

快时变 FDD 大规模 MIMO 系统智能 CSI 反馈方法

廖勇, 王帅, 孙宁

(重庆大学微电子与通信工程学院, 重庆 400044)

摘 要: 针对快时变频分双工 (FDD) 大规模多输入多输出 (MIMO) 系统中因无线信道干扰使信道状态信息 (CSI) 矩阵中存在噪声以及多普勒频移导致的时间相关性使系统无法保证高可靠和低时延通信的问题, 提出一种智能 CSI 反馈方法。该方法利用卷积神经网络 (CNN) 和批标准化 (BN) 网络对 CSI 矩阵中的噪声进行提取并且学习信道的空间结构, 通过注意力机制提取 CSI 矩阵间的时间相关性以提高 CSI 重构的精度。利用标准的快时变信道模型仿真产生的数据对网络进行离线训练。系统仿真与分析表明, 所提方法能够有效地抑制噪声的影响以及对多普勒引起的时间相关性进行提取。与代表性 CSI 压缩反馈方法和 CsiNet 方法相比, 所提方法拥有更好的归一化均方误差 (NMSE) 和余弦相似度性能。

关键词: 快时变; 频分双工; 大规模多输入多输出; 压缩反馈; 信道状态信息; 智能反馈

中图分类号: TN911.72

文献标识码: A

DOI: 10.11959/j.issn.1000-436x.2021129

Intelligent CSI feedback method for fast time-varying FDD massive MIMO system

LIAO Yong, WANG Shuai, SUN Ning

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

Abstract: In the frequency division duplexing (FDD) massive multiple-input multiple-output (MIMO) system, the channel state information (CSI) matrix existed noise caused by the wireless channel interference and the time correlation caused by Doppler shift. Because of these effects, the communication system couldn't guarantee the requirements of reliability and low delay. An intelligent CSI feedback method was adopted. The convolutional neural network (CNN) and batch normalization (BN) network was used to extract the noise in the CSI matrix and learned the spatial structure of the channel. The time correlation between the CSI matrices through the attention mechanism was extracted to improve the accuracy of CSI reconstruction. The data was generated by the standard fast time-varying channel model simulation to train the network offline. System simulation and analysis show that the proposed method can effectively suppress the influence of noise and extract the time correlation caused by Doppler. Compared with the traditional CSI compression feedback algorithm and CsiNet algorithm, the proposed method has better NMSE and cosine similarity performance.

Keywords: fast time-varying, FDD, massive MIMO, compression feedback, channel state information, intelligent feedback

1 引言

大规模多输入多输出 (MIMO, multiple-input multiple-output) 作为新一代无线通信的重要组成部分

分, 具有系统容量大、频率效谱高等诸多优点^[1]。在频分复用 (FDD, frequency division duplex) 大规模 MIMO 系统中, 基站 (BS, base station) 需要获取实时下行信道状态信息 (CSI, channel state in-

收稿日期: 2021-01-05; 修回日期: 2021-04-06

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资助项目 (No.cstc2019jcyj-msxmX0017)

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

formation) 进行下行波束成形以减少用户间干扰, 提高系统的信道容量, 因此精确的 CSI 反馈至关重要。在快时变场景下, CSI 矩阵间存在严重的多普勒频移影响。若 BS 不能精确地对接收到的 CSI 矩阵进行恢复, 系统则无法为用户提供超高可靠与低时延的通信保障, 因为在高速移动情况下, 多普勒频移会导致严重的子载波间干扰 (ICI, inter-carrier interference), 进而对通信系统的性能造成严重的影响。在 FDD 大规模 MIMO 系统中, BS 端使用大规模密集排列的天线阵列, 反馈 CSI 的比特数随着发射天线数量急剧增加^[2]。因此, 亟须研究 CSI 反馈方法来降低 FDD 模式下的反馈开销, 提高快时变场景中 CSI 重构的精度。

为了解决 FDD 大规模 MIMO 系统中由于多天线导致反馈信息量急剧增加从而使系统资源消耗严重的问题, 一些学者提出了基于码本^[3]和基于压缩感知 (CS, compressed sensing)^[4-6]的 CSI 反馈方法。基于码本的 CSI 反馈方法需要预先确定码本中的码字索引, 码本的大小与天线数成正比, 在大规模 MIMO 系统中天线数量急剧增加, 码本会给通信系统带来巨大的资源开销。文献[4]提出了离散余弦变换 (DCT, discrete cosine transform) 和卡洛南-洛伊变换 (KLT, Karhunen-Loeve transform) 2 种自适应算法对 MIMO 信道进行压缩变换, 但是在快时变场景中信道变化较快, BS 无法及时获取信道相关信息, 导致通信质量下降。文献[5]提出一种主成分分析 (PCA, principal component analysis) 的压缩反馈方法, 使用上一时段估计到的压缩矩阵来进行重构, 因此 BS 无法及时获取准确的 CSI。文献[6]使用一种基于全变分正则化的重建算法 (TVAL3, total variation augmented lagrangian alternating direction algorithm) 进行压缩重构, 但是该算法需要传感矩阵对数据进行过压缩, 数据重构的精度与传感矩阵的设计有关。使用 CS 方法对信道进行压缩时需要将信道矩阵进行投影, 损失了无线信道结构特征, 并且 CS 方法通常使用迭代求解, 算法计算量大、处理过程缓慢, 对无线通信系统造成严重的计算负担, 不利于实时通信。

