



计算机科学

COMPUTER SCIENCE

基于深度学习智能反射面辅助通信系统的联合波束成形

陈晓, 张权昊, 施建锋, 朱建月

引用本文

陈晓, 张权昊, 施建锋, 朱建月. 基于深度学习智能反射面辅助通信系统的联合波束成形[J]. 计算机科学, 2024, 51(11A): 231200125-5.

CHEN Xiao, ZHANG Quanhao, SHI Jianfeng, ZHU Jianyue. Deep Learning Based Joint Beamforming in Intelligent Reflecting Surface Enhanced Wireless Communication Systems [J]. Computer Science, 2024, 51(11A): 231200125-5.

相似文章推荐 (请使用火狐或 IE 浏览器查看文章)

Similar articles recommended (Please use Firefox or IE to view the article)

基于多模态融合的动态恶意软件检测方法

Multimodal Fusion Based Dynamic Malware Detection

计算机科学, 2024, 51(11A): 240200098-7. <https://doi.org/10.11896/jsjcx.240200098>

基于开放集的入侵检测方法研究

Study on Open Set Based Intrusion Detection Method

计算机科学, 2024, 51(11A): 231000033-6. <https://doi.org/10.11896/jsjcx.231000033>

基于CNN结合BiGRU的恶意流量分类算法研究

Study on Malicious Traffic Classification Algorithm Based on CNN Combined with BiGRU

计算机科学, 2024, 51(11A): 231100106-9. <https://doi.org/10.11896/jsjcx.231100106>

基于因果关系的领域泛化长尾学习

Domain Generalization and Long-tailed Learning Based on Causal Relationships

计算机科学, 2024, 51(11A): 240300041-8. <https://doi.org/10.11896/jsjcx.240300041>

基于改进超像素采样的立体匹配网络

Stereo Matching Network Based on Enhanced Superpixel Sampling

计算机科学, 2024, 51(11A): 231100005-7. <https://doi.org/10.11896/jsjcx.231100005>

基于深度学习智能反射面辅助通信系统的联合波束成形

陈晓^{1,4} 张权淏² 施建锋^{3,4} 朱建月^{3,4}

¹ 南京信息工程大学人工智能学院(未来技术学院) 南京 210044

² 南京信息工程大学计算机学院 南京 210044

³ 南京信息工程大学电子与信息工程学院 南京 210044

⁴ 东南大学移动通信国家重点实验室 南京 210096

(x.chen@nuist.edu.cn)

摘要 智能反射面(Intelligent Reflecting Surface, IRS)技术被认为是下一代无线通信中颇具潜力的技术之一。现有的 IRS 辅助多输入多输出(Multiple Input Multiple Output, MIMO)系统的波束成形设计对天线的计算能力要求很高,仍然是一个极具挑战的难题。为了克服这一难题,提出了一种用于 IRS 辅助多用户 MIMO 系统的基于深度学习的联合波束成形设计方案,以实现系统多用户和数据传输速率的最大化。该方案利用深度学习卷积神经网络学习和优化了基站端数字波束成形,同时设计出最优 IRS 端反射波束成形。所提方案克服了神经网络直接预测波束成形矩阵的困难,仅预测从波束成形矩阵中提取的关键特征,对神经网络预测能力的需求大大降低,并将线下训练及优化的结果用于线上,显著降低了实时计算复杂度。仿真结果显示,提出的最优波束成形能获得超过 0.5~1 bit/s/Hz 的系统和速率性能提升,且该优势会随着用户数增多而增大。

关键词: 智能反射面;深度学习;波束成形;和速率

中图分类号 TN929.5

Deep Learning Based Joint Beamforming in Intelligent Reflecting Surface Enhanced Wireless Communication Systems

CHEN Xiao^{1,4}, ZHANG Quanhao², SHI Jianfeng^{3,4} and ZHU Jianyue^{3,4}

¹ School of Artificial Intelligence/School of Future Technology, Nanjing University of Information Science and Technology, Nanjing 210044, China

² School of Computer Science, Nanjing University of Information Science and Technology, Nanjing 210044, China

³ School of Electronic and Information Engineering, Nanjing University of Information Science and Technology, Nanjing 210044, China

⁴ National Mobile Communications Research Laboratory, Southeast University, Nanjing 210096, China

