

MIMO-NOMA 系统中基于深度学习 CCDNN 框架的传输速率提高和能量效率优化算法

王金鹏, 窦顺瑶, 王 珏, 赵 昕

(大连工业大学 信息科学与工程学院, 辽宁 大连 116034)

摘 要: 多输入多输出非正交多址接入技术(MIMO-NOMA)将 NOMA 理念融入 MIMO 系统,能有效提高系统的能量效率和吞吐量,但是 MIMO-NOMA 系统复杂的空间结构和快速变化的空间信道会导致系统吞吐量下降,进而限制其广泛应用。为了解决这一问题,提出了一种基于深度学习的 MIMO-NOMA 系统框架,该系统采用一种适用于 MIMO-NOMA 的高效深度学习通信卷积方法(CCDNN)。该方法包括多个卷积层和隐藏层,能够通过特定算法解决功率分配问题,从而提高 MIMO-NOMA 系统的传输速率和能量效率。最后通过数值仿真进行验证,仿真结果表明,本文提出的 CCDNN 框架相较于传统方法具有更优的性能,为提高 MIMO-NOMA 功率分配性能提供了可行方案,并为该领域的进一步研究奠定了一定的理论基础。

关键词: MIMO-NOMA 系统;深度学习;能效;功率分配

中图分类号: TG115.28 **文献标志码:** A **文章编号:** 1671-5497(2026)03-0830-13

DOI: 10.13229/j.cnki.jdxbgxb.20240719

Optimization algorithm for transmission rate improvement and energy efficiency in MIMO-NOMA system based on a deep learning CCDNN framework

WANG Jin-peng, DOU Shun-yao, WANG Jue, ZHAO Xin

(College of Information Science and Engineering, Dalian Polytechnic University, Dalian 116034, China)

Abstract: Multiple-input-multiple-output non-orthogonal multiple access (MIMO-NOMA) technique involves the NOMA idea into MIMO systems, which can effectively improve the system energy efficiency and throughput. Nevertheless, complex spatial structures and rapidly varying spatial channels of the MIMO-NOMA system decrease the system's throughput and block its application. To address this issue, this paper proposes a deep-learning-based framework for MIMO-NOMA systems that employs an efficient Convolutional Deep Neural Network(CCDNN) tailored to MIMO-NOMA communications. The method comprises multiple convolutional and hidden layers and is able to solve the power-allocation

收稿日期: 2024-06-28.

基金项目: 国家自然科学基金项目(61402069, 61272369); 2018 年辽宁省普通高等教育本科教学改革立项项目(UP-RP20140139); 2017 年辽宁省自然科学基金项目(20170540059); 辽宁省研究生教育教学改革研究项目(LNYJG2024164).

作者简介: 王金鹏(1979-), 男, 副教授, 博士. 研究方向: 无线通信. E-mail: wangjp@dlpu.edu.cn

problem through a dedicated algorithm, thereby improving both the transmission rate and energy efficiency of the MIMO-NOMA system. Numerical simulations are conducted for validation, and the results demonstrate that the proposed CCDNN framework outperforms conventional approaches, offering a viable solution for enhancing MIMO-NOMA power-allocation performance and laying a theoretical foundation for future research in this area.

Key words: MIMO-NOMA system; deep learning; energy efficiency; power allocation

0 引言

5G系统中,由于非正交多址接入技术(Non-orthogonal multiple access, NOMA)技术可以极大地提高移动系统的频谱效率,已经在学术界得到了较大的关注,并已在工业领域得到了广泛应用^[1]。与传统的正交多址接入技术(Orthogonal multiple access, OMA)不同, NOMA技术仅通过一个公共基站就可以同时对其覆盖范围内多个具有不同功率级别的移动用户提供服务。通过在接收机处设置的连续干扰消除模块(Successive interference cancellation, SIC), NOMA技术可以一定程度上抑制相同信道的同频干扰和相同簇的内干扰。此外,为了测控调度在相同传输周期带宽条件下无线信号的传输, NOMA系统还采用了叠加编码技术(Superposition coding, SC)^[2]。

近年来,很多国内外的科研人员做了大量的以提高和改善NOMA系统性能为目的的研究。文献[3]研究了随机部署用户的下行链路NOMA方案的性能,并研究了NOMA的单播及多播系统,该系统能够使NOMA的分集顺序等于多播用户的数量。为了提高每个用户的遍历容量,文献[4]在配对近基站用户和小区边缘用户的情况下,提出了一种合理的NOMA方法。为了满足5G系统对海量数据及广泛接入大规模互联设备的需求,科研人员研究设计了MIMO技术,该技术可以通过部署辅助天线提高无线通信网络的容量,将MIMO技术应用于NOMA系统中能够进一步改善系统性能。

一般来说,基于深度神经网络(Deep neural network, DNN)设计的NOMA信号接收方法几乎均需依据OMA系统的符号检测机制。然而,对于这类检测方式的研究大多只是关注用户单一映射关系(即发射信号与接收信号的对应关系);此时,发射端叠加编码和功率分配的作用,会影响当前任务的网络难以同时、实时地检测远场用户

(Far-field user, FU)和近场用户(Near-field user, NU)终端的信号。更为重要的是,由于传统的NOMA系统中FU接收符号与NU接收符号具有明显不同的数据分布,因此网络需基于本地用户重新训练接收信号,而这必然引起网络训练开销的显著增长。

鉴于MIMO-NOMA系统良好的性能,科研人员研究了多种基于该技术的方案以解决各类难题。文献[4]将NOMA概念引入波束空间MIMO的毫米波传输中,以提高频谱利用率和能源效率。文献[5]提出了下行链路中多蜂窝MIMO-NOMA系统,并推演出两种干扰校准技术(Interference alignment, IA)的协同波束生成机制,其波束形成向量在两个基站处进行联合优化。随后,文献[6]针对毫米波NOMA系统提出了簇类算法,该方法对于同一簇中的移动用户采用NOMA技术,同时使用MIMO检测技术消除簇间干扰。然而,由于未考虑预编码,因此不能在基站处获取足够的空间自由度(即MIMO系统中可以独立传输的信号流数量),严重降低了功率效率及检测性能。此外,丰富的空间自由度主要由MIMO系统中信息的稀疏特性决定,即多信道中大多数系数的能量较小,而几个能量较大的抽头分布相隔较远。这类稀疏数据并不是无用数据,只是信息不完全,通过适当的数据挖掘或神经网络技术可以提取出大量有用信息。为解决这一问题,面向非分离的无线MIMO-NOMA系统框架,科研人员提出了一种基于机会矩阵的预编码方法。除此之外,文献[7]通过为同一簇中的用户联合设计预编码和均衡器,提出了一种新型的MIMO-NOMA传输策略,该方法在系统的总功耗方面,不仅优于OMA传输方式,也优于信号校准的NOMA方式。