近年来, 随着深度学习 (DL, deep learning) 技术的飞速发展, 已有科研人员将 DL 方法应用到无线通信系统中, 例如信道估计、信号检测等。文献[7]对 DL 如何应用于无线通信物理层进行了综述, 并对 DL 应用于无线通信的优势以及应用过程

中存在的挑战进行了说明。文献[8]提出了一种基于 DL 的网络 ChanEstNet, 用于高速移动场景中的信道估计。文献[9]提出了一种用于提取信道中噪声的网络 Ancinet, 但是该网络没有考虑快时变场景对 CSI 矩阵的影响。文献[10]提出了一种基于自编码器的神经网络 CsiNet 来实现大规模 MIMO 系统中的 CSI 反馈, 该方法在用户侧使用编码器将 CSI 矩阵进行压缩, 在 BS 端使用解码器恢复 CSI 矩阵。与传统 CS 方法相比, CsiNet 能够获取较好的性能, 但是该网络没有对 CSI 矩阵中存在的噪声进行处理, 同时也没有对时变场景中由多普勒频移造成的矩阵间的时间相关性进行处理, 只是单纯地对信道矩阵进行特征提取和压缩恢复。文献[11]提出了能够处理多用户场景并且利用大规模天线间的相关性进行 CSI 恢复的神经网络, 通过使用卷积神经网络 (CNN, convolutional neural network) 和最大池化 (maxpooling) 网络对信道进行特征提取与压缩, 信号恢复阶段使用双向长短期记忆 (Bi-LSTM, bidirectional long short-term memory) 网络, 该网络利用天线间的相关性对 CSI 进行恢复, 假设获取到的是完美 CSI, 仿真过程中也没有考虑快时变场景带来的影响。

因此, 针对现有的 CSI 反馈方法复杂度高、反馈精度低、未考虑实际 CSI 矩阵中存在的噪声以及快时变场景中多普勒频移对 CSI 矩阵造成的影响等缺点, 基于实际通信过程中快时变 FDD 大规模 MIMO 系统中 CSI 矩阵具有时间相关性的特点, 本文提出了一种具有抵抗噪声、消除快时变影响的智能 CSI 反馈方法。该方法包含 3 个网络模块, 分别为噪声提取、数据压缩和数据恢复。噪声提取和数据压缩模块都是由 CNN 和批标准化 (BN, batch normalization) 网络组成的。噪声提取模块用于去除信号传播过程中因干扰使 CSI 矩阵中存在的噪声, 数据压缩模块用于对 CSI 矩阵进行特征提取与压缩, 数据恢复模块则利用全局注意力机制提取 CSI 矩阵间的时间相关性以提高 CSI 矩阵重构精度。本文对比了所提方法与已有代表性 CSI 反馈方法和 CsiNet 方法的归一化均方差 (NMSE, normalized mean squared error)、余弦相似度和运行时间, 并分析了它们在不同速度和信噪比下的反馈性能。

2 系统模型

针对 FDD 大规模 MIMO 通信系统, 参考文献

[9-10]的仿真条件设置, BS 端部署 N_r 根以均匀线性阵 (ULA, uniform linear array) 排列的天线 ($N_r \gg 1$), 用户端配置单根接收天线, 子载波数为 N_c 。在由用户移动造成的时变信道中, 时刻 s 第 m 个子载波上用户的接收信号可以表示为

