景加性噪声的影响, 学习并适应稀疏、双选衰落信道特征, 在高压缩率与低信噪比条件下依然具有较好的性能表现, 所提算法性能大幅优于其他基于压缩感知 (CS) 和深度学习 (DL) 的 CSI 反馈算法。

**关键词:** 高速移动; 大规模 MIMO; CSI 反馈; 深度学习; 去噪

中图分类号: TN929.5

文献标志码: A

DOI: 10.11959/j.issn.1000-436x.2022097

## CSI feedback algorithm based on RM-Net for massive MIMO systems in high-speed mobile environment

LIAO Yong, WANG Shiyi

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

**Abstract:** Aiming at the complex and changeable channel characteristics in high-speed mobile environment, and the influence of additive noise and nonlinear effects, a residual mixing network (RM-Net) for massive MIMO CSI feedback was proposed. By learning the spatial structure and temporal correlation of high-speed mobile channel, the network was able to remove massive MIMO channel noise, and the CSI compression rate and recovery quality could be significantly improved. System simulation results show that RM-Net can eliminate the influence of additive noise in high-speed mobile scenarios, learn and adapt to the channel characteristics of sparse and double-selective fading channels, and still has good performance under the conditions of high compression rate and low signal-to-noise ratio. The proposed algorithm performance is much better than other CS-based and DL-based CSI feedback algorithms.

**Keywords:** high-speed mobility, massive MIMO, CSI feedback, deep learning, denoising

### 0 引言

大规模多输入多输出 (MIMO, multiple input multiple output) 技术作为 5G 通信系统的关键技术, 具有频谱利用率高<sup>[1]</sup>、系统容量大和系统稳健性强<sup>[2]</sup>等优点。因此, 大规模 MIMO 技术受到学术界和工业界的持续关注。然而, 大规模 MIMO 技术的显著优势建立在发射机可以获得下行链路信道状态信

息 (CSI, channel state information)<sup>[3]</sup>的基础上。在频分双工 (FDD, frequency division duplex) 大规模 MIMO 系统中, 基站 (BS, base station) 需要接收用户端 (UE, user equipment) 反馈的下行链路 CSI, 然而大规模天线阵列的使用会导致 CSI 反馈开销急剧增加, 同时 CSI 反馈也会受到信道中噪声与非线性效应的影响, 导致系统性能降低。因此, 如何在实际应用中降低 CSI 的反馈开销、克服信道噪声与

收稿日期: 2022-01-06; 修回日期: 2022-04-02

基金项目: 国家自然科学基金资助项目 (No.61501066); 重庆市自然科学基金项目 (No.cstc2019jcyj-msxmX0017)

**Foundation Items:** The National Natural Science Foundation of China (No.61501066), The Natural Science Foundation of Chongqing (No.cstc2019jcyj-msxmX0017)

非线性效应的影响成为亟待解决的问题<sup>[4]</sup>。

为了降低反馈开销, 一种有效的方法是对 CSI 矩阵进行压缩, 常见的有基于压缩感知 (CS, compressed sensing) 的方法<sup>[5]</sup>和基于深度学习 (DL, deep learning) 的方法<sup>[6]</sup>。基于 CS 的传统算法要求 CSI 矩阵在某个变换域上足够稀疏, 可以寻找合适的稀疏基, 然而实际的信道环境很难满足要求, 特别是在压缩率较大的情况下。近年来, 人工智能 (AI, artificial intelligence) 和 DL 受到了广泛关注, 这启发了研究人员将 DL 应用在通信领域以克服传统 CS 算法的缺陷。文献[7]提出了一种用于 CSI 压缩和恢复的名为 CsiNet 的自动编码器模型, 其在 UE 处将下行链路 CSI 压缩成低维码字, 并通过信道传输, 随后 BS 接收并恢复反馈码字。与基于 CS 的传统算法相比, CsiNet 可以获得更好的反馈性能。在此之后, 研究人员对该模型进行了扩展。文献[8]利用上行链路和下行链路 CSI 之间的相关性, 提出通过上行 CSI 恢复下行 CSI 的方法, 以降低 CSI 反馈开销。文献[9]设计了一种基于卷积神经网络 (CNN, convolutional neural network) 的算法来实现多速率 CSI 反馈。文献[10]利用不同时间隙中 CSI 的相关性恢复下行 CSI。文献[11]中提出的 CsiNetPlus 通过更新卷积核, 在不增加额外信息的情况下提高了网络性能。文献[12]提出了在 FDD 大规模 MIMO 系统下利用基于 CNN 的抗噪声 CSI 采集网络来重建 CSI, 其在一定程度上能有效减小信道的噪声影响。文献[13]研究了基于深度自动编码器的 CSI 反馈方法, 有效地降低了 FDD 大规模 MIMO 系统的反馈误差和反馈时延。文献[14]提出了 FDD 系统下基于深度学习的 CSI 重构方案, 该方案采用 CNN 和生成对抗网络 (GAN, generative adversarial network) 来实现 CSI 重构。

目前, 现有 CSI 反馈算法普遍基于室内或低速室外环境的 Cost2100 信道模型<sup>[15]</sup>, 且基于 CS 的反馈算法存在高度依赖于信道的稀疏度、在高压缩率下失效等缺点。为此, 本文提出了一种高速移动环境下大规模 MIMO 系统 CSI 反馈网络, 名为残差混合网络 (RM-Net, residual mixing network)。RM-Net 使用深度卷积神经网络 (DCNN, deep convolutional neural network)<sup>[16]</sup>、分组卷积神经网络 (GCNN, group convolutional neural network)<sup>[17]</sup>、深度可分离卷积神经网络 (DSCNN, deeply separable convolutional neural network)<sup>[18]</sup>, 学习并提取快时变 CSI 的数据特征并

