

## SCMA-D2D 混合网络卷积自编码器<sup>①</sup>

许耀华<sup>②\*\*\*</sup> 周鑫源<sup>③\*\*\*</sup> 黄兴<sup>\*\*\*</sup> 蒋芳<sup>\*\*\*</sup> 王翊<sup>\*\*\*</sup> 王跃<sup>\*\*\*</sup>

(\* 安徽大学智能计算与信号处理教育部重点实验室 合肥 230601)

(\*\* 安徽大学物联网频谱感知与测试工程中心 合肥 230601)

(\*\*\* 安徽电信规划设计有限责任公司 合肥 230031)

**摘要** 为满足物联网通信大连接、低功耗的需求,高效利用有限的频谱资源成为一项重要的挑战。在应用了稀疏码分多址接入(SCMA)技术的蜂窝网络中增加设备对设备(D2D)用户对,两者共享频谱资源,可以进一步提高频谱利用率,满足大规模连接和低功耗的通信需求。然而,当不同类型的用户共享相同的频谱资源时会导致严重的用户间干扰,导致多用户检测精度降低,译码复杂度增高。本文使用卷积神经网络(CNN)进行 SCMA-D2D 混合网络自编码器设计,通过端到端的联合训练,设计出合适的神经网络结构。用 CNN 单元实现混合网络的编码,学习 SCMA 蜂窝用户和 D2D 用户的有效码本;将混合网络的多用户检测问题建模为一个基于共享层机制的多任务分类解码问题,建立多用户分类解码器。实验结果表明,本文提出的自编码器能够生成对系统适应性更强的码本,结合接收端的多任务分类解码器能够有效地提高整个混合网络系统的误码率性能,同时减小译码计算复杂度。

**关键词** 卷积神经网络(CNN);稀疏码分多址接入(SCMA);设备对设备(D2D)通信;无线通信;多用户检测

## 0 引言

随着物联网和人工智能的快速发展,接入到通信网络中的移动智能终端的种类和数量不断增多,网络中采集的用户数据呈指数级增长。因此研究如何提升系统的用户容量、提升频谱资源利用效率、降低系统功耗等问题是非常必要的。文献[1]提出不同类型的网络集成到统一的系统中能够大大提高系统容量和频谱资源利用率。设备对设备(device to device, D2D)通信允许附近的设备之间在没有基站(base station, BS)或有限基站参与的情况下直接建立通信,进一步拓展社交网络结构,支持物联网的发展<sup>[2]</sup>。蜂窝和 D2D 通信混合网络能够进一步提升网络容量和资源利用效率。稀疏码分多址接入(sparse

code multiple access, SCMA)<sup>[3]</sup>技术由于其低密度扩频和高维调制的特点,能够以一定的过载率增加使用频谱资源的用户数量。文献[4]证实了将 SCMA 应用在蜂窝和 D2D 混合网络中能够支持 D2D 的海量连接以及提升混合网络系统的区域频谱效率(area spectral efficiency, ASE)。然而混合网络要面临许多新的问题,比如新的资源分配、新的解码方案及用户间的干扰管理等问题。本文将 SCMA 支持的蜂窝和 D2D 混合网络简称为 SCMA-D2D 混合网络。对于端到端的通信系统来说,编码和解码是最重要的问题。近年来,学者在 SCMA-D2D 混合网络编解码端进行了码本分配<sup>[4-9]</sup>、功率优化<sup>[2,10-11]</sup>等一系列研究。然而很少有专门针对 SCMA-D2D 混合网络接收机设计的研究。文献[12]设计了一种低复杂度

① 安徽省高校自然学科研究项目(No. 2022AH050109)和国家自然科学基金(No. 62071002, 62001001)资助。

② 男,1976年生,硕士,副教授;研究方向:无线通信,通信信号处理,通信集成电路设计与测试应用;E-mail:xyh@ahu.edu.cn。

③ 通信作者,E-mail:1761792949@qq.com。

(收稿日期:2023-02-23)

的上行链路 SCMA-D2D 混合网络解码器,针对传统系统用于解码的消息传递算法(message passing algorithm, MPA)和最大似然检测算法(maximum likelihood, ML)导致的译码复杂度过高的问题,提出了一种基于列表球解码(list sphere decoding, LSD)算法的接收机设计方案 LSD-MPA 和 MPA-ML 以缩小检索空间,降低解码复杂度,但解码精度没有明显提升且 D2D 用户的解码精度低于 SCMA 用户。SCMA-D2D 混合网络的用户间干扰所导致的系统误比特率(bit error rate, BER)性能差的问题在传统通信模式下难以有效解决。

