

基于低复杂度加法网络的非正交多址接入短报文多用户检测算法研究

王骥^① 李子龙^② 肖健^① 李涣哲^② 谢文武^{*②} 余超^②

^①(华中师范大学物理科学与技术学院 湖北 武汉 430079)

^②(湖南理工学院信息科学与工程学院 湖南 岳阳 414006)

摘要: 针对非正交多址接入(NOMA)系统中, 接收机使用串行干扰删除算法译码时需要已知干扰用户的调制方式而产生额外的信令开销问题, 该文提出一种基于联合星座轨迹图和深度学习的NOMA短包传输干扰用户调制方式盲检测算法。考虑在通信设备部署神经网络时存在计算复杂度高和能量消耗大等不足, 将原始卷积神经网络替换为深度加法网络, 在调制检测准确率, 计算延迟和能耗等方面进行了充分比较, 使用时域过采样技术改善低信噪比下的识别率。最后分析并验证了功率分配, 数据包长度对检测性能的影响。

关键词: 非正交多址接入; 调制检测; 深度加法网络; 过采样

中图分类号: TN911

文献标识码: A

文章编号: 1009-5896(2024)06-2409-09

DOI: [10.11999/JEIT231186](https://doi.org/10.11999/JEIT231186)

Research on Multi-User Detection Algorithm for Non-Orthogonal Multiple Access Short Message Based on Low Complexity Adder Network

WANG Ji^① LI Zilong^② XIAO Jian^① LI Huanzhe^②
XIE Wenwu^② YU Chao^②

^①(College of Physical Science and Technology, Central China Normal University, Wuhan 430079, China)

^②(School of Information Science and Engineering, Hunan Institute of Science and Technology, Yueyang 414006, China)

Abstract: A joint constellation trace diagram and deep learning-based blind modulation detection scheme is proposed for Non-Orthogonal Multiple Access (NOMA) systems, which can avoid the required expensive signaling overhead in successive interference cancellation algorithms, especially for NOMA-based short packet transmission. Considering the high computational complexity and energy consumption for communication equipment in the deployment of neural network, the original convolutional network is replaced by the adder network. The modulation detection accuracy, computing delay and energy consumption are fully compared for two kinds of network architectures. Meanwhile, time-domain oversampling technology is used to improve the recognition rate under low signal-to-noise ratio. Finally, the influence of power allocation and data packet length on detection performance is analyzed and verified.

Key words: Non-Orthogonal Multiple Access (NOMA); Modulation detection; Deep adder network; Oversampling

收稿日期: 2023-10-31; 改回日期: 2024-03-15; 网络出版: 2024-04-01

*通信作者: 谢文武 gavinxie@hnist.edu.cn

基金项目: 国家自然科学基金(62101205, 62372070), 湖北省重点研发计划(2023BAB061), 湖南省研究性创新项目(QL20230275, CX20231220), 湖南省自然科学基金(2023JJ50045), 湖南省大学生创新创业项目(S202310543040)

Foundation Items: The National Natural Science Foundation of China (62101205, 62372070), The Key Research and Development Program of Hubei Province (2023BAB061), The Research and Innovation Projects in Hunan Province (QL20230275, CX20231220), Hunan Provincial Natural Science Foundation (2023JJ50045), Hunan Provincial College Students' Innovation and Entrepreneurship Projects (S202310543040)

1 引言

大规模机器通信(massive Machine-Type Communications, mMTCs)旨在实现海量物联网(Internet of Things, IoT)设备的智能连接,而无需人工干预^[1]。mMTC中大量设备以零星的方式传输短数据包,由于设备数量多而可用无线电资源有限,基于正交多址接入(Orthogonal Multiple Access, OMA)的资源分配成为mMTC性能瓶颈。非正交多址接入(Non-Orthogonal Multiple Access, NOMA)被认为是一种有希望提供大规模连接的关键技术^[2,3]。它通过功率域复用或码域复用从而允许多个用户在同一信道资源上同时传输数据^[4-7]。NOMA作为一种数据叠加传输方式,提升系统吞吐量的同时,也增加了接收端正确译码的难度。目前串行干扰删除(Successive Interference Cancellation, SIC)为NOMA系统常用译码方法^[8]。在NOMA下行链路传输中,当近场用户(Near field User, UN)译码时,必须首先解调远场用户(Far field User, UF)信号,然后从接收信号中减去远场信号,再根据近场调制方式解调自身信号。因此UN译码时需要已知UF的调制方式,这会带来不必要的信令开销。特别对于传输短数据包同时要求低时延的mMTC场景,需要设计NOMA下行链路中干扰用户调制方式的盲检测算法来避免信令开销。

从信号的调制方式上看,NOMA信号因其在发射端采用了叠加编码,所以属于一种时频完全混叠的调制信号,不同于OMA系统中因为信道环境重叠导致在接收端产生的单通道时频混叠信号,单通道信号在时域或频域往往存在差异,基于这种差异可以设计相应的调制检测算法^[9]。当存在高斯白噪声并且候选调制方案是等可能的情况下,最大似然算法已被验证在OMA系统中能够提供最佳性能^[10],文献[11]将其应用于NOMA信号调制检测,但该算法具有较高复杂度,实际实现存在困难。文献[12]扩展OMA系统中的基于高阶累积量的调制识别算法到NOMA系统,其相较于最大似然算法可以明显降低计算复杂度。文献[13]使用Anderson-Darling检验提取特征然后采用机器学习方法分类检测,但是该特征的性能受噪声和信道衰落影响较大,要求在信号检测之前必须进行有效的信道均衡。