对其进行稀疏化表示, 重构原始快时变 CSI, 并在网络中引入残差块 (RB, residual block) 结构<sup>[19]</sup>, 有效防止深层网络产生退化问题, 以此提高 CSI 的重构精度, 且极大地降低了网络参数量, 提高了模型训练与推理速度。同时, 针对信道中存在的高斯白噪声, 在编码器中加入去噪模块, 增强网络的抗噪能力。系统仿真结果表明, RM-Net 能够学习高速移动环境下稀疏、双选衰落信道的特征, 并具备一定的抗噪能力, 算法性能大幅优于其他基于 CS 和 DL 的 CSI 反馈算法。RM-Net 兼具训练速度快、在高压缩率与低信噪比条件下性能依然良好等优点。

## 1 系统模型

对于一个单小区下的下行链路 FDD 大规模 MIMO 系统, 其中 BS 端配置  $N_t \gg 1$  根发射天线, UE 配置  $N_r = 1$  根接收天线, 该系统在  $L$  个子载波上运行, 在第  $n$  个子载波处的接收信号为<sup>[20]</sup>

$$y_l = \tilde{\mathbf{h}}_l^H \mathbf{v}_l x_l + z_l \quad (1)$$

其中,  $\tilde{\mathbf{h}}_l \in \mathbb{C}^{N_t \times 1}$ 、 $\mathbf{v}_l \in \mathbb{C}^{N_t \times 1}$ 、 $x_l \in \mathbb{C}$  和  $z_l \in \mathbb{C}$  分别表示信道矩阵向量、预编码向量、数据符号和附加在子载波上的噪声,  $(\cdot)^H$  表示矩阵的共轭转置。最终所有  $L$  个子载波的接收信号可表示为

$$\mathbf{y} = \mathbf{H}\mathbf{V}\mathbf{x} + \mathbf{z} \quad (2)$$

其中,  $\mathbf{y} = (y_1, \dots, y_L)^T$ ,  $\mathbf{H} = (\tilde{\mathbf{h}}_1, \dots, \tilde{\mathbf{h}}_L)^H$ ,  $\mathbf{x} = (x_1, \dots, x_L)^T$ ,  $\mathbf{z} = (z_1, \dots, z_L)^T$ ,  $\mathbf{V} = (\mathbf{v}_1, \dots, \mathbf{v}_L)$ ,  $(\cdot)^T$  表示矩阵/向量的转置。

一旦 BS 接收到反馈的 CSI 矩阵  $\mathbf{H}$  后, 便可进行其他处理, 如设计预编码向量。同时, 在大规模 MIMO 系统中, 由于发射端和接收端天线数较多、天线间距较小, 因此天线之间存在较强的空间相关性<sup>[21]</sup>。在大规模 MIMO 信道中, 由于真实环境中的散射环境有限, 一方面, 时域无线多径信道大部分路径的能量为零, 而只有某几个路径的能量较大, 这使多径信道呈稀疏性。另一方面, 由于 BS 周围的散射体有限, 大规模 MIMO 信道在虚拟角度域内呈稀疏性<sup>[22]</sup>。

同时, 高速移动环境下的无线信道是一个明显的多径快时变信道。一方面, 由于受到多径的影响, 无线信道呈频率选择性衰落特性。另一方面, 由于移动端的快速移动, 无线信道由于速度差引起的多普勒频移将呈时间选择性衰落特性, 具有非线性效应。

本文采用 Clarke 模型<sup>[23]</sup>表征高速移动信道模型, 多个路径的发射信号从任意方向到达接收端, 每个路径的信号具有随机的相位且信号的平均功率一样。假设每一个电磁波与移动台之间的夹角为  $\theta$ , 其中移动台的速度为  $v$ , 当移动终端运动时, 从任意路径到达接收机的信号都会经历多普勒频移。令发射的基带信号为  $x(t)$ , 通过具有多径数为  $P$  的散射信道后, 接收的通频带信号可以表示为

$$\tilde{y}(t) = \text{Re} \left[ \sum_{i=1}^P C_i e^{j2\pi(f_c + f_i)(t - \tau_i)} x(t - \tau_i) \right] = \text{Re} \left[ y(t) e^{j2\pi f_c t} \right] \quad (3)$$

其中,  $\text{Re}[\cdot]$  表示信号的实部,  $C_i$  表示信道增益, 全连接层表示发射信号的载波频率,  $\tau_i$  和  $f_i$  分别表示路径时延和多普勒频移,  $y(t)$  表示接收的基带信号。式(3)可以重新表示为

$$\tilde{y}(t) = \text{Re} \left[ y(t) e^{j2\pi f_c t} \right] = \text{Re} \left[ \{ h_1(t) + j h_0(t) \} e^{j2\pi f_c t} \right] = h_1(t) \cos 2\pi f_c t - h_0(t) \sin 2\pi f_c t \quad (4)$$

其中,  $h_1(t)$  和  $h_0(t)$  分别表示  $h(t)$  的同相和正交分量。当  $P$  足够大时,  $h_1(t)$  和  $h_0(t)$  近似为正态分布, 通过多径信道后, 接收信号的幅度  $\tilde{y}(t) = \sqrt{h_1^2(t) + h_0^2(t)}$  服从瑞利分布。此外, 如果信号的收发端之间存在视距分量, 那么此时的接收信号幅度服从莱斯分布。

