

# 基于深度学习的 1-比特超大规模 MIMO 信道估计 \*

蒲旭敏<sup>1,2</sup>, 吴超<sup>1,2</sup>, 杨小珑<sup>1,2</sup>

(1.重庆邮电大学 通信与信息工程学院, 重庆 400065; 2.重庆邮电大学 移动通信技术重庆市重点实验室, 重庆 400065)

**摘要:** 超大规模多输入多输出(Multiple Input Multiple Output, MIMO)技术在未来的移动通信中具有巨大的潜力。然而, 采用超大型的天线阵列会出现空间非平稳性信道特征, 如果为基站的每根天线都配备一个高精度量化器, 系统功耗将大幅度增加, 从而阻碍超大规模 MIMO 系统的广泛应用。因此, 假设基站的每根天线都配备有一对 1-比特模数转换器(Analog-to-Digital Converters, ADC), 利用子阵列与用户之间的映射关系来描述非平稳信道特征, 借助深度神经网络(Deep Neural Network, DNN)强大的泛化能力, 设计一种新的生成式监督 DNN 模型, 该模型可以使用合理数量的导频进行训练。仿真结果表明, 所提出的网络可以使用较少的导频得到较好的估计性能, 在性能与计算复杂度之间取得良好的平衡。

**关键词:** 信道估计; 深度学习; 空间非平稳性; 1-比特 ADC

中图分类号: TN92

文献标识码: A

DOI: 10.16157/j.issn.0258-7998.211341

中文引用格式: 蒲旭敏, 吴超, 杨小珑. 基于深度学习的 1-比特超大规模 MIMO 信道估计[J]. 电子技术应用, 2021, 47(8): 87-90, 96.

英文引用格式: Pu Xumin, Wu Chao, Yang Xiaolong. Channel estimation for 1-bit extremely massive MIMO via deep learning[J]. Application of Electronic Technique, 2021, 47(8): 87-90, 96.

## Channel estimation for 1-bit extremely massive MIMO via deep learning

Pu Xumin<sup>1,2</sup>, Wu Chao<sup>1,2</sup>, Yang Xiaolong<sup>1,2</sup>

(1. School of Communication and Information Engineering, Chongqing University of Posts and Telecommunications,  
Chongqing 400065, China;

2. Chongqing Key Laboratory of Mobile Communications Technology, Chongqing University of Posts and Telecommunications,  
Chongqing 400065, China)

**Abstract:** Extremely massive multiple input multiple output(MIMO) has shown considerable potential in future mobile communications. However, the use of extremely massive aperture arrays will lead to spatial non-stationary channel conditions, and each antenna of the base station is equipped with a high-precision quantizer, the power consumption of the system will be greatly increased, which will hinder the widespread application of ultra-large-scale MIMO systems. Therefore, this article assumes that each antenna of the base station is equipped with a pair of 1-bit analog-to-digital converters(ADC), and uses the mapping relationship between the sub-array and the user to describe the non-stationary channel characteristics. Based on the powerful generalization ability of neural network(DNN), this paper designs a new generative supervised DNN model that can be trained with a reasonable number of pilots. The simulation results show that the proposed network can achieve better estimation performance with less pilots and achieve a good balance between performance and complexity.

**Key words:** channel estimation; deep learning; spatial non-stationary; 1-bit ADC

## 0 引言

大规模多输入多输出(Multiple Input Multiple Output, MIMO)技术是第五代(Fifth Generation, 5G)移动通信的关键技术之一。随着天线阵列尺寸数量级的增加, 形成了超大规模 MIMO 系统。通过增加天线阵列的尺寸, 可以提升频谱效率、能量效率和空间分辨率等, 还有望获取

超高的数据速率和系统吞吐量。超大规模 MIMO 技术也因此成为第六代(Sixth Generation, 6G)移动通信关键技术的候选<sup>[1]</sup>。然而, 大口径阵列的使用会造成不同的信道条件。当整个阵列的孔径有限并且服务相同的用户时, 空间稳定性是成立的。但是, 对于大孔径阵列, 由于天线阵列不同区域所服务的用户不同, 接收功率的级别也因此不同, 这称为空间非平稳性<sup>[2]</sup>。因此, 可以引入子阵列和用户可见区域(Visibility Region, VR)来描述信道非平

\* 基金项目: 国家自然科学基金青年科学基金(61701062); 中国博士后科学基金(2019M651649); 江苏省博士后科研资助计划项目(2018K041C)