Abstract Intelligent reflecting surface(IRS), as one of the most potential technologies in the next-generation wireless communication, plays a significant role. However, the existing IRS-assisted multiple-input multiple-output(MIMO) systems face a challenging problem that the beamforming methods require high computational capabilities of the antennas. To address this challenge, a deep learning(DL)-based joint beamforming design has been proposed for IRS-aided multi-user MIMO communication systems aiming to maximize the sum data rate of all users. The proposed DL-based beamforming scheme utilizes convolutional neural network to jointly optimize digital beamforming at base station and reflection beamforming at IRS. The proposed DL-based beamforming method forecasts the essential features extracted from the beamforming matrix, which overcomes the challenge of direct prediction of beamforming matrix by neural network. This method significantly reduces the demand on the predictive capability of the neural network, and the trained and optimized beamforming designs are using online that can significantly reduce the real-time computational complexity. Simulation results demonstrate that the proposed beamforming design can achieve over 0.5~1 bit/s/Hz data rate improvement, which will be enhanced with the growth of user number.

Keywords Intelligent reflecting surface, Deep learning, Joint beamforming, Sum rate

1 引言

第六代(The 6th Generation, 6G)通信的兴起,旨在应对未来通信领域对新性能指标的不断追求。这些指标包括提高

数据速率,拓宽通信覆盖范围,实现智能通信等^[1-2]。多输入多输出(Multiple Input Multiple Output, MIMO)技术的提出有望解决移动终端数量和数据流量呈指数增长所带来的问题。然而,高昂的硬件成本和能耗是大规模 MIMO 系统中的

基金项目:国家自然科学基金(62101273,62201274);江苏省自然科学基金项目(BK20210641, BK20220439)

This work was supported by the National Natural Science Foundation of China(62101273,62201274) and Natural Science Foundation of Jiangsu Province(BK20210641, BK20220439).

通信作者:施建锋(jianfeng.shi@nuist.edu.cn)

主要挑战,未来需要能源高效技术来解决这些问题。对此,文献[3-4]提出了智能反射面(Intelligent Reflecting Surface, IRS)作为6G无线通信领域的一项创新技术。具体来说,IRS是由大规模低成本的无源反射元件构成的平面表面;每个无源元件都可以独立地反射接收到的信号并调节元件的相位,从而产生可重新配置振幅和相位的反射信号,最终通过联合调节所有元件增强所需信号或抑制干扰信号。此外,IRS已经成为提高覆盖范围、频谱和能量效率的潜在技术。在IRS辅助的系统中,为了充分发挥该体系结构的优势,需要采用多种高效能技术,包括联合主动和被动波束成形、资源分配以及节能设计等。需要注意的是,上述所有设计都依赖于基站与IRS以及IRS与用户设备之间的完美信道状态信息。

在具备完美信道信息条件下,考虑IRS辅助通信系统中的联合波束成形设计,即基站端发射波束成形和IRS端反射波束成形的联合设计问题,该问题为复杂的非凸优化设计问题。文献[5]考虑IRS辅助多用户多输入单输出(Multiple Input Single Output, MISO)系统,基于交替优化的高效算法使发射和反射波束成形向量以交替的方式进行优化。文献[6]提出了一种用于IRS辅助的单用户通信系统的自适应选择波束成形方案,广泛使用了半定松弛和交替优化方法。此外,文献[7-9]提出了使用正交匹配追踪、流形优化等的混合波束成形方法来优化组合传输问题的方案。这些基于严格数学模型的传统算法虽然可以获得令人满意的性能,但由于计算复杂度导致严重延时,无法满足实时应用的要求。

根据深度学习技术的最新进展,深度学习算法可以实时学习最优波束成形,同时考虑性能和计算延时两个因素。这是因为深度学习技术离线训练神经网络,然后部署经过训练的神经网络进行在线优化。计算复杂度从在线优化转移到离线训练,并且当使用训练的神经网络来寻找最优波束成形解时,只需要简单的线性和非线性运算,从而大大降低了计算复杂度和延时。Lin等[10]采用深度学习网络进行信道估计,有效地提高了接收端的效率以及信道估计的准确性。Gao等[11]将无监督学习用于波束成形设计,获得了性能优异的结果。文献[12]利用深度学习提出了一种基于中断概率的传输波束成形方法,以应对基站处的信道不确定性。文献[13]使用了深度学习模型,直接从分布式基站接收的信号中预测波束成形矩阵,但受到了量化码本约束的限制,对系统的总速率性能产生了影响。这些研究都证明了深度学习在降低复杂性方面的优势。但是,现有工作主要研究了基于深度学习的单用户MIMO系统的波束成形设计以及IRS辅助下毫米波MISO系统的快速波束成形设计方法,缺乏基于深度学习的IRS辅助多用户MIMO联合波束成形的研究。