深度学习技术的兴起为无线通信系统的物理层算法设计拓展了崭新的研究思路。MIMO-NOMA无线信道具有非平稳、随机过程的特性,

属于典型的非线性求解问题,尤其适合利用深度学习技术通过大数据训练进行求解。利用深度自编码器(Auto-encoder, AE)设计研究中继通信系统,且与解码转发(Decode-and-forward, DF)和中继放大转发(Amplify-and-forward, AF)进行对比,用户可以通过最大比合并方式或选择性合并等分集方式验证符号的检测优劣,结果验证神经网络相比于传统方式可以获得更大的增益。此外,基于长短期记忆网络与卷积神经网络能够设计MIMO系统的接收机模型,同时将长短期记忆网络应用于NOMA系统可以实现用户符号检测;而基于DNN技术的符号检测算法能够获得更低的误符号率。

目前,MIMO-NOMA系统的技术发展和应用为无线通信网络带来了新的机遇,但同时也面临诸多问题亟需解决,包括:①多用户分配机制采用的公平原则或基于效用最大化原则仍存在问题;②由于系统引入了更多的控制信道,导致系统复杂度增加,对系统性能的影响也更加明显;③在实际网络中,由于信道衰落、多径传播等原因,系统的性能指标与理论值有较大差异,这会进一步影响系统的性能;④由于MIMO-NOMA技术的标准化工作相对滞后、不够完善,会导致实际部署时,各设备之间的参数配置可能需要多次调整才能得到较好的性能。为了改进MIMO-NOMA系统的网络吞吐量及其保密性能,文献[8]针对3D-MIMO信道提出了一种基于机会型NOMA的分层安全模型,该模型可以根据不同的基站和用户提供若干种安全级别。此外,基于MIMO-NOMA系统,文献[9]将用户端天线动态地分为多个簇,并推导演化了功率分配方案以最大化小区容量,其中簇的数量不少于基站处发射天线的数量。需要注意的是,上述SIC模块需要获得每个用户端的信道状态信息(Channel state information, CSI),且MIMO系统的增益性能在很大程度上依赖于CSI的准确率。目前的功率分配方案几乎都是在假设系统处于完美CSI前提条件下设计的。然而,由于CSI具有超高的复杂度,MIMO-NOMA系统很难获得高精度CSI,因此会严重影响现有的功率分配方式。如前所述,相比于低复杂度等其他因素,虽然空间自由度是影响MIMO系统信道估计和预编码性能的关键因素之一^[10],但目前仅有少部分研究考虑了MIMO-NOMA系统

的空间自由度因素。此外,在MIMO-NOMA系统中,功率分配机制的优化基本上都属于非确定性多项式复杂性问题(Non-deterministic polynomial complexity, NP),传统技术仅能求得次优解,导致现有的功率分配算法均有不同程度的局限性。

基于上述分析,开发对MIMO-NOMA系统的功率分配进行优化的新算法就显得尤为重要。近来,机器学习中的深度学习理论被广泛应用于处理大数据、求解非线性过程等难题。机器学习与处理大数据、求解非线性过程的关系在某种意义上是相辅相成的。一方面,大数据为机器学习算法的训练提供基础数据;另一方面,对于复杂的非线性问题,机器学习算法可以对大数据中的非线性特征进行建模,进而实现对复杂问题的求解。尽管基于深度学习的无线通信系统尚未成熟,但科研人员已经开展了一系列开创性工作,并已初步验证了该方法的良好性能^[11]。文献[12]首次将深度学习的理念融入NOMA系统,并验证了深度学习在NOMA系统编码、解码、信道检测等方面的改进优势和有效性。此后,深度学习在无线通信领域引起了更为广泛的关注,部分学者将其应用于正交频分复用系统(Orthogonal frequency division multiplexing, OFDM)进行信道估计;部分学者将其引入大规模MIMO系统中进行信道估计及超分辨率到达方向(Super-resolution direction of arrivals, SDOA)估计,并得到了充分的证明。此外,无线通信中的深度学习方法在信道编码、毫米波(mm wave)、无人机(Unmanned aerial vehicles, UAVs)、OFDM接收机、认知无线电、移动用户卸载框架等多个领域中也进行了初步的相关研究^[13]。

同时,将深度学习应用于流量控制,可以优化系统的丢包率和平均延迟性能。文献[14]提出了一种基于深度学习的流量负载预测算法,通过优化信道分配实现较好性能,进而预测未来的流量负载和堵塞问题;在移动场景的无人机应用中,无人机控制系统(Unmanned aircraft systems, UASs)的资源分配问题会降低系统性能^[15],而深度学习技术是一种可供选择的解决方案^[16]。综上,在MIMO-NOMA系统中应用深度学习对于功率优化问题具有重要意义。

目前,深度学习技术发展非常迅速,涌现出许

多新的先进模型和技术,包括卷积神经网络(Convolutional neural network, CNN)、生成对抗网络(Generative adversarial network, GAN)、深度强化学习(Deep reinforcement learning, DRL)、变分自编码器(Variational auto encoder, VAE)、循环神经网络(Recurrent neural network, RNN)、多任务学习(multi-task learning)等。鉴于数字通信网络中需要对信号进行多次卷积操作,这类似于图像信息的压缩和处理,因此本文尝试将最先进深度学习中的CNN与MIMO-NOMA系统相结合,以期实现较好的功率分配性能,进而完成对传输速率和能效的优化。此外,本文将MIMO-NOMA系统视为仅具有外部输入/输出端的黑匣子,所提框架可以实现端到端的性能优化,基于深度学习,该算法能够充分利用稀疏统计特性,并辅以新颖的学习机制,实现具有较高分辨率的信道估计。

针对NOMA系统由时空信道快速变化导致系统吞吐量下降,以及功率分配机制优化等问题,本文首先创新性地将NOMA理念融入MIMO系统;其次将经典的最大比值合并(Maximum ratio combining, MRC),即依据阵列增益,通过合并多个信号路径改善接收端的信号质量,检测向量作为MIMO系统的自由度;最后将深度学习引入MIMO-NOMA系统,提出了适用于MIMO-NOMA的高效深度学习通信卷积方法CCDNN。

综上,本文提出了一种新的卷积通信深度神经网络CCDNN,用于近似模拟逼近MIMO-NOMA系统,此框架由设计的激活函数处理网络中的多个隐藏层及卷积层。此外,基于该模型,本文还提出了一种新的功率分配算法,以优化提高系统的传输速率和能效。

1 MIMO-NOMA系统概述及其数学表达

1.1 多集群MIMO-NOMA系统模型

如图1所示,本文主要讨论经典MIMO-NOMA系统的下行链路。其中基站采用具有 M 根天线和 D 个多天线用户的均匀线性阵列(Uniform linear array, ULA),假设该下行链路的衰落环境为瑞利衰落信道(Rayleigh fading channel)。本文中每个移动用户配备有 N_r 根天线,并且基站没有用户的上、下行链路信息。