在 FDD 系统中, UE 通过反馈链路向 BS 返回  $H$ , 反馈参数的总量为  $N_t N_r L$ , 这对有限反馈链路来说是不允许的, 因此需要进行 CSI 压缩<sup>[24]</sup>。

## 2 RM-Net

### 2.1 网络结构

为了有效进行大规模 MIMO 快时变 CSI 的压缩及反馈重构, 本文提出基于 DL 的 RM-Net, 其结构

如图 1 所示。

图 1 中,  $\times$  表示维度连接, Linear 即全连接层, 该网络包括编码器和解码器两部分, 其中解码器由噪声处理单元与解压缩单元两部分组成。

### 2.2 数据处理

依据图 1 所示的 RM-Net 结构, 分别对编码器和解码器中不同网络中的数据流处理过程进行描述。

#### 2.2.1 编码器

1) 在编码器网络中, 网络的输入数据是一个  $N_t \times N_r \times L$  的信道矩阵, 即  $H \in \mathbb{C}^{N_t \times N_r \times L}$ , 其中  $N_t$ 、 $N_r$ 、 $L$  分别表示发射天线数、接收天线数、子载波数。由于快时变 CSI 矩阵  $H$  为复数信号, 网络无法直接使用, 需要通过预处理模块进行处理。

①首先对  $H$  进行形状变换, 变换后的矩阵维度为  $M \times M$ , 其中  $M \times M = N_t \times N_r \times L$ ,  $M$  表示矩阵的大小, 再将  $H$  的实部和虚部分别提取出来, 作为一个新的维度, 得到新的矩阵  $H_{\text{reshape}} \in \mathbb{C}^{M \times M \times 2}$ , 将其作为网络的训练样本, 并将训练样本记为  $X$ 。

②信道矩阵  $H$  经过预处理之后, 再对训练样本  $X$  进行数据标准化处理, 网络中标准化处理方式为

$$X' = \frac{X - X_{\text{mean}}}{X_{\text{std}}} \quad (5)$$

其中,  $X_{\text{mean}}$  表示样本均值,  $X_{\text{std}}$  表示样本方差。数据的标准化可以加快网络的训练速度与学习能力, 更快地找到最优解, 避免梯度更新时数值的振荡。与数据的归一化相比, 当出现异常点时, 标准化模型具有更强的稳健性。

2) 经过预处理模块后, 网络通过快时变 CSI 特征提取模块进行高速快时变信道特征的提取与 CSI 的稀疏化表示, 如图 2 所示。特征提取由 GCNN 完成, 卷积操作可以充分地提取 CSI 矩阵之间数据的线性相关性, 使网络学习到高速移动环境下信道矩阵的特征。同时, 不同于常见的线性变换, 如 DCT

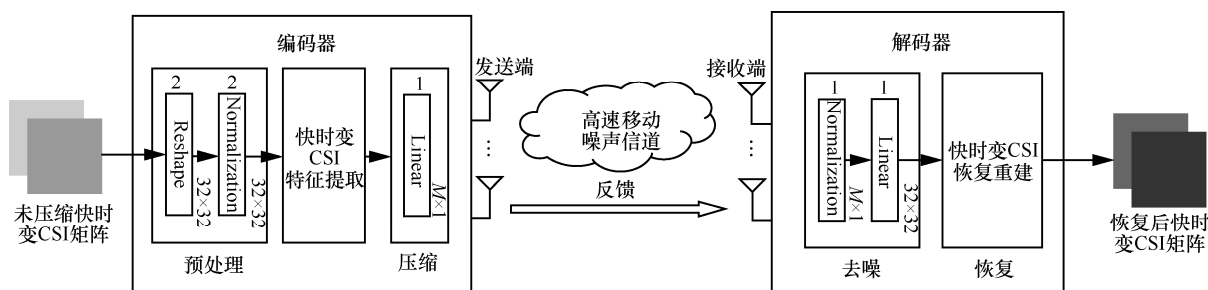


图 1 RM-Net 结构

稀疏变换, 在 GCNN 后使用 ELU 激活函数和批归一化 (BN, batch normalization) 层对 CSI 进行非线性映射完成稀疏化表示, 这样做可以克服数据在线性映射域中稀疏度不足的问题, 提高网络非线性特征的学习能力。同时, 引入 RB 防止深层网络产生退化现象, 网络输出记为  $X'$ 。ELU 激活函数在负数域存在非线性斜率, 相比 ReLU、Leaky-ReLU 等激活函数, 其可以使网络拥有更强的稳健性以及抗噪性。ELU 激活函数表达式为

$$f(x) = \begin{cases} x, & x > 0 \\ \alpha(e^x - 1), & x \leq 0 \end{cases} \quad (6)$$