本文的主要贡献如下:

1)提出了一种基于深度学习IRS辅助多用户MIMO系统的联合波束成形方案,在以系统和速率最大化为目标的基础上,对IRS反射波束成形和基站端数字波束成形进行学习 and 优化,设计出最优IRS端反射波束成形。

2)采用卷积神经网络(Convolutional Neural Network, CNN)的架构,使复杂信道系数的实部和虚部之间共享参数,克服了神经网络直接预测波束成形矩阵的困难,仅预测从波束成形矩阵中提取的关键特征。仿真结果显示,该方案能获得较好的鲁棒性以及系统和速率性能。

2 系统模型和问题设计

2.1 系统模型

本文考虑IRS辅助的多用户MIMO下行通信系统,系统模型如图1所示,其中基站具备 M 根天线,IRS具备 N 个可重构反射元件,它们共同服务于 K 个单天线用户。由于动态无线通信环境中存在不可预测的衰减和各种潜在障碍物,假设基站和多用户之间不存在理想的直达路径,从而忽略基站和多用户间的直接传输信道[4]。IRS是一种无源反射装置,它配备了一个控制器和若干移相器。控制器用于切换IRS的工作模式,以实现接收模式和反射模式之间的切换;移相器用于将传输信号反射到终端时控制相移。由于IRS装置的无源性,我们考虑了时分双工场景,并假设下行和上行传输存在信道互易性。




图1 IRS辅助多用户MIMO系统模型

Fig. 1 IRS-aided multi-user MIMO system

首先,基站通过数字波束成形传输信号。在基站处,传输的信号可写成:

$$x = \sum_{k=1}^K w_k s_k \quad (1)$$

其中, $s_k \sim \mathcal{C}\mathcal{N}(0,1)$ 是对第 k 个用户的发送信号, $w_k \in \mathbb{C}^{M \times 1}$ 是基站数字波束成形 $W = [w_1, \dots, w_K] \in \mathbb{C}^{M \times K}$ 的第 k 列。

因此,在图1中,级联发射信道由基站-IRS信道 $G \in \mathbb{C}^{N \times M}$ 和IRS-用户信道 $h_k^H \in \mathbb{C}^{1 \times N}$ 两部分组成,具体来说,可以视为IRS在一个物理点源接收或反射所有信号。另外, $\Theta = \text{diag}(e^{j\theta_1}, \dots, e^{j\theta_n}, \dots, e^{j\theta_N})$ 为IRS的反射矩阵, $\theta_n \in [0, 2\pi)$ 是反射元件的相位并且 $n=1, \dots, N$ 。因此,第 k 个用户接收到的信号可以写成:

$$y_k = h_k^H \Theta G \sum_{i=1}^K w_i s_i + n_k \quad (2)$$

其中, $n_k \sim \mathcal{C}\mathcal{N}(0, \sigma_k^2)$ 为第 k 个用户的加性高斯白噪声,由此得到第 k 个用户的信干噪比(Signal to Interference plus Noise Ratio, SINR)为:

$$\text{SINR}_k = \frac{|h_k^H \Theta G w_k|^2}{|h_k^H \Theta G \sum_{i \neq k} w_i|^2 + \sigma_k^2} \quad (3)$$

其中,分子 $|h_k^H \Theta G w_k|^2$ 为信号功率;分母中 $|h_k^H \Theta G \sum_{i \neq k} w_i|^2$ 项为其他用户干扰功率, σ_k^2 则为噪声功率。