为了在MIMO系统中应用NOMA技术,本文将所有用户随机分成 M 簇,且每一簇均由 K 个用户构成,即系统中多天线用户总数 $D=K \cdot M$ 。

1.2 MIMO-NOMA系统的数学描述

为了避免传播矢量分配问题过于复杂且脱离实际情况,本文假定 $N_r \geq M$ 。5G系统中存在数量庞大的微蜂窝,与之对应的是系统同样拥有数量庞大的低成本、低功耗微蜂窝基站。因此,本文合




图1 具有多天线用户的经典MIMO-NOMA系统

Fig. 1 Classic MIMO-NOMA system with multi-antenna users

理地假设 5G 系统中配备的微蜂窝基站数量应与用户端配备的天线数量相当,甚至少于该天线数量。如果 $M \times 1$ 信源矢量为 s ,那么该基站处的发射信号 x 可以表示为:

$$x = Ps \quad (1)$$

式中: P 为预编码矩阵; s 为信源矢量,可由式(2)描述:

$$s = \begin{bmatrix} \beta_{1,1}s_{1,1} + \beta_{1,2}s_{1,2} + \cdots + \beta_{1,K}s_{1,K} \\ \vdots \\ \beta_{M,1}s_{M,1} + \beta_{M,2}s_{M,2} + \cdots + \beta_{M,K}s_{M,K} \end{bmatrix} \cong \begin{bmatrix} \bar{s}_1 \\ \vdots \\ \bar{s}_M \end{bmatrix} \quad (2)$$

式中: $s_{m,k} \sim \mathcal{CN}(0, \epsilon)$ 为第 m 簇中第 k 个用户承载的信息,其中 ϵ 为每个符号的发送功率; $\beta_{i,j}$ 为 NO-MA 系统的功率分配系数。

同时, $H_{m,k} \in \mathbb{C}^{N_t \times M}$ 为信道矩阵,其包含第 m 簇中第 k 个用户与距离相关的路径损耗。第 1 簇中第 k 个用户的接收信号为:

$$y_{1,k} = H_{1,k}Ps + z_{1,k} \quad (3)$$

式中: $z \sim \mathcal{CN}(0, \sigma^2 I_{N_t})$ 为加性高斯白噪声(Additive white Gaussian noise, AWGN)。本文假设功率分配系数为 $\beta_{1,1} \leq \beta_{1,2} \leq \cdots \leq \beta_{1,K}$,则信道增益可以描述为:

$$\left| v_{1,K}^H H_{1,K} p_1 \right|^2 \leq \left| v_{1,K-1}^H H_{1,K-1} p_1 \right|^2 \leq \cdots \leq \left| v_{1,1}^H H_{1,1} p_1 \right|^2 \quad (4)$$

对于给定固定值的 P ,检测向量应满足以下约束条件:

$$v_{1,K}^H h_{m,1k} = 0 \quad (5)$$

式中: $h_{m,1k}$ 为 $H_{1,k}$ 的第 m 列; $v_{1,k}$ 为第 k 个用户的检测向量; p_i 为 P 的第 i 列。

通常, MIMO-NOMA 系统会将 MRC 检测向量作为检测器,监测 MIMO 系统的自由度,故 $v_{1,k}$ 可由式(6)获得:

$$v_{1,k} = U_{1,k} n_{1,k} \quad (6)$$

式中: $U_{1,k}$ 含有 $\bar{H}_{1,k}$ 的左奇异值,其中 $\bar{H}_{1,k} = [h_{2,1k}, h_{3,1k}, \cdots, h_{M,1k}]$ 为矩阵 $H_{1,k}$ 删掉一行零奇异值后得到的子矩阵;依据 MRC 理论, $n_{1,k}$ 为归一化的向量,可描述为:

$$n_{1,k} = \frac{U_{1,k}^H h_{1,1k}}{|U_{1,k}^H h_{1,1k}|} \quad (7)$$

因此,第 1 集群中第 k 个用户信号传输的数学模型为:

$$\begin{aligned} v_{1,k}^H y_{1,k} &= v_{1,k}^H H_{1,k} Ps + v_{1,k}^H z_{1,k} \\ &= v_{1,k}^H H_{1,k} p_1 (\beta_{1,1}s_{1,1} + \cdots + \beta_{1,K}s_{1,K}) + \\ &\quad \sum_{m=2}^M v_{1,k}^H H_{1,k} P m \bar{s}_m + v_{1,k}^H z_{1,k} \end{aligned} \quad (8)$$

假设本文系统是理想的 SIC,且发送的信噪比为 η ,则第 1 集群中第 k 个用户信号传输的信干比(Signal to interference plus noise ratio, SINR)可以写为:

$$\gamma_{1,k}^k = \frac{|v_{1,k}^H H_{1,k} p_1|^2 \beta_{1,k}^2}{\sum_{n=1}^H |v_{1,k}^H H_{1,k} p_1|^2 \beta_{1,n}^2 +} \quad (9)$$

2 基于 CCDNN 深度学习的 MIMO-NOMA 系统

基于最先进的深度学习理论,本文将 DNN 引入 MIMO-NOMA 系统,提出了一种端到端的速率求和及能效优化算法。为了提高端到端的性能,本文首先对 CCDNN 网络进行训练,然后在基站 BS 端进行实现,可以为每个用户端提供不同的功率。虽然本文在 CCDNN 网络框架中并没有涉及一般意义上的“物理用户”,但是选用信道链路及用户的多样特征作为该网络的训练特征集,而这也确保了网络的训练特征集可以涵盖该网络的全部信息。此外,还需要在该框架上采用有效的深度学习方法进行实现。

2.1 优化问题描述

在本文采用的 MIMO-NOMA 系统中,第 1 集群中第 k 个用户的速率可以表示为:

$$R_{1,k} = \log_2(1 + \gamma_{1,k}^k) \quad (10)$$

同时,假设其他集群中用户的速率也采用与式(10)相同的定义方法,则 MIMO-NOMA 系统可实现的速率总和为:

$$R_{\text{sum}} = \sum_{m=1}^M \sum_{k=1}^K R_{m,k} \quad (11)$$

式中: R_{sum} 为速率总和,由预编码器 p_m 和功率分配系数 $\{\beta_{m,k}\}$ 共同决定,此时优化问题可以定量地描述为:

$$\max_{p_m, \beta_{i,j}} R_{\text{sum}} = \max_{p_m, \beta_{i,j}} \sum_{m=1}^M \cdot \sum_{k=1}^K R_{m,k} \quad (12)$$

式(12)应满足以下 5 个约束条件:

$$\left\{ \begin{array}{l} \text{条件1: } \sum_{m=1}^M \|p_m\| \leq P_{\text{tr}}, \forall m \\ \text{条件2: } R_{m,k} \geq R_{\min}, \forall m, k \\ \text{条件3: } 0 \leq \|p_m\| \leq P_{\text{tr}}, \forall m \\ \text{条件4: } 0 \leq \beta_{m,k} \leq 1, \forall m, k \\ \text{条件5: } \sum_{m=1}^M \sum_{k=1}^K \beta_{m,k} = 1 \end{array} \right. \quad (13)$$