人工智能(Artificial Intelligence, AI)被认为是B5G/6G的关键技术之一并期待其能重新定义通信设计理念^[12-14]。深度学习技术作为人工智能算法中的重要组成,因其对样本数据强大的特征学习能力,启发了相关研究人员将深度学习应用于通信信号识别领域,从而避免传统技术需要人工设计特征

且特征鲁棒性差等问题^[15-17]。目前深度学习应用于通信的掣肘之一就是神经网络训练所消耗的计算资源太大。虽然图像处理单元(Graphics Processing Units, GPU)的快速发展可以满足深度学习的计算需求。但是对于大量的IoT设备和移动设备很难去配备高计算能力的GPU。与此同时,文献[18]测试了几种大型AI模型的网络训练时的二氧化碳排放量可以达到283 948.8 kg。因此基于AI的通信算法原型设计如何满足B5G/6G提出的绿色节能通信需求也是亟需解决的挑战。

深度神经网络中包含大量网络权值之间的乘法运算,而乘法运算所消耗的能量和计算时延都大于加法运算。文献[19]通过替换卷积网络(Convolution Network, ConvNet)的互相关相似性度量为曼哈顿距离度量,从而提出一种可以用加法操作替代卷积操作的加法网络(Adder Network, AdderNet)。传统的基于星座图模板匹配的调制识别算法常以求解对应位置的平方距离来设计分类器^[20]。因两者度量方式的相似性,本文基于深度AdderNet和联合星座图设计了NOMA系统中干扰用户调制方式盲检测算法。调制检测网络使用残差单元作为AdderNet的基本结构块,避免网络过拟合和梯度消失或爆炸问题^[21],并使用过采样技术将输入数据从联合星座图调整为星座轨迹图进一步改善低信噪比下的调制检测性能。

2 系统模型

本文所研究的系统模型如图1所示,考虑单小区两用户功率域NOMA下行链路^[11-13],基站首先使用两个调制器将对应用户的数据流编码成两路复信号,根据用户信道增益确定不同的功率因子,再将这两路复信号叠加实现在同一时频资源块上传输两个用户信息,叠加编码后信号流为

$$x(n) = \sqrt{\alpha_1 P} x_1(n) + \sqrt{\alpha_2 P} x_2(n) \quad (1)$$

其中, α_1 和 α_2 为功率分配因子,满足 $\alpha_1 + \alpha_2 = 1$; P 为发射总功率; x_1 和 x_2 为分别发送给用户1和用户2的调制信号; n 为当前时间点;对于相移键控法(Phase Shift Keying, PSK)调制方式, $x_i(n) = e^{j(2i+1)\pi/M}$, $i = 0, 1, \dots, M-1$;对于正交幅度调制(Quadrature Amplitude Modulation, QAM)调制方式 $I(n), Q(n) \in \{2i-M/4+1, i = 0, 1, \dots, M/4-1\}$, M 为调制阶数。

NOMA系统中发送端的功率分配算法对接收端信号的正确检测有重要影响,最优功率分配算法如迭代注水功率分配算法往往计算量过大,所以本文采用次优分数阶功率分配算法^[22]。用户 u_n 的功率分配系数 $\beta(n)$ 为




图1 两用户NOMA下行链路

$$\beta(n) = \frac{1}{\sum_{k \in S} (g(k)/w(k))^{-\alpha_{\text{fpc}}}} \left(\frac{g(n)}{w(n)} \right)^{-\alpha_{\text{fpc}}} \quad (2)$$

其中, $g(n)$ 表示等效信道增益; $w(n)$ 表示噪声和干扰信号的功率; α_{fpc} 表示分数阶功率分配算法衰减因子, 衰减因子越大将会为信道条件较差的用户分配更大的功率; $g(k)$ 表示用户的信道增益; $w(k)$ 表示当前用户的噪声和干扰信号的功率。

数字传输系统常采用具有升余弦频谱特性的成型滤波来压缩基带信号频谱, 其时域冲激响应 $\rho_{\Gamma}(t)$ 为

$$\rho_{\Gamma}(t) = \frac{\sin(\pi t/T)}{\pi t/T} \cdot \frac{\cos(\mu \pi t/T)}{1 - 4\mu^2 t^2/T^2} \quad (3)$$

其中, μ 为滚降系数, 且 $0 \leq \mu \leq 1$; T 为码元周期。

基站发射的基带等效信号可以表示为

$$\begin{aligned} s(t) &= x(t) * \rho_{\Gamma}(t) \\ &= \sum_{n=-\infty}^{\infty} x(n) \delta(t - nT) * \rho_{\Gamma}(t) \\ &= \sum_{n=-\infty}^{\infty} x(n) \rho_{\Gamma}(t - nT) \end{aligned} \quad (4)$$