稳定性<sup>[3]</sup>。

常见的超大规模 MIMO 系统中存在两个严重的问题。一个是由于阵列体积较大,空间非平稳性和固有的高矩阵维数对性能和计算复杂度带来了负面影响<sup>[4]</sup>;另一个是由于接收机中配备的高精度模数转换器(Analog-to-Digital Converters, ADC)消耗了相当多的功率,导致硬件成本和功耗增加<sup>[5]</sup>。虽然 1-比特 ADC 可以显著降低功耗,但是性能较差。因此,需要在超大规模 MIMO 系统中利用非平稳性来描述信道模型,并采用低精度的量化方式来降低功耗,在服务大量用户时寻求性能和计算复杂度间的良好平衡。

随着计算能力的提升,深度学习方法已被广泛应用于大规模 MIMO 系统中,尤其是与信道估计相关的研究<sup>[6-7]</sup>。在 1-比特 ADC 大规模 MIMO 系统中,通过应用神经网络可以在相同导频数量下获得更好的信道估计性能,从而在计算复杂度和导频数量间取得折中<sup>[8-9]</sup>。然而,这些研究并没有考虑天线阵列增大时出现的信道非平稳特性。虽然文献[10]提出了子阵列和散射体两种信道估计方法来估计非平稳信道,但是并未考虑 ADC 功耗问题。在此基础上,本文通过子阵列与用户之间的映射来描述非平稳信道,设计了一种新的生成式监督深度神经网络(Deep Neural Network, DNN),并对配置 1-比特 ADC 的基站接收机子阵列开展了信道估计的相关研究。该网络可以采用较少的导频进行训练,能在使用较少导频的条件下取得良好的信道估计性能。

## 1 系统模型

本文考虑一个单小区超大规模 MIMO 上行传输系统,如图 1 所示。该基站有  $M$  根均匀线性阵列天线,每根天线配置一对 1-比特 ADC,为  $K$  个单天线用户提供服务。将基站的天线阵列均匀分成  $S$  个不相关的子阵列,每个子阵列的天线数为  $N=M/S$ ,并且每组子阵列都有用于信道估计的本地处理单元。为了保证多用户 MIMO 系统的效能,假定  $N \geq K$ ,则子阵列  $s$  对应的第  $p$  个导频接收信号为:

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

其中,  $\mathbf{x}_p^{(s)} = [x_{p1}^{(s)}, x_{p2}^{(s)}, \dots, x_{pK}^{(s)}]^T$  表示所有用户发送的导频符号;  $\mathbf{H}^{(s)} = [\mathbf{h}_1^{(s)}, \dots, \mathbf{h}_K^{(s)}] \in \mathbb{C}^{N \times K}$  为子阵列  $s$  与所有用户之间的信道矩阵,假定每个子阵列信道系数服从复高斯分布,且满足  $E[\mathbf{H}^{(s)} \mathbf{H}^{(s)H}] = N \sigma_{(s)}^2 \mathbf{I}_N$ ;  $\mathbf{n}^{(s)} \in \mathbb{C}^{N \times 1}$  表示方差为  $\sigma^2$  的零均值高斯白噪声。

子阵列  $s$  到用户  $k$  之间的信道系数  $\mathbf{h}_k^{(s)}$  为<sup>[4]</sup>:

$$\mathbf{h}_k^{(s)} = \sqrt{a_k^{(s)}} \odot \bar{\mathbf{h}}_k^{(s)} \quad (2)$$

其中,  $a_k^{(s)} = \Omega(\mathbf{d}_k^{(s)})^{-v}$  表示大尺度衰落,  $\Omega$  为路径损耗衰减系数,  $\mathbf{d}_k^{(s)} \in \mathbb{R}^{N \times 1}$  为子阵列  $s$  的每根天线到用户  $k$  之间的