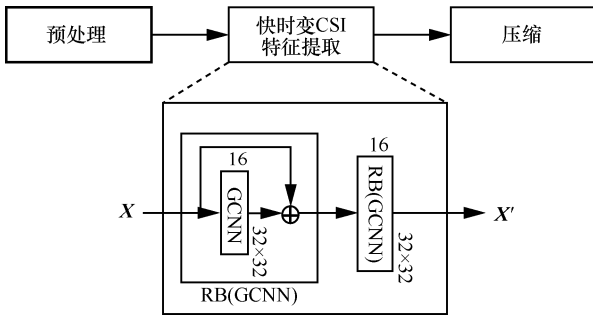


图 2 快时变 CSI 特征提取模块

在 BN 层中存在参数向量  $\gamma$ 、 $\beta$ , 其可控制 BN 层输出  $Y_k^{BN}$  的数据分布特征。  $Y_k^{BN}$  计算式为

$$Y_k^{BN} = \gamma_k x_{k-1} + \beta_k \quad (7)$$

其中,  $\gamma_k = \sqrt{\text{Var}[x_{k-1}]}$ ,  $\beta_k = E[x_{k-1}]$ ,  $x_{k-1}$  表示  $k-1$  层网络的输入,  $E[x_{k-1}]$  表示  $x_{k-1}$  的均值,  $\text{Var}[x_{k-1}]$  表示  $x_{k-1}$  的方差。GCNN 的计算式为

$$Y_k^{GCNN} = f_{GCNN}(x_{k-1} * W_k^g + b_k) \quad (8)$$

其中,  $x_{k-1}$  表示  $k-1$  层网络的输出,  $W_k^g$  表示分组数为  $g$  的第  $k$  层权重矩阵,  $b_k$  表示第  $k$  层的偏置向量,  $*$  表示卷积运算,  $f_{GCNN}(\cdot)$  表示分组卷积处理。

3) 经过特征提取模块, 快时变 CSI 由压缩模块进行压缩并通过天线发送到 BS 端。编码器的压缩模块由全连接层构成, 全连接层通过对数据的线性叠加完成数据压缩, 并通过设置其输出特征的数量控制 CSI 的压缩率。压缩率与输出特征数量的关系为

$$t = \frac{n}{m} \quad (9)$$

其中,  $t$  为压缩率,  $m$  为该全连接层输出特征数量,  $n = M \times M$  为信道矩阵元素个数。对于压缩模块中的全连接层, 其输出  $Y_k^{FC}$  可表示为

$$Y_k^{FC} = f_{ELU}(W_k x_{k-1} + b_k) \quad (10)$$

其中,  $f_{ELU}(\cdot)$  表示 ELU 激活函数。CSI 经过压缩后, 即可通过天线发送到 BS 端, 编码器最终输出记为  $s$ , 其中  $s \in \mathbb{C}^{m \times 2}$ 。

### 2.2.2 解码器

1)  $s$  经过信道由 BS 端接收, 根据第 1 节系统模型所述,  $s$  仅受到加性噪声的影响, 接收后的信号  $s'$  为

$$s' = s + n \quad (11)$$

其中,  $n$  为加性噪声。随后将  $s'$  送入解码器进行恢复。

2) 解码器首先通过去噪模块 (如图 1 所示) 对  $s'$  进行处理, 由标准化结构和全连接层组成。然后通过标准化操作对其进行去噪, 弱化噪声对原始信号的影响。最后利用全连接层完成数据维度的线性扩展, 该结构输出记为  $s''$ , 其中  $s'' \in \mathbb{C}^{n \times 2}$ 。

3)  $s''$  随后由重构模块进行数据恢复, 该结构如图 3 所示。重构模块由 DCNN、GCNN、DSCNN、CNN 构成, 进行卷积操作以完成数据特征的提取, 并在其后使用 ELU 激活函数进行非线性稀疏化逆映射, 恢复原始快时变 CSI 矩阵。恢复后的 CSI 记为  $H'$ , 且  $H' \in \mathbb{C}^{M \times M \times 2}$  与原始信号形状一致。

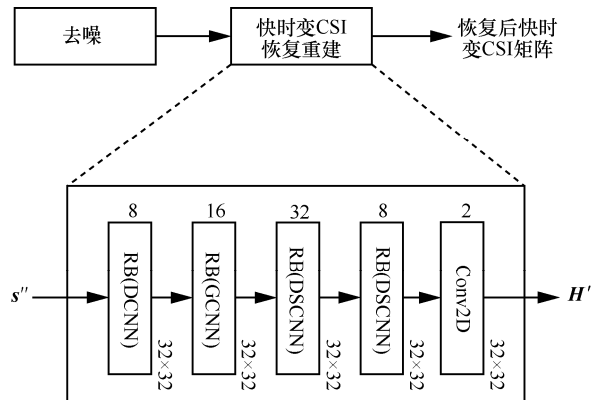


图 3 快时变 CSI 重构恢复模块

### 2.3 训练与预测

本文所提算法采用离线训练和在线预测的方式进行数据处理, 搭建基于高速移动环境下 FDD 大规模 MIMO 的 CSI 反馈系统, 采用具有快时变和非平稳特征的高速信道模型 WINNER-II D2a<sup>[25]</sup>, 生成大规模 MIMO 信道矩阵数据集, 并将数据集分为训练集、测试集与验证集。使用训练集进行端到端的方式训练更新网络中所有权重和偏置; 使用验证集调整网络训练过程中的超参数; 使用测试集模拟真实信道场景进行模型性能的测试。

RM-Net 训练使用自适应矩估计 (ADAM, adaptive moment estimation) 更新网络参数。ADAM 算法与传统采用固定学习率的梯度下降算法不同, 它能够通过训练自适应地更新学习率。网络的损失函数为均方误差 (MSE, mean squared error), 因此本文模型的预测损失为

$$L(\Theta_{\text{est}}) = \frac{1}{M_s} \sum_{i=1}^{M_s} (f_{\text{est}}(\mathbf{H}_i, \Theta_{\text{est}}) - \mathbf{H}'_i)^2 \quad (12)$$