其中, $*$ 表示卷积; $\delta(t)$ 为单位冲激函数。

UN的接收信号可以表示为

$$r(t) = h(t) * s(t) + w(t) \quad (5)$$

其中, $h(t)$ 为信道衰落, $w(t)$ 为加性高斯白噪声。

在接收端首先进行匹配滤波来提高判决的准确性, 最佳匹配滤波器系统函数 $\rho_{\text{R}}(t)$ 是成型滤波器 $\rho_{\Gamma}(t)$ 的共轭匹配, 然后对处理后的信号进行采样, 最后得到采样后的接收序列 $r(n)$ 为

$$r(n) = \sum_{k=-\infty}^{\infty} r(k) \rho_{\text{R}}(n - kT) \quad (6)$$

UN的SIC译码如图1所示, 用户需要先解调UF信号, 然后在从接收信号中减去UF信号, 最后

再解调UN信号。这意味着基站必须通过控制信道或其它方式向UN发送信令来告知UF的调制方式, 而信令开销将会增加整个系统数据传输的时延。

3 干扰用户调制检测算法设计

3.1 联合星座图

多用户信号经过叠加编码后的星座图称为联合星座图, 将不同信号在功率域上进行划分会影响整个信号的星座域表征, 图2为UN与UF在不同SNR差值(Discrepancy in different SNR, D-SNR)下使用分数阶功率分配算法的联合星座图。当D-SNR越大时, UF会被分配更高的功率, 此时联合星座图的整体分布将会朝UF的正交相移键控(Quadrature Phase Shift Keying, QPSK)星座图发展, 而星座点数会接近于64QAM星座图。因为多个用户信号叠加的NOMA信号, 其联合星座图阶数会等价于高阶QAM调制方式, 此时NOMA系统的叠加传输方式在提高系统容量的同时, 传输符号也更易受噪声干扰, 导致低信噪比下的联合星座图会丧失理想的分布特征。

过采样技术可以将通信信号平稳循环化^[23], 因此常被用于传统通信信号处理中, 包括盲均衡, 盲检测和盲源分离等领域。文献[24]应用过采样技术提取星座轨迹图来增强射频指纹分类的性能。为了增强用户接收短包NOMA信号的特征, 本文在接收端采用高于发射端的采样率进行判决采样, 以获得联合星座轨迹图作为信号特征。假设过采样后的码元周期为 T_s , 则过采样倍数 $\text{OSF} = T/T_s$ 。图3是在图2基础上发展的联合星座轨迹图。接收机在实际处理通信信号时, 一般是逐步逐级进行降采样。因此在接收机中部署本文设计的调制识别算法时, 可根据实际情况和系统性能要求, 将调制识别模块部署在对应的降采样阶段。

将星座图的空间划分为一个矩形网格, 由于信

道条件和噪声的干扰，对于每一个分辨单元，它可能具有一个以上的顶点。通过对每个分辨单元内恢复的星座图顶点的数目进行直方图分析，就可以构造星座图形状的空间统计特性。从图4的直方图统计可以看出受像素密度的限制，一个像素点内可能有多个信号样本点。为更好体现不同信号间联合星座图的区别，本文将统计固定区域内像素的数量计算出散点密度，并将其转换为该区域的像素强度值，从而产生联合星座密度图。

传统星座模板匹配特征的调制识别方法基于距离度量思想^[20]。假设共有 N 种不同的调制方式，每种调制方式具有唯一的星座图作为标示。将预处理(如盲均衡和聚类)后得到的星座图 C_p 和模板 $j = 1, 2, \dots, N$ 中的 C_j 比较，得到相似指数 sim_j 。即

$$\text{sim}_j = \sum_{i=1}^{N_c} (|C_{pi} - C_{ji}|^2) \quad (7)$$

其中 N_c 为星座点数。

3.2 深度加法网络

ConvNet通过数据之间大量的卷积运算来实现特征提取，而卷积运算又包含乘法和加法两种操作，对于硬件设备而言，乘法操作在计算延迟和能量消耗上都大于加法操作。分类任务需要估算不同样本之间的相似性度量来确定每个样本的类别，常采用的方法就是距离度量，ConvNet中的卷积实质上计算两个输入的互相关来衡量两者的余弦距离。假设ConvNet中间层滤波器 $F \in R^{w_c \times h_c \times c_{in} \times c_{out}}$ ， w_c 和 h_c 分别表示卷积核的宽度和高度， c_{in} 和 c_{out} 分




