

基于信道映射的 RCF-mmMIMO 系统波束赋形算法

朱泽邦¹ 许 鹏¹ 尹 航¹
ZHU Zebang XU Peng YIN Hang

摘 要

针对现有基于信道状态信息 (channel state information, CSI) 的波束赋形方法中, 导频开销大、训练成本高且不适宜实际应用需要的问题, 文章提出一种基于信道映射的智能超表面 (reconfigurable intelligent surface, RIS) 辅助毫米波无蜂窝大规模多输入多输出 (cell-free massive MIMO, CF-mmMIMO) 系统 (RCF-mmMIMO) 的波束赋形网络方案。该算法采用遍历最优波束向量选择子网络, 计算出级联信道最适合的波束向量, 并且为后续网络学习提供基础数据集, 再利用波束赋形训练子网络负责对于生成的数据集进行训练, 预测信道最优波束。仿真实验结果表明, 这一算法能有效改善现有基于 CSI 和基于波束训练的波束赋形方案会产生大量的训练开销和能量损耗的问题, 显著提升整个无线通信系统的性能和效率。

关键词

智能超表面; 波束赋形; 信道状态信息; 遍历算法; 多输入多输出; 信道映射

doi: 10.3969/j.issn.1672-9528.2024.12.017

0 引言

随着移动通信需求的不断增长, 通信系统的发展已经逐渐转向大规模多输入多输出技术 (multiple-input multiple-output, MIMO) 和毫米波通信。智能超表面 (reconfigurable intelligent surface, RIS) 因其可智能调控无线信道的特性也备受关注。为了充分挖掘与利用 RIS 辅助毫米波 MIMO 通信系统的潜力与优势, 需要获取精确的信道状态信息 (channel state information, CSI), 并设计高效的波束赋形方案。针对 RIS 辅助毫米波无蜂窝大规模 MIMO (RIS assisted cell-free millimeter-wave massive MIMO, RCF-mmMIMO) 系统中 RIS 波束赋形离线信道估计会导致硬件成本和能量损耗过大, 而在线波束训练则由于 RIS 信道的分段性质会引发过多的训练开销的问题, 本文提出了一种基于信道映射的 RIS 被动波束赋形算法。

当前, RIS 辅助通信系统中的波束赋形技术主要有两种, 分别是基于 CSI 的波束赋形和依赖波束训练的波束赋形。

在基于 CSI 的 RIS 波束赋形中, 系统首先需要准确获取包括了 RIS 与用户之间、RIS 与基站之间等多个信道的信息。利用这些信道状态信息, RIS 能够计算出最优的反射系数配置, 以便在用户位置构建更强的信号质量。文献 [1] 和文献 [2] 采用交替优化技术对 RIS 波束赋形进行优化, 但由于所有基

站 CSI 都需要发送至 CPU 集中处理从而产生了较大的信息传递开销。此外, 有学者也引入了深度学习 (deep learning, DL) 算法来改善基于 CSI 的波束赋形算法。文献 [3] 采用了一种不需要标签的无监督学习方法, 利用最小化深度神经网络 (deep neural network, DNN) 的损失函数得到使得接收机可达速率最大的最优 RIS 反射系数。基于 CSI 的方法通常能达到较高的通信效率, 但其对精度的要求会导致显著的系统开销, 而利用深度学习算法来进行基于 CSI 的 RIS 波束赋形则需要有精度较高的 CSI 基础, 同时也会造成大量的训练开销。

基于波束训练的 RIS 波束赋形最基础的方案是在不同的时隙中, 向不同方向发射高指向性波束, 并在遍历所有波束后选择能够使接收信噪比最大的波束对作为该时隙的最优波束对^[4-6]。然而, 这种训练方法的时间过长, 无法满足当下通信系统快速接入要求。

综上所述, 为改善现有基于 CSI 和基于波束训练的波束赋形方案存在的对环境依赖性强、训练开销较大、信道估计误差较大的缺陷, 在文献 [7] 所提出的信道估计算法基础上, 本文提出了一种基于信道映射的 RIS 波束赋形算法。首先, 该算法通过信道映射获取信道 CSI; 其次, 通过遍历算法选择出使得可达速率最大的最优波束向量优化系统, 形成数据集; 最后, 通过深度学习的方式创新性地建立 RIS 信道信息与最大可达速率的映射关系, 训练出能够根据环境特征精准预测最优波束赋形策略的模型。