2.2 问题设计

本文假设在基站处有完美的级联信道的信道状态信息,即基站-IRS信道 h_k^H 和IRS-用户信道 h_k^H 已知,并且信道是缓慢衰落的。

本文的主要目标是在功率约束的条件下最大化加权

速率,优化数字波束成形 \mathbf{W} 和反射矩阵 Θ 。那么,和速率最大化的优化问题可表示为:

$$P1: \max_{\mathbf{w}, \Theta} \sum_{k=1}^K \alpha_k \log_2(1 + \text{SINR}_k) \quad (4)$$

$$\text{s. t. } \sum_{k=1}^K \|\mathbf{w}_k\|^2 \leq P_{\max} \quad (5)$$

$$0 \leq \theta_n < 2\pi, \forall n \quad (6)$$

其中, α_k 是第 k 个用户的权重。式(5)中 P_{\max} 为基站的最大发射功率,因此发射端数字波束成形受限于此。由于数字波束成形和反射矩阵是耦合的,该优化问题为非凸问题,传统的优化方法无法得到最优解。

3 基于深度学习的波束成形框架

本章主要给出了联合波束成形的设计和基于深度学习的波束成形优化框架。

3.1 联合波束成形设计

首先,将式(2)中中级信道和反射矩阵的乘积进行如下重构:

$$\mathbf{h}_k^H \Theta \mathbf{G} = \mathbf{h}_k^H \begin{pmatrix} \mathbf{g}_1 & & \\ & \ddots & \\ & & \mathbf{g}_N \end{pmatrix} \begin{pmatrix} \Theta_1 \\ \vdots \\ \Theta_N \end{pmatrix} \quad (7)$$

其中, $\mathbf{g}_n = (g_{n,1}, g_{n,2}, \dots, g_{n,M}) \in \mathbb{C}^{1 \times M}$ 为基站-IRS 信道矩阵 \mathbf{G} 的第 n 行, $\Theta_n = \text{dia}(e^{j\theta_n}, \dots, e^{j\theta_n}, \dots, e^{j\theta_n}) \in \mathbb{C}^{M \times M}$ 为对角线元素全部相同的对角阵。因此,可以得到基站-IRS-用户 k 的等效级联信道向量 $\mathbf{h}_{eq,k} \in \mathbb{C}^{1 \times NM}$ 为:

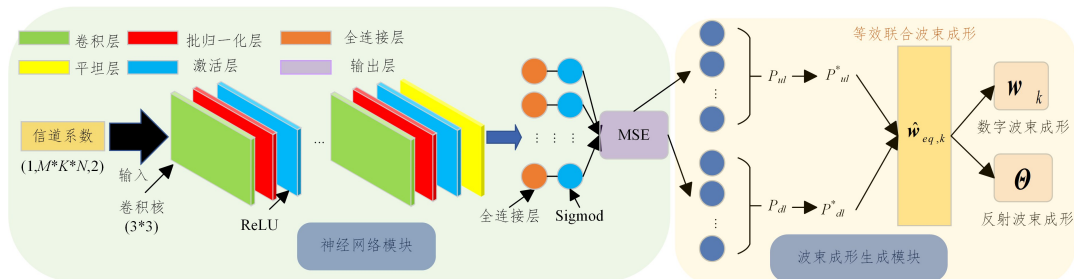


图2 基于深度学习的波束成形框架

Fig. 2 Deep-learning based beamforming framework

所提出的框架包括两个主要模块:神经网络模块和波束成形生成模块。神经网络模块由输入层、卷积层、批归一化层、激活层、平坦层、全连接层和输出层等组成,而波束成形生成模块将在后续进行介绍。以下先对神经网络模块所含层进行简要介绍。

1) 输入层和卷积层:将复杂的信道系数输入到神经网络来预测关键特征是很困难的,需要进行数据转换,将复数信道向量分解成同相分量和正交分量,分别包括了信道系数的实部和虚部,输入值需要是一组向量。每个卷积层创建一个或多个与输入层进行卷积的卷积核,并且卷积核的参数在不同的信道系数之间共享。

2) 批归一化层和激活层:将批归一化层放于激活层之前,批归一化层通过减去均值和除以标准差来对卷积层的输出进行归一化,有助于加速训练过程和提高模型稳定性。由于预测的变量是连续的正实数,因此激活层中不使用能生成负值的激活函数。

3) 平坦层和输出层:平坦层可将其输入的形状更改为正确的格式。输出层的主要功能是在神经网络完成训练后生成

$$\mathbf{h}_{eq,k} = \mathbf{h}_k^H \begin{pmatrix} \mathbf{g}_1 & & \\ & \ddots & \\ & & \mathbf{g}_N \end{pmatrix} \quad (8)$$