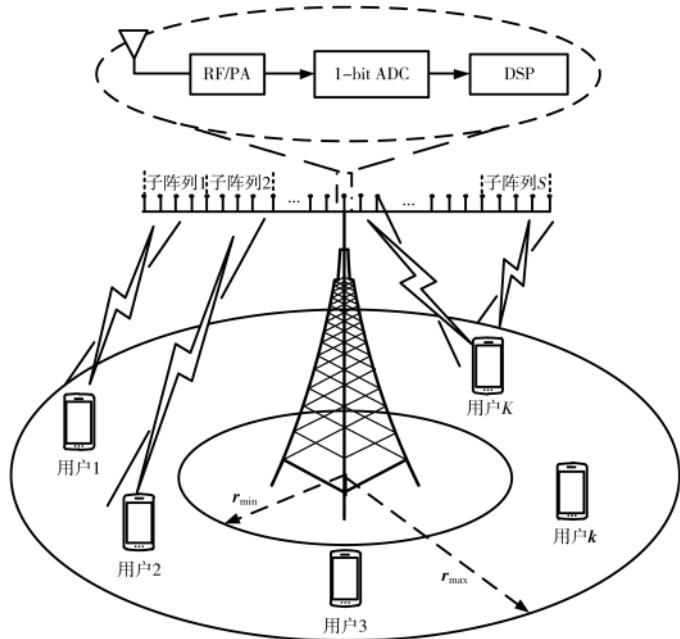


图 1 单小区 1-比特 ADC 超大规模 MIMO 系统架构

距离,  $v$  为路径损耗指数;  $\bar{\mathbf{h}}_k^{(s)} \sim N_c(0, \Theta_k^{(s)})$  表示由小尺度衰落引起的信道响应,  $\Theta_k^{(s)} \in \mathbb{R}^{N \times N}$  为考虑非平稳性和信道相关响应的子阵列信道协方差矩阵。超大规模 MIMO 阵列所有天线的整体信道协方差矩阵为  $\Theta_k = \text{blkdiag}(\Theta_k^{(1)}, \dots, \Theta_k^{(S)}) \in \mathbb{R}^{M \times M}$ ,  $\text{blkdiag}(\cdot)$  表示分块对角构造函数, 主对角线上的非零子块依次为矩阵  $\Theta_k^{(1)}, \Theta_k^{(2)}, \dots, \Theta_k^{(S)}$ , 并且满足:

$$\Theta_k = \mathbf{D}_k^{1/2} \mathbf{R}_k \mathbf{D}_k^{1/2} \quad (3)$$

其中,  $\mathbf{R}_k \in \mathbb{R}^{M \times M}$  表示捕获空间信道相关效应的对称半正定矩阵,  $\mathbf{D}_k \in \{0, 1\}^{M \times M}$  是通过可见区域概念建模的包含非平稳特性的对角矩阵。

### 1.1 VR 建模

VR 描述了阵列中被每个用户“看见”的部分,即用户大部分能量集中的部分。特别地,本文采用了文献[4]中描述的模型,其中每个用户都有一个由两个参数识别的 VR。因此,将 VR 的中心建模为  $c_k \sim U(0, L)$ ,  $L$  为超大规模 MIMO 阵列的物理长度,VR 的长度建模为  $l_k \sim \text{LN}(\mu_l, \sigma_l)$ 。设  $D_k$  表示服务用户  $k$  的天线数量,定义为  $[c_k - l_k, c_k + l_k]$  所划定的物理区域内阵列天线的总和。因此,式(3)的对角矩阵  $\mathbf{D}_k$  中有  $D_k$  个非零对角元素。本文以非平稳信道的范数小于或等于平稳信道的情况为例,在这种情况下满足  $\text{tr}(\Theta_k) = D_k (\forall k)$ ,  $\mathbf{D}_k = \text{diag}([\mathbf{0}, \mathbf{1}_{D_k}, \mathbf{0}]^T)$ 。

### 1.2 1-比特 ADC 超大规模 MIMO 信号分析

$\mathbf{y}_p^{(s)}$  经过 1-比特 ADC 量化器  $Q(\cdot)$  量化后,基站端子阵列  $s$  收到的量化输出信号可以表示为:

$$\mathbf{r}_p^{(s)} = Q(\mathbf{y}_p^{(s)}) = \frac{1}{\sqrt{2}} \operatorname{sign}(\mathcal{R}(\mathbf{y}_p^{(s)})) + \frac{i}{\sqrt{2}} \operatorname{sign}(\mathcal{I}(\mathbf{y}_p^{(s)})) \quad (4)$$

其中,  $\mathcal{R}(\mathbf{y}_p^{(s)})$  和  $\mathcal{I}(\mathbf{y}_p^{(s)})$  分别表示  $\mathbf{y}_p^{(s)}$  的实部和虚部。由于本文处理的是时域样本, 而且子阵列信道系数服从复高斯分布, 因此  $\mathbf{y}_p^{(s)}$  可以近似为复高斯分布。根据 Bussang 分解原理知, 高斯信号的任意非线性函数都可以用原高斯信号表示<sup>[11]</sup>。具体来说, 量化失真为:

$$\mathbf{d}_p^{(s)} = \mathbf{r}_p^{(s)} - A\mathbf{y}_p^{(s)} \quad (5)$$

等价为:

$$\mathbf{r}_p^{(s)} = A\mathbf{y}_p^{(s)} + \mathbf{d}_p^{(s)} \quad (6)$$

通过设计矩阵  $A$  使得  $\mathbf{d}_p^{(s)}$  和  $\mathbf{y}_p^{(s)}$  不相关, 从而减小量化噪声, 满足:

$$E[\mathbf{d}_p^{(s)} \mathbf{y}_p^{(s)H}] = E[\mathbf{d}_p^{(s)}] E[\mathbf{y}_p^{(s)H}] \quad (7)$$