图2 UN=16QAM, UF=QPSK, $\alpha_{ftpc} = 0.5$ 时联合星座图

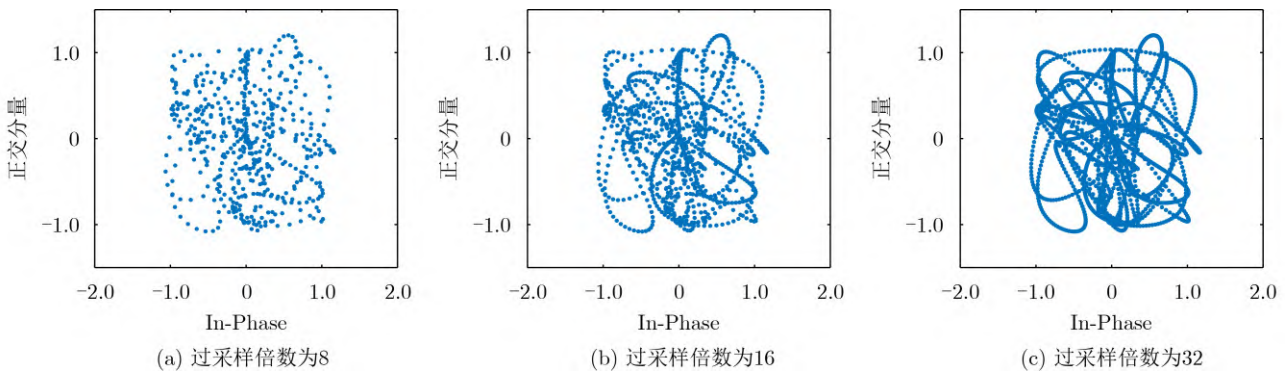


图3 UN=16QAM, UF=QPSK, $\alpha_{ftpc} = 0.5$, D-SNR=6 dB时联合星座轨迹图




图4 $\alpha_{ftpc} = 0.5$, D-SNR=6 dB时联合星座直方统计图

别表示中间层的输入通道数和输出通道数。输入特征 $X \in R^{h_f \times w_f \times c_i}$ ， w_f 和 h_f 分别表示输入的宽度和高度。中间层的输出可以表示为

$$Y_c(m, n, t) = \sum_{i=0}^{w_c} \sum_{j=0}^{h_c} \sum_{k=0}^{c_m} (X(m+i, n+j, k) \times F(i, j, k, t)) \quad (8)$$

除ConvNet使用余弦距离的相似度度量以外，在机器学习中还有其他的距离度量，如欧式距离和曼哈顿距离等等，而其中大多数距离度量都含有乘法或者难以用神经网络计算的操作。由于曼哈顿距离未涉及乘法运算，可全部依靠加法实现，并且其与式(7)中的传统模板匹配的距离度量方法存在相似性，两种度量都能够体现个体数值特征的绝对差异。假设2维平面两个 n 维向量 $\mathbf{a} = (x_1, x_2, \dots, x_n)$ 和 $\mathbf{b} = (y_1, y_2, \dots, y_n)$ ，则两向量间的曼哈顿距离为

$$d_{\mathbf{a}, \mathbf{b}} = \sum_{k=1}^n |x_k - y_k| \quad (9)$$

此时式(8)可改写为

$$Y_m(m, n, t) = \sum_{i=0}^{w_c} \sum_{j=0}^{h_c} \sum_{k=0}^{c_m} |X(m+i, n+j, k) - F(i, j, k, t)| \quad (10)$$

由于式(8)中 X 与 F 越相似， X 和 F 的余弦距离越大，所以输出 Y 越大。而对于式(10)， X 与 F 越相似， X 和 F 的曼哈顿距离越小。因此式(10)可以通过取负数与式(8)对齐

$$Y_m^*(m, n, t) = - \sum_{i=0}^{w_c} \sum_{j=0}^{h_c} \sum_{k=0}^{c_m} |X(m+i, n+j, k) - F(i, j, k, t)| \quad (11)$$

AdderNet在网络训练时依然使用反向传播算法进行梯度计算，并使用梯度下降法进行优化，但是由于曼哈顿距离度量中直接对滤波器 F 求偏导会使得梯度被计算为+1或-1，因此无法实现梯度的有效更新，出现梯度爆炸现象，该现象的产生是因为参数梯度较大，大幅度调整容易使得新参数越过该方向上的最优解，导致收敛缓慢甚至无法收敛。因此梯度计算方法改进为

$$\frac{\partial Y_m(m, n, t)}{\partial F(i, j, k, t)} = X(m+i, n+j, k) - F(i, j, k, t) \quad (12)$$

$$\frac{\partial Y_m(m, n, t)}{\partial X(m+i, n+j, k)} = \text{HT}(F(i, j, k, t) - X(m+i, n+j, k)) \quad (13)$$

其中，HT表示为硬阈值Tanh函数

$$\text{HT}(x) = \begin{cases} x, & -1 < x < 1 \\ 1, & x > 1 \\ -1, & x < -1 \end{cases} \quad (14)$$

3.3 调制检测网络

当输入数据维度越大时，神经网络的计算复杂度越高，需要消耗的内存资源也越多。虽然已有文献研究结果表明将原始2维星座图上色转化为3维彩色图像进行处理可提高调制识别正确率^[16]，但是当将网络模型实际部署至移动设备进行在线测试时，该步骤的计算代价很大且对后续通信信号处理是无意义的，同时也会给神经网络带来更大的计算负担。NOMA联合星座图相较于计算机视觉中的图像，其像素(星座点)分布更加鲜明，因此本文将输入星座图设计为 32×32 的灰度图像，即将联合星座密度图 C_d 进行归一化

$$G = \frac{C_d - \min(C_d)}{\max(C_d) - \min(C_d)} \quad (15)$$

本文设计的干扰用户调制检测网络整体架构如图5。

在网络的第1部分，AdderNet首先通过一个标准加法块实现数据的底层特征提取，由于AdderNet中每个加法层的输出特征量级会大大高于输入的特征，所以需要使用批量归一化(Batch Normalization, BN)来控制每层的特征量级相似^[25]。在第2部分，通过叠加多个加法残差块来挖掘数据的深层特征，其中使用了两个降维加法残差块对输入数据进行降维，实现特征压缩。网络最后部分使用 1×1 的加法核来等效全连接层，输出维度转化为对应的干扰用户调制方式种类数量。使用加法层代替全连接层可以使训练集和测试集的数据维度大小不需要严格保持一致，并且在前向传播可以减少计算量从而提高效率。

网络训练时通过模拟余弦函数的变化来降低学习率^[26]，第 i 个训练周期数的学习率 η_i 为

$$\eta_i = \frac{\eta_0}{2} \left(1 + \cos \left(\frac{E_i}{E} \pi \right) \right) \quad (16)$$