式中: $R_{\min}$ 为每个集群中每个用户的最小数据速率; 条件1为对信号总传输功率的限制, 其中 P_{tr} 为信号总传输功率的最大值; 条件2和条件3分别为对最小数据速率和最小分配功率的约束; 条件4和条件5为对功率分配系数 $\{\beta_{m,k}\}$ 的约束。此外, 还需对 SIC 的解码顺序进行如下约束:

$$v_{m,k} = \begin{cases} 0, & |v_{m,k}^H H_{m,k}|^2 \leq |v_{m,k+1}^H H_{m,k+1}|^2 \\ 1, & \text{其他} \end{cases} \quad (14)$$

式中: $v_{m,k}$ 为第 m 个集群内第 k 个用户的检测向量, 当该值为零时表示该用户不执行 SIC; 当该值为 1 时表示该用户执行 SIC。此外, 由式(14)可以看出, 该系统既包含连续变量, 又包含组合变量, 属于非凸性问题。这意味着系统的能量函数有多个极值, 即系统有多个稳定的平衡态。利用穷举性方法计算式(10), 会导致难以接受的高复杂度问题。深度学习算法可以对复杂问题进行近似计算, 如果训练网络由足够的神经元和隐藏层组成, 那么该网络能够较好地解决此类难题。

2.2 用于提高 MIMO-NOMA 系统速率与优化能量效率的基于深度学习的 CCDNN 框架

近年来, 深度学习算法广泛应用于各种新兴领域, 如计算机视觉(Computer vision, CV)、自然语言处理(Natural language processing, NLP)、自动驾驶(Automatic driving, AD)等方面。根据经典的逼近定理可知, 具有多层感知(Multi-layer perception, MLP)技术的单个隐藏层前馈网络能够逼近复杂度为 R^n 的紧子集上的连续函数。由于 MIMO-NOMA 系统的统计信息可以通过网络

若干隐藏层的信息传输被完全提取, 因此深度学习的 DNN 网络可以解决大量的非线性非凸性问题。当然, MIMO-NOMA 系统需要复杂的信道估计算法执行 SIC, 而功能强大的 CCDNN 网络可以克服这一难题。

如前所述, DNN 网络是对传统人工神经网络的扩展, 其内部包含具有大量神经元的若干隐藏层。DNN 网络的输入信息经输入层进入隐藏层, 由神经元处理。本文 DNN 网络的激活函数选用常见的 Sigmoid 函数和整流线性单元(Rectified linear unit, ReLU)函数:

$$f_{\text{Sigmoid}}(x) = \frac{1}{1 + \exp(x)}, f_{\text{ReLU}} = \max(0, x) \quad (15)$$

式中: x 为自变量。此时, 如果假设 f_o, x_{in} 分别为 DNN 网络的输出及 MIMO-NOMA 系统的输入, 那么:

$$f_o = f(x_{\text{in}}, \omega) = f^{(n-1)}[f^{(n-2)}(\dots, f^2(f^1(x_{\text{in}})))] \quad (16)$$

式中: ω 为 DNN 网络的权重; n 为 DNN 网络的层数。

图2给出了本文所提基于深度学习的 CCDNN 框架。其中, Conv 为卷积层, FC 为全连接层, Max-Pool 代表 maxpooling 操作, S 为步长。本文提出的 CCDNN 框架将 MIMO-NOMA 系统的功率分配视为穷举搜索问题。该网络能够提取样本的信道向量、功率分配因子、传输功率、噪声等特征和相关信息, 并可以通过非线性映射遍历所有功率分配策略。

如图2所示, 该框架包括 11 个卷积层、2 个全连接层及 1 个最大值池化层。同时, 预编码矩阵 P 包含每根天线的预编码器, 并且假设输出预编码器 $\bar{p}_m$ 及其对应的功率分配因子为最优的功率分配结果。

在本文所提系统中, 网络的初始输入为信道




图2 基于深度学习的 CCDNN 框架

Fig. 2 CCDNN framework based on deep learning

向量 $\mathbf{h}_m$ 和预编码矩阵 $\mathbf{P}$ 。该网络的输入层是由具有 64 个不同 $4 \times 4 \times 1$ 滤波器和 1 个步长组成的卷积层,用于生成特征图,该卷积层遵循 ReLU 函数。具体来说,该卷积层有 4 个通道,但不同于无线通信信道的概念,它表示的是 CCDNN 网络特征图的数量,即如果通道数为 N_c ,那么意味着输入的数量(如特征图的数目)应为 N_c 。因此,第一和第二通道分别由信道向量 $\mathbf{h}_m$ 的实部和虚部组成。

此外,第三通道包含了预编码矩阵 $\mathbf{P}$,而第四通道则承载了功率分配因子。本文引入传输功率的最大值 P_{tr} 作为包含输出层的激活函数的功率约束,那么对于所有的 $\mathbf{P}$,均需满足 $\sum_{m=1}^M \|\mathbf{p}_m\| \leq P_{tr}$ 条件。在上述功率约束条件下,首先采用类似注水法的穷举方法产生预编码器,其次 CCDNN 网络在学习训练中持续更新这些预编码器,最后可以得到最优预编码器。

相比于 Sigmoid 函数,ReLU 函数更适合于处理非线性问题,可以防止梯度爆炸和梯度消失问题,即当 DNN 网络反向传播更新参数时,网络权重 ω 过大或逼近零的问题。因此,本文所提网络的卷积层运算过程可以表示为:

$$\mathbf{o}_l^{(u)}(d_x, d_y) = f_{\text{ReLU}} \left\{ \sum_{c=1}^B \sum_{r=1}^R \sum_{r'=1}^{R'} \text{kernel}_l^{(u)}(r, r') \times \mathbf{o}_c^{(u-1)}(d_x + r, d_y + r') + b_l^{(u)} \right\} \quad (17)$$

式中: u 为网络卷积层的层数索引; r 和 r' 为偏移量; $R \times R'$ 为网络内核的尺寸; $\mathbf{o}_l^{(u)}$ 为当前层输出的第 l 个特征图; $\mathbf{o}_c^{(u-1)}(c=1, 2, \dots, m)$ 为 CCDNN 网络上一层第 c 个输入特征图,且其像素坐标为 (d_x, d_y) 。此时,网络中的最大值池化操作可以描述为:

$$\max \mathbf{o}_l^{(u+1)}(d_x, d_y) = \mathbf{o}_l^{(u)}(d_x \cdot \text{len} + r, d_y \cdot \text{len} + r') \quad 0 \leq r < Q-1, 0 \leq r' < Q-1 \quad (18)$$

式中: Q 为最大值池化运算的尺寸; len 为步长。如果充分利用卷积层的共享权重结构及平移不变特性,本文算法就可以实现良好的表达性能,并能够容易地将生成的特征映射至码字。