由于式(1)的期望值  $E[\mathbf{y}_p^{(s)}] = 0$ , 同样地, 可以容易证明  $E[\mathbf{d}_p^{(s)} \mathbf{y}_p^{(s)H}] = 0$  和  $E[\mathbf{d}_p^{(s)} \mathbf{x}_p^{(s)H}] = 0$ 。存在以下引理:

引理 1: 子阵列  $s$  的信道矩阵  $\mathbf{H}^{(s)}$  可以由 1-比特量化观测信号  $\mathbf{r}_p^{(s)}$  和导频信号  $\mathbf{x}_p^{(s)}$  得到, 具体形式为:

$$E[\mathbf{r}_p^{(s)} \mathbf{x}_p^{(s)H}] = \sigma_{\text{pilots}}^2 \sqrt{\frac{2}{\pi(N\sigma_{(s)}^2 \sigma_{\text{pilots}}^2 + \sigma_n^2)}} \mathbf{H}^{(s)} \quad (8)$$

其中,  $\sigma_{\text{pilots}}^2 = E[\mathbf{x}_p^{(s)} \mathbf{x}_p^{(s)H}] / N$ 。

证明: 将  $E[\mathbf{r}_p^{(s)} \mathbf{x}_p^{(s)H}]$  展开, 带入  $E[\mathbf{d}_p^{(s)} \mathbf{x}_p^{(s)H}] = 0$  得:

$$E[\mathbf{r}_p^{(s)} \mathbf{x}_p^{(s)H}] = AE[\mathbf{y}_p^{(s)} \mathbf{x}_p^{(s)H}] + E[\mathbf{d}_p^{(s)} \mathbf{x}_p^{(s)H}] = \sigma_{\text{pilots}}^2 A \mathbf{H}^{(s)} \quad (9)$$

Bussang 定理指出, 如果对无记忆系统  $Q(\cdot)$  的输入是一个零均值高斯过程, 如  $\mathbf{y}_p^{(s)}$ , 则输入输出的互相关矩阵  $\mathbf{C}_{\mathbf{y}_p^{(s)} \mathbf{r}_p^{(s)}}$  与输入自相关矩阵  $\mathbf{C}_{\mathbf{y}_p^{(s)} \mathbf{y}_p^{(s)}}$  成比例, 即:

$$\mathbf{C}_{\mathbf{y}_p^{(s)} \mathbf{r}_p^{(s)}} = A \mathbf{C}_{\mathbf{y}_p^{(s)} \mathbf{y}_p^{(s)}} \quad (10)$$

其中,  $A$  是一个对角矩阵, 第  $k$  个对角元素为:

$$[A]_{k,k} = E[\mathbf{r}_{pk}^{(s)}] = 2E[\delta(\mathbf{y}_{pk}^{(s)})] \quad (11)$$

结合高斯概率分布函数得到<sup>[12]</sup>:

$$A = \sqrt{\frac{2}{\pi}} \left[ \operatorname{diag}(\mathbf{C}_{\mathbf{y}_p^{(s)} \mathbf{y}_p^{(s)}}) \right]^{-\frac{1}{2}} \quad (12)$$

利用式(1)计算  $\mathbf{C}_{\mathbf{y}_p^{(s)} \mathbf{y}_p^{(s)}}$  得:

$$\begin{aligned} \mathbf{C}_{\mathbf{y}_p^{(s)} \mathbf{y}_p^{(s)}} &= E[(\mathbf{H}^{(s)} \mathbf{x}_p^{(s)} + \mathbf{n}^{(s)})(\mathbf{H}^{(s)} \mathbf{x}_p^{(s)H} + \mathbf{n}^{(s)H})] \\ &= E[\mathbf{H}^{(s)} \mathbf{x}_p^{(s)} \mathbf{x}_p^{(s)H} \mathbf{H}^{(s)H}] + E[\mathbf{n}^{(s)} \mathbf{n}^{(s)H}] \\ &= \sigma_{\text{pilots}}^2 E[\mathbf{H}^{(s)} \mathbf{H}^{(s)H}] + \sigma_n^2 \mathbf{I}_N \end{aligned} \quad (13)$$

又因为  $E[\mathbf{H}^{(s)} \mathbf{H}^{(s)H}] = N\sigma_{(s)}^2 \mathbf{I}_N$ , 所以  $\mathbf{C}_{\mathbf{y}_p^{(s)} \mathbf{y}_p^{(s)}}$  可以表示为