$$y_{s,m} = \mathbf{h}_{s,m}^H \mathbf{w}_{s,m} x_{s,m} + n_{s,m} \quad (1)$$

其中, $\mathbf{h}_{s,m}^H \in \mathbb{C}^{N_r \times 1}$ 表示 s 时刻的信道频域矢量, $(\cdot)^H$ 表示共轭转置, $\mathbf{w}_{s,m} \in \mathbb{C}^{N_c \times 1}$ 表示发送信号的预编码矢量, $x_{s,m} \in \mathbb{R}$ 表示在 s 时刻的发送信号, $n_{s,m} \in \mathbb{C}$ 表示用户接收到的均值为 0、方差为 1 的加性白高斯噪声, 时刻 s 空间频率域的 CSI 矩阵可以表示为 $\mathbf{H}_s = [\mathbf{h}_{s,1}, \mathbf{h}_{s,2}, \dots, \mathbf{h}_{s,N_c}]^H \in \mathbb{C}^{N_c \times N_r}$ 。在 FDD 大规模 MIMO 系统中, BS 端首先对数据流进行预编码处理, 然后通过下行链路将信号发送给用户, 用户端接收到信号后通过信道估计获得 CSI 并对 CSI 进行处理, 通过上行链路将处理后的数据反馈给 BS, BS 恢复出 CSI 根据反馈信息设计预编码矩阵。在实际中, 用户端持续进行信道估计和反馈下行链路 CSI 到 BS, 使 BS 能够实时处理由于用户移动导致 CSI 改变带来的影响。

若将 CSI 矩阵全部反馈到 BS, 则需要反馈的 CSI 参数总数为 $N_c \times N_r$, 这需要消耗大量的系统资源。为了减少反馈开销, 需要对 CSI 矩阵进行稀疏降维。通过二维离散傅里叶变换 (DFT, discrete Fourier transform) 可以将空间频率域矩阵转换为角度时延域矩阵

$$\mathbf{H}'_s = \mathbf{F}_d \mathbf{H}_s \mathbf{F}_q^H \quad (2)$$

其中, $\mathbf{F}_d \in \mathbb{C}^{N_c \times N_c}$ 和 $\mathbf{F}_q \in \mathbb{C}^{N_r \times N_r}$ 是 DFT 矩阵。文献[12]分析证明了当发射天线 N_r 非常大时, 对空域信道向量即 \mathbf{H}_s 的行向量执行 DFT, 变换后的信道矩阵在角度域是稀疏的。在通信过程中, 信号在传播过程中最大多径时延数量是有限的, 对频域信道向量即 \mathbf{H}_s 的列向量执行 DFT, 变换后的信道矩阵 \mathbf{H}'_s 只有部分行向量具有非零值^[9]。本文保留 \mathbf{H}'_s 的前 $N'_c (N'_c < N_c)$ 的信息, 使反馈矩阵变成 $\mathbf{H}^*_s \in \mathbb{R}^{N'_c \times N_r}$ 。稀疏变换之后信道矩阵的参数量仍然很大, 因此本文提出了一种基于 DL 的 CSI 压缩和反馈结构使 CSI 矩阵的参数量进一步降低。

在实际通信过程中由于信道估计不完善, CSI 矩阵中会存在噪声。文献[13]给出了典型的 CSI 误

差模型, 经过稀疏变换以及截断后包含噪声的信道矩阵可以表示为

$$\mathbf{H} = \mathbf{H}^*_s + \mathbf{N} \quad (3)$$

其中, \mathbf{H}^*_s 为截断后的角度域信道矩阵, $\mathbf{N} \in \mathbb{C}^{N'_c \times N_r}$ 为加性噪声。

在 FDD 大规模 MIMO 系统通信过程中, 由于用户端移动导致多普勒频移造成时延扩展, 从而使无线信道出现时变特性。相干时间 Δt 可以表示为

$$\Delta t = \frac{c_0}{2\nu f} \quad (4)$$

其中, c_0 为光速, ν 为用户移动的速度, f 为载波的频率。在时间 Δt 内的 2 个 CSI 矩阵是相关的, 所以 BS 在恢复重建 CSI 矩阵过程中可以提取这种相关性来提高 CSI 矩阵重构精度。本文将反馈时间设置为 $\delta_t (\delta_t < \Delta t)$, 连续 T 个持续反馈的信道矩阵序列可以表示为 $\{\mathbf{H}_t\}_{t=1}^T = \{\mathbf{H}_1, \mathbf{H}_2, \dots, \mathbf{H}_T\}$, 此时相邻的 \mathbf{H}_t 之间存在时间相关性。

3 智能 CSI 反馈

本文所提方法通过使用噪声提取网络去除 CSI 矩阵中存在的噪声以恢复出相对完美的 CSI 矩阵; 数据压缩网络对 CSI 矩阵进行压缩使反馈参数数量减少以降低系统的资源开销; 数据恢复网络利用注意力机制提取 CSI 矩阵间的相关性对压缩后的数据进行重构。

3.1 网络结构

本文提出的基于 DL 算法的网络结构如图 1 所示, 网络主要由噪声提取、数据压缩和数据恢复 3 个部分组成。所提方法使用的神经网络为 CNN、BN 以及注意力机制。下面, 对网络中的各个结构进行描述。

