

北京邮电大学学报

Journal of Beijing University of Posts and Telecommunications

ISSN 1007-5321, CN 11-3570/TN

《北京邮电大学学报》网络首发论文

题目：一种应用于协作 MIMO-NOMA 系统的符号检测算法
作者：谢文武，李攀，肖健，王骥，杨亮
DOI：10.13190/j.jbupt.2023-135
收稿日期：2023-06-29
网络首发日期：2024-04-24
引用格式：谢文武，李攀，肖健，王骥，杨亮. 一种应用于协作 MIMO-NOMA 系统的符号检测算法[J/OL]. 北京邮电大学学报. <https://doi.org/10.13190/j.jbupt.2023-135>



网络首发：在编辑部工作流程中，稿件从录用到出版要经历录用定稿、排版定稿、整期汇编定稿等阶段。录用定稿指内容已经确定，且通过同行评议、主编终审同意刊用的稿件。排版定稿指录用定稿按照期刊特定版式（包括网络呈现版式）排版后的稿件，可暂不确定出版年、卷、期和页码。整期汇编定稿指出版年、卷、期、页码均已确定的印刷或数字出版的整期汇编稿件。录用定稿网络首发稿件内容必须符合《出版管理条例》和《期刊出版管理规定》的有关规定；学术研究成果具有创新性、科学性和先进性，符合编辑部对刊文的录用要求，不存在学术不端行为及其他侵权行为；稿件内容应基本符合国家有关书刊编辑、出版的技术标准，正确使用和统一规范语言文字、符号、数字、外文字母、法定计量单位及地图标注等。为确保录用定稿网络首发的严肃性，录用定稿一经发布，不得修改论文题目、作者、机构名称和学术内容，只可基于编辑规范进行少量文字的修改。

出版确认：纸质期刊编辑部通过与《中国学术期刊（光盘版）》电子杂志社有限公司签约，在《中国学术期刊（网络版）》出版传播平台上创办与纸质期刊内容一致的网络版，以单篇或整期出版形式，在印刷出版之前刊发论文的录用定稿、排版定稿、整期汇编定稿。因为《中国学术期刊（网络版）》是国家新闻出版广电总局批准的网络连续型出版物（ISSN 2096-4188，CN 11-6037/Z），所以签约期刊的网络版上网络首发论文视为正式出版。

一种应用于协作 MIMO-NOMA 系统的符号检测算法

谢文武¹, 李攀¹, 肖健², 王骥², 杨亮³

(1. 湖南理工学院 信息科学与工程学院, 岳阳 414006; 2. 华中师范大学 物理科学与技术学院, 武汉 430079; 3. 湖南大学 信息科学与工程学院, 长沙 410082)

摘要：受发射端的功率分配与叠加编码的影响，基于单任务神经网络的功率域非正交多址接入（NOMA）符号检测算法无法兼容不同用户的符号检测任务。针对用户辅助的协作多输入多输出（MIMO）-NOMA 通信系统，设计基于多任务神经网络的符号检测算法，通过学习协作 MIMO-NOMA 系统中信号的深层共享特征，实现不同用户的联合符号检测。由于协作通信中不同用户接收信号的数据分布不同，并且存在数据孤岛问题，而机器学习模型要求训练数据和测试数据均独立采样于同一数据分布，因此提出多任务联邦学习框架来解决这一问题。实验结果表明，随着信噪比的提高，所提出的符号检测算法较传统符号检测算法展现出更好的性能。

关键词：协作非正交多址接入；符号检测；多任务联邦学习

中图分类号：TN925+.1

文献标志码：A

A Symbol Detection Algorithm for Cooperative MIMO-NOMA Systems

XIE Wenwu¹, LI Pan¹, XIAO Jian², WANG Ji², YANG Liang³

(1. School of Information Science and Engineering, Hunan Institute of Science and Technology, Yueyang 414006, China; 2. School of Physical Science and Technology, Central China Normal University, Wuhan 430079, China; 3. School of Information Science and Engineering, Hunan University, Changsha 410082, China)

Abstract: Influenced by the power allocation and superposition coding at the transmitter side, the power-domain non-orthogonal multiple access (NOMA) symbol detection algorithm based on a single-task neural network is not compatible with the symbol detection task for different users. A symbol detection algorithm based on multi-task neural network is designed for user-assisted cooperative multiple-input Multiple-output (MIMO) -NOMA communication system, which can learn the deep shared features of data and detect symbols of different users simultaneously. In cooperative communication, the signal data received by different users are distributed differently, and there is a problem of data island. However, the training data and the test data are required by the machine learning model to be independently and equally distributed. Therefore, the multi-task federal learning framework is proposed to address this problem. The experimental results show that with the improvement of signal-noise-ratio (SNR), the proposed symbol detection algorithm has better performance than the traditional symbol detection algorithm.