式(8)可以由已知的基站-IRS 信道矩阵 \mathbf{G} 和 IRS-用户信道 \mathbf{h}_k^H 得到。

其次,定义用户 k 的等效联合波束成形 $\mathbf{w}_{eq,k} \in \mathbb{C}^{NM \times 1}$ 为:

$$\mathbf{w}_{eq,k} = \begin{pmatrix} \Theta_1 \\ \vdots \\ \Theta_N \end{pmatrix} \mathbf{w}_k \quad (9)$$

因此,可将 P1 优化问题转化为寻找最优等效联合波束成形 $\mathbf{w}_{eq,k}$,再将联合波束成形去耦合,分别得到数字波束成形 \mathbf{w}_k 和反射矩阵 Θ 。

3.2 基于深度学习的波束成形优化框架

基于深度学习的神经网络最初旨在解决分类问题,然而它们在回归问题中同样取得了令人满意的性能。例如,深度神经网络(Deep Neural Network, DNN)已被用于预测传输功率^[14-15]。但由于信道和波束成形矩阵的复杂性,直接预测波束成形矩阵可能会导致不准确甚至欠拟合的结果。显然,我们可以通过增加神经网络的深度或宽度,以及引入更多的神经元,来提升学习能力。

本节提出了基于深度学习的波束成形优化框架,如图2所示。为了处理复杂数据,我们选择了 CNN 架构,因为 CNN 可以在复杂信道系数的实部和虚部之间共享参数,从而减少参数数量。

预测结果。

除了这些功能层以外,损失函数在模型中的作用也至关重要,损失函数与学习率共同指导神经网络的学习过程。由于输出值是连续的,因此使用平均绝对误差(Mean Absolute Error, MAE)或均方误差(Mean Square Error, MSE)作为度量。给定神经网络模块中第 k 个样本的预测结果为 $\hat{q}^{(k)}$,目标结果为 $q^{(k)}$ 时,MAE 和 MSE 定义为^[16]

$$\text{MAE} = \frac{1}{LK} \sum_{k=1}^K \|q^{(k)} - \hat{q}^{(k)}\|_1 \quad (10)$$

$$\text{MSE} = \frac{1}{LK} \sum_{k=1}^K \|q^{(k)} - \hat{q}^{(k)}\|_2^2 \quad (11)$$

其中, L 为 BatchSize 的大小, K 为样本数量。

波束成形生成模块如图2右部所示,其目的是从输出层的预测关键特征中生成波束成形矩阵。为了克服直接预测波束成形矩阵的困难,使用上下行链路对偶性和特定解结构等专业知识,仅预测从波束成形矩阵中提取的关键特征。与直接映射出波束成形矩阵相比,该方法可以显著减少待预测变量的数量^[17]。进一步来说,对神经网络预测能力的要求也

大大降低,包括神经元数目、网络层数以及复杂性等方面。

此模型输出层输出 $2K$ 个值,分别包括上行和下行功率分配向量 \mathbf{p}_{ul} 和 \mathbf{p}_{dl} ,通过以下方法进行归一化,确保每个样本中的信号满足发射功率约束。

$$\mathbf{p}_{ul}^* = \frac{P_{\max}}{\|\mathbf{p}_{ul}\|_1} \mathbf{p}_{ul}, \mathbf{p}_{dl}^* = \frac{P_{\max}}{\|\mathbf{p}_{dl}\|_1} \mathbf{p}_{dl} \quad (12)$$

因此,利用上行链路和下行链路的对偶性,可得最佳下行链路等效联合波束成形向量为:

$$\hat{\mathbf{w}}_{eq,k} = \sqrt{\rho_{ul,k}^*} \frac{\left(\mathbf{I}_N + \sum_{i=1}^K \frac{\rho_{dl,i}^*}{\sigma^2} \mathbf{h}_{eq,k} \mathbf{h}_{eq,k}^H \right)^{-1} \mathbf{h}_{eq,k}}{\left\| \left(\mathbf{I}_N + \sum_{i=1}^K \frac{\rho_{dl,i}^*}{\sigma^2} \mathbf{h}_{eq,k} \mathbf{h}_{eq,k}^H \right)^{-1} \mathbf{h}_{eq,k} \right\|_2}$$