其中,  $\mathbf{H}'_i$  表示第  $i$  个目标值,  $\mathbf{H}_i$  表示第  $i$  个预测值,  $M_s$  表示训练集中的总样本数,  $\Theta_{\text{est}}$  表示网络中的参数,  $f_{\text{est}}(\cdot)$  表示经过网络计算。通过多次训练与验证, 筛选出损失验证最小的模型作为最终的测试模型。

RM-Net 通过不断循环这一过程, 学习高速移动环境下的信道特征, 逐渐提高网络的拟合度, 不断减小  $\mathbf{H}'_i$  与  $\mathbf{H}_i$  之间的误差, 最终误差在可接受范围内, 两者趋于一致。本文模型训练参数与相关软硬件配置如表 1 所示。

表 1 模型训练参数与相关软硬件配置

配置类型	配置参数
显卡	GeForce GTX 1660Ti
处理器	Intel Core® i7-9750H
优化器	ADAM
损失函数	MSE
运行环境	Python 3.6.5
DL 框架	Pytorch 1.2.0
训练集	10 000
验证集	3 000
测试集	1 000
epoch	200
batch	250
学习率	0.001
神经元数量	$2.1 \times 10^6 \sim 3.1 \times 10^6$

## 2.4 算法流程

高速移动环境下基于 RM-Net 的大规模 MIMO CSI 压缩反馈过程如算法 1 所示。

**算法 1** 高速移动环境下基于 RM-Net 的大规模 MIMO CSI 压缩反馈算法

输入 快时变 CSI 矩阵  $\mathbf{H}$

输出 重构快时变 CSI 矩阵  $\mathbf{H}'$

1) UE 获取信道矩阵  $\mathbf{H}$ , 通过预处理模块对  $\mathbf{H}$  进行标准化和重构;

2) UE 通过快时变 CSI 特征提取模块学习并提

取  $\mathbf{H}$  的特征信息;

3) UE 通过压缩模块对  $\mathbf{H}$  进行压缩, 形成压缩码字, 记为  $\mathbf{s}$ , 完成编码器的处理, 通过  $N_t$  根天线送入高速移动信道;

4)  $\mathbf{s}$  经过信道由  $N_r$  根天线的 BS 接收, 记为  $\mathbf{s}'$ ;

5) BS 通过去噪模块对  $\mathbf{s}'$  进行去噪和维度扩展;

6) BS 通过快时变 CSI 重构模块, 对  $\mathbf{s}'$  进行解码, 并恢复原始快时变 CSI 矩阵, 记为  $\mathbf{H}'$ , 完成解码器处理。

## 3 仿真结果与分析

为了验证所提算法在高速移动环境下 FDD 大规模 MIMO 的 CSI 反馈系统的性能, 本节将比较 RM-Net 与其他典型的基于 CS 和 DL 的 CSI 反馈算法性能, 并假设 UE 已获得理想的下行 CSI, 仿真系统主要参数如表 2 所示, 其中本文通过多普勒频移参数模拟非线性效应的影响程度。

表 2 仿真系统主要参数

参数	数值
双工模式	FDD
发射天线/根	64
接收天线/根	4
载波频率/GHz	2.9
子载波数	84
系统带宽/MHz	1.4
观测矩阵	高斯随机矩阵
稀疏基	DCT、FFT
多径时延/ $\mu\text{s}$	[0, 4, 8, 12, 16]
路径增益/dB	[0, -3, -6, -8, -17.2]
多普勒频移/kHz	[0.422, 0.845]
最大相对速度/( $\text{km} \cdot \text{h}^{-1}$ )	[150, 300]
信噪比/dB	[-10, -5, 0, 5, 10, 15, 20]

### 3.1 归一化均方误差

本节分别比较了数据在不同压缩率下所提 RM-Net 与其他基于 CS 和 DL 的 CSI 反馈算法在高速移动环境下大规模 MIMO 系统下的归一化均方误差 (NMSE, normalized mean square error)。NMSE 计算式为

$$\text{NMSE} = \text{E} \left( \frac{\|\mathbf{H} - \mathbf{H}'\|_2^2}{\|\mathbf{H}\|_2^2} \right) \quad (13)$$

其中,  $\mathbf{H}$  和  $\mathbf{H}'$  分别表示原始信道数据和恢复信道

数据。NMSE 越小，说明 CSI 压缩反馈误差越小，算法性能越好。图 4 和图 5 分别表示当速度分别为 300 km/h 和 150 km/h 时，不同算法在不同压缩率下 NMSE 的系统仿真结果。需要说明的是，由于基于 CS 的 CSI 反馈算法在高压压缩率下失效，故仅展示压缩率为  $\frac{1}{2}$ 、 $\frac{1}{8}$  时的结果。其中， $\frac{1}{2}$  DCT-OMP 表示压缩率为  $\frac{1}{2}$  时的 DCT-OMP 算法。





图 4 300 km/h 时不同算法在不同压缩率下 NMSE 的系统仿真结果





图 5 150 km/h 时不同算法在不同压缩率下 NMSE 的系统仿真结果

图 4 和图 5 中，CsiNet 为基于 DL 的 CSI 经典反馈算法。系统仿真结果还受到信噪比影响，信噪比越低，NMSE 越高，CSI 恢复精度就越低，系统性能就越差。

从图 4(a)和图 5(a)中可以看出，在不同高速移动环境与不同压缩率下，RM-Net 算法的 NMSE 更低，且与传统 CS 算法相比，NMSE 有 2~3 个数量级的优势。因此，RM-Net 与传统 CS 算法相比在不