Key words: cooperative non-orthogonal multiple access; symbol detection; multi-task federated learning

收稿日期：2023-06-29

基金项目：国家自然科学基金项目(62101205); 湖南省自然科学基金项目(2023JJ50045); 湖北省重点研发计划项目(2023BAB061)

作者简介：谢文武（1979—），男，副教授，硕士生导师。

通信作者：王骥（1986—），男，副研究员，硕士生导师，邮箱：jiwang@ccnu.edu.cn。

非正交多址接入(NOMA, non-orthogonal multiple access)技术通过引入新的维度,在功率域^[1]或者码域进行复用实现非正交方式传输,提升了系统容量和频谱效率。为提高距离基站(BS, base station)较远的小区边缘用户的可靠数据传输速率,引入协作通信技术提升信道条件较差的远场用户(FU, the far-field user)的数据速率^[2]。基于用户辅助的协作 NOMA 系统中利用信道条件较好的近场用户(NU, the near-field user)作为中继,可以降低工程部署开销,但要求用户设备具有足够的能量支撑,而无线携能通信技术则可以对此进行弥补^[3]。Ding 等^[4]和胡相格等^[5]将多输入多输出(MIMO, multiple-input multiple-output)技术的阵列增益和 NOMA 共享资源的优势相结合构建了 MIMO-NOMA 系统,可以提高系统吞吐量,但也使得接收端译码变得更加复杂。传统协作 MIMO-NOMA 系统中,NU 常采用串行干扰删除译码方法^[6],FU 则先使用最大比合并或选择性合并方式合并信号后再译码,两者很大程度上依赖信道状态信息估计的准确性,并存在误码传播。

深度学习技术的兴起给无线通信物理层的算法设计提供了一种新的设计思路^[7]。Lu 等^[8]应用深度自编码器(AE, auto-encoder)设计协作中继通信系统,并对比中继在放大转发(AF, amplify-and-forward)和解码转发(DF, decode-and-forward)情况下,用户采用最大比合并方式和选择性合并方式的符号检测性能,验证了神经网络相对传统方法可以获得更大的增益。Baek 等^[9]基于卷积神经网络和长短期记忆网络设计了 MIMO 系统接收机模型。Gui 等^[10]将长短期记忆网络用于 NOMA 系统实现用户浮号检测。Lin 等^[11]提出了基于深度神经网络(DNN, deep neural network)的符号检测算法,获得了更低的误符号率。

上述的基于 DNN 的 NOMA 符号检测算法均是基于正交多址接入系统的符号检测算法^[12]进行设计的。这类算法仅考虑从用户接收信号到对应用户发送符号的一对一映射,由于发射端的功率分配与叠加编码的影响^[12],导致现有的单任务神经网络不能同时用于 NU 和 FU 处的符号检测。此外,协作 NOMA 通信系统中 NU 接收信号与 FU 接收信号的数据分布不同,但标准的机器学习框架中神经网络要求训练数据和测试数据均独立采样于同一数据分布,因此单任务神经网络在线部署时需要根据本地用户的接收数据进行重新训练,这显著增加了神经网络训练开销。针对上述单任务神经网络的不足,Ye 等^[14]和 Lu 等^[15]采

用多任务学习思想,以 AE 为原型架构分别设计了端到端的单天线 NOMA 系统和协作 NOMA 系统,联合优化多址签名和多用户检测。然而,AE 需要一个可微分的信道模型,信道函数必须已知。现常采用线下方式训练神经网络,此时发送端网络模型不可微调,无法适用于 AE,得到的仅是次优解。