3.3 数字波束成形与反射矩阵设计

根据式(9)可将等效联合波束成形向量展开为:

$$\mathbf{w}_{eq,k} = \begin{pmatrix} \Theta_1 \\ \vdots \\ \Theta_N \end{pmatrix} \mathbf{w}_k = \begin{pmatrix} e^{j\theta_1} & & & \\ & \ddots & & \\ & & e^{j\theta_1} & \\ & & & \ddots \\ & & & & e^{j\theta_N} \\ & & & & & \ddots \end{pmatrix} \begin{pmatrix} \tau_{k,1} \\ \vdots \\ \tau_{k,M} \end{pmatrix}$$

$$= \begin{pmatrix} e^{j\theta_1} \tau_{k,1} \\ \vdots \\ e^{j\theta_1} \tau_{k,M} \\ \vdots \\ e^{j\theta_N} \tau_{k,1} \\ \vdots \\ e^{j\theta_N} \tau_{k,M} \end{pmatrix} = \begin{pmatrix} e^{j\theta_1} \mathbf{w}_k \\ \vdots \\ e^{j\theta_N} \mathbf{w}_k \end{pmatrix} = \hat{\mathbf{w}}_{eq,k}$$

其中,右侧 $\hat{\mathbf{w}}_{eq,k}$ 由基于深度学习的波束成形框架训练并优化得到。那么,不失一般性,可令 $e^{j\theta_1} = 1$,则可得数字波束成形 \mathbf{w}_k 和反射矩阵 Θ 各元素通用解,当任意 $i \in \{1, \dots, M\}$ 时,存在:

$$\mathbf{w}_k = \hat{\mathbf{w}}_{eq,k} (1:M) \quad (13)$$

$$\begin{cases} e^{j\theta_1} = 1 \\ e^{j\theta_n} = \frac{\hat{\mathbf{w}}_{eq,k}((n-1)M+i)}{\mathbf{w}_k(i)}, n=2, \dots, N \end{cases} \quad (14)$$

其中, $\mathbf{w}_k(i)$ 是 \mathbf{w}_k 中第 i 个元素, $\hat{\mathbf{w}}_{eq,k}((n-1)M+i)$ 是 $\hat{\mathbf{w}}_{eq,k}$ 中第 $(n-1)M+i$ 个元素, $e^{j\theta_n}$ 为反射波束成形矩阵 Θ 的第 n 个对角线元素。

综上所述,在 IRS 辅助多用户 MIMO 系统中,根据式(13)和式(14)可以分别得到最大化和速率条件下的数字波束成形向量 \mathbf{w}_k 和反射波束成形矩阵 Θ 。

4 仿真结果

该波束成形方法的仿真基于 Keras,以 TensorFlow 为后端,并用 GTX 3070 实现。仿真中有如下设置:基站天线数量 $M=4$;用户数 $K=2, 3, 4$; IRS 反射元件数 $N=16, 64, 144, 196, 256$ 。仿真中所有信道均采用莱斯衰落信道模型,即基站-IRS 信道模型和 IRS-用户信道模型分别为:

$$\mathbf{G} = \sqrt{\frac{\beta_{Bl}}{1+\beta_{Bl}}} \mathbf{G}^{LoS} + \sqrt{\frac{1}{1+\beta_{Bl}}} \mathbf{G}^{NLoS} \quad (15)$$

$$\mathbf{h}^k = \sqrt{\frac{\beta_{U}}{1+\beta_{U}}} \mathbf{h}_k^{LoS} + \sqrt{\frac{1}{1+\beta_{U}}} \mathbf{h}_k^{NLoS} \quad (16)$$

其中, β_{Bl} 和 β_{U} 分别为基站-IRS 链路和 IRS-用户链路的信道莱斯因子, \mathbf{G}^{LoS} 和 \mathbf{G}^{NLoS} 分别表示基站-IRS 信道中的直达径 (Line-of-Sight, LoS) 和非直达径 (Non-Line-of-Sight, NLoS) 信道部分;同理, \mathbf{h}_k^{LoS} 和 \mathbf{h}_k^{NLoS} 分别表示 IRS-用户信道中的