随着人工智能技术的发展,将深度学习应用于未来移动通信网络是解决现有诸多通信问题的一种可行方法<sup>[13]</sup>。深度学习(deep learning, DL)已被用于解决码本设计<sup>[14-15]</sup>、解码<sup>[16-22]</sup>以及信道估计<sup>[22]</sup>等问题。文献[16]和[17]都是将深度学习和 MPA 相结合改善系统的解码性能,学习调整神经网络边的权值来实现 SCMA 多用户检测。文献[18]提出了一种基于卷积神经网络(convolutional neural network, CNN)的 SCMA 的下行链路盲译码策略,通过离线训练构建了神经网络模型,在线测试阶段只需要通过一次神经网络的运算即可完成解码。避免了传统的多用户检测算法的多次迭代,降低了解码复杂度。但是文献[16-18]都没有涉及到神经网络辅助的编码问题。文献[14]提出了一种深度学习辅助的 SCMA(deep learning aided SCMA, D-SCMA)自编码器结构,能够自适应地构造最小化误码率的码本,并使用基于深度神经网络的编解码器来学习译码策略。在码字的生成和译码策略的确定中采用了一种受自动编码器的结构。文献[15]将整个网络看成一个自动编码器,将编码和解码结合在一起进行训练以生成最优的 SCMA 码字和重建原始比特。文献[19]提出了一种基于卷积和残差网络的端到端的 SCMA 自动编解码器,在编码端使用 CNN 单元学习码字映射规律,在解码端引入了参加网络结构解决由深度增加导致的梯度消失问题,提升了系统的误比特率(bit error rate, BER)性能,降低了计算复杂度。综上所述可知,神经网络辅助的 SCMA 系统编解码器能够通过神经网络单元发掘数据之间的关联,减少网络

中可训练参数,降低计算复杂度并获得良好的译码性能。SCMA-D2D 混合网络是多种用户类型的网络系统,不仅要考虑到多种用户的不同编码特征进行编码,还要考虑构建解码器时要降低用户间的干扰,保证多种用户解码精度。文献[20,21]都提到的基于共享层的多用户分类器给混合网络解码问题提供了新思路。基于共享层的多任务解码模型能够在共享层学习总的解码任务,各个解码子任务之间互不干扰独立进行,增强了多用户译码的抗干扰性。

受上述文献启发,本文提出了 SCMA-D2D 混合网络卷积自编码器(CNN-SCMA-D2D)。在编码端,自适应学习使系统误码率性能最好的用户最佳码本代替传统的码本映射方式,将信道信息和解码性能都作为码本生成的训练条件,提升系统编码灵活性、鲁棒性;在解码端,提出基于共享层机制的多用户分类解码器,提升解码精度,降低译码复杂度。

## 1 网络模型

### 1.1 蜂窝和 D2D 混合网络

图 1 展示的是由  $J_c$  个蜂窝用户和  $J_d$  个设备对设备(D2D)用户共存的多用户混合网络系统,  $C_i$  表示第  $i$  个蜂窝用户,  $DT_j, DR_j$  分别表示第  $j$  个 D2D 用户对发送器和接收器,其中  $1 \leq i \leq J_c, 1 \leq j \leq J_d$ 。上行链路中 D2D 用户对基站的干扰很小,混合网络的干扰主要体现在一种用户将另一种用户的信息视为干扰。

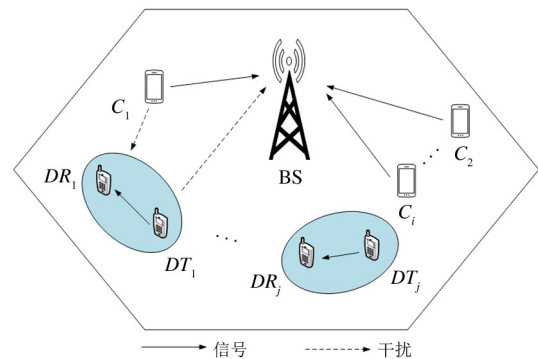


图 1 混合网络系统图

### 1.2 SCMA-D2D 混合网络模型

$J_c$  个蜂窝用户、 $J_d$  个 D2D 用户、 $K$  个频谱资源

的上行链路混合网络系统中使用稀疏码分多址技术 (SCMA) 可以实现频谱资源的过载。在本系统中, 蜂窝用户数据以 SCMA 映射的方式将分配到的 SCMA 码字信息复用到  $K$  个频谱资源上, 每个蜂窝用户占用  $K_c$  个频谱资源,  $1 \leq K_c \leq K$ , 实现了一维数据到二维码字的拓展。D2D 用户采用二进制相移键控 (binary phase shift keying, BPSK) 调制的方式, 直接占用  $K$  个频谱资源中的 1 个。令用户数  $J_c + J_d > K$ , 达到过载的目的, 令  $J_d < K$  以限制干扰的强度。根据系统中各个用户对频谱资源的占用情况, 随机生成一个映射矩阵  $\mathbf{F}$ , 如式 (1) 所示, 其中矩阵元素为  $\{0, 1\}$  2 种取值。矩阵  $\mathbf{F}$  的列对应用户, 矩阵  $\mathbf{F}$  的行对应频谱资源。矩阵  $\mathbf{F}$  的前  $J_c$  列代表 SCMA 用户占用频谱资源的情况, 矩阵  $\mathbf{F}$  的后  $J_d$  列代表 D2D 用户占用频谱资源的情况。矩阵  $\mathbf{F}$  的前  $J_c$  列的列权重为  $K_c$ , 表示这一列有  $K_c$  个取值为 1 的元素; 矩阵  $\mathbf{F}$  的后  $J_d$  列的列权重为 1, 表示这一列仅有 1 个取值为 1 的元素。若矩阵的第  $k$  行和第  $m$  列的元素  $F_{|k,m|} = 1$ , 代表该列所对应的用户  $m$  占用了第  $k$  个资源块, 反之则表示对应用户不会占用该资源块,  $1 \leq m \leq J_c + J_d$ 。矩阵的行权重取值为  $\left\{ \frac{K_c \times J_c}{K}, \frac{K_c \times J_c}{K} + 1 \right\}$  2 种情况, 其中,  $\frac{K_c \times J_c}{K}$  取值为整数。

