

激光与光电子学进展

基于非正交多址和卷积神经网络的光接入网

邓鹏程, 王睿, 杨慧*, 易安林

西南交通大学信息科学与技术学院, 四川 成都 610031

摘要 针对下一代光接入网,提出了一种基于功率域非正交多址的扩容无源光网络方案。传统的功率域非正交多址网络基于信道估计函数,采用串行干扰消除(SIC)算法进行解调和恢复,需要精确的信道估计,存在差错传播效应。针对该问题,提出了基于修正卷积神经网络(CNN)的信号接收方案,利用大量数据独立拟合各用户信道函数,打破了SIC解调算法中用户间的依赖链,提升了系统的传输性能和公平性。结果表明,在扩容功率域非正交多址无源光网络中,相比传统SIC解调算法,基于修正CNN的接收方案对远端用户(传输60 km)和近端用户(传输20 km)的传输性能可分别提升约0.5 dB和1.7 dB,且其公平性指数更接近1。

关键词 光通信; 功率域非正交多址; 卷积神经网络; 串行干扰消除; 扩容无源光网络

中图分类号 TN913.7

文献标志码 A

DOI: 10.3788/LOP202259.1306006

Optical Access Network Based on Non-Orthogonal Multiple Access and Convolutional Neural Network

Deng Pengcheng, Wang Rui, Yang Hui*, Yi Anlin

School of Information Science and Technology, Southwest Jiaotong University, Chengdu 610031, Sichuan, China

Abstract This paper proposes a long reach passive optical network based on power-domain non-orthogonal multiple access for the next generation optical access network. Based on channel estimation function, the traditional power-domain non-orthogonal multiple access networks employ successive interference cancellation (SIC) algorithm for signal demodulation and recovery, which require accurate channel estimation and has error propagation problem. To overcome this problem, a signal receiving scheme based on modified convolutional neural network (CNN) is proposed, which exploits a large amount of data to independently fit the channel function of each user, thus to break the dependence chain between users in the SIC demodulation algorithm, and improve transmission performance and fairness of the system. The results show that, compared with the traditional SIC demodulation algorithm in the long reach power-domain non-orthogonal multiple access passive optical network, the receiving scheme based on the modified CNN can improve the transmission performance of far-end users (transmission 60 km) and near-end users (transmission 20 km) by about 0.5 dB and 1.7 dB, respectively, and its fairness index closer to 1.

Key words optical communications; power-domain non-orthogonal multiple access; convolutional neural network; successive interference cancellation; long reach passive optical network

1 引言

由于信息技术的迅猛发展,云计算、物联网、人工智能等大数据量业务逐渐兴起并普及。海量数据的快速交互和处理要求从骨干网到接入网具有更大容量的传输和交换能力^[1],如何实现大容量低成本光接入也成为接入网研究领域和运营商共同关心的一个重要课

题^[2-4]。为扩大容量,研究人员已开发了多种正交维度以实现长距离广覆盖,包括时隙、频率、波长、码字、空间等^[5-9]。但正交复用方式需要严格保证用户信号之间的正交性,难以灵活地在多维度上重叠扩大网络容量。