1. 沈阳航空航天大学电子信息工程学院 辽宁沈阳 110000

[基金项目] 沈阳航空航天大学创新创业训练计划 (Z202410143030)

1 系统模型

如图1展示了RIS辅助无蜂窝的系统模型,在该模型中,无线接入点(accesspoint, AP)通过RIS与多个用户进行通信。




图1 RIS辅助无蜂窝MIMO系统

RIS无蜂窝MIMO系统和信道模型,在第 k 个用户的上的接收信号表示为:

$$\begin{aligned} y_k &= \mathbf{h}_{RU,j}^T \Psi_k \mathbf{h}_{AR,j} \bar{S}_{k,j} + n_{k,j} \\ &\stackrel{(a)}{=} (\mathbf{h}_{RU,j} \odot \mathbf{h}_{AR,j}) \Psi_{k,j} \bar{S}_{k,j} + n_{k,j} \end{aligned} \quad (1)$$

式中: (a) 由交互矩阵 $\Psi_{k,j}$ 的对角结构得出, $\Psi_{k,j} = \text{diag}(\Psi_{k,j})$; $\bar{S}_{k,j}$ 代表第 k 个用户在第 j 个子载波上发出的信号,从而构建出一个新的向量 $\Psi_{k,j} \in \mathbb{C}^{M \times 1}$ 。该对角结构由RIS被动反射形成,对于RIS上的每个元素 m , $m \in \{1, 2, \dots, M\}$ 在与相互作用因子相乘之后会反射入射信号。而对这些相互作用向量有两点需要强调。首先,虽然相互作用因子可以具有不同的幅度,但是本文假设其仅使用移相器来实现RIS元件;其次,由于移相器的实现是在模拟域中使用RF电路完成的,因此所有的子载波上的信号会采用相同的相移,即 $\Psi_j = \Psi$ 。考虑到这些实际因素,假设每个相互作用因子都只是一个移相器,即 $[\Psi]_m = e^{j\phi_m}$ 。在这种情况下,本文将相互作用矢量称为反射波束赋形矢量。

本文采用宽带几何信道模型用于AP/UE与RIS之间的信道 $\mathbf{h}_{RU,j}$ 、 $\mathbf{h}_{AR,j}$ 。具体来说,对于由 L 个发射路径组成的从AP到RIS上的信道 $\mathbf{h}_{AR}$,该路径参数有:时延为 $\tau_l \in \mathbb{R}$,到达方位角为 $\phi_l \in [0, 2\pi)$,到达仰角 $\theta_l \in [0, \pi)$,路径损耗 ρ^T ,复系数 $\alpha_l \in \mathbb{C}$ 。 $p(\tau)$ 表示在 τ 秒时的 T_s 间隔信令的脉冲整形函数。令RIS在到达角为 ϕ_l 、 θ_l 时的阵列响应向量定义为 $\mathbf{a}(\phi_l, \theta_l) \in \mathbb{C}^{M \times 1}$ 。则发射机和RIS之间的延迟信道向量可以用公式表示为:

$$\mathbf{h}_{T,d} = \sqrt{\frac{M}{\rho T}} \sum_{l=1}^L \alpha_l p(dT_s - \tau_l) \mathbf{a}(\phi_l, \theta_l) \quad (2)$$

在给定该延迟信道后,在子载波 j 处的信道向量 $\mathbf{h}_{AR}$ 在频域中可以定义为:

$$\mathbf{h}_{AR} = \sum_{d=0}^{D-1} \mathbf{h}_{T,d} e^{-j\frac{2\pi k}{K}d} \quad (3)$$