同压缩率下更具优势，并且能够适应不同的高速移动环境。从图 4(b)和图 5(b)中可以看出，在不同高速移动环境与不同压缩率下，RM-Net 算法的 NMSE 均远低于 CsiNet。因此，RM-Net 算法与 CsiNet 算法相比在不同压缩率下更具优势，并且能够适应不同的高速移动环境。

由上述分析可知，RM-Net 算法与其他基于 CS 和 DL 的 CSI 反馈算法相比，NMSE 更低，具有更加优异的算法性能。


### 3.2 相似度

本节分别比较了数据在不同压缩率下 RM-Net 算法与其他 CSI 反馈算法在高速移动环境下大规模 MIMO 系统下的余弦相似度。余弦相似度计算式为

$$\rho = \frac{|ab|}{\|a\|_2 \|b\|_2} \quad (14)$$

其中， $a$  和  $b$  分别表示原始信道矩阵和恢复后的信道矩阵的矢量化结果， $\rho$  越高，说明 CSI 压缩反馈误差越小，算法性能越好。图 6 和图 7 分别表示当速度分别为 300 km/h 和 150 km/h 时，不同算法在不同压缩率时余弦相似度  $\rho$  的仿真结果。需要说明的是，由于基于 CS 的 CSI 反馈算法在高压压缩率下失效，故仅展示压缩率为  $\frac{1}{2}$ 、 $\frac{1}{8}$  时的结果。

图 6 和图 7 的系统仿真结果同时受到信噪比影响，信噪比越低，相似度  $\rho$  越低，CSI 恢复精度就越低，系统性能就越差。



从图 6(a)和图 7(a)可以看出，在不同高速移动环境与不同压缩率下，RM-Net 算法的  $\rho$  更高，传统 CS 算法在  $\frac{1}{16}$ 、 $\frac{1}{32}$  等高压压缩率下已失效，无法

恢复原始 CSI，然而 RM-Net 算法在高压压缩率下依然具有良好的效果。因此该仿真结果反映出 RM-Net 算法与传统 CS 算法相比更具优势，尤其是在高压压缩率条件下，并且能够适应不同的高速移动环境。从图 6(b)和图 7(b)中可以看出，在不同高速移动环境与不同压缩率下，RM-Net 算法的  $\rho$  远高于 CsiNet，同时图 6(b)和图 7(b)中 CsiNet 的  $\rho$  均低于 0.7，说明 CsiNet 结构过于简单，已无法完全学习与适应高速移动环境下的双选信道特征。因此该仿真结果反映出在不同压缩率下，RM-Net 算法与 CsiNet 算法相比更具优势。RM-Net 算法与其他基于 CS 和 DL 的 CSI 反馈算法相比  $\rho$  更高，具有更加优异的算法性能，能够适应不同的高速移动环境。

### 3.3 系统容量

本节分别比较了数据在不同压缩率下 RM-Net 算法与其他 CSI 反馈算法在高速移动环境下大规模 MIMO 系统下的系统容量。系统容量的计算式为

$$C = \text{lb} \left\{ \det \left[ \mathbf{I} + \frac{1}{N_t} \frac{P_t}{\sigma^2} \mathbf{H}\mathbf{H}^H \right] \right\} \quad (15)$$

其中， $(\cdot)^H$  表示共轭转置， $\det[\cdot]$  表示求矩阵的行列式， $\mathbf{I}$  表示单位阵， $N_t$  表示发射天线数量， $\frac{P_t}{\sigma^2}$  表






图 6 300 km/h 时不同算法在不同压缩率时余弦相似度  $\rho$  的仿真结果

示信噪比，信道容量的单位为 bit/(s·Hz)。C 越高，说明信道容量越高，算法性能越好。需要说明的是，由于基于 CS 的 CSI 反馈算法在高压压缩率下失效，故仅展示压缩率为  $\frac{1}{2}$ 、 $\frac{1}{8}$  时的结果。

0.5~1 bit/(s·Hz)的提升。因此该仿真结果反映出 RM-Net 与其他 CSI 反馈算法相比，在不同压缩率下更具优势，并且能够适应不同的高速移动环境。由上述分析可知，RM-Net 算法与其他基于 CS 和 DL 的 CSI 反馈算法相比，系统容量更高，具有更加优异的算法性能。



(a) RM-Net与传统的CS和DL算法




(b) RM-Net与CsiNet


图 7 150 km/h 时不同算法在不同压缩率时余弦相似度  $\rho$  的仿真结果

图 8 的系统仿真结果同时受到信噪比影响，信噪比越低系统容量越低，系统性能就越差。

从图 8(a)和图 8(b)中可以看出，在不同高速移动环境与不同压缩率下，RM-Net 算法的系统容量更高，与传统 CS 算法相比，系统容量有 1~2 bit/(s·Hz)的提升；与 CsiNet 相比，系统容量有



(a) 速度为 150 km/h



(b) 速度为 300 km/h

图 8 RM-Net 与传统的 CS 和 DL 算法的系统容量仿真结果

### 3.4 复杂度与系统耗时分析

本节在理论上对不同算法的时间复杂度和实际的系统耗时进行了分析与对比。其中，时间复杂度对比如表 3 所示。表 3 中， $k$  表示稀疏度， $r$  表示压缩率， $N$  表示 CSI 矩阵维度大小，以一次矩阵元素的先乘后加运算（MACC, multiply-accumulate operation）次数为单位，计算算法恢复 CSI 所需要全部 MACC 运算作为算法复杂度。对于不同算法实际的系统耗时  $t$ ，其计算式为

$$t = T_1 + T_2 \quad (16)$$

其中， $T_1$  和  $T_2$  分别表示 CSI 压缩耗时和 CSI 恢复耗时。系统耗时  $t$  可以反映出不同算法的时间复杂度，其中系统耗时  $t$  越短，算法的时间复杂度越低。表 4 和表 5 分别表示当速度分别为 300 km/h 和