此外,为了提高 MIMO-NOMA 系统的功率分配性能,本文采用了改进的 ReLU,即最大最小输出 Maxout 函数作为激活函数,其优势在于具有

良好的功率约束条件作为保障:

$$f_{\text{Max}} = \min(\max(\mathbf{x}_{in}^T \boldsymbol{\omega}_{\dots i} + b_i), P_{tr}) \quad (19)$$

式中: b_i 为优化过程中第 i 次迭代计算的偏差;该式表明基于提出的 CCDNN 模型,本文可以通过网络较强的深度学习将优化问题近似为连续函数,进而能够找到 MIMO-NOMA 系统的最优解。此时,在第 1 集群中第 k 个用户实现的用于第 q 个用户解码的 SINR 为:

$$\gamma_{1,k}^q = \frac{|\mathbf{v}_{1,k}^H \mathbf{H}_{1,k} \mathbf{p}_1|^2 \beta_{1,q}^2}{\sum_{n=1}^{q-1} |\mathbf{v}_{1,k}^H \mathbf{H}_{1,k} \mathbf{p}_1|^2 \beta_{1,n}^2 +} \quad (20)$$

2.3 样本生成和学习机制

作为支持深度学习的框架,CCDNN 模型面临的关键问题之一同样是网络需要足够丰富的训练样本。本文在网络训练学习过程中选择了多领域的大量样本。例如,在选用的不同信道环境下获得了多样的发送数据序列和信道向量,包括 AWGN、平坦衰落、频率选择性衰落环境等。

本文提出的 CCDNN 模型能够对新捕获的数据进行额外训练,而不需要训练在之前训练过程中已经训练的数据。具体来说,CCDNN 模型将 30 个样本视为一组新数据,学习训练开始后依次输入每组数据直至 CCDNN 模型将之学会并能够适应该信道环境。此时,系统能否导出适当的损失函数(见式(21))以优化 CCDNN 框架是非常重要的:

$$l_{\text{CDNN}} = \mathbb{E} \left\{ - \sum_{m=1}^M R_{m,k} + \zeta \sum_{k=1}^K \sum_{m=1}^M (R_{\min} - R_{m,k}) - \rho \sum_{m=1}^M p_m \right\} + l_2 = \frac{-1}{NMK} \sum_{j=1}^N R_{\text{sum}}(\beta_{i,j}, p_m) + \zeta \sum_{k=1}^K \sum_{m=1}^M (R_{\min} - R_{m,k}) - \rho \sum_{m=1}^M p_m \|\mathbf{W} - \mathbf{W}_p\|_2 \quad (21)$$

式中: N 为训练样本的数量; $\mathbf{W}_p$ 为训练 CCDNN 模型学习预先设定的权重矩阵。不同于一般意义下基于均方误差(Mean squared error, MSE)或能量熵的损失函数,本文引入了约束条件 $R_{\min} - R_{m,k} > 0$ 或 $p_m < 0$ 。只有满足该条件,CCDNN 网络才可以持续更新学习。

具体来说,缩放参数 ζ 和 ρ 为在学习训练中需要调整的用于确定模型的超参数。由于优化侧重于满足约束项而不是优化特征函数,因此过大的

ζ 和 ρ 将会降低CCDNN框架的系统性能,但过小的缩放参数将无法在优化中满足约束条件。此外,正则化项 l_2 用于防止CCDNN的不可行输出,而 ϱ 同样为超参数。本文提出的基于深度学习的MIMO-NOMA方案的能效性能可以表示为:

$$\xi = \frac{R_{\text{sum}}}{P + N_{\text{RF}}P_{\text{RF}} + N_{\text{RF}}P_{\text{S}} + P_{\text{BB}}} \quad (22)$$

式中: P 为总的发射功率; P_{RF} 为每个射频链路消耗的功率; P_{S} 为为提高阵列增益而引入的模拟移相器的功率消耗,该功耗是由插入损耗和激励功率而引起的; N_{RF} 为RF链路数量, $N_{\text{RF}}=M$; P_{BB} 为基带功耗。

3 基于CCDNN的MIMO-NOMA系统框架算法的实现

本文所提的基于CCDNN的MIMO-NOMA系统框架由两部分算法共同实现,包括基于CCDNN的MIMO-NOMA系统训练算法1和基于CCDNN的MIMO-NOMA系统测试算法2。

基于CCDNN的MIMO-NOMA系统训练算法1如下所示:

算法1 基于CCDNN的MIMO-NOMA系统训练算法

输入:仿真环境参数、信道矢量 $\mathbf{h}_m$ 、预编码矩阵 $\mathbf{P}$

输出:CCDNN.

1. 开始运行,产生AWGN等因素共同影响作用的无线信道;
2. 产生由信道矢量 $\mathbf{h}_m$ 和预编码矩阵 $\mathbf{P}$ 共同组成的训练集;
3. 实现CCDNN网络架构;
4. 网络学习速率及无线环境的各类衰落因子, $\sigma=10^{-7}$;
5. 参数的初始化: $\mathbf{P}=0, \beta_m \in \{0, 1\}, \forall i, j$;
6. 开始while循环(循环条件 $\geq \sigma$):依据样本训练网络;
7. 依据式(19)及其参数运算更新CCDNN的网络参数;
8. 运算更新CCDNN网络每一层的权重 ω 及输出;
9. 结束while循环;
10. 返回CCDNN.

算法1中,输入由仿真环境参数、信道矢量 $\mathbf{h}_m$ 、预编码矩阵 $\mathbf{P}$ 等3部分组成,而训练集由信道矢量 $\mathbf{h}_m$ 和预编码矩阵 $\mathbf{P}$ 共同组成,并假定涉及的无线信道会受到无线环境各类衰落因子、高斯白噪声AWGN等因素共同影响作用。同时,设定网络的误码率阈值 $\sigma=10^{-7}$,最终CCDNN网络

训练结束,对网络参数和每层的权重进行更新。

算法2 基于CCDNN的MIMO-NOMA系统测试算法

输入:仿真环境参数、CCDNN网络及其参数

输出:预编码矩阵 $\bar{\mathbf{P}}$ 、功率分配系数 β_m .

1. 开始,加载CCDNN网络参数及无线环境衰落因子;
3. 运行CCDNN网络架构;
4. 更新CCDNN网络每一层的输出;
5. 计算第 m 簇的预编码器 $\mathbf{p}_m$ 及其功率分配系数 $\beta_m \in \{0, 1\}, \forall i, j$;
6. 依据预编码器 $\bar{\mathbf{p}}_m, \forall m$ 计算预编码矩阵 $\bar{\mathbf{P}}$;
7. 依据式 $\beta_m = \frac{\|\bar{\mathbf{P}}_m\|}{P}$ 运算更新功率分配参数,并得到功率分配系数 $\beta_{m,k}$;
8. 结束运算,返回输出预编码矩阵 $\bar{\mathbf{P}}$ 、功率分配系数 $\beta_{m,k}$.