$\mathbf{C}_{\mathbf{y}_p^{(s)} \mathbf{y}_p^{(s)}} = (N\sigma_{(s)}^2 \sigma_{\text{pilots}}^2 + \sigma_n^2) \mathbf{I}_N$ ,  $A$  简化后表达式为:

$$A = \sqrt{\frac{2}{\pi(N\sigma_{(s)}^2 \sigma_{\text{pilots}}^2 + \sigma_n^2)}} \mathbf{I}_N \quad (14)$$

将式(14)代入到式(9)即得证。

引理 1 为本文生成的一个监督表达式, 由引理 1 知道, 在已知瞬时子阵列信道、导频和噪声三者功率的情况下, 在每个信道相干时间间隔内发送大量导频, 可以很好地估计出 1-比特 ADC 超大规模 MIMO 的子阵列信道。

## 2 生成式监督学习模型

如果在每个信道相干时间内, 除了瞬时子阵列信道、导频和噪声三者功率外, 还有许多导频, 则可以很好地估计出信道。但是导频的数量过大, 不但会导致导频资源匮乏, 而且会带来额外的计算复杂度。所以应尽量减少导频的数量来控制带宽和功率。另外, 知道瞬时子阵列信道功率也不切实际。因此, 基于 DNN 监督学习的思想, 本文根据引理 1 构造了一个生成式的监督学习模型, 其目的在于充分利用 DNN 泛化能力, 以少量的导频得到较好的信道估计性能。

利用 DNN 估计子阵列信道可以看作为一个回归任务, 所提出的 DNN 网络结构利用特殊标签  $\operatorname{vec}(\mathbf{r}_p^{(s)} \mathbf{x}_p^{(s)H})$  来进行训练, 该标签是由  $\mathbf{r}_p^{(s)} \mathbf{x}_p^{(s)H}$  按行堆叠起来的  $NK \times 1$  维向量数据。DNN 网络结构如图 2 所示, 由输入层、5 个隐藏层、2 个 shortcut 连接和输出层构成。神经网络的输入为导频信号  $\mathbf{x}_p^{(s)}$ , 对应的输出为  $\mathbf{z}_p^{(s)}$ ,  $p = 1, \dots, N_t, N_t$  为一个相干时间间隔内通过子阵列信道传输的导频总数。神经网络的输出可以写成可训练权值  $\mathbf{W}$  和激活函数  $\sigma(\cdot)$  的形式:

$$\begin{aligned} \mathbf{z}_p^{(s)} &= \sigma_6(\mathbf{W}_6 \sigma_5(\mathbf{W}_5 \sigma_4(\mathbf{W}_4 \sigma_3(\mathbf{W}_3 \sigma_2(\mathbf{W}_2 \sigma_1(\mathbf{W}_1 \mathbf{x}_p^{(s)}) + \mathbf{x}_p^{(s)})))) \\ &\quad + \sigma_3(\mathbf{W}_3 \sigma_2(\mathbf{W}_2 \sigma_1(\mathbf{W}_1 \mathbf{x}_p^{(s)}) + \mathbf{x}_p^{(s)}))) \end{aligned} \quad (15)$$

所有参数均根据下列的代价函数进行优化:

$$J = \min_{\mathbf{W}_1, \dots, \mathbf{W}_6} \left\| \mathbf{z}_p^{(s)} - \operatorname{vec}(\mathbf{r}_p^{(s)} \mathbf{x}_p^{(s)H}) \right\|^2 \quad (16)$$

本文所提的生成式监督 DNN 的各层神经元数量分别为  $2K, 4K, 2K, 4K, 2K, 2NK$ , 中间隐藏层使用 Leaky ReLU 作为加快收敛的激活函数, 并在每一层之间增加了批处理规范化(Batch-Normalization, BN), 使网络中的数据前馈更加有效。由于这个过程是一个回归任务, 因此输出层使用 linear 激活函数, 两层之间的权值由矩阵指定。由于现有的软件库实现的神经网络并不支持复数的操作, 因此需要将复数形式导频的实部和虚部提取出来连接成一个  $2K \times 1$  维实数向量。同样地, 标签为  $2NK \times 1$  维。

训练神经网络, 使得式(16)中的输出  $\mathbf{z}_p^{(s)}$  和标签  $\operatorname{vec}(\mathbf{r}_p^{(s)} \mathbf{x}_p^{(s)H})$  之间的均方估计误差(Mean Square Error, MSE) 最小, 意味着神经网络输出的学习概率分布近似于  $\operatorname{vec}(\mathbf{r}_p^{(s)} \mathbf{x}_p^{(s)H})$  的概率分布。一旦模型训练完成, 将相干区间内生成的随机导频样本输入到训练好的模型中, 得到所需的输出样本, 并根据式(8)取其平均值来估计向量形