150 km/h，压缩率分别为  $\frac{1}{2}$ 、 $\frac{1}{4}$ 、 $\frac{1}{8}$ 、 $\frac{1}{16}$ 、 $\frac{1}{32}$  时，不同算法系统耗时  $t$  的仿真结果。

由表 4 和表 5 可知，与传统 CS 算法相比，RM-Net 算法能够适应不同的高速移动环境，并且在不同压缩率下的系统耗时更短，且系统耗时  $t$  有 2~3 个数量级的优势，算法复杂度明显低于传统 CS 算法，这在低压缩率下更加显著；与 CsiNet 相比，RM-Net 算法在不同压缩率下的  $t$  虽略高于 CsiNet，然而差距仅在 0.03 ms 以内，差距并不明显，并且 CsiNet 在该系统环境下已无法正确恢复出原始 CSI，而 RM-Net 保证了 CSI 恢复的准确性，说明 RM-Net 依然具有更优秀的算法性能。

综上，RM-Net 算法与基于 CS 和 DL 的代表性 CSI 反馈算法相比，具有更加优异的算法性能，这也验证了所提算法的有效性。

表 3 不同算法时间复杂度对比

算法	MACC 次数	时间复杂度
DCT-OMP	$2\left(\frac{N^3}{r}\right) + k((N+2))\left(\frac{N}{r}\right)^8 + N^3$	$O\left(k\left(\frac{N}{r}\right)^8\right)$
FFT-OMP	$3\left(\frac{N^3}{r}\right) + 2k\left((N+2)\left(\frac{N}{r}\right)^2 + \left(\frac{N}{r}\right)^8\right) + 2N^3$	$O\left(k\left(\frac{N}{r}\right)^8\right)$
DCT-SP	$2\left(\frac{N^3}{r}\right) + k\left(3\left(\frac{N}{r}\right)^2 + \left(\frac{N}{r}\right)^8\right) + N^3$	$O\left(k\left(\frac{N}{r}\right)^8\right)$
FFT-SP	$3\left(\frac{N^3}{r}\right) + 2k\left(3\left(\frac{N}{r}\right)^2 + \left(\frac{N}{r}\right)^8\right) + 2N^3$	$O\left(k\left(\frac{N}{r}\right)^8\right)$
CsiNet	$63N^2 + \frac{N^3}{r} + \frac{N^3}{r^2} + 17N$	$O\left(\left(\frac{N^3}{r}\right)\right)$
RM-Net	$\left(81 + \frac{81}{8}\right)N^2 + 36N + 2N^3 + \frac{N^3}{r} + \frac{N^3}{r^2}$	$O\left(\left(\frac{N^3}{r}\right)\right)$

表 4 速度为 300 km/h 时不同算法在不同压缩率下的系统耗时

压缩率	DCT-OMP/s	DCT-SP/s	FFT-OMP/s	FFT-SP/s	CsiNet/s	RM-Net/s
$\frac{1}{2}$	0.046 111	0.113 320	0.354 618	0.509 470	0.000 041	0.000 050
$\frac{1}{4}$	0.029 846	0.090 926	0.089 616	0.210 245	0.000 039	0.000 058
$\frac{1}{8}$	0.019 217	0.077 054	0.053 133	0.166 253	0.000 038	0.000 670
$\frac{1}{16}$	0.013 105	0.051 884	0.032 966	0.110 745	0.000 037	0.000 059
$\frac{1}{32}$	0.010 936	0.002 812	0.025 075	0.005 312	0.000 037	0.000 620

表 5 速度为 150 km/h 时不同算法在不同压缩率下的系统耗时

压缩率	DCT-OMP/s	DCT-SP/s	FFT-OMP/s	FFT-SP/s	CsiNet/s	RM-Net/s
$\frac{1}{2}$	0.058 612	0.139 869	0.385 385	0.553 002	0.000 029	0.000 053
$\frac{1}{4}$	0.036 871	0.107 178	0.110 933	0.243 348	0.000 027	0.000 068
$\frac{1}{8}$	0.024 685	0.095 483	0.066 412	0.198 248	0.000 021	0.000 044
$\frac{1}{16}$	0.017 630	0.065 788	0.042 496	0.127 908	0.000 025	0.000 058
$\frac{1}{32}$	0.014 217	0.073 280	0.029 348	0.046 163	0.000 026	0.000 051

## 4 结束语

本文研究了高速移动环境下 FDD 大规模 MIMO 系统 CSI 压缩反馈问题, 提出了一种基于 DL 的 RM-Net, 其在 UE 完成 CSI 压缩, 通过标准化处理加快网络训练, 使用 GCNN 学习信道特征, 并通过设置全连接层神经元的数量控制 CSI 压缩率, CSI 压缩后经过信道加噪, 在 BS 端完成 CSI 恢复, 通过标准化与全连接层提高网络的抗噪能力, 采用 GCNN、DCNN、DSCNN 与全连接层学习数据特征并恢复 CSI, 并在 RM-Net 中引入 RB, 防止网络退化。通过离线训练使模型充分学习高速移动场景下稀疏、双选信道的特征, 提高 CSI 压缩反馈的性能。系统仿真结果表明, 与其他 CSI 反馈算法相比, RM-Net 算法不仅时间复杂度更低、系统耗时更短、NMSE 更低、相似度更高、系统容量更大, 而且模型训练速度快、所需训练样本少, 能够克服加性噪声的影响, 从而跟踪学习到高速移动环境下的信道特征, 同时在高压缩率与低信噪比条件下, 该算法依然具有较好的性能表现。由于采用端到端的方式进行模型训练, 因此所提算法具有一定扩展性, 可在其他信道场景下重新进行训练, 以达到相似效果。