$$\mathbf{F} = \begin{bmatrix} 0 & 1 & 1 & 0 & 1 & 0 \\ 1 & 0 & 1 & 0 & 0 & 1 \\ 1 & 0 & 0 & 0 & \dots & 0 & 0 \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ 0 & 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 1 & 0 & 0 \end{bmatrix}_{K \times (J_c + J_d)} \quad (1)$$

为了便于描述问题, 本文暂时以一个有 6 个 SCMA 用户、2 个 D2D 用户对和 4 个频谱资源的系统为例, 则有式 (2) 所示的因子矩阵。本文后续会对 D2D 用户对数量对系统性能的影响做实验探究。

$$\mathbf{F} = \begin{bmatrix} 0 & 1 & 1 & 0 & 0 & 1 & 1 & 0 \\ 1 & 0 & 1 & 0 & 1 & 0 & 0 & 1 \\ 1 & 0 & 0 & 1 & 0 & 1 & 0 & 0 \\ 0 & 1 & 0 & 1 & 1 & 0 & 0 & 0 \end{bmatrix} \quad (2)$$

由式 (2) 给出如图 2 所示的用户占用资源的因子图。




图 2 SCMA-D2D 混合网络因子图

接收端接收的信号用式 (3) 表示。

$$\mathbf{y} = \sum_{i=1}^{J_c} \text{diag}(\mathbf{h}_c^i) \mathbf{x}_c^i + \sum_{j=1}^{J_d} \text{diag}(\mathbf{h}_d^j) \mathbf{x}_d^j + \mathbf{n} \quad (3)$$

其中,  $\text{diag}(\cdot)$  表示对角矩阵;  $\mathbf{x}_c^i$  表示第  $i$  个蜂窝用户的码字向量;  $\mathbf{x}_d^j$  表示第  $j$  个 D2D 用户对调制信号向量;  $\mathbf{h}_c^i = (\mathbf{h}_{c1}^i, \dots, \mathbf{h}_{cK}^i)^T$  是蜂窝用户数据和频谱资源之间的信道向量;  $\mathbf{h}_d^j = (\mathbf{h}_{d1}^j, \dots, \mathbf{h}_{dK}^j)^T$  是 D2D 用户数据和频谱资源之间的信道向量,  $\mathbf{T}$  表示矩阵的转置;  $\mathbf{n}$  表示均值为 0、方差为 1 的高斯信道噪声向量;  $1 \leq i \leq J_c, 1 \leq j \leq J_d$ , 其中  $J_c = 6, J_d = 2$ 。

## 2 CNN-SCMA-D2D 自编码器

由于增加了新的用户类型, SCMA-D2D 混合网络系统既要考虑新的编码策略, 也要考虑能够降低用户间干扰、提升解码精度的解码算法, 将系统的误比特率 (BER) 降低到可接受范围内去提升系统的容量、提升系统的过载率。针对传统的 SCMA-D2D 混合网络采用预设好的固定码本编码导致的编码鲁棒性较差以及传统的迭代译码算法在解码精度上没有明显提升且译码复杂度高问题, 本节介绍一种基于卷积神经网络 (CNN) 的 SCMA-D2D 混合网络系统卷积自编码器 CNN-SCMA-D2D。在编码端, 分别根据不同的用户到频谱资源的连接情况设计了多用户联合编码器的结构, 并在模型训练的过程中将

信道条件、解码端性能都考虑在内,使用自适应编码代替固定码本,得出对系统适应能力最强、解码 BER 性能最好的编码器结构。在解码端,针对不同类型的多用户解码问题,采用一种基于共享层的多用户分类解码结构,以降低用户间干扰、提升解码精度。

### 2.1 CNN-SCMA-D2D 编码器设计

相比于传统的固定码本编码,神经网络辅助的自编码器能够灵敏地发掘数据之间的规律,快速地学习使系统模型达到最优的编码映射规则,并且能够减少可训练参数降低编码复杂度。将图 2 中连接用户和频谱资源的边称为用户到频谱资源的数据