式的子阵列信道：

$$\hat{\mathbf{h}}^{(s)} = \text{vec}(\hat{\mathbf{H}}^{(s)}) = \frac{1}{M} \sum_{i=1}^M \mathbf{z}_i^{(s)} \quad (17)$$

其中,  $M$  为随机生成输出样本总数, 对  $M$  除了处理复杂度之外, 没有任何限制。

值得一提的是, 与传统的 DNN 结构相比, 本文增加了两个 shortcut 连接, 其目的是为了减少 DNN 中常出现的梯度消失或梯度爆炸问题<sup>[13]</sup>。理论研究发现, 神经元数量足够大的单个隐藏层可以提供与两个隐藏层相同的性能, 但是单个隐藏层带来的计算复杂度却大得多<sup>[14]</sup>。为了降低计算复杂度, 在每个 shortcut 连接中设置了两个隐藏层。该估计模型的总体计算复杂度由训练 DNN 模型和从训练的 DNN 中生成随机样本两部分组成。第一阶段训练神经网络产生的计算复杂度为  $O(N_t \Theta^2)$ , 其中  $\Theta = (36 + 4N)K^2$  为神经网络的总共的可训练参数, 平方项来自反向传播。shortcut 连接既不引入额外参数, 也不引入计算复杂度。第二阶段的复杂度相对较低, 来自于矩阵向量乘法。所以本文中生成式监督 DNN 的计算复杂度为  $O(N_t \Theta^2)$ 。

### 3 仿真结果和分析

为了验证本文所提的生成式监督 DNN 模型在 1-比特 ADC 超大规模 MIMO 系统中的信道估计性能, 本节进行了两组仿真实验。表 1 列出了相关仿真参数, 并且定义归一化均方误差 (Normalized Mean Square Error, NMSE) 来描述信道估计性能:

$$\text{NMSE} = E \left\{ \left| \left| \mathbf{h}^{(s)} - \hat{\mathbf{h}}^{(s)} \right| \right|_2^2 / \left| \left| \mathbf{h}^{(s)} \right| \right|_2^2 \right\} \quad (18)$$

基于表 1 所给参数构建子阵列信道模型, 然后用  $N_t = \{8, 15, 25\}$  3 种不同数量的导频来训练估计网络。在训练中, 采用梯度下降和自适应学习率, 通过反向传播算法寻找梯度因子, 借助 Adam 优化器获得初始学习率为 0.001 的自适应学习率。DNN 训练完成后, 随机生成  $M = 10000$  个样本并输入到训练好的 DNN 模型中, 对其 10000 个输出样本取平均值, 得到对应子阵列的信道估计。值得注意的是, 当导频数量足够大时,  $M$  的数量可以远小于 10000。

图 3 展示了由 3 个不同导频数训练得到的生成式监督 DNN 的估计 NMSE。从图中可以看出, 随着信噪比 (Signal to Noise Ratio, SNR) 增加, 决定模型效率的关键

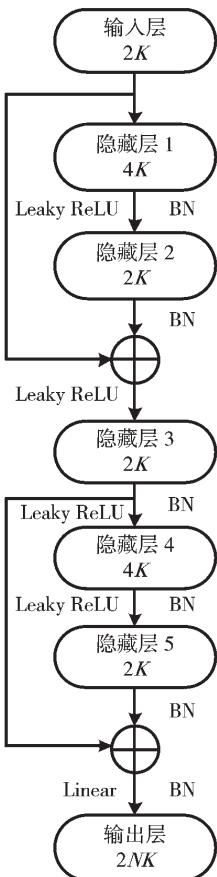


图 2 本文所提的生成式监督 DNN 模型结构

所以本文中生成式监督 DNN 的计算复杂度为  $O(N_t \Theta^2)$ 。

表 1 仿真参数列表

参数	值	参数	值
蜂窝范围 $r_{\max}/\text{m}$	30	衰减系数 $\Omega$	4
最短距离 $r_{\min}/\text{m}$	100	损耗指数 $V$	3
天线总数 $M$	100	载波频率/GHz	2.6
子阵列数 $S$	4	天线间隔/m	0.23061
子阵列天线数 $N$	25	天线阵列长度 $L/\text{m}$	23.0610
用户数 $K$	25	VR 中心 $c_k$	$U(0, L)$
信道相关性	$\mathbf{R}_k = \mathbf{I}_M$	VR 长度 $l_k$	$\text{LN}(0.1L, 0.1)$