LoS 和 NLoS 部分。本文仿真中假设基站-IRS 信道的莱斯因子满足 $\beta_{Bl} \rightarrow \infty$,则基站-IRS 信道等效为直达径信道;假设 IRS-用户信道的莱斯因子满足 $\beta_{U} = 0$,则 IRS-用户信道为瑞利衰落信道,仿真采用均值为 0 且标准差为 $\sqrt{0.5}$ 的瑞利分布。

在深度学习模型中,本文将式(8)作为信道系数分批次送入神经网络进行训练。选择 Adam 作为优化器,它在非凸问题中具有良好的性能。学习率 L 设置为 0.1,在中间的激活层采用线性整流函数 (Rectified Linear Unit, ReLU),最后一层采用 Sigmoid 激活函数。在每一个激活层后加入了 Dropout 层,保留神经元的概率 P 设置为 0.3,用于随机将一部分神经元的输出置为 0,以减小过拟合的可能性。

图 3 和图 4 分别给出了在不同 BatchSize 和样本数量下系统和速率随信噪比变化的仿真结果,其中,用户数 $K=4$ 且反射元件数 $N=16$ 。由图 3 和图 4 可以看出,和速率随着信噪比增大而增大,符合理论规律;其次,随着 BatchSize 或样本数量的改变,和速率并没有显著变化,表明该深度学习模型的鲁棒性较好。另外,考虑到计算耗时和最佳性能,后续实验的样本数设置为 10 000, BatchSize 设置为 50,该参数设置不会对系统和速率性能造成波动。




图 3 不同 BatchSize 下的和速率曲线

Fig. 3 Sum rate versus the number of BatchSize




图 4 不同样本数量下的和速率曲线

Fig. 4 Sum rate versus the number of samples

图 5 给出了不同用户数情况下,和速率随着信噪比变化的仿真结果。随着用户数量从 2 增加到 4,系统和速率呈现增长趋势,符合理论结果。然而,与用户数量的增加相比,和速率的增长速度逐渐减缓。原因在于随着用户数量的增加,用户之间的干扰逐渐增加,从而降低了和速率的增长速度。



图 5 不同用户数量下的和速率曲线

Fig. 5 Sum rate versus the number of users

图 6 给出了不同波束成形方案情况下,和速率随着反射

原件数变化的仿真结果。仿真中考虑了3种波束成形方案,包括提出的波束成形方案的连续相移情况(即最优波束成形方案)、1-bit量化相移情况和2-bit量化相移情况,其中用户数为2,信噪比为0 dB。从图6可以看出,随着反射元件数从16增大到256,系统和速率显示出明显的增长趋势。然而,与反射元件数的增加相比,和速率的增长并非同比例进行。随着反射元件数的增加,和速率的增长速率逐渐减缓。另外可以观察到,在提出的波束成形方案中,连续相移的方案相对于2-bit量化相移和1-bit量化相移表现出更好的性能,分别有超过 $0.5/(\text{bit/s/Hz})$ 和 $1/(\text{bit/s/Hz})$ 的性能提升。结果表明,在现有的离散相移约束下,提高相移的量化精度可以有效提高系统和速率性能。然而,需要注意的是,提高量化精度只能有限地提升系统和速率性能,其上界为连续相移情况下的系统性能。




图6 不同数量反射元件的和速率曲线

Fig. 6 Sum rate versus the number of reflecting elements

结束语 本文提出了用于IRS辅助多用户MIMO系统的基于深度学习的联合波束成形设计。该方案以最大化系统和速率为目标,以信道信息作为输入,通过CNN模块进行训练和学习输出上下行功率;而后设计了波束成形生成模块,从而得到等效的联合波束成形;最终将等效的联合波束成形去耦合,分别生成IRS反射矩阵和基站数字波束成形。这种基于深度学习的方案相比于传统联合波束成形优化方案,大大降低了通信系统实时的计算复杂度。通过仿真分别测试了不同信噪比、用户数和反射元件数对系统和速率性能的影响,验证了此方案能获得较高的系统和速率。然而,本文尚未考虑系统配置多IRS系统场景,此场景下的多跳反射路径将大大增加联合波束成形设计的复杂度,这是后续的主要研究方向。