## 参考文献:

- [1] LI C G, LIU P, ZOU C, et al. Spectral-efficient cellular communications with coexistent one- and two-hop transmissions[J]. IEEE Transactions on Vehicular Technology, 2016, 65(8): 6765-6772.
- [2] BOCCARDI F, HEATH R W, LOZANO A, et al. Five disruptive technology directions for 5G[J]. IEEE Communications Magazine, 2014, 52(2): 74-80.
- [3] BARRIAC G, MADHOW U. Space-time communication for OFDM with implicit channel feedback[J]. IEEE Transactions on Information Theory, 2004, 50(12): 3111-3129.
- [4] TSENG C C, WU J Y, LEE T S. Enhanced compressive downlink CSI recovery for FDD massive MIMO systems using weighted block-minimization[J]. IEEE Transactions on Communications, 2016, 64(3): 1055-1067.
- [5] HE K M, ZHANG X Y, REN S Q, et al. Identity mappings in deep residual networks[C]//Proceedings of the 14th European Conference on Computer Vision. Berlin: Springer, 2016: 630-645.
- [6] SZEGEDY C, IOFFE S, VANHOUCHE V. Inception-v4, inception-ResNet and the impact of the residual connections on learning[C]//Proceedings of the 31st AAAI Conference on Artificial Intelligence. Palo Alto: AAAI Press, 2017: 4278-4284.
- [7] 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.
- [8] 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.
- [9] YAO H T, DAI F, ZHANG S L, et al. DR2-Net: deep residual reconstruction network for image compressive sensing[J]. Neurocomputing, 2019, 359: 483-493.
- [10] 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.
- [11] 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.
- [12] SUN Q, WU Y Z, WANG J, et al. CNN-based CSI acquisition for FDD massive MIMO with noisy feedback[J]. Electronics Letters, 2019, 55(17): 963-965.
- [13] JANG Y, KONG G, JUNG M, et al. Deep autoencoder based CSI feedback with feedback errors and feedback delay in FDD massive MIMO systems[J]. IEEE Wireless Communications Letters, 2019, 8(3): 833-836.
- [14] LIU L F, OESTGES C, POUTANEN J, et al. The COST 2100 MIMO channel model[J]. IEEE Wireless Communications, 2012, 19(6): 92-99.
- [15] HUANG G, LIU S C, DER MAATEN L V, et al. CondenseNet: an efficient DenseNet using learned group convolutions[C]//Proceedings

- of 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE Press, 2018: 2752-2761.
- [16] ZHANG T, QI G J, XIAO B, et al. Interleaved group convolutions[C]//Proceedings of 2017 IEEE International Conference on Computer Vision. Piscataway: IEEE Press, 2017: 4383-4392.
- [17] KAISER L, GOMEZ A N, CHOLLET F. Depthwise separable convolutions for neural machine translation[J]. Computer Science Computation and Language, 2017, 34(4): 145-168.
- [18] VEIT A, WILBER M J, BELONGIE S. Residual networks behave like ensembles of relatively shallow networks[C]//Proceedings of the 2016 Conference on Advances in Neural Information Processing Systems. Barcelona: Neural Information Processing Systems Foundation, 2016: 550-558.
- [19] IOFFE S, SZEGEDY C. Batch normalization accelerating deep network training by reducing internal covariate shift[J]. Computer Science Machine Learning, 2015, 15: 56-61.
- [20] KOLOMVAKIS N, MATTHAIIOU M, COLDREY M. Massive MIMO in sparse channels[C]//Proceedings of 2014 IEEE 15th International Workshop on Signal Processing Advances in Wireless Communications. Piscataway: IEEE Press, 2014: 21-25.
- [21] BARANIUK R G. Compressive sensing lecture notes[J]. IEEE Signal Processing Magazine, 2007, 24(4): 118-121.
- [22] KUO P H, KUNG H T, TING P A. Compressive sensing based channel feedback protocols for spatially-correlated massive antenna arrays[C]//Proceedings of 2012 IEEE Wireless Communications and Networking Conference (WCNC). Piscataway: IEEE Press, 2012: 492-497.
- [23] IQBAL R, ABHAYAPALA T D, LAMAHEWA T A. Generalised Clarke model for mobile-radio reception[J]. IET Communications, 2009, 3(4): 644-654.
- [24] FAN G H, SUN J L, GUI G, et al. Fully convolutional neural network based CSI limited feedback for FDD massive MIMO systems[J]. IEEE Transactions on Cognitive Communications and Networking, 2021, PP(99): 1.
- [25] JUHA M, PEKKA K, TOMMI J, et al. WINNER II channel models[M]. New Jersey: Wiley Publishing, 2008.

#### [作者简介]



廖勇 (1982- ), 男, 四川自贡人, 博士, 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、区块链及其在无线通信中的应用等。

王世义 (1996- ), 男, 山东淄博人, 重庆大学硕士生, 主要研究方向为无线通信 CSI 反馈。