近年来,功率域非正交多址(PD-NOMA)接入作为一种新的复用/多址技术引起了研究人员的关注,其

收稿日期: 2021-08-06; 修回日期: 2021-09-06; 录用日期: 2021-09-10

基金项目: 四川省科技计划(2020YFSY0021)、区域光纤通信网与新型光通信系统国家重点实验室开放基金

通信作者: *yanghui@swjtu.edu.cn

在不改变原编码方式的基础上,增加功率这一可用维度进行复用,可以与任意编码/复用方式进行结合。PD-NOMA 能有效提高通信系统的灵活性和吞吐量,被广泛应用于无线通信和可见光通信等领域^[10-14]。在光接入网领域,基于 PD-NOMA 的接入技术在短距离传输上取得了初步进展。Lin 等^[15]对 20 km 长上行多用户 PD-NOMA 无源光网络(PD-NOMA-PON)方案的有效性进行了实验验证。Sarmiento 等^[16]探究了 50 Gbit/s 基于多波带无载波幅度相位(Multi-band CAP)调制的 PD-NOMA-PON 在背靠背传输时的功率预算,其中,PD 为光电二极管。在上述 PD-NOMA 系统中,功率复用信号需要按照功率分布的先后顺序,采用串行干扰消除(SIC)算法进行串行连续解调。SIC 算法依赖于用户信道估计函数,当信号遭受复杂的线性或非线性的损伤时,难以通过导频符号获得准确的信道估计函数。不同用户之间的解调存在依赖链,这会导致差错传播(EP)问题,劣化系统的传输性能和公平性^[17]。为了减轻差错传播效应,Tan 等^[18]采用新型线性信道估计方法获得信道信息,最大化大功率用户的平均信噪比。Feng 等^[19]在 PD-NOMA-PON 中结合残留边带技术和迭代干扰消除算法,减轻了色散效应和平方律检测引起的载波间干扰。上述方案本质上仍然是基于信道估计和均衡实现多用户检测,当网络覆盖距离增大,扩容 PD-NOMA 通信系统在增加容量的同时,也会带来更复杂多样的信号损伤。这些损伤相互作用,经过平方律检波后呈现出复杂的非线性变换,输入输出的显式统计描述变得越来越困难,这对基于信道估计和均衡的多用户检测方法提出了更高的要求。

机器学习技术凭借强大的认知能力在各个领域得到了广泛应用,如计算机视觉、语音识别、自然语言处理。在光学和光通信领域,各种神经网络模型被用于光学图像处理、光性能监控、调制格式识别和信道损伤补偿等^[20-23]。相比传统的 SIC 检测算法,基于神经网络的补偿方法基于大量有效数据,利用智能学习能力捕捉信号受到的不同损伤特性,进而实现与信号损伤相对应的补偿功能。Karanov 等^[24]提出了一种基于人工神经网络的端到端光通信系统,并在 40 km 标准单模光纤(SSMF)上实现了 42 Gbit/s 的传输。Yi 等^[25]通过基于神经网络的均衡器消除信道损伤,并给出了模型的训练和测试规则,实现了 100 Gbit/s/ λ 的无源光网络传输(λ 为波长)。Jana 等^[26]在 20 Gbit/s PD-NOMA 系统中采用了 K-means 算法消除远端用户干扰。Lin 等^[27]针对短距离 NOMA-PON 提出基于神经网络的接收方案,并进行了 20 km 的传输实验验证。

目前,在扩容 PD-NOMA-PON 中采用神经网络技术实现一体化接收解调的研究较少,因此,本文在扩容 PON 中进一步研究了基于修正卷积神经网络(CNN)的接收方案。利用大量的发射数据和接收数

据独立拟合每个用户的信道传输过程,接收到的多用户信号不需要信道状态信息即可实现解码。相比传统 SIC 算法,基于 CNN 的接收方案从原理上打破了用户检测的依赖链,具有高精度和高度非线性的特点,能提升系统的传输性能和公平性。在此基础上,搭建 VPI 仿真平台和神经网络实验平台,以验证基于 PD-NOMA 和 CNN 扩容 PON 方案的有效性。结果表明,CNN 能有效补偿扩容 PON 中的损伤并提升接入系统的公平性。