1) CNN

在本文提出的基于 DL 的网络结构中, CNN 主要用于对矩阵中的噪声和特征值进行提取。CNN 单个通道的输出值是由单个卷积核计算得到的, 采用共享权值的方式使网络可训练的参数极大减少, 同时 CNN 可以对大规模 MIMO 信道的空间结构进行提取^[10]。CNN 的输入数据是一个 $c \times h \times w$ 的三维结构, 其中 c 表示输入数据的通道数, h 表示数据的高度, w 表示数据的宽度。CNN 输出的每个通道数据是通过一个卷积核对所有输入通道的数据进行卷积求和得到的, 设 $\mathbf{W}_1 \in \mathbb{R}^{h \times w}$ 为第一个输出通道的




图 1 所提智能 CSI 反馈网络结构

卷积滤波器，其中 h 为卷积核的高度， w 为卷积核的宽度。卷积滤波器的尺寸远小于输入数据的尺寸，所以使用滑动窗口的方法对输入数据加权求得卷积和。因此 CNN 每个通道的输出为

$$x = \sigma(H * W + b) \quad (5)$$

其中， b 为偏置， σ 为激活函数， $*$ 为卷积操作。本文提出的学习网络使用的激活函数为 LeakyReLU，当输入值小于 0 时，激活函数具有不为 0 的输出值，使网络能够对负值进行处理。

2) BN

当学习网络中的层数增加时，网络的训练就会变得越来越慢，因为 LeakyReLU 函数对正值不做处理，输出的值即为卷积滤波器的加权和，只对负值做变换。随着学习网络的加深，激活函数的输入值的分布会发生改变，出现极端的输入值，这就导致反向传播时低层神经网络梯度消失，学习网络在训练时越来越慢。

为了提高网络的训练速度，需要对每一层网络的数据进行规范化，将每层神经网络中神经元的输入值分布强行拉回到均值为 0、方差为 1 的标准正态分布。通过这样的处理使激活函数的输入值落入相对敏感的区域，解决梯度消失的问题。BN 的转化式为

$$\widehat{x}_i^k = \frac{x_i^k - \mu^k}{\sqrt{\delta^2 + \varepsilon}} \quad (6)$$

其中， x_i^k 为第 k 层 BN 的第 i 个神经元的输入值， μ^k 为第 k 层 BN 所有神经元输入值的均值， δ^2 为第 k 层 BN 所有神经元输入值的方差， ε 是为了防止分母为 0 预设的一个值。

3) 注意力机制

在快时变场景中，多普勒频移的存在会使 CSI

矩阵间存在相关性，若能对这种相关性进行提取并将提取到的数据应用到 CSI 重构中，那么将有助于提高 CSI 矩阵的恢复精度。注意力机制可以对需要关注的信息投入更多的注意力，获取更多所需的细节信息并抑制其他无用的信息。因而，本文利用注意力机制提取 CSI 矩阵间的相关性来对 CSI 矩阵进行重构。

数据恢复网络中注意力机制用于对 CSI 矩阵间的时间相关性进行提取，通过全局注意力池化提取多普勒频移对每个数据通道的影响。多普勒频移对信道矩阵中的每个元素都有影响，CNN 层的处理可以将输入的数据变成多通道数据，多普勒频移造成的影响被分散到这些通道的数据上，此时每个通道的数据被多普勒频移影响的程度差异很大。全局注意力池化对通道上的所有数据进行处理，得到每个通道数据的均值，反向传播算法对每个通道数据的均值进行学习和更新，从而得到多普勒频移对每个通道的影响程度的权重系数，将权重系数与原始的数据相乘得到每个通道受多普勒影响的程度。数据在每个通道的注意力池化公式为

$$m_c = \frac{1}{hw} \sum_{i=1}^h \sum_{j=1}^w x_c(i, j) \quad (7)$$

其中， m_c 为通道 c 生成的参数值， h 和 w 分别为该通道数据的高度和宽度， $x_c(i, j)$ 为通道 c 中 i 行 j 列的数据值。

3.2 网络中数据流

本文所提的智能 CSI 反馈网络中的数据流如图 2 所示，其中 m_1, m_2, n_1, n_2 表示数据的通道数量。下面，分别对数据预处理、噪声提取、数据压缩和数据恢复中的数据流进行描述。

