基于深度学习的模式可重构大规模 MIMO 信道外推

Mu Liang、Ang Li

arXiv:2303.04432v3 [eess.SP] 6 Apr 2023

摘要——可动态改变工作状态的可重构天线，相较于传统天线具有出色的适应性和灵活性；由多功能可重构天线（MRAs）组成的 MIMO 阵列，则被视为迈向未来全息 MIMO 的一种前景方案。具体而言，在模式可重构 MIMO（PR-MIMO）通信系统中，准确获取所有辐射模式的信道状态信息（CSI）是一项艰巨的任务，因为在 PR-MIMO系统中采用传统的基于导频的信道估计技术会产生巨大的导频开销。在本文中，我们利用深度学习方法设计了一种模式可重构神经网络，该网络可以利用一种辐射模式下估计出的信道状态信息，推断出其他辐射模式下的信道状态信息。为减少导频开销，我们专门针对 PR-MIMO系统提出了一种新的信道估计方法：将 PR-MIMO 的发射天线分组，不同组中的天线采用不同的辐射模式。与传统的全连接实值深度神经网络（DNN）相比，采用复值系数的模式可重构神经网络能够直接在复数域中运行。实验结果表明，与基准方案相比，所提出的信道外推方法在外推精度方面具有显著优势。

索引词——深度学习、模式可重构天线、信道外推、神经网络。

I 引言

MULTIFUNCTIONAL 与可重构天线（MRAs）能够调整其工作状态，例如频率、极化方式和辐射方向图，相较于传统阵列具有这一优势，因此被视为 6G 的有前景候选方案 [1]。研究表明 [2] ，使用 MRAs 能够提升 MIMO 通信系统的频谱效率，因为 MRAs 增加了额外的自由度，并能改变天线阵列的电流分布及由此产生的电磁场。MRAs 的现有实现方案包括半导体开关、液态金属、微机电系统（MEMS）开关、超表面等 [3]。

MIMO系统的性能高度依赖发射机与接收机之间的链路质量，而链路质量由出发角、到达角、路径增益以及天线增益和方向性等与阵列相关的系数决定。这些参数取决于无线环境的物理特性以及天线阵列的辐射模式。与辐射模式固定的传统阵列相比，采用可重构多模天线的通信系统能够通过动态改变辐射模式来提升性能。在[4], 中，研究表明，采用可重构多模天线的MIMO系统性能会随着可重构模式数量的增加而提升但可重构模式数量较多时，性能增益会变得不那么显著。

模式可重构 MIMO（PR-MIMO）通信系统中的一个重要问题是，如何在数据传输过程中选择有前景的辐射模式。迄今为止，文献中的大多数解决方案都基于多臂老虎机或汤普森采样理论 [5]–[7]。例如， [6], 将 PR 模式选择问题建模为多臂老虎机问题，通过在线学习过程选择最佳辐射方向图，而无需获取所有辐射模式的瞬时信道状态信息（CSI）。 [7], 基于多臂老虎机理论提出了一种带信道预测的汤普森采样算法（TS-CP）。TS-CP 利用信道相关性来预测尚未探索的辐射模式的信道条件。

上述模式选择方法需要PR-MIMO系统的完整/部分信道状态信息，而PR-MIMO系统的信道获取是一项颇具挑战的任务。这是因为，改变单个天线的辐射模式会改变阵列的辐射模式；如果发射机希望通过传统信道估计方法获取所有辐射模式的信道信息，就需要大量导频开销。针对上述问题，现有解决方案包括 [8] ，该方法通过传统的基于导频的信道估计，仅选择部分可重构模式，而忽略其他可重构模式，导致可重构性增益下降。此外，Bahceci等人 [9] 提出了一种基于格拉姆–施密特的分解算法，利用不同可重构模式之间的相关性来预测信道状态信息，从而减少导频开销。 [9] 提出的算法需要准确获知信道统计信息，但这无法实现，且其导频开销至少是传统 MIMO 系统的两倍。综上所述，上述方法无法充分发挥PR-MIMO系统的性能优势，也无法获得令人满意的外推性能。另一方面，近年来，基于深度学习的方法已被广泛研究，用于MIMO信道估计以减少信令开销 [10]–[13]。在 [10],中，作者使用卷积神经网络压缩CSI反馈，从而大幅减少所需的反馈信息量。在 [11], 中，作者提出了一种稀疏神经网络（SCNet），利用FDD大规模MIMO系统中的上行链路信道状态信息外推下行链路信道状态信息。在 [12], 中，作者使用卷积神经网络外推TDD MIMO系统中的信道状态信息。在 [13], 中，作者提出了一种用于