2 系统模型

基于 PD-NOMA 和 CNN 的扩容 PON 系统模型如图 1 所示。其中,OLT 为光线路终端,ODN 为光分配网,ONU 为光网络单元。PD-NOMA 增加功率域作为复用维度,在与其他复用技术结合(以时频复用为例)时,通过为用户分配不同的功率后叠加传输,使多用户共享相同的时频资源块,提高频谱效率、扩大网络容量。假定网络中有 n 个用户,第 i 个用户对时频资源编码进行调制后得到基带信号 X_i ,每路基带信号的功率分配系数为 $\sqrt{p_i}$,在功率域进行线性叠加后得到 X_{NOMA} ,可表示为

$$X_{\text{NOMA}} = \sum_{i=1}^n \sqrt{p_i} X_i. \quad (1)$$

将叠加后的信号 X_{NOMA} 送入各自的信道 H_i 中进行传输,ONU 接收到的信号 Y_i 可表示为

$$Y_i = X_{\text{NOMA}} H_i + n_i, \quad (2)$$

式中, n_i 为噪声。

神经网络作为深度学习的代表,能够基于监督学习的思想,学习接收信号和原始比特之间的映射关系,从而实现信道均衡和信号的解调。基于神经网络的接收机方案包含在线和离线两个阶段。在离线阶段通过训练和测试数据集建立对应的神经网络接收机模型。在线阶段选择相应的神经网络接收机模型对接收到的信号进行实时检测,恢复发送端的原始比特数据。采用 CNN 作为接收机的网络模型具有局部权值共享的特殊结构和良好的空间特征提取能力,也是应用最广泛的深度学习模型之一。传统 CNN 由卷积层(Conv)、池化层和全连接层组成。其中,池化层本质上是一个下采样过程,可实现特征降维,减少网络模型的参数。考虑到将 CNN 模型应用到扩容 PD-NOMA-PON 中,需要输出每个符号对应的比特信息,使用池化层进行降维会影响模型的精度,因此,对传统的 CNN 模型进行修正,同时对模型参数进行了一系列优化。优化后的模型由一层输入层、两层一维卷积层、铺平层和输出层组成。传统 CNN 无法处理复数输入数据,在处理子载波数量为 N 的复数信号时,将其划分为两个通道,使输入的复数信号转化成维度为 $N \times 2$ 的二维数据,并送入输入层中。卷积层通过多个滤波器