其中， η_0 表示学习率的初始值， E_i 表示当前执行至第 i 个周期， E 表示总的训练周期数。

4 实验设计与分析

4.1 数据生成与网络训练

本文使用MATLAB 2018a作为NOMA通信系统仿真平台，具体仿真参数如表1。NOMA用户可采用的调制方式及调制方式组合与文献[13]相同，表1中干扰用户为“None”表示没有干扰用户，此

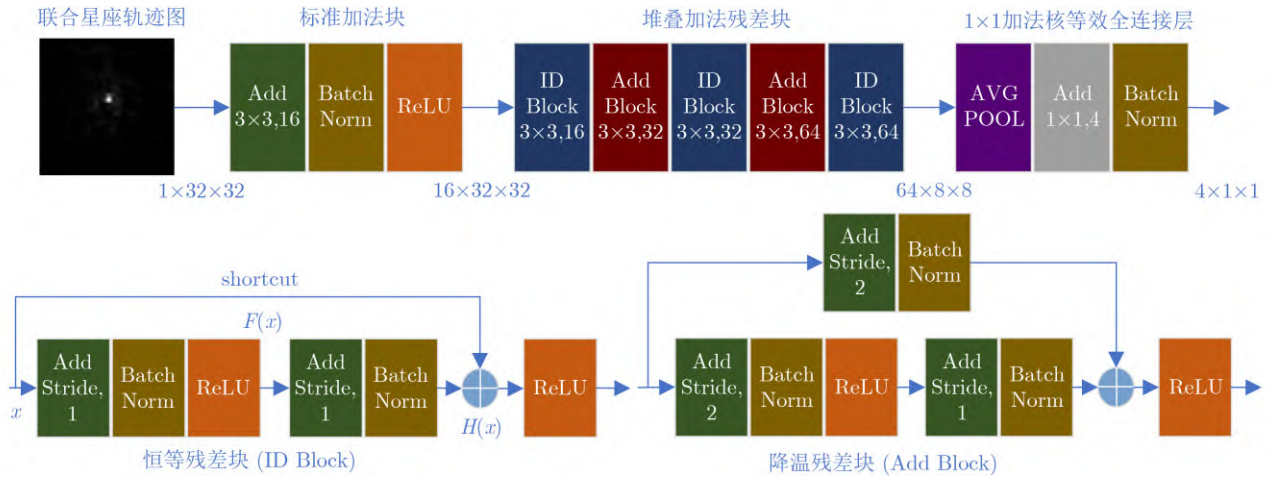


图5 调制检测网络结构

表1 NOMA系统仿真参数

参数名	参数值
数据包符号数	100
功率衰减因子	0.5
成型滤波器	平方根升余弦
滚降系数	0.5
信道衰落	瑞利分布
多径数	3
多普勒频移	20 Hz
多普勒频谱	Jakes
目标用户	16QAM/64QAM
干扰用户	None/QPSK/16QAM/64QAM

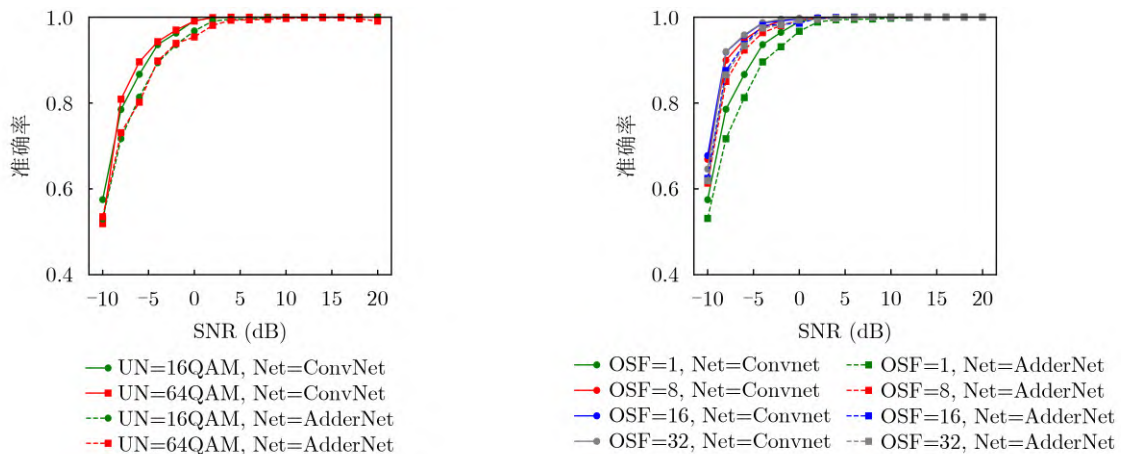
时等价于OMA系统。信噪比范围以2 dB为间隔从-10~20 dB，每个信噪比下每种调制方式组合随机生成1000个样本。Python3.7和PyTorch 10.2分别作为基准网络ConvNet和AdderNet的开发环境和机器学习库。

神经网络优化器为带动量的随机梯度下降，动量值为0.9，学习率初始值为 $\eta_0 = 0.1$ ，权重衰减值为 5×10^{-4} 。网络批量输入样本数为64。训练周期数 $E = 64$ 。网络训练过程通过调用CUDA实现加速。