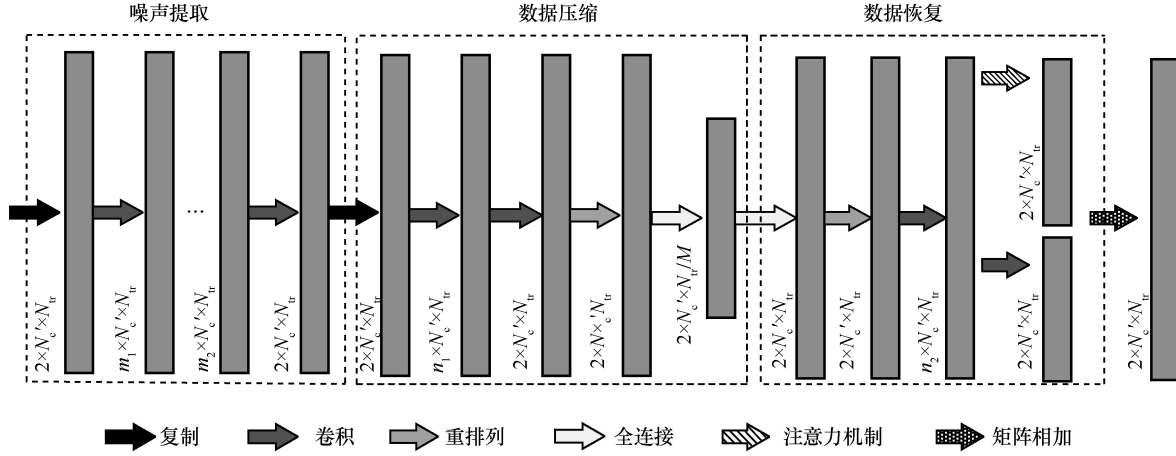


图 2 所提智能 CSI 反馈网络的数据流

1) 数据预处理

CSI 反馈的目的是在降低系统反馈过程中资源开销的情况下，提高接收端恢复 CSI 的精度。为了降低反馈开销，需要对数据进行压缩处理以减少反馈参数。本文提出的智能 CSI 反馈网络训练和测试使用的数据都是经信道估计产生的数据，其大小为 $N_c' \times N_{tr}$ ，该信道数据是一个复数矩阵，学习网络无法直接对复数进行处理，因此在数据输入网络前需要进行预处理，这里将输入的信道矩阵实部和虚部分离组成一个新的维度，新数据的大小为 $2 \times N_c' \times N_{tr}$ ，即输入数据为 $H_t' \in \mathbb{R}^{2 \times N_c' \times N_{tr}}$ 。

2) 噪声提取

由于信道干扰使生成的 CSI 矩阵中存在噪声，因此需要对 CSI 矩阵中的噪声进行提取去除。输入学习网络的数据维度和图片的维度相似，因此，本文对文献[14]中的图片噪声提取网络进行改进，用于提取 CSI 矩阵中的噪声。

经过预处理后的数据输入噪声提取网络中，首先数据经过 CNN 层处理，得到噪声的初步提取，CNN 中的数据格式为 $c_1 \times c_2 \times m \times m$ ，其中 c_1 表示输入数据的通道数， c_2 表示输出数据的通道数， m 表示该 CNN 使用卷积核的高和宽。每个 CNN 中的卷积核的数目与该 CNN 层输出数据的通道数相同，即每个卷积核用于生成一个输出通道。卷积层的输出为

$$H_t'' = f(H_t' * W + b) \quad (8)$$

其中， $H_t'' \in \mathbb{R}^{c_2 \times N_c' \times N_{tr}}$ ， W 和 b 分别为卷积核的权重和偏置， f 为 LeakyReLU 激活函数。数据经过 CNN

提取噪声后，输入 BN 中。BN 不改变输入数据的大小，但改变数据的分布情况，使网络更加容易训练。噪声提取网络的输出为噪声数据，最后用原始数据减去噪声数据即可得到去噪后的 CSI 矩阵 $\widehat{H}_t \in \mathbb{R}^{2 \times N_c' \times N_{tr}}$ 。

3) 数据压缩

数据压缩中使用的网络结构与噪声提取网络结构类似，但是 CNN 进行的操作不同。在噪声提取网络中，CNN 用于对信道矩阵中的噪声进行提取，而数据压缩中 CNN 用于对 CSI 矩阵中的信道特征进行提取，通过使用卷积核对输入数据的特征进行提取并生成该卷积核的特征表示。将信道特征信息分散到多个通道后，使每个通道能关注到不同的信道特征。

数据压缩网络的最后使用全连接网络对输入数据进行压缩。首先将卷积网络的输出展开成一维的数据，将展开后的数据输入全连接网络，通过控制最后一层网络神经元的个数来控制数据的压缩率。全连接网络的输出为

$$\widehat{H}_t = f_c(\widehat{H}_t * W + b) \quad (9)$$

其中， \widehat{H}_t 为展开成一维的信道数据， f_c 为 sigmoid 激活函数， W 和 b 分别为全连接网络的权重和偏置， $\widehat{H}_t \in \mathbb{R}^{\frac{2 \times N_c' \times N_{tr}}{M}}$ ， M 为最后的压缩率。

4) 数据恢复

在 CSI 重构阶段，首先使用全连接网络将数据扩展到原始大小，得到 $\widehat{H}_t \in \mathbb{R}^{2 \times N_c' \times N_{tr}}$ 。然后将一维的数据变换成二维数据，形状和原始数据相同，即