参 考 文 献

- [1] OU L, LIAO S, QIN Z, et al. Millimeter Wave Wireless Hadamard Image Transmission for MIMO Enabled 5G and Beyond [J]. IEEE Wireless Communications, 2020, 27(6): 134-139.
- [2] GUI G, LIU M, TANG F, et al. 6G: Opening New Horizons for Integration of Comfort, Security, and Intelligence [J]. IEEE Wireless Communications, 2020, 27(5): 126-132.
- [3] WU Q, ZHANG R. Intelligent Reflecting Surface Enhanced Wireless Network via Joint Active and Passive Beamforming [J]. IEEE Transactions on Wireless Communications, 2019, 18(11): 5394-5409.
- [4] HUANG C, ZAPPONE A, ALEXANDROPOULOS G C, et al. Reconfigurable Intelligent Surfaces for Energy Efficiency in Wireless Communication [J]. IEEE Transactions on Wireless Communications, 2019, 18(8): 4157-4170.
- [5] XIE H, XU J, LIU Y F. Max-Min Fairness in IRS-Aided Multi-Cell MISO Systems with Joint Transmit and Reflective Beamforming [J]. IEEE Transactions on Wireless Communications, 2021, 20(2): 1379-1393.
- [6] MUNAWAR M, LEE K. Low-Complexity Adaptive Selection Beamforming for IRS-Assisted Single-User Wireless Networks [J]. IEEE Transactions on Vehicular Technology, 2023, 72(4): 5458-5462.
- [7] LIN T, CONG J, ZHU Y, et al. Hybrid Beamforming for Millimeter Wave Systems Using the MMSE Criterion [J]. IEEE Transactions on Communications, 2019, 67(5): 3693-3708.
- [8] SOHRABI F, YU W. Hybrid Digital and Analog Beamforming Design for Large-Scale Antenna Arrays [J]. IEEE Journal of Selected Topics in Signal Processing, 2016, 10(3): 501-513.
- [9] AYACH O E, RAJAGOPAL S, ABU-SURRA S, et al. Spatially Sparse Precoding in Millimeter Wave MIMO Systems [J]. IEEE Transactions on Wireless Communications, 2014, 13(3): 1499-1513.
- [10] LIN T, ZHU Y. Beamforming Design for Large-Scale Antenna Arrays Using Deep Learning [J]. IEEE Wireless Communications Letters, 2020, 9(1): 103-107.
- [11] GAO J, ZHONG C, CHEN X, et al. Unsupervised Learning for Passive Beamforming [J]. IEEE Communications Letters, 2020, 24(5): 1052-1056.
- [12] SHI Y, KINAR A, SIDIROPOULOS N D, et al. Learning to Beamform for Minimum Outage [J]. IEEE Transactions on Signal Processing, 2018, 66(19): 5180-5193.
- [13] ALKHATEEB A, ALEX S, VARKEY P, et al. Deep Learning Coordinated Beamforming for Highly-Mobile Millimeter Wave Systems [J]. IEEE Access, 2018, 6: 37328-37348.
- [14] SUN H, CHEN X, SHI Q, et al. Learning to Optimize: Training Deep Neural Networks for Wireless Resource Management [C] // 2017 IEEE 18th International Workshop on Signal Processing Advances in Wireless Communications (SPAWC). 2017: 1-6.
- [15] LIANG F, SHEN C, YU W. Towards Optimal Power Control via Ensembling Deep Neural Networks [J]. IEEE Transactions on Communications, 2020, 68(3): 1760-1776.
- [16] XIA W, ZHENG G, ZHU Y, et al. A Deep Learning Framework for Optimization of MISO Downlink Beamforming [J]. IEEE Transactions on Communications, 2020, 68(3): 1866-1880.
- [17] BJÖRNSSON E, BENGTTSSON M, OTTERSTEN B. Optimal Multiuser Transmit Beamforming: A Difficult Problem with a Simple Solution Structure [J]. IEEE Signal Processing Magazine, 2014, 31(4): 142-148.



CHEN Xiao, born in 1993, Ph.D, lecturer. Her main research interests include massive multiple-input and multiple-output wireless communication systems, deep-learning based communication systems, beamforming design and channel estimation technologies.



SHI Jianfeng, born in 1994, Ph.D, associate professor. His main research interests include 5G/6G communication wireless resource management, earth integrated networks, user-centered networks, beamforming theory and machine learning-

based communication technologies.