式中: D 是抽头长度。可以类似定义RIS到UE的信道 $\mathbf{h}_{RU}$,假设信道向量 $\{\mathbf{h}_{RU}\}_{j=1}^J$ 和 $\{\mathbf{h}_{AR}\}_{j=1}^J$ 在一个相干时间 T_c 的周期内是恒定的,这取决于环境的动态和用户移动性。其中,信道路径的数量 L 高度依赖于操作频带和传播环境。

2 算法设计

针对现有研究中波束赋形算法训练开销大、训练成本高且不宜实际应用需要的问题,本文对RCF-mmMIMO系统中RIS波束赋形算法进行了重新设计,完成了RIS被动反射波束向量的优化问题。文中所提出的基于信道映射的波束赋形网络总体结构如图2所示。首先,运用信道映射方案对信道进行初始估计;其次,以三维坐标形式生成波束码本,通过遍历计算选择码本中使得可达速率最大的反射向量,并形成相应的数据集;最后,将数据集投入全连接神经网络(fully connected neural network, FCNN)进行模型训练,预测信道最优波束以及最大可达速率。




图2 基于信道映射的波束赋形网络

本文所提出的基于信道映射的波束赋形网络主要分为遍历最优波束向量选择子网络和波束赋形训练子网络。

2.1 遍历波束选择子网络设计

本文基于文献[8]中所提的信道映射方案进行RIS级联信道获取,利用训练完成的网络模型映射CSI可以大大减少导频开销以及训练开销。为波束训练奠定了良好基础。假设将RIS级联的信道向量定义为:

$$\bar{\mathbf{h}} = \mathbf{v}([\bar{\mathbf{h}}_1, \bar{\mathbf{h}}_2, \dots, \bar{\mathbf{h}}_J]) \quad (4)$$

式中: $\mathbf{h}_j = \mathbf{h}_{RU,j} \otimes \mathbf{h}_{AR,j}$ 。此外,令 $\bar{\mathbf{h}}(s)$ 表示第 s 个相干干块的级联采样信道向量 $s=1, 2, \dots, S$, S 表示数据集数据样本的总数。

具体的最优波束选择算法如图3所示。首先,使用离散化波束方向的方法,通过计算每个波束方向上的波束权重,以生成用于射频波束赋形的波束码本。具体而言,它将空间角度范围分为离散的角度点,并根据每个角度点计算相应的波束权重,最终将这些波束权重组合成三维空间中的波束码本。对于经过映射所得到的CSI与波束码本中的向量通过穷

举搜索, 遍历反射码本 P 中的所有反射码字。对于每个候选的波束形成向量 Ψ_n ($n=1, 2, \dots, |P|$), RIS 都会测量通过该波束赋形向量所能获得的通信速率 $R_n(s)$, 其中 $R_n(s)$ 的计算公式为:

$$R_n(s) = \frac{1}{J} \sum_{j=1}^J \log_2 \left(1 + \text{SNR} \left| (\mathbf{h}_{\text{RU}} \otimes \mathbf{h}_{\text{AR}})^T \Psi_n \right|^2 \right) \quad (5)$$

式中: 对于每一个 $\bar{\mathbf{h}}(s)$, 将经过遍历最优波束算法后得到的信道向量和对应的速率向量组成的新的数据加入到深度学习数据集 D 中, 形式为 $D \leftarrow \{\bar{\mathbf{h}}(s), \mathbf{r}(s)\}$, 其中, $\bar{\mathbf{h}}(s)$ 表示信道向量; $\mathbf{r}(s)$ 表示对应的速率向量。由此构建基于 DL 的波束赋形网络数据集。在完成数据集采样后, 根据得到的速率向量 $\mathbf{r}(s)$, 即可以得到最高通信速率的反射波束形成向量进行, 即选择 $\mathbf{n}^* = \arg \max_n [\mathbf{r}(s)]_n$ 。




图3 遍历最优波束选择

2.2 波束赋形训练子网络设计

本文所提出的波束赋形训练子网络主要分为两个阶段, 即学习阶段和预测阶段。在学习阶段, RIS 采用穷举遍历搜索的方式得到反射波束赋形向量, 并建立深度学习模型的数据集, 在建立数据集后, 就会训练深度学习模型。