大规模MIMO系统信道校准的全连接深度神经网络（DNN），其信道估计性能优于传统方法。据我们所知，基于深度学习的方法尚未在PR-MIMO中得到充分应用。

本文提出一种新的信道估计方法，将天线单元划分为多个组，使不同组中的天线在信道估计期间采用不同的辐射模式，并利用基于深度学习的解决方案，解决PR-MIMO 系统信道估计过程中的信令开销问题。所提出的信道估计方法具有与传统 MIMO 系统相同的信令开销。我们不仅利用并证明了 PR-MIMO 系统中确定性估计到外推信道映射函数的存在性，还展示了如何训练神经网络以拟合该信道映射函数。在此基础上，我们提出了 PR-Net，无需引入任何额外开销即可外推所有辐射模式的信道状态信息。数值结果表明，在导频开销较低时，复值 PR-Net 在信道外推任务中的性能优于实值 DNN；两者的性能均优于现有的 PR-MIMO 系统信道外推方法。

符号说明： α、 $\boldsymbol{\alpha}$、 $\boldsymbol{A}$ 分别表示标量、向量和矩阵。$vec(\cdot)$表示矩阵的向量形式， $\Re[\cdot]$和 $\Im[\cdot]$ 分别提取参数的实部和虚部。 $\|\cdot\|_2$ 表示欧几里得范数。$(\cdot)^H$ 表示共轭转置。 $\circ$ 表示复合映射运算。 $\mathbb{E}[\cdot]$ 表示期望。 $\rightarrow$ 表示映射运算。

II. 系统模型

我们考虑一个点对点 PR-MIMO（P2P-PR-MIMO）系统，其中发射机配备了由$M \gg 1$ 个可重构天线组成的可重构天线，接收机配备了 $N > 1$ 个传统全向天线。我们假设可重构模式的数量为 P，其中$P \ll M$ 适用于大规模MIMO场景。可重构天线中的每个天线都可以独立改变其可重构模式。为简便起见，收发两端均采用均匀线性阵列。我们采用如 [14],所示的多径信道模型，其中接收机与发射机之间 p号可重构模式下的信道 $\boldsymbol{H}^p \in \mathbb{C}^{N\times M}$ 可表示为:

$$\boldsymbol{H}^p = \frac{1}{\sqrt{MN}} \sum_{i=1}^{N_{cl}} \sum_{j=1}^{N_{ray}} \alpha_{i,j} \cdot \beta_{i,j}(\theta_{i,j}, \phi_{i,j}) \boldsymbol{\alpha}_r(\theta_{i,j}) \boldsymbol{\alpha}_t^H(\theta_{i,j}), \tag{1}$$

其中， N_{cl}、 N_{ray}、 $\alpha_{i,\ j}$、 $\theta_{i,\ j}$ 和 $\phi_{i,\ j}$ 分别表示簇的数量、每个簇中的射线数、复路径增益、第 i 个簇和第 j 条射线的方位出发角，以及第 i 个簇和第 j 条射线的俯仰出发角。$\beta_{i\ ,\ j}^p(\theta_{i,\ j}$、$\phi_{i,\ j})$ 是由 $\theta_{i,\ j}$ 和 $\phi_{i,\ j}$确定的可重构模式增益。此外，$\boldsymbol{\alpha}(\theta_{i,\ j})$ 是阵列导向矢量，定义如下:

$$\boldsymbol{\alpha}(\theta_{i,j}) = [1, e^{-j\chi \sin\theta_{i,j}}, \cdots, e^{-j\chi(M-1)\sin\theta_{i,j}}]^T, \tag{2}$$