流。在 CNN-SCMA-D2D 编码器中,在每一个用户到频谱资源的数据流中间放置一个 CNN 单元去寻找如图 2 所示的从输入数据到指定的频谱资源的星座点的映射关系。CNN-SCMA-D2D 编码器结构如图 3 所示。分别用  $f_c$ 、 $f_d$  表示蜂窝用户和 D2D 用户的 CNN 编码单元, $f_c^i$ 、 $f_d^j$  分别表示第  $i$  个蜂窝用户编码单元、第  $j$  个 D2D 用户编码单元 ( $1 \leq i \leq J_c, 1 \leq j \leq J_d$ )。 $f_{ck}^i(\cdot)$  表示第  $i$  个蜂窝用户加载到第  $k$  个频谱资源的码字生成函数或码字生成器。 $f_{dk}^j(\cdot)$  表示第  $j$  个 D2D 用户加载到第  $k$  个频谱资源的调制信息生成函数或调制信息生成器。




图 3 CNN-SCMA-D2D 混合网络编码端结构

$r_c$ 、 $r_d$  分别是蜂窝用户和 D2D 用户的二进制输入数据。 $r_c^i$ 、 $r_d^j$  分别表示第  $i$  个蜂窝用户的二进制输入数据和第  $j$  个 D2D 用户的二进制输入数据。每个用户的二进制比特数据按照  $b$  比特一组转换成能被神经网络单元识别的单热向量  $l_c$ 、 $l_d$ , 单热向量的维度为  $M$ , 其中  $b = \log_2 M$ 。图 4 所示是 CNN 编码单元的内部结构示意图,共有 3 个隐藏层进行数据处理操作,CNN 的输入节点个数为  $M$ , 对应输入数据单热向量的维度;输出节点个数为 2, 对应学习到的码字信息的维度。 $l_c^i$ 、 $l_d^j$  分别表示第  $i$  个蜂窝用户的输入数据所对应的单热向量和第  $j$  个 D2D 用户的输入

数据所对应的单热向量 ( $1 \leq i \leq 6, 1 \leq j \leq 2$ )。加载到频谱资源  $k$  上的第  $i$  个蜂窝用户的原始数据所对应的码字向量  $x_{ck}^i$  如式(5)所示。加载到频谱资源  $k$  上的第  $j$  个 D2D 用户所对应的编码单元调制信息向量  $x_{dk}^j$  如式(6)所示。

$$x_{ck}^i = f_{ck}^i(r_c^i, \theta_{ec}^i) \quad (5)$$

$$x_{dk}^j = f_{dk}^j(r_d^j, \theta_{ed}^j) \quad (6)$$

其中,  $\theta_{ec}^i$  表示蜂窝用户编码过程中产生的网络参数,包括权重  $w_{ec}^i$  和偏差  $b_{ec}^i$ ;  $\theta_{ed}^j$  表示 D2D 用户调制过程中产生的网络参数,包括权重  $w_{ed}^j$  和偏差  $b_{ed}^j$ 。

将频谱资源上的所有码字进行叠加之后作为编



码端的输出,如式(7)所示。

$$\bar{y}_k = \sum_{i=1}^{J_c} f_{ck}^i(\mathbf{r}_c^i, \boldsymbol{\theta}_{ec}^i) + \sum_{j=1}^{J_d} f_{ck}^j(\mathbf{r}_d^j, \boldsymbol{\theta}_{ed}^j) \quad (7)$$

其中,  $\bar{y}_k \in \bar{\mathbf{y}}, k = 1, 2, 3, 4$ 。




图 4 CNN 单元隐藏层结构

频谱资源上的混合信号送到高斯信道中,传输到接收端,接收端接收到的信号如式(8)所示,其中  $\mathbf{n}$  表示高斯信道向量。

$$\mathbf{y} = \bar{\mathbf{y}} + \mathbf{n} \quad (8)$$

## 2.2 基于共享层的 CNN-SCMA-D2D 多用户分类解码器

基于共享层的 CNN-SCMA-D2D 混合网络多用户分类解码器由共享层和用户分类解码层组成。解码器的任务是输出不同类型用户的信息。由于存在多种用户识别任务,需要建立一个具有共享分支的模型,共享层结构刚好满足了这一点。共享层<sup>[20]</sup>,简单来说,就是对一个层的多次调用,即共享这个层。由于不需要每次调用都建立一个新的层,每次调用都可以重复使用相同的权重。在共享层中学习总的解码任务,并在多任务分支解码结构中独立学习本层的解码任务,各个分支任务独立进行、互不干扰。由此便可以建立一个接收信号  $\mathbf{y}$  为共享层、多用户分类解码层为分支的基于共享层机制的多用户分类解码器,如图 5 所示。

接收端的接入信号  $\mathbf{y}$  首先经过共享层处理,共享层的输入输出表达式如式(9)所示。

$$\mathbf{y}_s = s(\mathbf{y}, \boldsymbol{\theta}_s) \quad (9)$$




图 5 基于共享层的 CNN-SCMA-D2D 多用户分类解码器

共享层的输出  $\mathbf{y}_s, \boldsymbol{\theta}_s$  表示共享层的神经网络超参数,包括权重  $\mathbf{w}_s$  和偏差  $\mathbf{b}_s$ 。图 5 中  $u_c$  表示蜂窝用户的分类解码器,  $u_d$  表示 D2D 用户的分类解码器;