在学习阶段中的深度学习模型训练之后, RIS 利用经训练的模型直接从估计的信道向量来预测反射波束赋形向量。首先, 根据信道映射模型估计和构造 RIS 级联信道向量; 其次, 将估计的信道向量被传输到训练的深度学习模型中得到预测可实现的速率矢量, 该矢量用于识别最佳的基于 DL 的反射波束赋形矢量; 最后, 对应于最高预测可实现速率的预测深度学习反射波束赋形向量 $\mathbf{n}^* = \arg \max_n [\mathbf{r}(s)]_n$ 用于反射来自发送器的发送数据以用于相干块的其余部分。

对于 RIS 的波束赋形环境复杂的问题, 本文采用最具普适性的 FCNN 网络来解决对于 RIS 级联信道中被动波束向量的优化问题。

(1) 数据处理

神经网络模型的单个输入被定义为在 J 个子载波频率处的信道信息, 即信道向量 $\mathbf{h}$ 。这样设定了每个输入向量的维度为 $J \times M$ 。这里采用的归一化保留了信道信息中的距离信息, 是本文提出的机器学习调动 RIS 的基础。归一化技术在此处是按数据集进行简单的缩放; 所有样本都在整个输入数据上用一个常数值进行归一化, 得到:

$$\hat{\mathbf{h}}_{\text{norm}}(s) = \frac{\hat{\mathbf{h}}(s)}{\max \left\| \hat{\mathbf{h}}(s) \right\|}, s=1, \dots, S \quad (6)$$

(2) 模型训练

为了达到掌握如何将信道特征映射至码本中潜在的反射波束赋形向量, 并预测这些向量相应的可实现通信速率的目标, 首先需要构造一组实值向量 $\mathbf{r}(s)$ ($s=1, 2, \dots, S$), 其中包含了每个潜在反射向量的目标速率。为了保证训练的效率, 常规操作是对标签数据进行归一化。在本文中, 选择对每个样本进行等比例缩放, 即利用每个速率向量 $\mathbf{r}(s)$ 的最大速率值 $\max_n [\mathbf{r}(s)]_n$ 作为缩放基准。这样处理后, 归一化的数据表示为 $\hat{\mathbf{r}}(s)$, 从而确保了模型不会因某些较大的数值响应而产生偏向。

为了实现预测那些具有最高可实现速率估计的最佳反射波束赋形向量这一目标, 本文通过采用回归损失函数来指导模型的训练过程。即在每个相干块处训练神经网络使其预测输出与期望的输出相匹配, 令其预测的速率尽可能逼近归一化后的实际可实现速率 $\mathbf{r}$ 。训练过程中通过最小化一个特定的损失函数 $L(\theta)$ 来实施这一目标, $L(\theta)$ 表示为:

$$L(\theta) = \text{MSE}(\bar{\mathbf{r}}, \hat{\mathbf{r}}) \quad (7)$$

式中: θ 表示所有神经网络参数的集合; $\text{MSE}(\bar{\mathbf{r}}, \hat{\mathbf{r}})$ 表示 $\bar{\mathbf{r}}$ 和 $\hat{\mathbf{r}}$ 之间的均方误差。

3 仿真结果与分析

在本节中, 通过仿真评估了基于信道映射的反射波束赋形方法的性能。首先, 描述了所采用的实验装置和数据集和仿真参数。然后, 研究了不同参数对深度学习解决方案性能的影响。最后, 比较了经过本文所提出的基于信道映射的波束赋形方案与基于 RIS 随机波束赋形算法以及基于最大化信道增益波束赋形算法的算法性能。

3.1 仿真参数设置

本文考虑由 DeepMIMO 数据集提供的室外分布式大规模 MIMO 场景 “O1”^[9], 如图 4。该场景基于精确的 3D 射线跟踪模拟器 Wireless InSite^[10], 且该场景由两条街道和一个十字路口组成的室外场景, 其中包括 18 个基站和一百多万候选用户。在采用毫米波 28 GHz 设置下, 对于仿真的相关参数设置,