针对协作 MIMO-NOMA 系统的符号检测问题,笔者提出一种基于多任务神经网络的联合符号检测算法。所提出的多任务神经网络首先设计共享网络层获取协作 MIMO-NOMA 系统中 NOMA 符号信号的深层共享表征,然后在网络输出部分通过多个并行的任务网络层来实现不同用户的符号检测。考虑到采用集中式多任务学习框架训练时存在数据隐私泄露和传输开销增大的风险,引入联邦学习技术^[16],进一步提出一种多任务联邦学习框架来优化所提多任务神经网络的训练过程。仿真实验结果可得,所提算法较已有算法有更优的性能表现。

1 协作 MIMO-NOMA 系统模型

协作 MIMO-NOMA 系统下行链路如图 1 所示。BS 配备 T 根发射天线,每个用户配有 R 根天线,其中处于小区中心的 NU 充当半双工中继向处于小区边缘的 FU 传输信号。NOMA 采用主流的功率域复用模式来共享相同的时频资源块。协作 MIMO-NOMA 系统下行链路的数据传输分为 BS 传输和用户转发 2 个阶段,每个阶段都有相同的时间周期 t 。




图 1 协作 MIMO NOMA 系统下行链路

假设 \mathbf{x}_n 和 \mathbf{x}_f 分别为 NU 和 FU 的期待接收信息,在 BS 传输阶段,BS 通过叠加编码后的发射信号为^[1]

$$\mathbf{s} = \sqrt{P_b \theta_n} \mathbf{x}_n + \sqrt{P_b \theta_f} \mathbf{x}_f \quad (1)$$

其中: P_b 为 BS 的发射功率; θ_n 和 θ_f 分别为 NU 和 FU 的功率分配因子,满足 $\theta_n < \theta_f, \theta_n + \theta_f = 1$ 。

FU 所接收的 BS 直射信号为

$$\mathbf{y}_{b,f} = \mathbf{H}_{b,f} \mathbf{s} + \mathbf{n}_{b,f} \quad (2)$$

其中: $\mathbf{H}_{b,f} \in \mathbf{C}^{T \times R}$ 为 BS 到 FU 的信道矩阵, 服从标准差为 $\sigma_{b,f}$ 的瑞利分布; $\mathbf{n}_{b,f}$ 为高斯白噪声。

NU 所接收的 BS 直射信号为

$$\mathbf{y}_{b,n} = \mathbf{H}_{b,n} \mathbf{s} + \mathbf{n}_{b,n} \quad (3)$$

其中: $\mathbf{H}_{b,n}$ 为 BS 到 NU 的信道矩阵, 服从标准差为 $\sigma_{b,n}$ 的瑞利分布; $\mathbf{n}_{b,n}$ 为高斯白噪声。

考虑 NU 具有能量收集功能用于自身译码, 并且假设只收集信号功率而不收集天线噪声功率, 则 NU 收集的能量为

$$E_n = \rho \eta P_b |\mathbf{H}_{b,n}|^2 t \quad (4)$$

其中: ρ 为功率分割因子, $0 < \rho < 1$; η 为能量转换效率, $0 \leq \eta \leq 1$ 。

因此, 具有能量收集功能的 NU 接收信号可以改写为

$$\mathbf{y}_n = \sqrt{1-\rho} \mathbf{H}_{b,n} \mathbf{s} + \mathbf{n}_{b,n} \quad (5)$$

在用户转发阶段, NU 将收到的信号转发给 FU, 假设所有收集的能量都被使用, 中继转发协议为 AF 协议, 则 FU 从 NU 处所接收的信号为

$$\mathbf{y}_{n,f} = \lambda \mathbf{H}_{n,f} \mathbf{y}_n + \mathbf{n}_{n,f} \quad (6)$$

其中: λ 为 AF 因子, $\lambda = \sqrt{P_n / (P_b |\mathbf{H}_{b,n}|^2 + N_0)}$, $P_n = E_n / t = \rho \eta P_b |\mathbf{H}_{b,n}|^2$, N_0 为高斯白噪声方差;

$\mathbf{H}_{n,f}$ 为 NU 到 FU 的信道矩阵, 服从标准差为 $\sigma_{n,f}$ 的瑞利分布; $\mathbf{n}_{n,f}$ 为高斯白噪声。