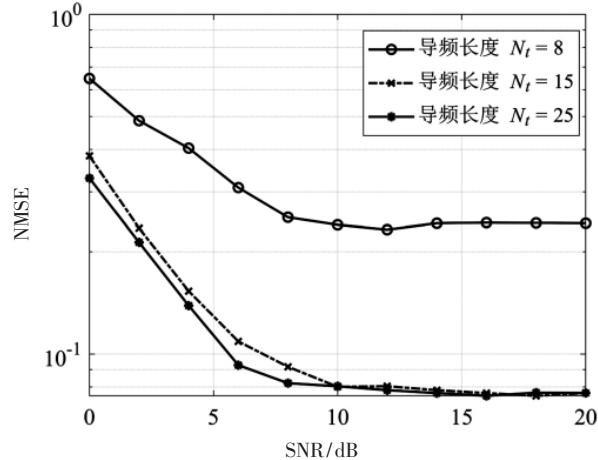


图 3 不同导频数量下生成式监督学习模型的 NMSE 性能对比

参数是导频数量, 当导频数量较少时, 信道估计的 NMSE 处于一个较高的状态, 随着导频数量从 8 增加到 15 后, 信道估计性能显著提升。进一步, 将导频数量增加到 25 后, 信道估计的性能没有产生太大影响。由此可以推断, 在超大规模 1-比特 ADC 系统中, 发送长度为 15 的导频是非常合理的, 能有效减少接收端的信道估计复杂度, 所以使用生成式监督 DNN 模型估计信道时, 可以用较少的导频数量得到较好的估计性能。

图 4 将导频数量固定  $N_t=15$ , 对比了不同信道估计模型与本文提出的生成式监督 DNN 模型的 NMSE 性

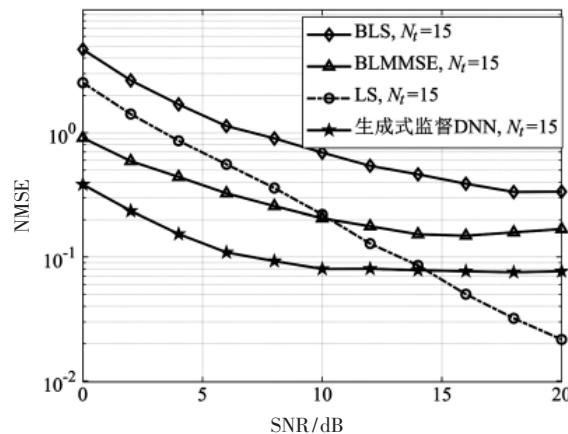


图 4 不同信道估计器与生成式监督 DNN 模型的 NMSE 性能对比

(下转第 96 页)

Biomolecular Chemistry, 2016, 14(5): 1623–1628.

- [14] WANG D , LI M. Stochastic configuration networks: fundamentals and algorithms[J]. IEEE Transactions on Cybernetics , 2017 , 47(10) : 3466–3479.
  - [15] HAN X M , DAI Q. Batch-normalized Mlpconv-wise supervised pre-training network in network[J]. Applied Intelligence , 2017 , 48(1) : 142–155.
  - [16] BUONGIORNO J , ZHOU M. Multicriteria forest decision making under risk with goal-programming Markov decision process models[J]. Forest Science , 2017 , 63(5) : 474–484.

(上接第 90 页)

能。其中 BLS 方法来自于文献[15], BLMMSE 方法来自文献[5]。从图 4 中可以看出, 在任何信噪比下, 生成式监督 DNN 模型的信道估计性能都优于 BLS 和 BLMMSE。此外, 本文还与未使用 1-比特 ADC 量化的最小二乘(Least Square, LS)估计进行了对比, 有趣的是, 所提的信道估计方案在 SNR 低于 14 dB 时, 性能始终优于未量化的 LS 估计。

4 结论

采用 1-比特 ADC 替代高分辨率 ADC 可以大幅度降低接收机成本和功耗,但使用传统方法,超大规模 MIMO 系统基站接收机在信道估计方面会造成严重的性能损失。本文利用生成模型和多层神经网络,提出了一种用于信道估计的生成式监督 DNN 模型。仿真结果表明,本文所提出的模型可以利用较少数量的导频得到较好的信道估计性能,即使存在 1-比特量化的非线性损害,仍然可以实现可靠的信道估计。