4 仿真实验、结果与分析

4.1 仿真参数设定及说明

由算法2可以看出,功率分配系数 $\beta_{m,k}$ 的选择意味着基站可以为集群中的每个用户分配最小功率,以实现显著提高速率和高能效。本文仿真过程中,MIMO-NOMA系统参数设置及CCDNN网络框架参数选取分别如表1和2所示;仿真实验结果中的变量或参数说明如表3所示。

表1 MIMO-NOMA系统参数设置

Table 1 MIMO-NOMA system parameter settings

发射机	空间信息	the angles $> \{-\pi \sim +\pi\}$
	射频(RF)链路的功耗	$P_{\text{RF}} = 300 \text{ mW}$
	误码率阈值	$\sigma = 10^{-7}$
	基带功耗	$P_{\text{BB}} = 200 \text{ mW}$
	基站BS覆盖面积	a 500 m circle area
	移相器的功耗	$P_{\text{S}} = 5 \text{ mW}$
	像素距离 Pixel Distance	$d = \lambda/2$
	信噪比 SNR	10 dB
	莱斯Rician信道因子	$k = 8 \text{ dB}$
	高斯白噪声 AWGN 信道	
信道衰落类型	瑞利 Rayleigh 信道	
	莱斯 Rician 信道	
	纳科拉米 Nakagami 信道 ($m=3$)	

4.2 系统的速率性能分析

图3给出了在不同序列训练长度和不同序列训练量情况下系统的速率总和与SNR之间的关系,其中序列训练长度分别为16、8 bits,而序列训

表 2 CCDNN 网络框架参数选取

Table 2 CCDNN network framework parameters selection

训练序列长度	$L=16$ bits, $L=8$ bits
序列批处理尺寸	1 000 batch sizes, 500 batch sizes
学习速率	0.1、0.02、0.01、0.001
每簇用户数	$K=4$
用户总数	$M=128$
初始信噪比 SNR	25 dB
缩放参数 ζ 和 ρ	学习训练动态调整

表 3 实验中的变量或参数说明

Table 3 Description of variables or parameters in experiment

	变量或参数名称	含义
仿真 图 3	$L=16$ bits, $L=8$ bits	序列训练长度
	Sum data rate/ (bit·Hz ⁻¹ ·s ⁻¹)	系统速率总和/ (bit·Hz ⁻¹ ·s ⁻¹)
仿真 图 4	Learning rate	网络学习速率分别为 0.1、0.01、0.02 及 0.001
	SNR/dB	信噪比/dB
仿真 图 5	Data rate per user/ (bit·Hz ⁻¹ ·s ⁻¹)	每个用户的速率/ (bit·Hz ⁻¹ ·s ⁻¹)
	Retraining time duration T/s	再训练时间/s
	$k=12$ dB, $q=3.8$	分解因子, 超参数
仿真 图 6	Spectrum efficiency	系统频谱效率
仿真 图 7	Energy efficiency/ (bps·Hz ⁻¹ ·W ⁻¹)	系统能效/ (bps·Hz ⁻¹ ·W ⁻¹)
	Data Rate/bps	系统速率/bps
仿真数 据表	L^2	二维范数正则化项
	DNN	深度学习网络
	4~6	乘法累加计数/百万次

训练量分别为 1 000、500 批量大小。由图 3 可以看出,除了与传统算法一致的随着信噪比的增加,速率总和会增加以外,本文算法在增加序列训练长度或序列训练量时,速率总和也可以得到相应的改善。

这种对于速率总和的优化效果是由于较长的序列训练长度有利于提取完整的信道信息^[17];同时,较大的序列训练量之所以能够提高速率总和是由于较小的序列训练量会导致本文算法的收敛速度较慢。图 4 为 MIMO-NOMA 系统中基于 CCDNN 网络的每簇速率与 SNR 变化的关系图,其中选用的学习速率 0.1、0.01、0.02 及 0.001 分




图 3 系统的速率总和与 SNR 之间的关系

Fig. 3 Relationship between sum of rate and SNR




图 4 每簇速率与 SNR 变化的关系图

Fig. 4 Relationship diagram of per cluster rate versus SNR variation

别对应蓝色、绿色、橙色和紫色曲线(彩图见电子版,以下同),而最上方的黑色断点曲线为速率的理论值^[18]。

在 CCDNN 网络的初始化阶段,本文将用于训练的序列训练长度设置为 16 bits,用户数 $M=128$ 。为便于比较,图 4 中的理论容量采用文献[18]中全数字预编码算法计算得出的理论值。该全数字预编码方案能够以极高的功耗、硬件成本和计算复杂度为代价,获得 MIMO 系统的最佳性能,因此可以将其视为本文所提 CCDNN 框架的理论上限。此外,每个用户的速率是通过对所有簇的模拟仿真进行测量的。

由图 4 可以看出,当采用较小的学习速率时,第一簇的数据率得到了优化,尤其是当学习速率为 0.001 时,第一簇的数据率比较接近理论容量。这是因为较大的学习速率将导致更高的验证误差,会降低基于 CCDNN 架构的 MIMO-NOMA

系统的性能。因而,为了确定最佳学习速率,实际应用中需要基于 $\{0.01, 0.001\}$ 集合的给定数据集动态调整学习速率,直至达到最佳性能。例如,文献[19]提出的RPROP算法可以根据性能自动调整学习速率,有助于找到最佳学习速率。




图5 每个用户平均速率与再训练时间 T 之间的关系

Fig. 5 Relationship between average rate per user and retraining time T

图5为考虑了CSI在理想和非理想情况下,每个用户的平均速率与再训练持续时间 T 之间的关系曲线。该仿真SNR的初始值为25 dB。同时,图5是在将其他初始参数设置为恒定值的前提下,仅用于衡量基于CCDNN的功率分配方案在不同信道环境下的在线学习性能。此外,考虑到城市地区安装了大量的通信设备,导致严重的信息折射、反射和遮挡,故而仿真中设置分解因子 $k=12$ dB及超参数 $q=3.8$ 模拟城区环境。

从图5中可看出,随着再训练时间的增加,用户平均速率一直在提高。这表明本文CCDNN方案随着时间的增加能够收敛,并且训练效果更好。与图4一样,为便于比较,图5仍采用文献[18]中算法给出的在理想CSI和非理想CSI情况下信道容量的理论值。

仿真过程中发现,当再训练时间 <30 s时,本文方案的可实现速率几乎为零。这是因为此时CCDNN网络没有得到很好的再训练,进而导致不能进行正确的功率分配。未来研究应该提出更有效的在线学习方法,将CCDNN框架的再训练时间减少到10 s或20 s以内。