对于 AF 协议, 理论上接收端使用最大比合并可以获得最大的信噪比增益, 因此在传统基准方法上, FU 将所接收的 BS 直射信号与 NU 转发信号进行最大比合并。FU 处合并的接收信号为

$$\mathbf{y}_f = \mathbf{H}_{b,f}^* \mathbf{y}_{b,f} + (\lambda \mathbf{H}_{b,n} \mathbf{H}_{n,f})^* \mathbf{y}_{n,f} \quad (7)$$

其中*为共轭转置。

2 算法设计

2.1 多任务学习框架

现有的基于单任务神经网络的 NOMA 符号检测算法仅针对单个用户进行符号检测, 而把其他用户信号作为噪声。实际上, 由于每个用户所接收得 NOMA 信号中都包含了其他用户的信号, 因此不同用户所接收的信号具有相关性。因此, 笔者提出一种低层共享的多任务学习框架, 如图 2 所示。将协作 MIMO-NOMA 系统中 K 个用户的符号检测算法设计视为 K 个相关联子任务。在所提出的多任务学习框架中, 每个子任务通过更新共享层中的公共权值参数来影响其他子任务, 权重共享发生在较低的层次上。每个子任务都以自己独特的方式构建在共享的低层次表示之上, 在多任务学习框架的最后输出部分, 则针对不同子任务权值不同的网络层。

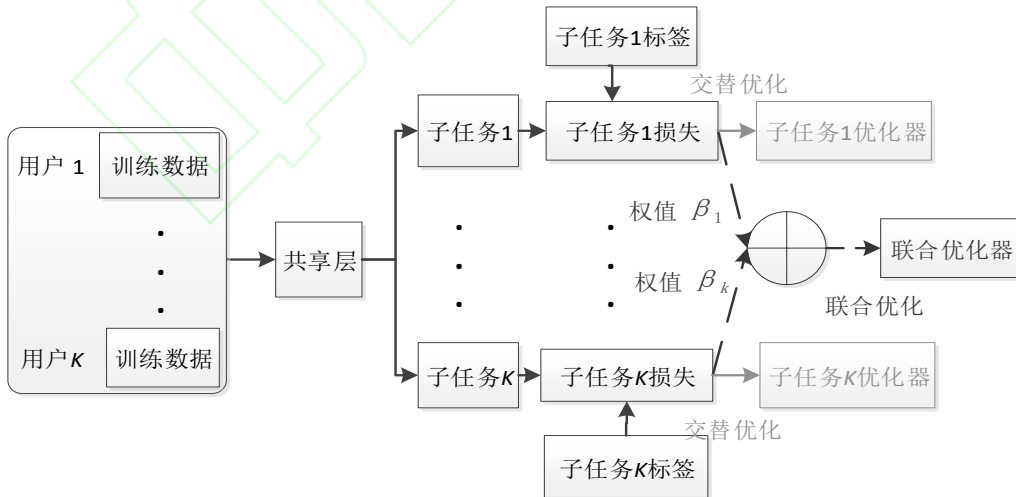


图2 低层共享的多任务学习框架

多任务学习框架的优化方式包括交替优化和联合优化^[17], 其中联合优化具体可以分为固定权值优化和联合自动优化。交替优化方式通过单独优化每个子任务的代价函数来使得每个子任务达到最优, 然而交

替优化可能会导致优化过程不稳定。联合优化方式是将损失函数进行加权合并, 得到全局最优解的联合训练优化。多任务学习框架联合优化的损失函数一般形式为

$$L_{\text{int}} = \sum_k^K \beta_k L_k \quad (8)$$

其中: K 表示子任务的数量, β_k 为每个子任务损失函数的加权值, L_k 为第 k 个子任务的损失函数。当采用固定权重优化时, β_k 为预设的固定超参数。

对于 NOMA 信号, 由于不同用户信号所分配的功率不同, 所以不同用户的符号检测的相对难度不同, 因此可以借鉴文献[18]中任务依赖不确定性的思想, 设计可以自动优化 β_k 的多任务损失函数。基于神经网络的符号检测问题可以转换为调制信号星座点分类问题, 则 K 个分类子任务的联合损失函数为

$$L_{\text{int}} \approx \sum_{k=1}^K \left(\frac{1}{\sigma_k^2} L_k + \text{lb} \sigma_k^2 \right) \quad (9)$$