$\widehat{\mathbf{H}}_t \in \mathbb{R}^{2 \times N_c \times N_r}$ 。将维度变换后的数据输入恢复网络中进行 CSI 重构。

在快时变场景中，由于多普勒频移的存在使 CSI 矩阵在相干时间内存在相关性，因此本文利用注意力机制提取时间相关性来进行 CSI 重构，以提高 CSI 重构精度。首先利用 CNN 将经过变换后的 2 通道数据变成多通道数据 $\widetilde{\mathbf{H}}_t \in \mathbb{R}^{m \times N_c \times N_r}$ 。接着使用全局平均注意力提取多普勒频移对每个通道数据的影响参数值，平均注意力转换为

$$\mathbf{a}_c = \text{avgPool}(\widetilde{\mathbf{H}}_t) \quad (10)$$

其中， \mathbf{a}_c 是一维向量，向量中的每个元素表示多普勒频移对该通道的影响参数值。然后将 \mathbf{a}_c 输入全连接网络中将参数值转化成权重系数，并将得到的权重系数与原数据相乘，通过权重系数对多普勒频移造成的相关性投入更多的注意力即提取数据中的相关性。将相乘后的数据通过卷积网络变换到 2 通道数据，分别得到实部和虚部的相关性。最后将经注意力提取的数据与 CNN 恢复的矩阵进行相加得到最终的网络重构的 CSI 矩阵 $\widetilde{\mathbf{H}}_t \in \mathbb{R}^{2 \times N_c \times N_r}$ 。

3.3 模型训练

本文所提方法采用离线训练的方式得到网络的权重，以及在线预测的方式对性能进行评估。本文离线训练网络时使用的数据是由 MATLAB 对现有的标准扩展车辆信道模型 (EVA, extended vehicular a model) 仿真得到的，标准的信道模型可以在统计领域很好地描述信道，利用这些信道可以模拟实际的场景。本文使用 EVA 生成所需的训练数据，训练设备的配置为 GeForce GTX 1080 显卡，Intel Core i5 8400 处理器。对于离线训练阶段，将信道估计出的 CSI 作为学习网络的输入数据，完美的 CSI 作为标签数据对学习网络进行训练，使用的训练集、校验集和测试集的样本数分别为 100 000、20 000 和 10 000。

为了得到网络中的参数，本文使用端到端的训练方式来获取学习网络中的所有权重。设整个学习网络的变换公式和所有参数分别为 $f(\cdot)$ 和 θ ，因此学习网络重构得到的 CSI 可以表示为 $\widetilde{\mathbf{H}}_t = f(\mathbf{H}_t, \theta)$ 。本文使用自适应矩估计 (ADAM, adaptive moment estimation) 算法来更新学习网络的

参数值，初始学习率设为 0.001，训练 Epoch 为 100，Batch 为 200，通过均方误差 (MSE, mean square error) 损失函数计算学习网络的输出与标签数据之间差值。MSE 损失函数的计算式为

$$L(\theta) = \frac{1}{N} \sum_{t=1}^N (f(\mathbf{H}_t, \theta) - \mathbf{H}_t^*)^2 \quad (11)$$

其中， \mathbf{H}_t 表示 t 时刻输入到网络中的信道矩阵， \mathbf{H}_t^* 表示 t 时刻完美的信道矩阵， N 表示训练样本集中总的样本数。

4 仿真和分析

为了验证快时变大规模 MIMO 场景中所提方法的性能，本节对比了所提方法与 DCT^[4]、PCA^[5]、TVAL3^[6] 和 CsiNet^[10] 压缩反馈方法的 MATLAB 仿真性能，数据的压缩比参照文献[9]都设定为 1/4。仿真过程中，神经网络进行 CSI 压缩和 CSI 重构期间，移动速度是恒定的。用户端的 CSI 是通过信道估计得到的，仿真系统的主要参数如表 1 所示。

表 1 仿真系统的主要参数

仿真参数	设置
双工模式	FDD
用户个数	1
发射天线	32
接收天线	1
子载波数	600
调制方式	QPSK
信道模型	EVA
载波频率/GHz	5.9
信道带宽/MHz	10

4.1 归一化均方误差

本节比较了速度分别为 100 km/h 和 200 km/h、发射天线为 32 根、单根接收天线、截断载波数为 32 时所提方法与其他算法的归一化均方误差 $\text{NMSE} = E \left\{ \|\widetilde{\mathbf{H}}_t - \mathbf{H}_t^*\|_2^2 / \|\mathbf{H}_t^*\|_2^2 \right\}$ 。NMSE 值越小，表示重构的 CSI 与理想的 CSI 误差越小，学习网络的性能越高，最后 NMSE 的结果以对数的形式来展现。