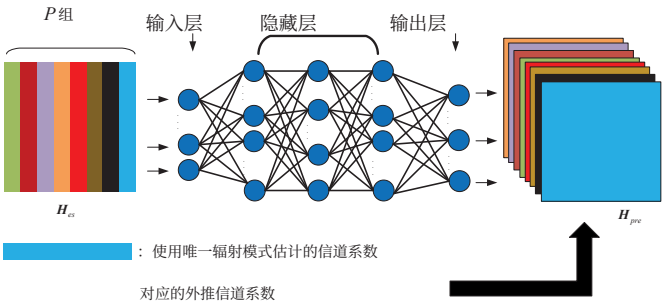


图 1 所提出的 PR-MIMO 信道估计与外推方法示意图

其中， $\chi = 2\pi df/c$、 d 表示天线间距， c 表示光速， f 表示载波频率。 θ 和 ϕ 分别服从 $[0, 2\pi]$ 和 $[0, \pi]$上的均匀离散分布。

III. 信道估计与映射公式

本节介绍针对 PR-MIMO系统提出的信道获取方法。首先，我们介绍一种适用于 PR-MIMO系统且导频开销较低的新型信道估计方案，并以此为基础，按照 [12] 构建信道映射函数。最后，我们使用深度学习来寻找用于信道外推的信道映射函数。

A. PR-MIMO 的信道估计

首先，我们将发射机的所有天线划分为 P组，每组包含 $\lfloor M/P \rfloor$ 根天线。同一组中的天线在信道估计期间采用相同的辐射模式，如图 1 所示。具体而言，如果$mod(M, P) \neq 0$，则最后一组包含 $mod(M, P)$ 个天线单元。随后，发射机发送一组导频信号来估计信道，因此导频开销与传统 MIMO 系统相同。接收信号可表示为:

$$\boldsymbol{Y} = \boldsymbol{H}\boldsymbol{X} + \boldsymbol{W}, \tag{3}$$

其中， $\boldsymbol{Y} \in \mathbb{C}^{N\times M}$ 为接收信号矩阵。我们将导频序列的长度定义为与发射天线的数量相等， $\boldsymbol{X} \in \mathbb{C}^{M\times M}$为满足 $\mathbb{E}\left[\boldsymbol{X}\boldsymbol{X}^H\right] = \boldsymbol{I}_M$ 的导频矩阵， $\boldsymbol{W} \in \mathbb{C}^{N\times M}$表示噪声矩阵，其元素服从均值为零、方差为 σ^2 的复高斯分布。我们将 $\boldsymbol{H}_{es} \in \mathbb{C}^{N\times M}$ 定义为估计信道矩阵，并使用线性最小均方误差（LMMSE）估计器，可得 $\boldsymbol{H}_{es}$：

$$\boldsymbol{H}_{es} = \boldsymbol{Y}(\boldsymbol{X}^H\boldsymbol{R}_H\boldsymbol{X} + \sigma^2 N\boldsymbol{I}_M)^{-1}\boldsymbol{X}^H\boldsymbol{R}_H, \tag{4}$$

其中 $\boldsymbol{R}_H = \mathbb{E}\left[\boldsymbol{H}^H\boldsymbol{H}\right] \in \mathbb{C}^{M\times M}$。为便于后续推导，我们进一步引入 $\boldsymbol{h}_{es} = vec(\boldsymbol{H}_{es}) \in \mathbb{C}^{MN\times 1}$ ，作为 $\boldsymbol{H}_{es}$的向量形式； $\boldsymbol{H}_{all} \in \mathbb{C}^{N\times M\times P}$ 表示所有可重构模式对应的汇集信道状态信息； $\boldsymbol{h}_{all} = vec\ \boldsymbol{H}_{all} \in \mathbb{C}^{M*N*P\times 1}$ $\boldsymbol{H}_{all}$ $\boldsymbol{H}_{pre} \in \mathbb{C}^{N\times M\times(P-1)}$ 表示 的向量形式； 表示需要外推的信道状态信息；$\boldsymbol{h}_{pre} = vec(\boldsymbol{H}_{pre}) \in \mathbb{C}^{N*M*(P-1)\times 1}$ 表示 $\boldsymbol{H}_{pre}$ 的向量形式。