此外,依据理论容量结果^[18]和图5所示CCDNN网络的离线学习结果可知,如果能将离线学习和

在线学习机制进行有效的结合^[20],基于深度学习的方案可以在MIMO-NOMA系统中实现更优的性能。

4.3 系统的能效性能分析

图6显示了系统能效与总簇数 m 之间的关系,其中分别给出了理想的能效结果、本文方案的完美训练结果、仿真结果。由于基于深度学习的方法的学习性能在每次训练中都会出现波动,完美训练的结果是指重复训练CCDNN框架后获得的最佳结果。完美训练的结果通常被用作评估基于深度学习框架鲁棒性和稳定性的重要参考。图6中,仿真参数设置如下:SNR为20 dB;序列训练长度为16 bits;每条射频链路(Radio frequency link, RFL)消耗的功率 $P_{RF}=300$ mW;基带功耗 $P_{BB}=200$ mW;移相器的功耗 $P_S=5$ mW。




图6 系统能效与总簇数 m 之间的关系

Fig. 6 Relationship between system energy efficiency and total number of clusters m

从图6可以看出,随着总簇数 m 的增加,系统能效也在不断提高。这是由于簇的数量越多,相同功率水平下系统有更多的机会被选择到不同的簇中。因此,虽然现有的MIMO-NOMA方法会出现明显的性能损失,但本文基于CCDNN的MIMO-NOMA方法可以显著改善能效性能。

此外,本文还对系统能效与速率的对应关系进行了量化实验分析,图7为当信噪比20 dB、信噪比阈值 -2 dB时系统能效与传输速率之间的关系。与本文算法进行比较的3种算法分别为OMA、NOMA和CRS-NOMA系统。

由图7可以看出,即使在速率较大的情况下,本文算法的能效也高于其他系统。虽然随着速率的增加,所有方案的能效都有所下降,但本文算法仍然可以表现出最高的性能,比其他3种系统的能效分别高出2%、3%及4%左右,体现了本文




图 7 系统能效与传输速率之间的关系

Fig. 7 Relationship between system energy efficiency and transmission rate

算法的有效性。

系统模型的收敛速度与本文关注的传输速率、能量效率之间的关系复杂,可以分类说明:①当给定网络参数时,若信道参数不变,则增加发送速率会提高信道利用率,但当能效达到最大值后,增大发送速率反而会降低信道质量;②当给定网络参数和信道参数时,增大发送速率会提高能效,增大信道长度会降低能效;③对于相同的网络参数和信道长度,增大发送速率或者增大信道长度会使网络的能效性能趋于恶化。

4.4 系统 CCDNN 算法的鲁棒性分析

本节将评估本文 CCDNN 框架的稳健性,重点观察卷积层数的变化是否影响基于深度学习的 MIMO-NOMA 方案性能。此外,还会讨论本文 CCDNN 网络的性能是否很大程度上依赖于隐藏层的数量,以及能否通过正则化项提高系统的性能等。

本文测试了基于深度学习的 MIMO-NOMA 框架性能的鲁棒性。为了评估所开发的 CCDNN 结构的性能,本文引入了用于类似功率分配任务的数据集。该数据集包括具有 34 万个样本的训练数据集和具有 10 000 个样本的测试数据集。这些样本用于大规模 MIMO 网络下行链路中执行 max-min 和 max-prod 功率分配。在仿真实验中,本文对数据集进行随机采样,实际采用的数据集由包含 12 000 个样本^[21]的训练集和包含 4 000 个样本^[22]的测试集组成。其中,测试精度定义为测试阶段正确预测数与预测总数的比值,用于评估 CCDNN 网络的学习误差,即更高的测试精度意味着网络在学习过程中出现的误差更少,表明网络获得了更好的学习性能。本文通过

改变卷积层的数量,比较了部署正则化项和不部署正则化项时的性能,如表 4 所示。

表 4 不同数量卷积层和正则化项的测试精度

Table 4 Test accuracy of different number of convolution layers and regularization terms

卷积层数	算法	测试精度/%
8	DNN	96.004
	DNN+ L^2 正则运算	97.179 6
9	DNN	97.460
	DNN+ L^2 正则运算	98.271
10	DNN	98.332
	DNN+ L^2 正则运算	98.331
11	DNN	98.334
	DNN+ L^2 正则运算	98.335

从表 4 可以看出,当 CCDNN 框架部署少量卷积层时,借助正则化项 L^2 方法可以实现进一步的改进,这是由于正则化项可以抑制过拟合问题带来的风险。有正则化项的 CCDNN 框架的测试准确率总是略高于没有正则化项的 CCDNN 框架。值得一提的是,少量的卷积层并没有明显地降低测试精度,这意味着本文所提 CCDNN 框架具有鲁棒性和高效性。而表 5 显示了在不同隐藏层数量及正则化项配置下的精度对比。

表 5 不同数量隐藏层和正则化项的测试精度

Table 5 Test accuracy of different number of hidden layers and regularization terms

隐藏层数	算 法	测试精度/%
8	DNN	95.596
	DNN+ L^2 正则运算	96.223
9	DNN	97.511
	DNN+ L^2 正则运算	97.730
10	DNN	98.194
	DNN+ L^2 正则运算	98.205
11	DNN	98.331
	DNN+ L^2 正则运算	98.332

从表 5 可以看出,增加隐藏层的数量可以提高测试精度。然而,当隐藏层数接近 10 时,本文所提框架的精度提高幅度变小,可以忽略不计。此外,在隐藏层数较大的情况下,正则化项对 MIMO-NOMA 的性能不会产生显著影响。

4.5 系统的算法复杂度分析

为了评估本文 CCDNN 框架的计算复杂度,采用乘法累加计数(Multiplication and addition counts, MAC)作为度量,比较网络参数^[23,24]。MAC 可以在网络训练过程中,以乘法和加法的

形式度量参数的数量。为了直观地评估本文算法的计算复杂度,本节将本文所提 CCDNN 框架与基于 LSTM NOMA 的方案^[25]、基于深度学习辅助的 MIMO 功率分配方案^[26]中使用的功率分配数据集进行比较(见表6)。

表6 不同深度学习方法的 MAC 性能和运行时间

Table 6 MAC performance and runtime of different deep learning methods

算 法	MAC 性能/百万	运算时间/s
OMA ^[24]	0.54	43 921
NOMA ^[25]	0.52	43 921
CRS-NOMA ^[26]	0.09	9 894
本文算法	0.50	36 997

表6描述了这4种方案在训练过程中的 MAC 性能和运行时间。从表6中可以看出, CCDNN 框架的 MAC 不超过 0.5 百万,这在深度神经模型中是比较低的。此外,基于4个 Nvidia Quadro P6000 显卡的图形处理器,完全训练只需要 10.3 h 左右。这意味着 CCDNN 框架虽然与其他方法相比优势不大,但其计算复杂度处于可以接受范围。同时,由于本文提出的 CCDNN 框架可以在高性能服务器上进行完整的离线训练,并且在用户终端的运行阶段只需要很小的计算复杂度,因此本文提出的 CCDNN 框架即使在复杂庞大的数据集和场景下仍然是可行的。