4.2 性能测试与分析

4.2.1 实验1网络结构对调制检测性能影响

图6(a)展示当使用联合星座图作为NOMA调制方式检测的特征时，在信噪比区间为[-10, 5] dB时，ConvNet相对于AdderNet有着更好的识别性能。当信噪比大于5 dB时，此时AdderNet拥有100%的识别准确率，已满足一般通信场景下的性能要求。过采样技术可以提高检测性能的原因是它提供了更多关于信号的信息，从而增强了信号的特征和可辨识度。当对信号进行过采样时，以较高的采样率对信号进行采样时，可以获得了比标准采样率更多的采样点。这些额外的采样点可以捕捉到信号的更细微的变化和特征，从而提高了信号的可检测性能。对接收端进行一定倍数的过采样，可以明显改善低



(a) 联合星座图作为网络输入

(b) 联合星座轨迹图作为网络输入

图6 ConvNet与AdderNet的调制识别率比较

信噪比下的调制检测性能，但不断提高过采样因子OSF并不会持续提高性能增益。因为更高倍数的过采样的仅是增加了星座轨迹图的点数，但是并没有带来新的特征量，网络的特征提取效果也无法相应增强，从图6(b)可以看到当OSF超过16时，其相对的性能提升已不明显。此外，引入过采样技术会拉近AdderNet与ConvNet的识别率差距。

AdderNet仅将ConvNet的卷积操作替换为加法操作，两者网络参数相同。但是在计算操作上有区别，当每一层都考虑偏置计算时，ConvNet中卷

积层的乘法和加法次数均为 $c_{in} \times w_c \times h_c \times w_f \times h_f \times c_{out}$ 。AdderNet中加法层只包含加法操作，其加法次数为 $2 \times c_{in} \times w_c \times h_c \times w_f \times h_f \times c_{out}$ 。对VIA Nano 2000系列CPU，其运行1次乘法和加法操作的指令延迟分别为4和2。TSMC 45nm工艺中，32位浮点乘法和加法分别需要3.7 pJ和0.9 pJ能量^[27]。由于AdderNet和ConvNet中的BN层，激活函数层和平均池化层的运算量相对加法层和卷积层较小，故本文比较两者计算量时只考虑加法层和卷积层，性能指标统计如表2。

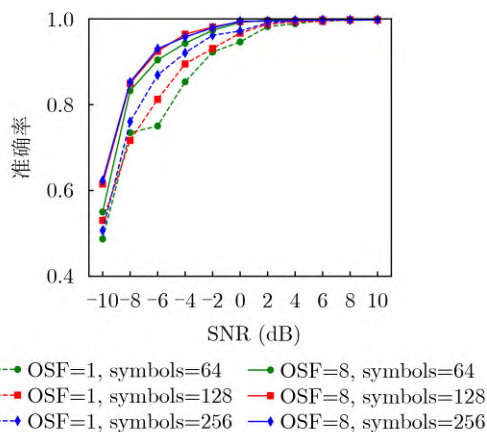
表 2 AdderNet与ConvNet性能指标

网络	加法次数	乘法次数	指令延迟	能耗(pJ)	参数量
AdderNet	32.6 M	0	65.2 M	29.34 M	7.2 k
ConvNet	16.3 M	16.3 M	97.8 M	74.98 M	7.2 k

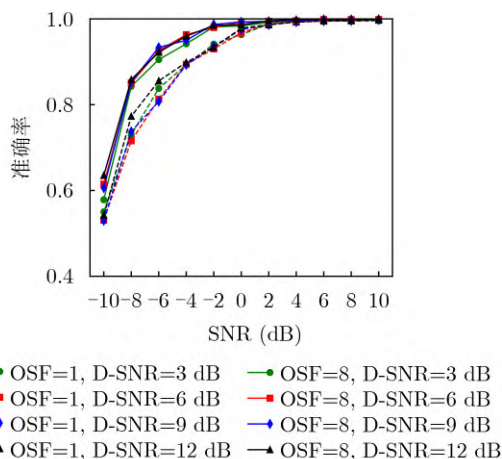
4.2.2 实验2信号特征变化对调制检测性能影响

短包传输下调制识别的一个挑战就是符号长度过短将会造成高阶调制信号的星座图不完整，从而导致NOMA信号的叠加星座图同样会缺失部分星座点。图7(a)中当符号长度变短时，调制检测性能将会降低。当采用过采样技术后一定程度上可以缓解数据包长度过短问题，当OSF=8时，数据包长

度分别为128和256时的检测正确率很接近。UN和UF的D-SNR越大，如图2所示，整体分布趋势将使联合星座图更接近UF星座图。在较大的功率比差异下(如图7(b)中D-SNR=12 dB时，功率分配比为2:8)，联合星座图的星座点分布将十分明显，对于AdderNet而言也能实现更准确的分类，调制识别率相对更高。



(a) 不同符号长度下检测性能



(b) 不同D-SNR下检测性能

图 7 UN=16QAM，不同数据包长度与功率分配下调制识别率比较

5 结束语

随着5G全方位的落地和6G开发的正式启动，AI技术在下一代移动通信领域的应用逐渐成为研究热点^[28]。针对深度学习技术存在计算复杂度高和能耗大等问题。本文提出的基于联合星座轨迹图和AdderNet的干扰用户调制方式检测算法，将减小短包传输场景下NOMA系统接收机进行串行干扰删除时所需要的额外信令开销，有利于提高SIC的

解调效率，并且本算法的计算延迟和能耗都明显小于传统神经网络。在未来的工作中，本文将扩展AdderNet至下一代无线通信物理层中所存在的更复杂的信号处理任务^[29]。

参考文献

- [1] ELGARHY O, REGGIANI L, ALAM M M, *et al.* Energy efficiency and latency optimization for IoT URLLC and mMTC use cases[J]. *IEEE Access*, 2024, 12: 23132-23148.