B. PR-MIMO 信道映射函数的存在性

与传统 MIMO系统中信道状态信息仅取决于无线传播环境不同，PR-MIMO系统的信道状态信息既取决于无线传播环境，也取决于发射机/接收机处的辐射模式。因此，在接收机和发射机的位置已知的情况下，当天线阵列的辐射模式保持不变时，在一个信道相干时间间隔内，接收机与发射机之间应存在一个确定性的映射函数。为便于描述，我们将 $\boldsymbol{h}(p)$ 定义为 $\boldsymbol{H}^p$ 的向量形式。

定义1：信道向量 $\boldsymbol{h}(p)$ 与接收机位置之间第 p 个辐射模式的映射函数 $\boldsymbol{\Psi}$ 可描述如下：

$$\boldsymbol{\Psi}:(D,\theta,\phi,f)\rightarrow\boldsymbol{h}(p), \tag{5}$$

其中， D 是发射机与接收机之间的距离，(D,θ,ϕ,f) 和 $\boldsymbol{h}(p)$ 分别表示映射函数的定义域和陪域。

对于第 p 个辐射模式，可根据发射机天线的信道系数是经过估计还是外推，将其分为两组。我们分别将这两组定义为估计信道系数集 $\mathcal{M}_1$ 和外推信道系数集 $\mathcal{M}_2$。令 $h^{nm}{}_{,es}{}^{p}\in\mathcal{M}_1$ 表示从第 n 个接收机天线到第 m 个发射机天线的第 p 个辐射模式的估计信道系数；令 $h^{nl}{}_{,pre}{}^{p}\in\mathcal{M}_2$ 分别表示从第 n 个接收机天线到第 l 个发射机天线的第 p 个辐射模式的外推信道系数。由于这两组信道系数经历相同的无线传播环境，我们可以自然地得出结论：两组之间存在映射关系。基于此，我们定义可重构天线映射函数 $\boldsymbol{\Psi}_{\mathcal{M}}$。

定义2：可重构天线映射函数$\boldsymbol{\Psi}_{\mathcal{M}}$ 在 $\mathcal{M}_1$ 和 $\mathcal{M}_2$ 之间可描述为：

$$\boldsymbol{\Psi}_{\mathcal{M}}:\boldsymbol{h}_{es}(\mathcal{M}_1,p)\rightarrow\boldsymbol{h}_{pre}(\mathcal{M}_2,p),p=1,2,...,P, \tag{6}$$

接下来，我们采用以下假设。

假设1：位置到信道映射函数$\boldsymbol{\Psi}$：$(D,\theta,\phi,f)\rightarrow\boldsymbol{h}(p)$ 以及估计到外推信道映射函数 $\boldsymbol{\Psi}_{\mathcal{M}}$：$\boldsymbol{h}_{es}(\mathcal{M}_1,p)\rightarrow\boldsymbol{h}_{pre}(\mathcal{M}_2,p)$ $p=1,2,...,P$是双射。

假设 I 意味着，信道系数 $h^{nm}{}_{,es}{}^{p}$ 和 $h^{nl}{}_{,pre}{}^{p}$ 与发射机和接收机的位置之间存在唯一关系。尽管无法从解析上证明这一点，但在实际无线通信场景 [11] 中，$\boldsymbol{\Psi}$ 和 $\boldsymbol{\Psi}_{\mathcal{M}}$ 为双射的概率接近于 1。

结合位置到信道映射函数和估计到外推信道映射函数，我们得到 PR-MIMO 信道映射函数，如下方命题 I 所示：

命题1：根据假设I，PR-MIMO信道映射函数可表示为：

$$\boldsymbol{\Phi}=\boldsymbol{\Psi}\circ\boldsymbol{\Psi}_{\mathcal{M}}:\boldsymbol{h}_{es}(D,\theta,\phi,f,\mathcal{M}_1,p)\rightarrow\boldsymbol{h}_{pre}(D,\theta,\phi,f,\mathcal{M}_2,p), \tag{7}$$

where $\boldsymbol{\Psi}\circ\boldsymbol{\Psi}_{\mathcal{M}}$ represents the composite function.