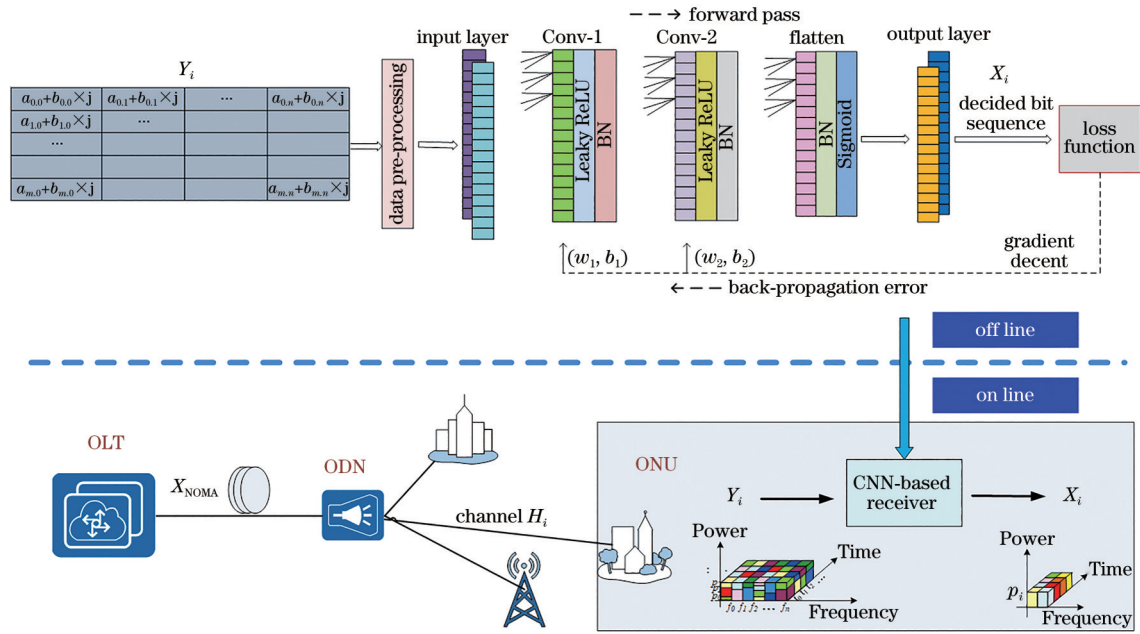


图 1 基于 PD-NOMA 和 CNN 的扩容 PON 系统

Fig. 1 Long reach PON system based on PD-NOMA and CNN

识别输入数据的不同浅层特征,通过权值共享的特殊结构大幅度减少了模型的参数量,降低模型的复杂程度。将卷积层的多维输出拼接并转换为一维信号到输出层。输入层的大小为 $(N, 2)$, 对应于 N 个子载波信号的实部和虚部数目。两个卷积层分别具有 $2N$ 和 N 个滤波器。对于 M -QAM(正交幅度调制), 输出层有 $\log_2(M) \times N$ 个节点, 对应于预测的比特位数。卷积层和输出层分别选取带泄漏修正线性单元(Leaky ReLU)和 Sigmoid 函数作为相应的激活函数, 可表示为

$$\text{Leaky ReLU: } f_1(x) = \max(\alpha x, x), 0 < \alpha < 1, \quad (3)$$

$$\text{Sigmoid: } f_2(x) = \frac{1}{[1 + \exp(-x)]}. \quad (4)$$

模型中使用大量尺寸为 1×1 的卷积核, 结合非线性激活函数, 可有效增加非线性特性, 使网络能学习更复杂的信道响应函数。在训练阶段, 首先, 初始化所有连接节点的权重, 将训练集划分为多个批次送入网络中。然后, 通过前向传播计算输出, 根据反向传播调整中间层权值连接的参数 (w, b) 最小化损失函数。其中, w, b 分别为每一层网络的权重和偏置。用均方误差(MSE)作为模型的损失函数, 可表示为

$$X_{\text{MSE}} = \frac{1}{m} \sum_{i=1}^m (X_i^{\text{label}} - \sum_{i=1}^m X_i^{\text{predict}})^2, \quad (5)$$

式中, m 为训练中使用的总比特数, X_i^{label} 为第 i 位的原始值, X_i^{predict} 为第 i 位的预测值。需要注意的是, 网络模型的表达能力一定程度上可以通过增加卷积层和卷积核的数量增强, 但也会导致参数过大以及过拟合问题。在控制模型复杂度的情况下, 可使用一系列调优策略

提高模型的训练精度, 同时通过数据增强手段丰富检测数据集, 提高网络的鲁棒性。训练数据集(Training dataset)和测试数据集(Test dataset)的大小均为 48000。采用批归一化(BN)层将神经网络的输入归一化到 $[-1, 1]$ 范围, 避免协变量偏移现象。通过 BN 层加快模型的收敛速度, 有效提高了模型训练精度。初始学习率(Initial learning rate)是影响模型训练的重要因素之一, 经过对比测试, 使用了自适应学习率的 RMSprop 优化器优化网络性能。训练批量大小(Training batch size)和迭代次数(Epoch size)会影响梯度下降的方向, 进而影响模型的训练效果。经过优化策略处理后, 模型训练中的重要参数设置如表 1 所示。相比传统的 SIC 接收机, 基于修正 CNN 的接收机由于模型的离线训练和测试计算复杂度仍有所增加。因此, 主要考虑在线预测的计算复杂度。对于模型中使用的一维卷积, 其计算复杂度可表示为

$$X_{\text{Time}} = o\left(\sum_{l=1}^D NF_l K_l M_l\right), \quad (6)$$

式中, D 为卷积层的层数, F_l 为第 l 层的输入通道数量, K_l 为第 l 层的滤波器数量, M_l 为第 l 层卷积核的尺寸。

表 1 CNN 模型的训练参数

Table 1 Training parameters of the CNN model

Parameter	Value
Initial learning rate	0.001
Training dataset size	48000
Test dataset size	48000
Training batch size	800
Epoch size	300