其中 σ_k 为网络中第 k 个子任务的观测噪声参数, 表示输出数据中的噪声量。对于分类模型, L_k 可以用交叉熵损失表示为

$$L_k = -a_k \ln g_k(\mathbf{x}) \quad (10)$$

其中: $g_k(\mathbf{x})$ 为当输入数据为 \mathbf{x} 时多任务学习框架中的第 k 个子任务网络层的输出, a_k 为第 k 个子任务的期待输出。

式(9)中 σ_k 为一个网络可学习的参数, 较大的 σ_k 表示对应子任务不确定性大, 会降低 $L_k(w)$ 的影响, 较小的 σ_k 表示对应子任务不确定性小, 会增大 $L_k(w)$ 的影响。 $\text{lb} \sigma_k^2$ 表示对损失函数的惩罚, 一旦 σ_k 太大时, 损失函数将变成一个常数。此外, 该损失函数平滑可微并且可以使得子任务权重不会收敛到零。

2.2 多任务联邦学习框架

由于多任务学习框架需要提前获取 NU 和 FU 处的接收信号来构建数据集, 如果采用传统的集中学习方式, 会产生用户数据隐私泄露的风险。与此同时, 将大量数据传输到 BS 的过程会产生巨大的传输开销。为解决上述问题, 将联邦学习引入至已有的多任务学习框架, 开发出一种改进的多任务联邦学习框架, 通过在链路中传输网络模型取代直接传输用户数据。

令 D_k 表示第 k 个用户处的数据集, 大小为 n_k , $f_i(w)$ 表示给定神经网络参数为 w 的条件下, 关于第 i 个样本的损失, 则联邦学习的优化目标为最小化非凸的全局代价函数:

$$\min_{w \in R^d} f(w) = \sum_{k=1}^K \frac{n_k}{n} F_k(w) \quad (11)$$

其中, $F_k(w) = \frac{1}{n_k} \sum_{i \in D_k} f_i(w)$ 表示第 k 个用户处所有样

本的平均损失。

若 D_k 是通过将训练样本均匀随机地分布在用户上而形成的分区, 则有 $E_{D_k} [F_k(w)] = f(w)$, 此时不同用户的数据属于独立同分布, 优化方式为典型的分布式学习算法。而对于协作 NOMA 系统, NU 和 FU 的接收信号为非独立同分布情况, 因此使用联邦平均算法来缓解此种问题。若用户 k 从 BS 处下载网络模型, 使用本地数据进行网络训练, 经过 t 次迭代后所得到的神经网络参数为 w_{t+1}^k , 则 w_{t+1}^k 可以表示为

$$w_{t+1}^k = w_t - \eta g_k \quad (12)$$

其中 $g_k = \nabla F_k(w_t)$ 为用户 k 每次完整训练所计算的梯度。

所有用户所计算的自身模型参数再上传至 BS 进行聚合得到第 t 次迭代时全局的神经网络参数 $w_{t+1} \leftarrow \sum_{k=1}^K \frac{n_k}{n} w_{t+1}^k$ 。通过凸优化理论可以证明联邦平均策略在经过多次通信回合后神经网络可以实现收敛。

2.3 基于多任务神经网络的符号检测算法

基于上述的多任务联邦学习框架, 本节将具体阐述用户本地侧的多任务神经网络架构设计, 从用户天线所接收到的多路并行信号进行 MIMO 检测, 在一个时隙进行切片, 将接收信号视为一个向量进行联合检测。图 3 所示为多任务网络模型, 其中, N_1, N_2 分别为 NU 和 FU 的调制阶数, $N = \max(N_1, N_2)$ 。网络输入层的神经元数量为 $2 \times R$, 其对应某时刻用户接收的 $(1, R)$ 符号向量, 即式(5)中 y_n 和式(7)中 y_f , 其中复数符号的实部和虚部先进行分离后再在同一维度拼接作为网络输入。在输入层后加入一个批量归一化(BN, batch normalization)层使得数据分布标准化。网络共享层分为完全共享层和专家共享层, 两者都为包含全连接(FC, fully connected)层, BN 层和 LeakyReLU 激活函数层的全连接块结构。

共享层的 BN 层作用略不同于输入层, 它是将经过 FC 层后的数据分布拉到服从均值为 0, 方差为 1 的正态分布, 使得 LeakyReLU 函数的输入值可以落入更敏感的区间, 以避免梯度消失的问题。