图7 不同波束赋形算法的可达速率随AP发射功率变化曲线

图8给出了基于信道映射的波束赋形算法和其他对比算法的可达速率在不同RIS反射单元数量下的性能比较。本次实验AP发射功率为40 dBm。从图8中可以看出,基于信道映射的波束赋形方案可达速率随着RIS反射单元数 N 的增加而得到提高。然而,最大化信道增益设计RIS算法和随机设计RIS算法随着RIS单元数的增大却又较小的性能增益。这种现象的原因是由于仅仅最大化信道增益的设计算法没有充分考虑到信号在不同反射路径上的相干叠加效应。而完全随机的设计不能保证反射信号的相位对数据传输是有利的。相比之下,基于信道映射的波束赋形方案考虑到了RIS信道的整体结构和特性,因此能够随着反射单元数的增加而有效地增强信号增益,从而实现更大的性能提升。简而言之,传统的算法没有利用好每个反射单元对信道增益的贡献度,没有实现信号的有效相位控制。综上,基于信道映射的波束赋形算法的性能优于其他两种算法。




图8 不同波束赋形算法的可达速率随RIS反射单元数变化曲线

4 结论

为解决现有基于CSI波束赋形算法中由于RIS信道分段性所带来的巨大开销的问题,本文提出了一种基于信道映射的波束赋形算法。该算法充分利用了信道映射和深度学习对信道的拟合能力,以更低的导频开销与训练开销得到了CSI,为波束赋形提供可靠广泛的数据集。并利用FCNN网络拟合了CSI与最优波束向量下的可达速率之间的映射关系,能够实现更高效而精准的波束赋形,并极大提升用户可达速率。

参考文献:

- [1] LE Q N, NGUYEN V D, DOBRE O A, et al. Energy efficiency maximization in RIS-aided cell-free network with limited backhaul[J]. IEEE communications letters, 2021, 25(6): 1974-1978.
- [2] ZHANG Z J, DAI L L. A joint precoding framework for wideband reconfigurable intelligent surface-aided cell-free network[J]. IEEE transactions on signal processing, 2021(69): 4085-4101.
- [3] GAO J B, ZHONG C J, CHEN X M, et al. Unsupervised learning for passive beamforming[J]. IEEE communications letters, 2020, 24(5):1052-1056.
- [4] HUANG C W, YANG Z H, XIONG K, et al. Multi-hop ris-empowered terahertz communications: a deep-based hybrid beamforming design[J]. IEEE journal on selected areas in communications, 2021, 39(6):1663-1677.
- [5] ALKHATEEB A, AYACH O E, LEUS G, et al. Channel estimation and hybrid precoding for millimeter wave cellular systems[J]. IEEE journal of selected topics in signal processing, 2014, 8(5):831-846.
- [6] ZHANG R M, ZHANG H, XU W, et al. A codebook based simultaneous beam training for mmwave multiuser MIMO systems with split structures[C/OL].// 2018 IEEE Global Communications Conference (GLOBECOM). Piscataway: IEEE, 2018[2024-07-12]. <https://ieeexplore.ieee.org/document/8648139>.
- [7] 尹航, 许鹏, 陈佳美, 等. 基于深度学习的RCF-mmMIMO系统信道估计算法[J]. 软件, 2024, 45(2):135-139.
- [8] TAHA A, ALRABEIAH M, ALKHATEEB A. Enabling large intelligent surfaces with compressive sensing and deep learning[J]. IEEE access. 2021, 9: 44304-44321.
- [9] ALKHATEEB A. DeepMIMO: a generic deep learning dataset for millimeter wave and massive MIMO applications[DB/OL]. (2019-05-18)[2024-08-12]. <https://doi.org/10.48550/arXiv.1902.06435>.
- [10] REMCOM. Wireless InSite® 3D wireless propagation software[EB/OL]. [2024-06-24]. <http://www.remcom.com/wireless-insite>.

【作者简介】

朱泽邦(2002—), 男, 河南汝州人, 本科, 研究方向: 移动通信。

许鹏(1981—), 男, 辽宁沈阳人, 博士, 副教授, 研究方向: 移动通信。

尹航(1998—), 女, 河南商丘人, 硕士研究生, 研究方向: 移动通信。

(收稿日期: 2024-09-04)