3 仿真实验

参考上述系统模型,搭建了基于修正 CNN 的扩容 PD-NOMA-PON 仿真平台。选用以 TensorFlow 为后端的 Keras 框架搭建神经网络实验平台,采用商业软件 Matlab2014a 和 VPItransmissionMaker 9.2 搭建扩容 PD-NOMA PON 传输系统。基于 VPI 传输系统获取训练数据集和测试数据集,对已搭建好的 CNN 模型进行离线训练并调优,得到用于在线信道均衡及解调的修正 CNN 模型。数据集是神经网络实现功能的重要组件,关系到模型的准确性和泛化能力,在获取数据集进行离线训练时,为了提高数据的随机性,用当前时间作为随机种子以保证产生的训练集和测试集中的序列没有重复。此外,还对样本数据进行随机重组,保证模型训练的样本集足够充分。具体的在线仿真框图如图 2 所示。在发射端,用 Matlab2014a 生成基带正交频分复用(OFDM)信号。快速傅里叶变换(FFT)的点数 64,循环前缀(CP)大小为 8,每 50 个 OFDM 数据帧插入 4 个训练序列用于传统 SIC 算法的信道估计。为了避免不同用户训练序列之间的干扰,保证信道估计的准确性,每个用户的训练序列在不同的时隙中发送。用户信号在功率域中按一定的功率比叠加得到基带信号 X ,可表示为

$$X = \sqrt{p_1} x_1 + \sqrt{p_2} x_2, \quad (7)$$

式中, x_1 为用户 1(近端用户)的符号序列,被分配较高的发射功率 p_1 ; x_2 为用户 2(远端用户)的符号序列,被分配较低的发射功率 p_2 。用户之间的功率分配比(PDR)可表示为

$$X_{PDR} = 10 \log_{10}(p_1/p_2). \quad (8)$$

产生的基带信号上变频(RF up)到频率为 2.5 GHz 的射频(RF),进行功率分配后,将两个用户的信息进行叠加,将叠加的信息进行数模转换(DAC),然后用强度马赫-曾德尔调制器(MZM)将电信号转换为光学双边带信号。基带信号采用 4-QAM 方式,其带宽为 5 GHz,总数据速率为 10 Gbit/s。将复用后的光信号发射到传输链路中,仿真链路由两段标准单模光纤、分光器、两个衰减器和两个光电二极管组成。光信号经过一段 20 km 长的标准单模光纤传输后,由分光器将光功率进行 1:1 分光,再分别进入两条支路。其中,支路 1 的信号(用户 1)继续经过一段 40 km 长的标准单模光纤传输,通过衰减器后,连接一个 PD 进行直接检测,完成光电信号的转换。支路 2 的信号通过衰减器后连接光电二极管进行直接检测,得到用户 2 的信号。传输光纤的损耗系数和色散系数分别为 0.2 dB/km 和 17 ps/(nm·km)(波长相差 1 nm 的信号通过 1 km 的光纤后,两个信号的到达时间相差 17 ps)。光电二极管的热噪声为 10^{-14} A/Hz^{1/2},光电转换后的电信号被下变频(RF down)到基带,并由模数变换模块(ADC)进行采样。基于 SIC 的方案中,提取训练序列进行信道估计,然后基于迫零算法对失真的数据符号进行补偿。基于 CNN 的方案中,用 CNN 模型代替信道估计、信道均衡和 QAM 解映射。本仿真采用两个神经网络模型:支路 1 上的神经网络模型用于解调用户 1 的信号,支路 2 上的神经网络模型用于解调用户 2 的信号。在两用户复用系统中,高比特位代表用户 1 的信号,低比特位代表用户 2 的信号。因此,用两个神经网络模型分别进行训练并识别信号表示的高比特位和低比特位,完成信道均衡和解调。网络模型设计中输入层的节点数由 FFT 的点数决定,而