$s_c$  和  $s_d$  分别表示蜂窝用户和 D2D 用户的解码器预测结果,在模型训练和计算信噪比时需要处理成和输入数据类型相同类型的向量  $\hat{\mathbf{r}}_c$  和  $\hat{\mathbf{r}}_d$ , 方便代入模

型损失函数进行计算。 $\hat{r}_c^i$  表示  $\hat{r}_c$  的第  $i$  个元素,  $r_d^j$  表示  $\hat{r}_d$  的第  $j$  个元素。

第  $i$  个 SCMA 蜂窝用户解码过程如式 (10) 所示,第  $j$  个 D2D 用户解码过程用式 (11) 表示。

$$s_c^i = u_c^i(s(y; \theta_s); \theta_{dc}^i) \quad (10)$$

$$s_d^j = u_d^j(s(y; \theta_s); \theta_{dd}^j) \quad (11)$$

其中,  $i = 1, 2, \dots, J_c; j = 1, 2, \dots, J_d; u_c^i(\cdot)$  的输入为共享层  $s(\cdot)$  的输出  $y_s$ ;  $\theta_{dc}^i$  为第  $i$  个蜂窝用户解码器的网络参数,包括  $w_{dc}^i$  和  $b_{dc}^i$ ;  $\theta_{dd}^j$  为第  $j$  个 D2D 用户解码器的网络参数,包括  $w_{dd}^j$  和  $b_{dd}^j$ 。在分类解码器的输出层采用了 softmax 函数作为激活函数。softmax 函数将输出的结果转化为总和为 1 的概率值,将解码器输出的实值向量转换为归一化的概率分布。softmax 函数输入越大,概率越大,因此 softmax 函数用于本文的多用户分类解码器非常合适。softmax 函数的表示如式 (12) 所示。

$$S_i = \frac{e^{z_i}}{\sum_k e^{z_k}} \quad (12)$$

其中,  $z_i$  表示神经网络输出的一个结果,  $\sum_k e^{z_k}$  表示神经网络所有输出结果的总和,  $S_i$  表示神经网络输出结果的概率。

$s_c^i$  和  $s_d^j$  分别是第  $i$  个 SCMA 蜂窝用户解码器的输出结果和第  $j$  个 D2D 用户解码器的输出结果,都属于概率值。在计算之前需要转换成与输入数据相同类型的向量。 $s_c^i$  对应  $\hat{r}_c^i$ ,  $s_d^j$  对应  $\hat{r}_d^j$ ,  $\hat{r}_c^i$  是模型预测的蜂窝用户数据  $\hat{r}_c$  的第  $i$  个元素,  $\hat{r}_d^j$  是模型预测的 D2D 用户数据  $\hat{r}_d$  的第  $j$  个元素。

### 2.3 模型训练

为了使系统能尽可能地重构原始的用户信息,本文采用了端到端的训练方式,在不同的训练信噪比下训练网络,不断更新神经网络单元中的参数,发掘有用的信息,在有限的迭代次数内最小化模型损失函数的值。

为了使模型训练达到最好,使用交叉熵损失函数作为模型优化的目标函数。交叉熵损失函数用来衡量模型学习到的分布和真实分布的差异。交叉熵越大说明 2 种概率分布的差异越大。模型优化的目标是使最小化目标函数的值让模型达到最佳性能。经过解码器解码出来的预测数据会首先经过 softmax

处理成 0 ~ 1 之间的概率数据,然后送到  $\log(\cdot)$  中进行运算。

蜂窝用户对应的交叉熵损失函数  $L_c$  如式 (13) 所示。

$$\begin{aligned} L_c(\hat{r}_c, r_c) &= \sum_{i=1}^{J_c} L_c(\hat{r}_c^i, r_c^i) \\ &= \sum_{i=1}^{J_c} \sum_{k=1}^K -r_c^{ik} \log(\hat{r}_c^{ik}) \end{aligned} \quad (13)$$

其中,  $\hat{r}_c^{ik}$  是  $\hat{r}_c^i$  的第  $k$  项,  $r_c^{ik}$  是  $r_c^i$  的第  $k$  项。

D2D 用户对应的交叉熵损失函数  $L_d$  如式 (14) 所示。

$$\begin{aligned} L_d(\hat{r}_d, r_d) &= \sum_{j=1}^{J_d} L_d(\hat{r}_d^j, r_d^j) \\ &= \sum_{j=1}^{J_d} \sum_{k=1}^K -r_d^{jk} \log(\hat{r}_d^{jk}) \end{aligned} \quad (14)$$

其中,  $\hat{r}_d^{jk}$  是  $\hat{r}_d^j$  的第  $k$  项,  $r_d^{jk}$  是  $r_d^j$  的第  $k$  项。