5 结束语

为解决 MIMO-NOMA 系统中的功率分配优化问题,本文将深度学习集成到 MIMO-NOMA 系统中,提出了一种基于 CCDNN 的 MIMO-NOMA 系统框架。本文在提出功率分配问题后,首先设计了 CCDNN 网络框架,并在每层使用特定的激活函数。其次,提出了一种新的学习方法以提取 MIMO-NOMA 的重要空间特征,并训练所提 CCDNN 框架,该框架可分为离线学习状态和在线学习状态。利用深度学习良好的表示和映射能力,使复杂的 MIMO 系统能够在用户处获得准确的 CSI 和更好的 SIC 性能,并借助 CCDNN 的近似能力解决了功率分配优化问题。最后,本文进行了仿真分析,仿真结果验证了基于 CCDNN 的 MIMO-NOMA 框架的优越性能,并对 CCDNN 框架的鲁棒性进行了测试。在未来的工作中,拟将无线信道扩展到变衰落场景,其中功率分配需要遵循瞬时衰落条件。同时,尝试将新

兴的认知无线网络引入所提基于深度学习的 MIMO-NOMA 系统,并进一步优化 MIMO-NOMA 系统。此外,还将研究系统的安全和容量问题。

参考文献:

- [1] Saad W, Bennis M, Chen M Z. A vision of 6G wireless systems: applications, trends, technologies, and open research problems[J]. IEEE Netw, 2020, 34(3): 134-142.
- [2] Zhang H Z, Zhou T, Xu T H, et al. Remote interference discrimination testbed employing AI ensemble algorithms for 6G TDD networks[J]. Sensors, 2023, 23(4): No. 2264.
- [3] Akyildiz I F, Kak A, Nie S T. 6G and beyond: the future of wireless communications systems[J]. IEEE Access, 2020, 8: 133995-134030.
- [4] Zhu L P, Xiao Z Y, Xia X G, et al. Millimeter-wave communications with non-orthogonal multiple access for B5G/6G[J]. IEEE Access, 2019, 7: 116123-116132.
- [5] Jiao R C, Dai L L. On the max-min fairness of beam space MIMO-NOMA[J]. IEEE Transactions on Signal Processing, 2020, 68: 4919-4932.
- [6] 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.
- [7] Kaur J, Singh M L. User assisted cooperative relaying in beam space massive MIMO NOMA based systems for millimeter wave communications[J]. China Communications, 2019, 16(6): 103-113.
- [8] He H T, Wen C K, Jin S, et al. Deep learning-based channel estimation for beam space mmwave massive MIMO systems[J]. IEEE Wireless Communication letters, 2018, 7(5): 852-855.
- [9] Wu J Y, Xu T H, Zhou T, et al. Feature-based spectrum sensing of NOMA system for cognitive IoT networks[J]. IEEE Internet of Things Journal, 2023, 10(1): 801-814.
- [10] Wang J P, Cao F, He X Y, et al. Multi carrier system joint receiving method based on MAI and ICI[J]. Journal of Jilin University(Engineering and Technology Edition), 2018, 41(6):1793-1797.
- [11] 廖勇, 杨植景, 李雪. 人工智能在 6G 空口物理层的潜在应用研究进展[J]. 北京邮电大学学报, 2022, 45(6):21-30.

- Liao Yong, Yang Zhi-jing, Li Xue. Research progress of potential applications of AI in 6G air interface physical layer[J]. Journal of Beijing University of Posts and Telecommunications, 2022, 45(6): 21-30.
- [12] Tweneboah-Koduah S, Affum E A, Agyekum K A P, et al. Performance of cooperative relay NOMA with large antenna transmitters[J]. Electronics, 2022, 11(21): No. 3482.
- [13] Alraddady F, Ahmed I, Habtemicail F. Robust hybrid beam-forming for non-orthogonal multiple access in massive MIMO downlink[J]. Electronics, 2022, 11(1): No. 75.
- [14] Tang S Y, Ma Z, Xiao M, et al. Hybrid transceiver design for beam-space MIMO-NOMA in code-domain for mmWave communication using lens antenna array[J]. IEEE Journal on Selected Areas in Communications, 2020, 38(9): 2118-2127.
- [15] 胡相格, 吴广富, 李涛, 等. 基于 QoE 的 MIMO-NOMA 系统功率分配方案[J]. 北京邮电大学学报, 2021, 44(4): 62-67.
- Hu Xiang-ge, Wu Guang-fu, Li Tao, et al. Power allocation scheme for MIMO-NOMA system based on QoE[J]. Journal of Beijing University of Posts and Telecommunications, 2021, 44(4): 62-67.
- [16] Wang J P, Zou N Y, Zhang Y C, et al. Study on downlink performance of multiple access algorithm based on antenna diversity[J]. ICIC Express Letters, 2015, 9(4): 1221-1225.
- [17] Alimo D, Saito M. Beam selection for mm-wave massive MIMO systems using ACO & combined digital precoding under hybrid transceiver architecture[J]. IEICE Communications Express, 2020, 9(6): 170-175.
- [18] Qian L P, Wu Y, Yu N N, et al. Learning driven NOMA assisted vehicular edge computing via underlay spectrum sharing[J]. IEEE Transactions on Vehicular Technology, 2021, 70(1): 977-992.
- [19] Lu Y X, Cheng P, Chen Z, et al. Deep autoencoder learning for relay-assisted cooperative communication systems[J]. IEEE Transactions on Communications, 2020, 68(9): 5471-5488.
- [20] Ye N, Li X M, Yu H X, et al. Deep NOMA: A unified framework for NOMA using deep multi-task learning[J]. IEEE Transactions on Wireless Communications, 2020, 19(4): 2208-2225.
- [21] Saad M, Bennis M, Chen M. A vision of 6G wireless systems: applications, trends, technologies, and open research problems[J]. IEEE Network, 2020, 34(3): 134-142.
- [22] Lu Y X, Cheng P, Chen Z, et al. Deep multi-task learning for cooperative NOMA: system design and principles[J]. IEEE Journal on Selected Areas in Communications, 2021, 39(1): 61-78.
- [23] Sabuj S R, Asiedu D K P, Lee K J, et al. Delay optimization in mobile edge computing: Cognitive UAV-assisted eMBB and mMTC services[J]. IEEE Transactions on Cognitive Communications and Networking, 2022, 8(2): 1019-1033.
- [24] Corgnati L, Berta M, Kokkini Z. Assessment of OMA gap-filling performances for multiple and single coastal HF radar systems: validation with drift-er data in the ligurian sea[J]. Remote Sensing, 2024, 16(13): 2458-2471.
- [25] Wang X, Wang H T, Dong Z L. A NOMA-VLC power allocation scheme for multi-user based on sparrow search algorithm[J]. Optoelectronics Letters, 2023, 7: 1327-1336.
- [26] Tan Y Z, Chen B. Joint channel estimation and power allocation for the CRS-NOMA[J]. Chinese Journal of Electronics, 2020, 29(1): 177-182.