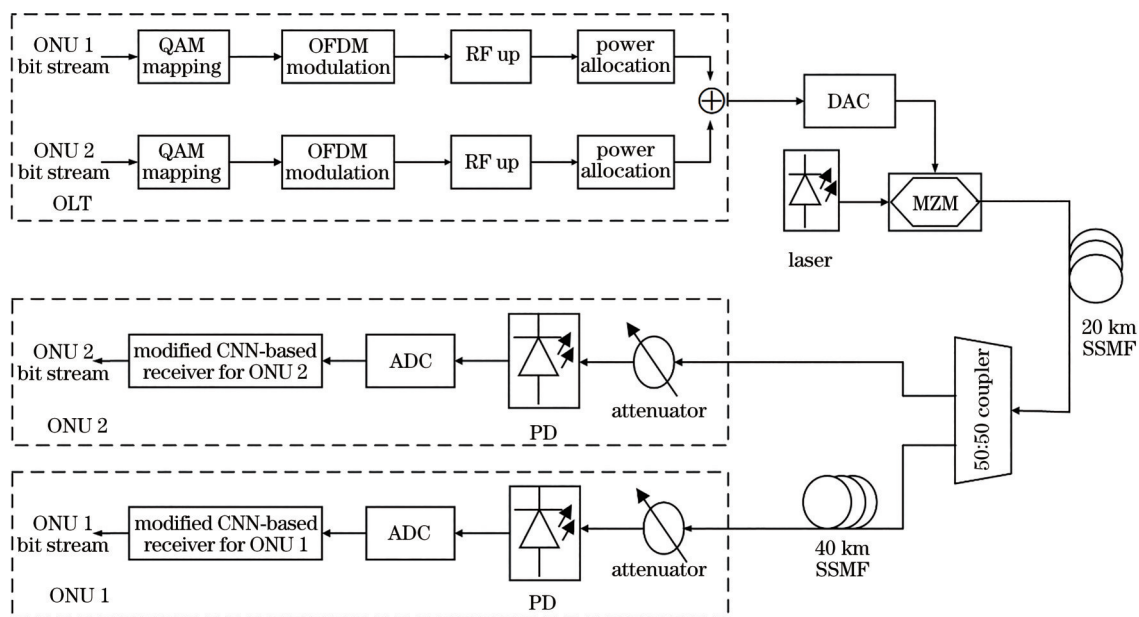


图 2 基于修正 CNN 接收机的扩容 NOMA-PON 下行传输仿真框图

Fig. 2 Simulation block diagram for long reach NOMA-PON downstream transmission based on modified CNN receiver

输出层的节点数与传输信号的 M -QAM 格式相关。在用户 1 和用户 2 均传输相同调制格式的 4-QAM 信号时,两者使用的神经网络模型结构是相同的。模拟过程中产生的数据样本为 5553152 个符号。其中, 3533824 个符号用于训练,其他 2019328 个符号用于测试。

4 仿真结果与讨论

在 PD-NOMA 系统中,功率分配系数会影响接收端联合星座图的星座点分布,进而影响系统的传输性能。PDR 过大会使星座点向原点收缩,导致星座点代表的低比特位出现混叠,用户性能恶化;PDR 过小会导致星座点向外扩展,使星座点代表的高比特位出现混叠,大功率用户的性能下降,进而通过差错传播效应使低功率用户的性能下降。