## 3 实验结果与讨论

本节首先对本文提出的 CNN-SCMA-D2D 混合网络自编码器的最佳参数进行实验分析与论述,其次与传统的混合网络解码算法的实验性能进行对比分析。为公平起见,本文所有的实验均在相同的实验设备上进行。所做实验的场景是单小区单天线下的上行链路 SCMA-D2D 混合网络系统。本节采用的模拟器实验使用了深度学习库,如 TensorFlow 和 KERAS。仿真实验基于 Python 3.7.6。训练信噪比定为 10 dB,先将用户原始数据按照 2 比特一组进行分组,然后转变成 4 比特一组的单热向量。每个 CNN 单元的隐藏层设为 3,步长为 1,宽度为 1。训练数据集由 20 万个随机数据点组成,批处理大小为 400。用自适应矩估计 (adaptive moment estimation, ADAM) 寻找式 (13)、(14) 中的最佳值,学习率设置为 0.0001。隐藏层的节点设置为 32、64、32。在加性高斯白噪声 (additive white Gaussian noise, AWGN) 信道下的混合网络上行信道中进行了仿真实验。

### 3.1 不同 D2D 用户数目对系统 BER 性能的影响

由于本文所对比的文献 [12] 中并没有对 D2D 的最佳数目进行探究说明,故本节对 D2D 用户数目对不同用户分类解码器的误比特率性能影响进行实验,SCMA 蜂窝用户的数目设置为 6,频谱资源的数目设置为 4,分别将 D2D 用户的数目设置成 1、2、3、

4 并进行相关的对比实验。实验结果如图 6、图 7 所示。




图 6 D2D 用户数目对 SCMA 分类解码器的 BER 性能影响




图 7 D2D 用户数目对 D2D 分类解码器的 BER 性能影响

从图 6 所示的实验结果可以看出,对于 SCMA 蜂窝用户来说,D2D 的数目越多干扰越大,SCMA 用户分类解码器解码性能越差。当 D2D 用户超过 2 个时,会导致 SCMA 用户分类解码器失去解码能力。从图 7 所示的实验结果可以看出,D2D 的数目为 1 和 4 的时候,D2D 用户分类解码器的解码性能都很差,当 D2D 用户的数目为 2 和 3 时,D2D 用户解码器的解码性能达到最佳。由于我们的系统是多用户混合网络,在考虑网络配置的时候综合考虑到每种用户的情况,将 D2D 用户数目设置为 2,可以使每种用户解码器的 BER 性能都达到良好的水平。

### 3.2 实验结果

本实验对比了本文所提出的 CNN-SCMA-D2D

解码方案与传统的使用 MPA 解码的 SCMA 方案 (SCMA system w/o D2D) 以及使用列表球算法的 SCMA-D2D 混合网络<sup>[12]</sup>解码方案的 BER 性能。文献[12]介绍了一种上行链路下的 SCMA-D2D 混合网络接收机设计方案,网络因子图与本文一致,对 SCMA 用户采用 LSD-MPA 算法,对 D2D 用户对采用 LSD-ML 算法。图 8 所示是本文的解码器性能与上述系统的解码器性能的对比如。由图 8 可知,在 AWGN 信道下,本文的 CNN-SCMA-D2D for SCMA 的误码率性能优于 LSD-MPA, CNN-SCMA-D2D for D2D 误码率性能优于 LSD-ML,并且 LSD-ML 的性能明显差于 LSD-MPA。文献[12]中的解码算法不同用户间解码差异很大。由于共享层的引入,本文所提出的基于共享层的 CNN-SCMA-D2D 多用户分类解码器能够很好地降低用户间干扰对系统解码器的影响,降低不同用户解码器的解码性能差异。由于用户间干扰的存在,混合网络的解码性能会比单一网络的解码性能要差一些。相比于使用 MPA 解码算法进行解码的单一用户的 SCMA 系统,本文的 SCMA 多用户分类解码器的 BER 性能损失在可接受范围内,且能够有效地降低译码复杂度。在相同的信噪比 (signal to noise ratio, SNR) 下,比如  $SNR = 10$  dB,本文提出的 CNN-SCMA-D2D 多用户分类解码器中的 SCMA 用户分类解码器相比于只有 SCMA 蜂窝用户系统的 MPA 解码的 BER 性能损失为 0.5 dB,在可接受的范围内。

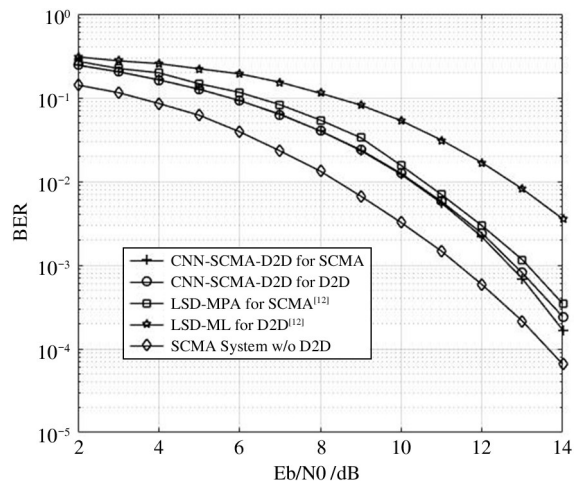


图 8 不同算法在 AWGN 信道下的误码率性能比较

### 3.3 复杂度分析

由于神经网络能够一次解码出全部用户信息,相比于传统的迭代译码方法能够显著降低译码复杂度。本节分析了 CNN-SCMA-D2D 算法的译码计算复杂度。设  $J$  为用户数,  $K$  为资源数,  $L_s(L_u)$  表示第  $n$  层共享层(用户层)的隐藏层数目。  $N_s(N_u)$  表示第  $n$  层共享层(用户层)的隐藏层节点数目。由