网络最后一个部分为多任务层, 每个子任务层首先经过一个全连接块进行子任务特征提取, 然后通过 FC 层和 softmax 激活函数分类层组成子任务层的输出部分。因为 MIMO-NOMA 系统中 BS 的发射天线数为 T , 每根天线的发射信号都是 NU 和 FU 信号的叠加编码。将符号检测转换为星座点分类问题, 则 NU 和 FU 子任务输出层的神经元数量分别为 $N_1 T$ 和 $N_2 T$,

最后使用 softmax 函数计算每个节点的输出概率为

$$\text{softmax}(z_i) = e^{z_i} / \sum_{c=1}^C e^{z_c} \quad (13)$$

其中: C 为协作 MIMO-NOMA 符号的所有可能类别, z_i 为网络的第 i 个节点输出。

多任务神经网络为实现式(9)联合损失函数中加权系数的自动优化, 所以根据式(9)额外设计损失函数网络层去优化参数 σ_k 以获得子任务层的整体最优。

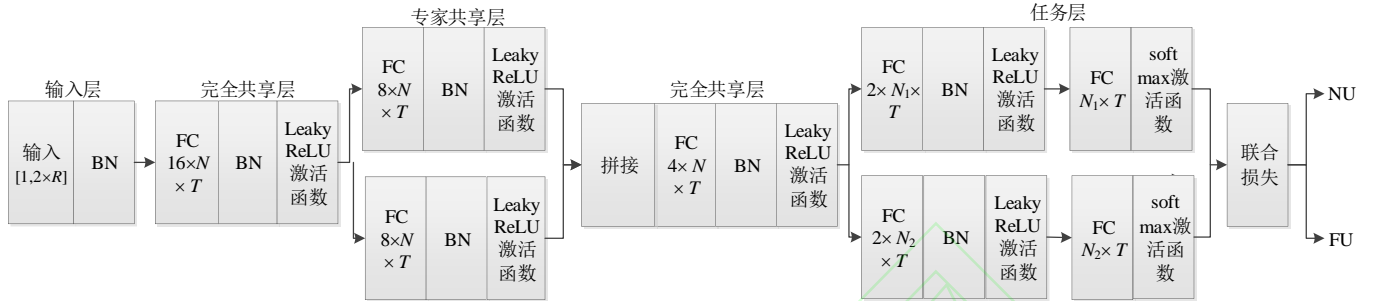


图3 多任务网络模型

所提出的协作 MIMO-NOMA 符号检测算法的整体算法流程如算法 1 所示, 整个算法分为 3 个阶段: ①初始化阶段进行相关参数的初始化; ②在网络离线训练阶段, 在用户处计算网络梯度, 更新本地网络权重, 然后 BS 处进行梯度聚合; ③在线测试阶段, 用户分别根据接收信号 y_n 和 y_f 来预测期待接收信息 x_n