证明：根据定义I和定义II，我们有函数 $\boldsymbol{\Psi}:(D,\theta,\phi,f)\rightarrow\boldsymbol{h}(p)$ 和 $\boldsymbol{\Psi}_{\mathcal{M}}:\boldsymbol{h}_{es}(\mathcal{M}_1,p)\rightarrow\boldsymbol{h}_{pre}(\mathcal{M}_2,p)$。同时，在假设I下，它们都是双射。因此，对于任意可能的信道参数 (D,θ,ϕ,f,p) 以及信道系数集合 $\mathcal{M}_1$, $\mathcal{M}_2$，复合映射 $\boldsymbol{\Psi}_f\circ\boldsymbol{\Psi}_{\mathcal{M}}$ 均存在。

C. 用于信道映射的深度学习

我们已在命题 I 中介绍了 PR-MIMO 系统的信道映射函数。然而，这种关系难以用传统的数学公式描述，因此我们采用基于深度学习的方法来构建这种关系。根据 [15],，定理 I 如下所示：

定理 1：对于任意给定的小误差 $\varepsilon>0$，总存在一个足够大的正常数 K，使得

$$\sup_{\boldsymbol{x}\in\boldsymbol{h}_{all}}\|NET_K(\boldsymbol{x},\boldsymbol{\Omega})-\boldsymbol{\Phi}\|\leq\varepsilon,\boldsymbol{h}_{all}=\boldsymbol{h}(D,\theta,\phi,f,\mathcal{M}), \tag{8}$$

其中， $NET_K(\boldsymbol{x},\Omega)$ 是一个多层前馈网络的输出，其输入数据为 $\boldsymbol{x}$，其中 Ω 和 K 分别表示网络参数和层数。

总而言之，PR-MIMO 系统完整信道状态信息的获取包括 3 个步骤：1）将天线划分为若干组，每组采用不同的辐射模式；2）使用传统信道估计方法获取 $\boldsymbol{H}_{es}$；3）使用复值 PR-Net 外推完整信道状态信息 $\boldsymbol{H}_{all}$，如算法 1 所示。在下文第 IV 节中，我们将详细介绍复值 PR-Net。

算法 1：PR-MIMO系统的信道估计与外推
PR-MIMO系统的

输入：导频矩阵 $\boldsymbol{X}$、学习率 γ、批大小 R，
辐射数 P、训练轮数 E
输出：完整信道状态信息 $\boldsymbol{H}_{all}$
随机初始化复数网络参数
$\boldsymbol{\Omega}$;
对于 $t=1,\ldots,E$ **do**
  使用 ADAM算法更新 Ω
  （学习率 γ），以最小化损失;
将发射天线划分为 P 组;
为每个天线组分配辐射方向图;
发送 $\boldsymbol{X}$ 并使用（4）得到 $\boldsymbol{H}_{es}$；
将 $\boldsymbol{H}_{es}$ 重塑为 $\boldsymbol{h}_{es}$;
根据（9）得到 $\boldsymbol{h}_{pre}$；
将 $\boldsymbol{h}_{pre}$ 和 $\boldsymbol{h}_{es}$ 重塑为 $\boldsymbol{H}_{all}$。

IV. 用于信道外推的 PR-Net

本节首先介绍复数值 PR-Net，随后讨论其在 PR-MIMO系统中的训练和部署，以基于所提出的信道估计方法获取所有信道状态信息。

A. PR-Net 架构

如图 1 所示，PR-Net 在复数定义域中运行，这意味着输入 $\boldsymbol{h}_{es}$ 和输出 $\boldsymbol{h}_{pre}$ 都可以直接纳入网络。具体而言，$\boldsymbol{h}_{pre}$ 包含所有辐射模式的全部信道系数。每个隐藏层中的神经元数量保持不变。 $\boldsymbol{h}_{es}$的一系列级联非线性变换可表示为：

$$\boldsymbol{h}_{pre}=\boldsymbol{f}^{(K-1)}(\cdots\boldsymbol{f}^{(1)}(\boldsymbol{h}_{es}(D,\theta,\mathcal{M}_1,f,p))), \tag{9}$$