## 参考文献

- [1] WANG H , KOSASIH A , WEN C , et al. Expectation propagation detector for extra-large scale massive MIMO[J]. IEEE Transactions on Wireless Communications , 2020 , 19(3) : 2036–2051.
  - [2] CARVALHO E D , ALI A , AMIRI A , et al. Non-Stationarities in extra-large-scale massive MIMO[J]. IEEE Wireless Communications , 2020 , 27(4) : 74–80.
  - [3] ALI A , CARVALHO E D , HEATH R W . Linear receivers in non-stationary massive MIMO channels with visibility regions[J]. IEEE Wireless Communications Letters , 2019 , 8(3) : 885–888.
  - [4] RODRIGUES V C , AMIRI A , ABRAO T , et al. Low-complexity distributed XL-MIMO for multiuser detection[C]. 2020 IEEE International Conference on Communications Workshops (ICCWorkshops) , 2020 : 1–6.
  - [5] LI Y , TAO C , SECO-GRANADOS G , et al. Channel estimation and performance analysis of one-bit massive MIMO systems[J]. IEEE Transactions on Signal Processing , 2017 , 65(15) : 4075–4089.
  - [6] NEUMANN D , WIESE T , UTSCHICK W . Learning the MMSE

(收稿日期:2020-03-24)

---

## 作者简介：

万涛(1976-),男,硕士,高级工程师,主要研究方向:人工智能、移动互联网、网络空间安全。

吴立刚(1980-),通信作者,男,本科,工程师,主要研究方向:大数据、人工智能视频图像处理和分析,E-mail:leikowu@126.com。

范叶平(1979-),男,本科,工程师,主要研究方向:人工智能、移动互联网、网络安全空间安全。



扫码下载电子文档

channel estimator[J].IEEE Transactions on Signal Processing, 2018, 66(11): 2905–2917.

- [7] SOLTANI M ,POURAHMADI V ,MIRZAEI A ,et al. Deep learning-based channel estimation[J].IEEE Communications Letters , 2019 , 23(4) : 652-655.
  - [8] ZHANG Y ,ALRABEIAH M ,ALKHATEEB A. Deep learning for massive MIMO with 1-bit ADCs : when more antennas need fewer pilots[J].IEEE Wireless Communications Letters , 2020 , 9(8) : 1273-1277.
  - [9] BALEVI E ,ANDREWS J G. One-bit OFDM receivers via deep learning[J].IEEE Transactions on Communications , 2019 , 67(6) : 4326-4336.
  - [10] HAN Y ,JIN S ,WEN C ,et al. Channel estimation for extremely large-scale massive MIMO systems[J].IEEE Wireless Communications Letters , 2020 , 9(5) : 633-637.
  - [11] BUSSGANG J J. Crosscorrelation functions of amplitude-distorted Gaussian signals[Z].MIT Research Laboratory Technical Report , 1952.
  - [12] PAPOULIS A ,PILLAI S U. Probability , random variables , and stochastic processes[M].Tata McGraw-Hill Education , 2002.
  - [13] HE K ,ZHANG X ,REN S ,et al. Deep residual learning for image recognition[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition(CVPR) , 2016 : 770-778.
  - [14] GOODFELLOW I ,BENGIO Y ,COURVILLE A ,et al. Deep learning[M].MIT Press , Cambridge , 2016.
  - [15] RISI C ,PERSSON D ,LARSSON E G. Massive MIMO with 1-bit ADC[J].arXiv preprint arXiv : 1404.7736 , 2014.

(收稿日期:2021-01-28)

---

## 作者简介

蒲旭敏(1983-),通信作者,男,博士,讲师,主要研究方向:B5G/6G移动通信理论与关键技术、机器学习在移动通信中的应用,E-mail:puxm@cqupt.edu.cn。

吴超(1993-),男,硕士,主要研究方向:基于深度学习的大规模MIMO系统信道估计。

杨小珑(1997-),男,硕士,主要研究方向:大规模MIMO系统的信号检测。



扫码下载电子文档

## 版权声明

经作者授权，本论文版权和信息网络传播权归属于《电子技术应用》杂志，凡未经本刊书面同意任何机构、组织和个人不得擅自复印、汇编、翻译和进行信息网络传播。未经本刊书面同意，禁止一切互联网论文资源平台非法上传、收录本论文。

截至目前，本论文已经授权被中国期刊全文数据库（CNKI）、万方数据知识服务平台、中文科技期刊数据库（维普网）、DOAJ、美国《乌利希期刊指南》、JST 日本科技技术振兴机构数据库等数据库全文收录。

对于违反上述禁止行为并违法使用本论文的机构、组织和个人，本刊将采取一切必要法律行动来维护正当权益。

特此声明！

《电子技术应用》编辑部

中国电子信息产业集团有限公司第六研究所