和 x_f 。

算法 1 基于多任务联邦学习的符号检测算法

1 初始化阶段

网络权重 w , 本地训练周期 L , 通信回合 U
一个通信回合内本地训练迭代次数 $l=0$
通信回合迭代次数 $u=0$ 。

2 网络离线训练阶段

3 if $u < U$

4 $u = u + 1$

5 if $l < L$

6 根据损失函数式(10)计算损失

7 根据式(12)更新本地神经网络参数 w_{t+1}^k

8 $l = l + 1$

9 else

10 根据公式 $w_{t+1} \leftarrow \sum_{k=1}^K \frac{n_k}{n} w_{t+1}^k$ 进行梯度聚合

11 $l = 0$

12 else

13 网络训练完成, 冻结网络权重 w_{t+1}^k

14 网络在线测试阶段: 用户分别根据接收信号 y_n 和 y_f 预测期待接收信息 x_n 和 x_f

3 性能分析

在协作 MIMO-NOMA 系统下行链路仿真通信系统中设置 $T = R = 4$, $K = 2$, $P_b = 4 \text{ W}$, $\theta_n = 1/5$, $\theta_f = 4/5$ 。平均信道功率增益 $\Omega = (1 + d^p)^{-1}$, d 为每条通信链路两端的距离, $p = 2$ 为路径损耗因子, 所有信道的小尺度衰落服从瑞利分布。BS 到 FU 距离为 10 m, BS 到 NU 的距离为 3 m, NU 到 FU 距离为 8 m。当 $\rho = 0.5$ 时有最小的系统中断概率, 故设置 $\rho = 0.5$, $\eta = 0.7$ 。调制方式采用二进制相移键控^[10]。通过该仿真通信系统产生数据时, 信噪比范围设置为 0~20 dB, 并以 2 dB 为间隔, 相同信噪比下产生 1.28×10^6 个符号样本。因此总的训练样本数量为 $D = 11 \times \sum_{k=1}^K D_k$, 通信系统仿真采用基带等效模型, 每个样本为用户一个时隙内所有天线接收信号。多任务联邦学习框架中通信回合数设置为 $\zeta = 500$ 。

图 4 所示为基于多任务神经网络的符号检测算法和现有符号检测方法的误符号率, 包括传统基于串行干扰删除的 NU 符号检测算法和基于最大合并比方法的 FU 符号检测算法, 以及经典的基于单任务神经网络的符号检测算法。单任务神经网络所采用的网络结构为只考虑 1 个子任务时的网络结构, 为达到与多

任务神经网络相同的数据兼容性，在用户终端部署了 2 个单任务神经网络。




图 4 不同信号检测方法下用户的误符号率

由图 4 可知，对于 NU，低信噪比时传统检测方法与基于神经网络的检测方法的误符号率接近，随着信噪比的增加，单任务神经网络和多任务神经网络的检测性能均优于传统方法，表明基于数据驱动的符号检测算法可以更好地学习到未知的信道特性。对于 FU，低信噪比时最大比合并作为最优的分集合并方式可以获得最好的信噪比，其误符号率比基于神经网络的符号检测方法更低。而神经网络则是将传统方法中的分集合并与符号检测 2 个步骤由一个网络模型同时完成。与 NU 检测结果类似的是，高信噪比下神经网络检测方法相较于传统方法展现出了更好的性能。所设计的多任务神经网络直接部署在 FU 侧时，数据驱动的端到端模块化处理，使神经网络学习到了分集合并和符号检测的联合增益。其中多任务神经网络可以充分挖掘近场信号和远场信号的共享知识，能够获得比单任务神经网络更好的性能。

图 5 所示为 3 种多任务神经网络优化方式下 FU 和 NU 的误符号率，其中固定权值优化中 β_k 固定为 0.5。由图 5 可知，对于 FU，在较高信噪比下，损失函数的联合优化可以取得更低的误符号率。联合优化的目标是整体的最优而避免局部最优，然而交替优化则容易对某一子任务产生偏向。




图 5 不同的网络优化方式下用户的误符号率

多任务神经网络与单任务神经网络的可训练参数量和浮点运算次数如表 1 所示。由于需要多个单任务神经网络才可以实现多个用户的符号检测，而多任务神经网络只需要在增加部分的子任务输出层便可以实现多用户检测，因此单任务可训练参数量接近多任务神经网络的 2 倍，且联合训练时，其相对于单任务神经网络的浮点运算量也具有优势。

表 1 2 种神经网络的可训练参数量与浮点运算次数

神经网络	可训练参数量/个	浮点运算次数/次
单任务神经网络	46160	190648
多任务神经网络	23252	156679

图 6 所示为多任务神经网络中分别使用集中学习框架和联邦学习框架时 NU 和 FU 的误符号率。可见，使用多任务神经网络使用联邦学习时比集中学习的性能更好，这是因为联邦学习具有一定的泛化能力，可以产生与 dropout 正则化相似的效果，在一定程度上可以缓解网络过拟合现象。

所提出的多任务集中学习框架在整个训练过程通信开销为 $\gamma_1 = 2(R+T)D$ 。多任务联邦学习框架的通信开销为 $\gamma_2 = \zeta \sum_{k=1}^K v_k$ ，其中 v_k 为第 k 个用户所传输的模型参数。结合实验参数设置，多任务集中学习框架和多任务联邦学习框架的通信开销分别为 $\gamma_1 = 225280000$ 和 $\gamma_2 = 11626000$ ，联邦学习的通信传输开销明显较低。