- doi: 10.1109/ACCESS.2024.3364349.
- [2] SHAHAB M B, ABBAS R, SHIRVANIMOGHADDAM M, *et al.* Grant-free non-orthogonal multiple access for IoT: A survey[J]. *IEEE Communications Surveys & Tutorials*, 2020, 22(3): 1805–1838. doi: 10.1109/COMST.2020.2996032.
- [3] SONG Ge, FANG Xiaojie, and SHA Xuejun. The extended hybrid carrier-based multiple access technology for high mobility scenarios[J]. *China Communications*, 2024, 21(1): 53–68. doi: 10.23919/JCC.fa.2023-0352.202401.
- [4] 张宏莉, 韩玲, 王星妍. 5G非正交多址关键技术研究 and 性能评估[J]. *信息通信技术与政策*, 2022, 49(6): 85–90. doi: 10.12267/j.issn.2096-5931.2022.06.015.
- ZHANG Hongli, HAN Ling, and WANG Xingyan. Study on 5G non-orthogonal multiple access technology & performance evaluation[J]. *Information and Communications Technology and Policy*, 2022, 49(6): 85–90. doi: 10.12267/j.issn.2096-5931.2022.06.015.
- [5] DING Zhiguo, LEI Xianfu, KARAGIANNIDIS G K, *et al.* A survey on non-orthogonal multiple access for 5G networks: Research challenges and future trends[J]. *IEEE Journal on Selected Areas in Communications*, 2017, 35(10): 2181–2195. doi: 10.1109/JSAC.2017.2725519.
- [6] DAI Linglong, WANG Bichai, YUAN Yifei, *et al.* Non-orthogonal multiple access for 5G: Solutions, challenges, opportunities, and future research trends[J]. *IEEE Communications Magazine*, 2015, 53(9): 74–81. doi: 10.1109/MCOM.2015.7263349.
- [7] SAITO Y, KISHIYAMA Y, BENJEBBOUR A, *et al.* Non-Orthogonal Multiple Access (NOMA) for cellular future radio access[C]. 2013 IEEE 77th Vehicular Technology Conference (VTC Spring), Dresden, Germany, 2013: 1–5. doi: 10.1109/VTCspring.2013.6692652.
- [8] MALI M D and CHORAGE S S. Spectrally efficient Multiple Input Multiple Output (MIMO) Non-Orthogonal Multiple Access (NOMA) technique for future wireless communication[C]. 2022 2nd Asian Conference on Innovation in Technology (ASIANCON), Ravet, India, 2022: 1–5. doi: 10.1109/ASIANCON55314.2022.9908664.
- [9] 蔡昕. 单通道时频混叠数字通信信号盲分离方法研究[D]. [博士学位论文], 国防科技大学, 2021. doi: 10.27052/d.cnki.gzjgu.2021.000088.
- CAI Xin. Researches on blind separation of single channel time-frequency overlapped digital communication signals[D]. [Ph. D. dissertation], National University of Defense Technology, 2021. doi: 10.27052/d.cnki.gzjgu.2021.000088.
- [10] WEI Wen and MENDEL J M. Maximum-likelihood classification for digital amplitude-phase modulations[J]. *IEEE Transactions on Communications*, 2000, 48(2): 189–193. doi: 10.1109/26.823550.
- [11] CHOI M, YOON D, and KIM J. Blind signal classification for non-orthogonal multiple access in vehicular networks[J]. *IEEE Transactions on Vehicular Technology*, 2019, 68(10): 9722–9734. doi: 10.1109/TVT.2019.2932407.
- [12] LI Tao, LI Yongzhao, and DOBRE O A. Modulation classification based on fourth-order Cumulants of superposed signal in NOMA systems[J]. *IEEE Transactions on Information Forensics and Security*, 2021, 16: 2885–2897. doi: 10.1109/TIFS.2021.3068006.
- [13] ZHANG Ningbo, CHENG Kai, and KANG Guixia. A machine-learning-based blind detection on interference modulation order in NOMA systems[J]. *IEEE Communications Letters*, 2018, 22(12): 2463–2466. doi: 10.1109/LCOMM.2018.2874218.
- [14] LASELVA S. 人工智能在5G和6G网络中的应用[J]. *软件和集成电路*, 2023(6): 8–9. doi: 10.19609/j.cnki.cn10-1339/tn.2023.06.022.
- LASELVA S. The application of artificial intelligence in 5G and 6G networks[J]. *Software and Integrated Circuit*, 2023(6): 8–9. doi: 10.19609/j.cnki.cn10-1339/tn.2023.06.022.
- [15] O'SHEA T J, ROY T, and CLANCY T C. Over-the-air deep learning based radio signal classification[J]. *IEEE Journal of Selected Topics in Signal Processing*, 2018, 12(1): 168–179. doi: 10.1109/JSTSP.2018.2797022.
- [16] HOU Changbo, LIU Guowei, TIAN Qiao, *et al.* Multisignal modulation classification using sliding window detection and complex convolutional network in frequency domain[J]. *IEEE Internet of Things Journal*, 2022, 9(19): 19438–19449. doi: 10.1109/JIOT.2022.3167107.
- [17] 张思成, 林云, 涂涯, 等. 基于轻量级深度神经网络的电磁信号调制识别技术[J]. *通信学报*, 2020, 41(11): 12–21. doi: 10.11959/j.issn.1000-436x.2020237.
- ZHANG Sicheng, LIN Yun, TU Ya, *et al.* Electromagnetic signal modulation recognition technology based on lightweight deep neural network[J]. *Journal on Communications*, 2020, 41(11): 12–21. doi: 10.11959/j.issn.1000-436x.2020237.
- [18] STRUBELL E, GANESH A, and MCCALLUM A. Energy and policy considerations for deep learning in NLP[C]. Proceedings of the 57th Annual Meeting of the Association for Computational Linguistics, Florence, Italy, 2019: 3645–3650. doi: 10.18653/v1/P19-1355.
- [19] CHEN Hanting, WANG Yunhe, XU Chunjing, *et al.* AdderNet: Do we really need multiplications in deep learning?[C]. The IEEE/CVF Conference on Computer Vision and Pattern Recognition, Seattle, USA, 2020: 1465–1474. doi: 10.1109/CVPR42600.2020.00154.
- [20] 王建新, 宋辉. 基于星座图的数字调制方式识别[J]. *通信学报*, 2004, 25(6): 166–173. doi: 10.3321/j.issn:1000-436X.2004.06.023.
- WANG Jianxin and SONG Hui. Digital modulation