其中， $\boldsymbol{f}$ 是该层的非线性变换函数，可表示为：

$$\boldsymbol{f}^{(k)}(\boldsymbol{x})=\begin{cases}\boldsymbol{g}\left(\boldsymbol{W}^{(k)}\boldsymbol{x}+\boldsymbol{b}^{(k)}\right),1\le k<K-1\\ \boldsymbol{W}^{(k)}\boldsymbol{x}+\boldsymbol{b}^{(k)},k=K-1\end{cases} \tag{10}$$

其中， $\boldsymbol{g}$ 是激活函数，定义如下：

$$\boldsymbol{g}(\boldsymbol{z})=max\left\{\Re\left[\boldsymbol{z}\right],\boldsymbol{0}\right\}+j\cdot max\left\{\Im\left[\boldsymbol{z}\right],\boldsymbol{0}\right\}, \tag{11}$$

其中，记号 $\Re[\cdot]$ 和 $\Im[\cdot]$ 分别表示向量的实部和虚部。

文献 [15], 证明，三层网络可以近似任意函数，而我们提出的 PR-Net 包含三层以上，以提高精度。与实值 DNN 网络相比，复值 PR-Net 具有更高的适应性，更适合学习复值函数。同时，所提出的 PR-Net 减少了隐藏层中的神经元数量，从而降低复杂度。因此，PR-Net 不仅能减少网络参数的数量，还能提供更高的外推精度。

B. 训练与部署

部署 PR-Net 以外推可重构模式信道分为两个阶段：离线训练和在线外推。在离线训练阶段，我们将发射天线分为 P 组，分别对应不同的辐射模式，并采用传统的信道估计方法获取估计信道矩阵。发射机将这些估计信道矩阵收集为训练样本，用于训练 PR-Net。在外推阶段，PR-Net 的参数保持固定。我们对 PR-Net 的输出进行重塑，以获得所有辐射模式对应的信道矩阵。我们将网络的含噪输出定义为 $\boldsymbol{h}_{pre}$。PR-Net 经过训练，以最小化 $\boldsymbol{h}_{pre}$ 与无噪声监督标签 $\boldsymbol{h}_{pre}$ 之间的差异。损失函数定义如下：

$$\text{Loss}=\frac{1}{RL_h}\sum_{r=0}^{R-1}\left\|\hat{\boldsymbol{h}}_{pre}-\boldsymbol{h}_{pre}\right\|_2^2, \tag{12}$$

其中， R 为批大小，上标(r)表示第 r个训练样本的索引，L_h 为向量$\boldsymbol{h}_{pre}$的长度。采用自适应矩估计（ADAM）算法最小化损失函数，直至 PR-Net 收敛。

V. 仿真结果

本节对所提出的 PR-MIMO 信道估计与外推方法进行数值验证。除非另有说明，系统参数设置如下：发射机配备 $M=64$个可重构多模天线；每根天线具有 $P=8$ 种可重构天线模式；接收机配备 $N=8$ 根传统全向天线；工作频率为 $f=2.5$ GHz；簇数和射线数分别为 $N_{cl}=10$ 和 $N_{ray}=20$；每条路径的路径增益$\alpha_{i,\ j}$ 服从标准复高斯分布。

为展示深度学习神经网络的有效性，我们将信道外推精度与 [9] 中提出的算法（记为“Duman”）进行比较。该算法需要多次发送导频矩阵，因此开销更大。我们还将实值 DNN 作为基准，该网络最初是为 MIMO系统的上行/下行信道校准而设计的。在所有仿真中，我们使用 Tensorflow 2.1 作为 PR-Net 的深度学习框架，并将隐藏层中的神经元数量设为 (512, 512, 512)。ADAM算法的初始学习率为 0.001，批大小为 32。PR-Net 第 k 层的参数初始化为均值为零、方差为