图 6 不同学习方式时用户的误符号率

4 结束语

针对已有基于深度学习的 NOMA 下行链路符号检测算法具有易忽视其他用户信号有用信息的不足，根据 NOMA 信号的叠加编码特性，笔者提出了一种基于多任务神经网络的符号检测算法。考虑数据隐私和数据传输带宽问题，笔者引入了多任务联邦学习框

架, 实现在数据不离开用户本地情况下完成神经网络训练, 使得所提算法得到进一步的完善。仿真实验表明, 所提算法获得更低的系统误符号率。由于协作 NOMA 系统中用户之间可以相互通信, 因此, 下一步研究方向是将所提出符号检测算法中的多任务联邦学习框架部分理论上改进为基于设备到设备通信的联邦学习, 从而避免过分依赖 BS 而容易产生的单点故障问题。

参考文献

- [1] ISLAM S M R, AVAZOV N, DOBRE O A, et al. Power-domain non-orthogonal multiple access (NOMA) in 5G systems: potentials and challenges[J]. IEEE Communications Surveys & Tutorials, 2016, 19(2): 721-742.
- [2] DING Z G, PENG M G, POOR H V. Cooperative non-orthogonal multiple access in 5G systems[J]. IEEE Communications Letters, 2015, 19(8): 1462-1465.
- [3] LIU Y W, DING Z G, ELKASHLAN M, et al. Cooperative non-orthogonal multiple access with simultaneous wireless information and power transfer[J]. IEEE Journal on Selected Areas in Communications, 2016, 34(4): 938-953.
- [4] DING Z G, ADACHI F, POOR H V. The application of MIMO to non-orthogonal multiple access[J]. IEEE Transactions on Wireless Communications, 2016, 15(1): 537-552.
- [5] 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 X G, WU G F, Li T, et al. Power allocation scheme of MIMO-NOMA system based on QoE[J]. Journal of Beijing University of Posts and Telecommunications, 2021, 44(4):62-67.
- [6] HIGUCHI K, BENJEBBOUT A. Non-orthogonal multiple access (NOMA) with successive interference cancellation for future radio access[J]. IEICE Transactions on Communications, 2015, 98(3): 403-414.
- [7] 廖勇, 杨植景, 李雪. 人工智能在 6G 空口物理层的潜在应用[J]. 北京邮电大学学报, 2022, 45(6):21-30.
LIAO Y, YANG Z J, LI X. 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.
- [8] 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.
- [9] BAEK M S, KWAK S, JUNG J Y, et al. Implementation methodologies of deep learning-based signal detection for conventional MIMO transmitters[J]. IEEE Transactions on Broadcasting, 2019, 65(3): 636-642.
- [10] GUI G, HUANG H J, SONG Y W, et al. Deep learning for an effective nonorthogonal multiple access scheme[J]. IEEE Transactions on Vehicular Technology, 2018, 67(9): 8440-8450.
- [11] LIN C, CHANG Q, LI X X. A deep learning approach for MIMO-NOMA downlink signal detection[J/OL]. Sensors, 2019, 19(11)[2023-5-20]
<https://www.mdpi.com/1424-8220/19/11/2526>
- [12] YE H, LI G Y, JUANG B H. Power of deep learning for channel estimation and signal detection in OFDM systems[J]. IEEE Wireless Communications Letters, 2017, 7(1): 114-117.
- [13] VANKA S, SRINIVASA S, GONG Z, et al. Superposition coding strategies: design and experimental evaluation[J]. IEEE Transactions on Wireless Communications, 2012, 11(7): 2628-2639.
- [14] YE N, LI X M, YU H X, et al. DeepNOMA: a unified framework for NOMA using deep multi-task learning[J]. IEEE Transactions on Wireless Communications, 2020, 19(4): 2208-2225.
- [15] 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.
- [16] MCMALAN H B, MOORE E, RAMAGE D, et al. Communication-efficient learning of deep networks from decentralized data[C]// 20th International Conference on Artificial Intelligence and Statistics(AISTAIS) 2017. Fort Lauderdale: JMLR, 2017: 1273-1282.
- [17] ZHANG Y, YANG Q. An overview of multi-task learning[J]. National Science Review, 2018, 5(1): 30-43.
- [18] KENDALL A, GAL Y, CIPOLLA R. Multi-task learning using uncertainty to weigh losses for scene geometry and semantics[C]// 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. New York: IEEE, 2018: 7482-7491.