图 3 和图 4 展示了速度分别为 100 km/h 和 200 km/h 时各方法的 NMSE 性能，从图中可以看出，所提方法的 NMSE 性能优于传统主流方法

DCT、PCA 和 TVAL3 以及神经网络方法 CsiNet，并且所提方法在低信道噪声比（CNR, channel-to-noise ratio）^[9]时 NMSE 下降较快，这是因为噪声提取网络可以对输入的含噪声数据进行处理以提高低信噪比时网络的性能。在高 CNR 时，所提方法可以对 CSI 矩阵间的时间相关性进行提取并用于 BS 端恢复 CSI 矩阵，提高 CSI 的重构精度。DCT、PCA 和 TVAL3 方法整体性能都较低，并且随着 CNR 的改善算法的性能都没有较大提升，这是因为 DCT 方法在实施的过程中，需要使用下行信道的 CSI 来生成压缩矩阵和恢复矩阵，用户端需要持续地向 BS 反馈信道变换信息，在快时变场景中，BS 无法利用 CSI 的相关性进行重构，从而造成 NMSE 性能下降。PCA 通过提取 CSI 矩阵的主要成分来进行压缩和恢复信道矩阵，但其使用的压缩矩阵是通过前一段时间估计得到的，因此 BS 端很难恢复出精确的 CSI。TVAL3 方法在处理时需要添加先验信息，在快时变场景中信道信息不停变化，BS 很难获得先验信息，因此 TVAL3 方法无法提高 CSI 恢复精度。此外，CsiNet 方法没有对 CSI 矩阵中含有的噪声进行处理，也没有考虑到快时变场景中多普勒的影响。




图 3 速度为 100 km/h 时各压缩算法 NMSE 性能对比

4.2 余弦相似度

在大规模 MIMO CSI 反馈中，余弦相似度是衡量重构 CSI 准确度的另一个指标。余弦相似度通过计算 2 个向量的夹角余弦值来评估它们的相似性，因为 CSI 是一个矩阵形式，本文通过对每个载波的向量分别求余弦相似度进而得到整个矩阵的相似性，余弦相似度的计算式为

$$\beta = E \left\{ \frac{1}{N_c} \sum_{i=1}^{N_c} \frac{|\widetilde{\mathbf{h}}_i^H \mathbf{h}_i^*|}{\|\widetilde{\mathbf{h}}_i\|_2 \|\mathbf{h}_i^*\|_2} \right\} \quad (12)$$

其中， $\widetilde{\mathbf{h}}_i^H$ 表示神经网络输出的信道向量， \mathbf{h}_i^* 表示完美的信道向量。 β 越接近 1，表示重构的数据与原始数据越相近。为了对比所提方法与其他典型 CSI 反馈方法的性能，图 5 和图 6 比较了 BS 端配置 32 根天线、接收端配置单根天线、载波数为 32、数据压缩率都设置为 1/4、速度分别为 100 km/h 和 200 km/h 时各算法的余弦相似度性能。




图 4 速度为 200 km/h 时各压缩算法 NMSE 性能对比




图 5 速度为 100 km/h 时各压缩算法余弦相似度性能对比

从图 5 和图 6 可以看出，所提方法具有更好的余弦相似度。当速度为 100 km/h 时，所提方法重构出的 CSI 在低 CNR 时余弦相似度为 0.84，在高 CNR 时接近 1，而其余方法在低 CNR 时余弦相似度只有 0.5 左右，在高 CNR 时只有 0.8~0.9。当速度为 200 km/h 时，所提方法在低 CNR 时重

构 CSI 的余弦相似度为 0.82, 在高 CNR 时为 0.98, 而其余方法在低 CNR 时余弦相似度只有 0.4 左右, 在高 CNR 时只有 0.7~0.9。传统的 DCT、PCA 和 TVAL3 方法以及神经网络方法 CsiNet 在低 CNR 时, 重构 CSI 的余弦相似度低于所提方法 0.3~0.4, 随着 CNR 的提高, 各方法重构 CSI 的余弦相似度性能都有所上升, 但都低于所提方法。因为所提方法在低 CNR 时, 利用噪声提取网络提取 CSI 矩阵中的噪声, 可以抵抗低信噪比的影响, 注意力机制可以对 CSI 矩阵间的时间相关性进行提取, 所以在快时变场景中也可以得到很高的恢复精度。




图 6 速度为 200 km/h 时各压缩算法余弦相似度性能对比

4.3 运行时间

为了对比上述 CSI 反馈方法的运行速率, 本节统计了速度分别为 50 km/h、150 km/h 和 250 km/h 条件下各方法运行 600 次的平均时间, 如表 2 所示。从表 2 中可以看出, 本文所提方法相较于传统方法运行时间更短, 因为基于深度学习的方法只需要进行简单的矩阵相乘就可以得到输出结果, 而传统方法需要迭代求解。所提方法的网络层数要多于 CsiNet, 因此其运行时间要略长于 CsiNet。虽然所提方法运行时间比 CsiNet 略长, 但是其 NMSE 和余弦相似度性能都要优于 CsiNet。