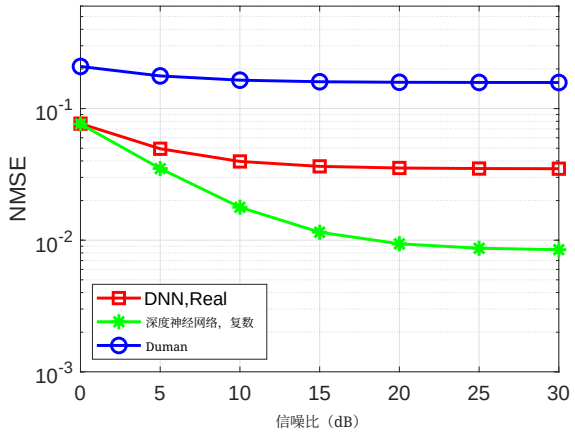


图 2 归一化均方误差与信噪比的关系， $M=64$, $N=8$, $P=8$

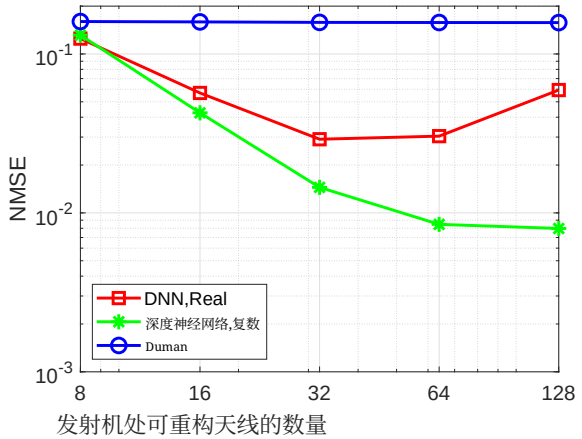


图 3 归一化均方误差与 M 的关系，信噪比=30 dB， $N=8$, $P=8$

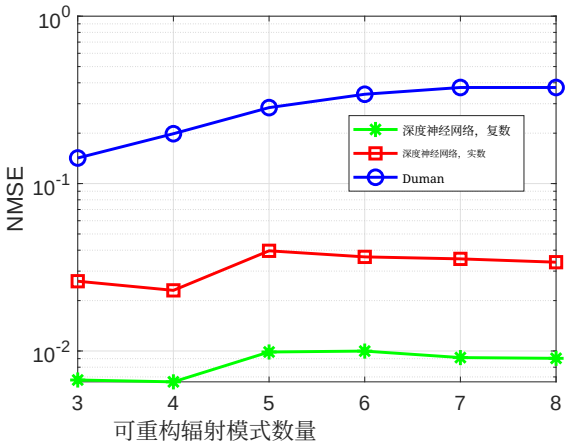


图 4 P、 $M = 64$、=30 dB 信噪比下的归一化均方误差， $N = 8$

$1/n_k$，其中 n_k 表示第 k 层的神经元数量。在训练阶段，当信噪比（SNR）为 25 dB 时，我们使用线性最小均方误差算法估计输入 PR-Net 的信道状态信息。训练样本数量为 10240，训练轮次为 500。仿真采用 0.4 的测试集比例，并使用归一化均方误差（NMSE）衡量信道外推精度，其定义如下：

$$\mathrm{NMSE} = \mathbb{E}\left[\left\|\boldsymbol{h}_{Pre} - \hat{\boldsymbol{h}}_{pre}\right\|_2^2 / \left\|\boldsymbol{h}_{pre}\right\|_2^2\right]. \qquad (13)$$

图 2 展示了 PR-Net、DNN 和 Duman 算法的平均归一化均方误差表现。结果表明，在信道外推精度方面，深度学习方法优于 Duman 算法。此外，复值 PR-Net 的表现优于实值 DNN，这表明复值 PR-Net 能够更好地拟合复函数。随着信噪比的提高，归一化均方误差曲线逐渐下降；在高信噪比区域，曲线斜率逐渐趋于平缓。

图 3 展示了在信噪比固定为 30 dB 时，发射机处可重构多模天线数量与归一化均方误差性能之间的关系。结果表明，随着天线数量增加，采用复值 PR-Net 进行信道外推的精度会提高；而当天线数量过多时，实值 DNN 的性能则会下降。这种现象的一个可能原因是，天线数量越多，可用于外推信道矩阵的辐射模式信息就越多。然而，随着天线数量增加，输出的维度也会随之增加。由于实值 DNN 拟合信道映射函数的性能较差，所得曲线相对平缓，且当天线数量过多时，性能甚至会下降。与此同时，Duman 算法基本不受发射机处天线数量的影响。