于 SCMA 和 D2D 用户解码端的隐藏层层数是一样的,  $L_u$  两者可以共用。本文以 SCMA 用户的解码复杂度性能进行对比, CNN-SCMA-D2D 和 LSD-MPA 的乘加(multiply-accumulate, MAC)操作次数如表 1 和图 9 所示,每个用户的平均解码时间对比如图 10 所示。

表 1 不同算法的复杂度

	LSD-MPA <sup>[12]</sup>	CNN-SCMA-D2D
MAC	$Kd_c T_{LSD} (3d_c - 2 + 5(J_{d2d})^{M_{d2d}})$	$2KN_{s,1} + \sum_{n=1}^{L_s-1} N_{s,n} N_{s,n+1} + J(\sum_{n=1}^{L_u-1} N_{u,n} N_{u,n+1}) + JN_{u,L_u}$




图 9 LSD-MPA 和 CNN-SCMA-D2D 的 MAC 数量对比

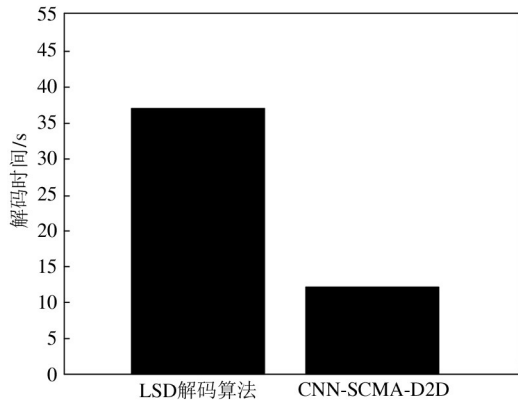


图 10 LSD 解码与 CNN-SCMA-D2D 解码时间对比

## 4 结论

本文为解决 SCMA-D2D 混合网络的编码设计

以及不同用户间干扰等问题,提出了一种基于卷积神经网络的 SCMA-D2D 混合网络卷积自编码器。建立端到端的自编码器训练模型,将所有用户的编码单元、信道条件和解码单元进行联合训练,得出对系统适应性最强、使 BER 性能最好的码本。在解码端提出一种基于共享层的多用户分类解码器,将解码问题转化成多输出分类问题,在共享层抽取所有用户的有效信息,由此降低用户间干扰,提升了解码精度。此外神经网络一次性解码相比于传统的迭代译码算法能够有效降低计算复杂度,在译码时间和译码复杂度上本文所提出的解码器都优于传统的迭代译码算法。

### 参考文献

- [ 1 ] ANWER A, WANG X, CHIH L I. Emerging, Technologies in software, hardware, and management aspects toward the 5G era; trends and challenges [ M ]. Hoboken: Wiley-IEEE Press Publisher, 2018:13-50.
- [ 2 ] LIU Y, CHEN W. Capacity analysis and sum rate maximization for the SCMA cellular network coexisting with D2D communications [ J ]. China Communications, 2022, 19(10):55-68.
- [ 3 ] HOSEIN N, HADI B. Sparse code multiple access [ C ] // Proceedings of the 2013 IEEE 24th Annual International Symposium on Personal, Indoor, and Mobile Radio Communications (PIMRC). London: IEEE, 2013:332-336.
- [ 4 ] LIU J, SHENG M, LIU L, et al. Modeling and analysis of SCMA enhanced D2D and cellular hybrid network [ J ]. IEEE Transactions on Communications, 2017, 65 ( 1 ): 173-185.
- [ 5 ] 赵可鹏. 基于 SCMA 的蜂窝与终端直通系统资源分配算法研究 [ D ]. 西安:西安电子科技大学, 2017:1-18.
- [ 6 ] 冯怀臻. 基于 SCMA 的 D2D 蜂窝混合网络性能仿真及用户配对研究 [ D ]. 成都:西南交通大学, 2017:46-54.