5 结束语

本文研究了快时变 FDD 大规模 MIMO 系统中的智能 CSI 反馈方法。针对传统 CSI 压缩反馈方法复杂度高、反馈精度低以及未考虑因为信道干扰导

致 CSI 矩阵中存在噪声和快时变场景中多普勒频移导致 CSI 矩阵间存在相关性的问题, 本文提出了一种新的 CSI 压缩反馈学习网络。该方法考虑了 CSI 矩阵中存在的噪声以及矩阵间的相关性, 通过标准高速移动场景信道数据训练网络使网络可以充分学习快时变场景中信道的结构特征, 从而提升 CSI 压缩反馈的精确度。系统仿真表明, 本文所提方法与代表性 CSI 压缩反馈方法以及 CsiNet 方法相比, 拥有更好的 NMSE 和余弦相似度性能。后续将会在保证 CSI 反馈精度的同时, 研究如何降低网络的复杂度, 以及消除因反馈 CSI 带来的时延对通信系统造成的影响。

表 2 各 CSI 反馈方法的运行时间对比

对比方法	运行时间/s		
	50 km/h	150 km/h	250 km/h
DCT	0.012 4	0.012 2	0.012 1
PCA	0.009 2	0.009 1	0.009 1
TVAL3	0.238 4	0.238 0	0.237 9
CsiNet	0.002 2	0.002 2	0.002 2
所提方法	0.005 6	0.005 6	0.005 6

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] ONGGOSANUSI E, RAHMAN M S, GUO L, et al. Modular and high-resolution channel state information and beam management for 5G new radio[J]. IEEE Communications Magazine, 2018, 56(3): 48-55.
- [3] ZHANG R Q, ZHOU Y X, QU B Y. High resolution CSI feedback with beam space MIMO[C]//2017 IEEE 28th Annual International Symposium on Personal, Indoor, and Mobile Radio Communications. Piscataway: IEEE Press, 2017: 1-5.
- [4] SIM M S, PARK J, CHAE C B, et al. Compressed channel feedback for correlated massive MIMO systems[J]. Journal of Communications and Networks, 2015, 18(1): 95-104.
- [5] GE A M, ZHANG T K, HU Z R, et al. Principal component analysis based limited feedback scheme for massive MIMO systems[C]//2015 IEEE 26th Annual International Symposium on Personal, Indoor, and Mobile Radio Communications. Piscataway: IEEE Press, 2015: 326-331.
- [6] KONG Q L, GONG R, LIU J T, et al. Investigation on reconstruction for frequency domain photoacoustic imaging via TVAL3 regularization algorithm[J]. IEEE Photonics Journal, 2018, 10(5): 1-15.
- [7] HUANG H J, GUO S, GUI G, et al. Deep learning for physical-layer 5G wireless techniques: opportunities, challenges and solutions[J].


IEEE Wireless Communications, 2020, 27(1): 214-222.

- [8] LIAO Y, HUA Y X, DAI X W, et al. ChanEstNet: a deep learning based channel estimation for high-speed scenarios[C]//2019 IEEE International Conference on Communications. Piscataway: IEEE Press, 2019: 1-6.
- [9] SUN Y Y, XU W, FAN L S, et al. AnciNet: an efficient deep learning approach for feedback compression of estimated CSI in massive MIMO systems[J]. IEEE Wireless Communications Letters, 2020, 9(12): 2192-2196.
- [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] LIAO Y, YAO H M, HUA Y X, et al. CSI feedback based on deep learning for massive MIMO systems[J]. IEEE Access, 2019, 7: 86810-86820.
- [12] WEN C K, JIN S, WONG K K, et al. Channel estimation for massive MIMO using Gaussian-mixture Bayesian learning[J]. IEEE Transactions on Wireless Communications, 2015, 14(3): 1356-1368.
- [13] HOUSFATER A S, LIM T J. Noisy feedback linear precoding: a Bayesian Cramér-Rao bound[C]//2009 IEEE International Symposium on Information Theory. Piscataway: IEEE Press, 2009: 1689-1693.
- [14] ZHANG K, ZUO W M, CHEN Y J, et al. Beyond a Gaussian denoiser: residual learning of deep CNN for image denoising[J]. IEEE Transactions on Image Processing, 2017, 26(7): 3142-3155.

[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、量子计算及其在无线通信中的应用等。



王帅（1995- ），男，安徽马鞍山人，重庆大学硕士生，主要研究方向为智能信号与信息处理。



孙宁（1995- ），男，河南长垣人，重庆大学硕士生，主要研究方向为智能信号与信息处理。