图 4 展示了在信噪比固定为 30 dB、发射机天线数量固定为 64 时，归一化均方误差性能与每根天线的辐射模式数量之间的关系。随着辐射模式数量增加，Duman 算法的性能会下降。相比之下，PR-Net 的性能优于深度神经网络，且这两种模型生成的曲线都近似为直线，仅有轻微波动。这一现象可能是因为每种辐射模式对应的归一化均方误差并不完全相同，导致所有辐射模式的平均误差出现波动。

VI. 结论

我们提出了一种适用于 PR-MIMO 系统的新型信道估计与外推方法，其所需导频开销与传统 MIMO 系统相同。该方法将发射天线划分为多个组，每组采用不同的辐射模式进行信道估计。随后，我们研究了 PR-MIMO 系统的信道映射函数，并采用复值 PR-Net 外推所有辐射模式的信道系数。仿真结果表明，在外推精度和复杂度方面，PR-Net 优于现有 DNN；此外，与非学习算法相比，深度学习方法在 PR-MIMO 系统中可显著降低归一化均方误差。

参考文献

[1] J. Rodriguez，《5G移动网络基础》。《5G移动网络基础》，2015年。[2] D. Piazza、N. J. Kirsch、A. Forenza、R. W. Heath 和 K. R. Dandekar，“面向MIMO系统的可重构天线阵列设计与评估”，IEEE天线与传播汇刊，第56卷，第3期，第869–881页，2008年。[3] K. Carver 和 J. Mink，“微带天线技术”，IEEE天线与传播汇刊，第29卷，第1期，第2–24页，2003年。[4] B. He 和 H. Jafarkhani，“面向毫米波通信的低复杂度可重构MIMO”，IEEE通信汇刊，2018年。[5] S. Agrawal 和 N. Goyal，“多臂老虎机问题中汤普森采样的分析”，机器学习研究杂志，第23卷，第4期，第357–364页，2011年。[6] N. Gulati 和 K. R. Dandekar，“ 可重构天线的状态选择学习：一种多臂老虎机方法 ”，IEEE天线与传播汇刊，第62卷，第3期，第1027–1038页，2014年。[7] T. Zhao、M. Li 和 Y. Pan，“利用信道相关性的基于在线学习的可重构天线模式选择”，IEEE无线通信汇刊，第PP卷，第99期，第1–1页，2021年。[8] H. Eslami、C. P. Sukumar、D. Rodrigo、S. Mopidevi、A. M. Eltawil、L. Jofre 和 B. A. Cetiner，“针对具备波束倾斜能力的多种可重构天线的低开销训练”，IEEE无线通信汇刊，第9卷，第12期，第3810–3821页，2010年。[9] I. Bahceci、M. Hasan、T. M. Duman 和 B. A. Cetiner，“可重构MIMO天线的高效信道估计：训练技术与性能分析”，IEEE无线通信汇刊，第16卷，第1期，第565–580页，2017年。[10] C. K. Wen、W. T. Shih 和 S. Jin，“大规模MIMO信道状态信息反馈的深度学习”，IEEE，第5期，2018年。[11] Y. Yang、F. Gao、G. Y. Li 和 M. Jian，“面向FDD大规模MIMO系统的基于深度学习的下行链路信道预测”，IEEE通信快报，第23卷，第11期，第1994–1998页，2019年。[12] M. Alrabeiah 和 A. Alkhateeb，“面向TDD和FDD大规模MIMO的深度学习：空间与频率上的信道映射”，载于2019年第53届Asilomar信号、系统与计算会议，.[13] C. Huang、G. C. Alexandropoulos、A. Zappone、C. Yuen 和 M. Debbah，“面向通用大规模MIMO系统的上行/下行信道校准深度学习”，载于ICC 2019——2019年IEEE国际通信会议（ICC），2019年。[14] Zhihong、Hong、Ke、Liu、Heath、W. R.、Jr.、Sayeed 和 M. A.，“相关衰落下基于虚拟信道表示的空间复用”，《IEEE通信选题期刊》，2003年。[15] K. Hornik、M. B. Stinchcombe 和 H. White，“多层前馈网络是通用逼近器”，《神经网络》，1989年。