- recognition based on constellation diagram[J]. *Journal on Communications*, 2004, 25(6): 166–173. doi: 10.3321/j.issn:1000-436X.2004.06.023.
- [21] SHAFIQ M and GU Zhaoquan. Deep residual learning for image recognition: A survey[J]. *Applied Sciences*, 2022, 12(18): 8972. doi: 10.3390/app12188972.
- [22] OTA O, KISHIYAMA Y, and HIGUCHI K. Performance of non-orthogonal access with SIC in cellular downlink using proportional fair-based resource allocation[C]. 2012 International Symposium on Wireless Communication Systems (ISWCS), Paris, France, 2012: 476–480. doi: 10.1109/ISWCS.2012.6328413.
- [23] 崔荣涛, 李辉, 万坚, 等. 一种基于过采样的单通道MPSK信号盲分离算法[J]. *电子与信息学报*, 2009, 31(3): 566–569. doi: 10.3724/SP.J.1146.2007.01792.
- CUI Rongtao, LI Hui, WAN Jian, *et al.* An over-sampling based blind separation algorithm of single channel MPSK signals[J]. *Journal of Electronics & Information Technology*, 2009, 31(3): 566–569. doi: 10.3724/SP.J.1146.2007.01792.
- [24] PENG Linning, ZHANG Junqing, LIU Ming, *et al.* Deep learning based RF fingerprint identification using differential constellation trace figure[J]. *IEEE Transactions on Vehicular Technology*, 2020, 69(1): 1091–1095. doi: 10.1109/TVT.2019.2950670.
- [25] IOFFE S and SZEGEDY C. Batch normalization: Accelerating deep network training by reducing internal covariate shift[C]. The 32nd International Conference on Machine Learning, Lille, France, 2015: 448–456. doi: 10.5555/3045118.3045167.
- [26] LOSHCHILOV I and HUTTER F. SGDR: Stochastic gradient descent with warm restarts[C]. 5th International Conference on Learning Representations, Toulon, France, 2017. doi: 10.48550/arXiv.1608.03983.
- [27] HOROWITZ M. 1.1 Computing's energy problem (and what we can do about it)[C]. 2014 IEEE International Solid-State Circuits Conference Digest of Technical Papers (ISSCC), San Francisco, USA, 2014: 10–14. doi: 10.1109/ISSCC.2014.6757323.
- [28] 施建锋, 杨照辉, 黄诺, 等. 面向6G的用户为中心网络研究综述[J]. *电子与信息学报*, 2023, 45(5): 1873–1887. doi: 10.11999/JEIT220242.
- SHI Jianfeng, YANG Zhaohui, HUANG Nuo, *et al.* A survey on user-centric networks for 6G[J]. *Journal of Electronics & Information Technology*, 2023, 45(5): 1873–1887. doi: 10.11999/JEIT220242.
- [29] 张海君, 陈安琪, 李亚博, 等. 6G移动网络关键技术[J]. *通信学报*, 2022, 43(7): 189–202. doi: 10.11959/j.issn.1000-436x.2022140.
- ZHANG Haijun, CHEN Anqi, LI Yabo, *et al.* Key technologies of 6G mobile network[J]. *Journal on Communications*, 2022, 43(7): 189–202. doi: 10.11959/j.issn.1000-436x.2022140.
- 王 骥: 男, 副教授, 研究方向为5G/6G无线通信.
 李子龙: 男, 硕士生, 研究方向为深度强化学习.
 肖 健: 男, 博士生, 研究方向为AI、信号处理.
 谢文武: 男, 副教授, 研究方向为5G&6G基带算法、NFC等.
 余 超: 男, 讲师, 研究方向为NOMA、凸优化.

责任编辑: 余 蓉