- [ 7 ] ZHAO K, SHI Y, DAI Y, et al. Resource allocation in device-to-device communication under laid cellular network using SCMA; an opportunistic approach[C] // Proceedings of the 2015 IEEE/CIC International Conference on Communications in China (ICCC). Shenzhen: IEEE, 2015:1-6.
- [ 8 ] LIU Y, FANG X, YANG H, et al. A mapping scheme of users to SCMA layers for D2D communications[C] // Proceedings of the 2016 IEEE 83rd Vehicular Technology Conference. Nanjing: IEEE, 2016:1-5.
- [ 9 ] LI Y, SHA X, JIANG F, et al. Sparse codes allocation in D2D communications underlying cellular network[C] // Proceedings of the 2016 International Wireless Communications and Mobile Computing Conference. Paphos: IEEE, 2016:948-952.
- [ 10 ] LI Y, SHENG M, ZHU Y, et al. Sum rate maximization in underlay SCMA device-to-device networks[C] // Proceedings of the 2016 IEEE Global Communications Conference. Washington: IEEE, 2016:1-6.
- [ 11 ] KIM H, NGUYEN H, KANG G, et al. Device-to-device communications underlying an uplink SCMA system[J]. IEEE Access, 2019,7: 21756-21768.
- [ 12 ] LIU Y, CHEN W, WEI F, et al. SCMA receiver design for cellular uplink transmission coexisted with D2D[C] // Proceedings of the 2019 11th International Conference on Wireless Communications and Signal Processing. Xi'an: IEEE, 2019:1-6.
- [ 13 ] LECUN Y, BENGIO Y, HINTON G. Deep learning[J]. Nature, 2015,521(7553):436-444.
- [ 14 ] KIM M, KIM N, LEE W, et al, Deep learning-aided SCMA[J]. IEEE Communications Letters, 2018,20(4): 720-723.
- [ 15 ] LIN J, FENG S, YANG Z, et al. A novel deep neural network based approach for sparse code multiple access [J]. Neurocomputing, 2020,382:52-63.
- [ 16 ] LU C, XU W, SHEN H, et al. An enhanced SCMA detector enabled by deep neural network[C] // Proceedings of the 2018 IEEE/CIC International Conference on Communications in China. Beijing: IEEE, 2018:835-839.
- [ 17 ] HAN Y, WANG Z, GUO Q, et al. Deep learning-based detection for moderate-density code multiple access in IoT networks[J]. IEEE Communications Letters, 2020,245(1):122-125.
- [ 18 ] ABIDI I, HIZEM M, AHRIZ I, et al. Convolutional neural networks for blind decoding in sparse code multiple access[C] // Proceedings of the 2019 15th International Wireless Communications and Mobile Computing Conference. Tangier: IEEE, 2019:2007-2012.
- [ 19 ] JIANG F, CHANG D, MA S, et al. A residual learning-aided convolutional autoencoder for SCMA [J]. IEEE Communications Letters, 2023,27(5):1337-1341.
- [ 20 ] WEI C, YANG H, LI C, et al. SCMA decoding via deep learning [J]. IEEE Wireless Communications Letters, 2021,10(4):878-881.
- [ 21 ] LUO Q, LIU Z, CHEN G, et al. A novel multitask learning empowered codebook design for downlink SCMA networks [J]. IEEE Wireless Communications Letters, 2022,11(6):1268-1272.
- [ 22 ] LI D, JIA M, ZHANG L, et al. Stochastic channel modeling for deep neural network-aided sparse code multiple access communications[C] // 2021 IEEE 94th Vehicular Technology Conference. Norman: IEEE, 2021:1-5.

## SCMA-D2D hybrid network convolutional autoencoder

XU Yaohua<sup>\*\*\*</sup>, ZHOU Xinyuan<sup>\*\*\*</sup>, HUANG Xing<sup>\*\*\*</sup>, JIANG Fang<sup>\*\*\*</sup>, WANG Yi<sup>\*\*\*</sup>, WANG Yue<sup>\*\*\*</sup>

(\* Key Laboratory of Intelligent Computing and Signal Processing,  
Ministry of Education, Anhui University, Hefei 230601)

(\*\* The IoT Spectrum Sensing and Testing Engineering Center of Anhui University, Hefei 230601)

(\*\*\* Anhui Telecom Planning and Design Co., Ltd., Hefei 230031)

### Abstract

In order to meet the needs of massive connectivity and low power consumption in Internet of Things communication, efficient use of limited spectrum resources has become an important challenge. Adding D2D(device to device) user pairs to SCMA (sparse code multiple access) cellular network and sharing spectrum resources among them can further improve spectrum utilization and meet the communication needs of massive connectivity and low power consumption. However, serious inter-user interference will be caused when different types of users share same spectrum resources, resulting in lower accuracy of multi-user detection and higher complexity of decoding. In this paper, convolutional neural network (CNN) is used to design the SCMA-D2D hybrid network autoencoder, and a suitable neural network structure is designed through end-to-end joint training. Using CNN unit to implement hybrid network coding, learn the valid codebook of SCMA cellular users and D2D users; The multi-user detection problem of hybrid networks is modeled as a multi-task classification decoding problem based on shared layer mechanism, and a multi-user classification decoder is established. The results show that the proposed autoencoder can generate codebooks with better adaptability to the system, and combined with the multi-task classification decoder at the receiving end, it can effectively improve the bit error rate performance of the whole hybrid network system and reduce the computational complexity of decoding.

**Key words:** convolutional neural network(CNN), sparse code multiple access(SCMA), device to device (D2D) communication, wireless communication, multi-user hybrid network