首先,基于 SIC 解调算法仿真了发射功率 $P_t = 0$ dBm 时 PDR 与接收机灵敏度的关系,结果如图 3 所示。仿真时接收机灵敏度采用误码率(BER)为 10^{-3} 时的最小平均接收机光功率。仿真结果表明,在一定的 PDR 范围内,用户 1 的接收机灵敏度随着 PDR 的增大而提升。对于用户 1 而言,PDR 越大,表明用户 1 分配的功率越高,信噪比得到了一定改善,PDR 增加的极端情况就是只承载用户 1 的信号;对于用户 2 而言,PDR 的减小会改善用户 2 的信噪比。当 $X_{PDR} > 6$ 时,用户 2 几乎不受差错传播效应的影响,此时用户 2 的接收机灵敏度随着 PDR 的增大而恶化;当 $X_{PDR} = 6$ 时,联合星座图的星座点分布与标准的 16-QAM 星座点分布相同,用户 2 的接收机灵敏度到达最优;当 $X_{PDR} < 6$ 时,星座点向外扩展并开始出现混叠,导致用户 1 的解码性能下降,继而通过差错传播效应恶化用户 2 的性能。

为了对比基于 CNN 和基于 SIC 算法接收方案的系统传输性能和公平性,图 4、图 5 分别给出了用户 1 和用户 2 分别基于 SIC 算法和 CNN 的 BER 性能。可




图 3 基于 SIC 解调方案中接收机灵敏度和 PDR 的关系
Fig. 3 Relationship between receiver sensitivity and PDR for SIC-based demodulation scheme

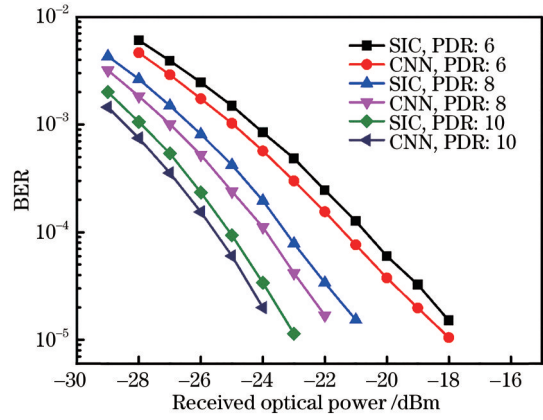


图 4 不同 PDR 下用户 1 的接收机 BER
Fig. 4 Receiver BER of user 1 under different PDR




图 5 不同 PDR 下用户 2 的接收机的 BER
Fig. 5 Receiver BER of user 1 under different PDR

以发现:对于用户 1,当 $X_{PDR} = 10, 8, 6$ 时,基于 SIC 解调算法的接收机灵敏度分别为 -28 dBm、 -26.4 dBm、 -24.4 dBm,基于 CNN 的接收机灵敏度分别为 -28.5 dBm、 -27 dBm、 -24.9 dBm,相比基于 SIC 解调算法的模型,分别提高了约 0.5 dB、 0.6 dB、 0.5 dB;对于用户 2,基于 SIC 解调算法的接收机灵敏度分别为 -22.9 dBm、 -25.7 dBm、 -27.6 dBm,基于 CNN 的接收机灵敏度分别为 -24.6 dBm、 -27.5 dBm、 -28.2 dBm,相比基于 SIC 解调算法的模型,分别提高了约 1.7 dB、 1.8 dB、 0.6 dB。当 $X_{PDR} > 6$ 时,用户 1 和用户 2 受到星座点混叠带来的干扰较小,CNN 模型对用户 1 接收机灵敏度带来的提升效果有限(约为 0.5 dB),对用户 2 的接收机灵敏度提升效果受到了 PDR 的影响。当 $X_{PDR} = 6$ 时,联合星座图的星座点分布与标准 16-QAM 星座点分布类似,此时,神经网络模型对用户 2 的接收机灵敏度提升了约 0.6 dB,与用户 1 接近;当 $X_{PDR} > 6$ 时,神经网络模型对用户 2 的接收机灵敏度提升了约 $1.7 \sim 1.8$ dB。这表明 CNN 模型对信号进行独立解调,避免了差错传播效应,对用户 2 在低信噪比情况下的提升十分明显。综上所述,基于 CNN 模型的接收方案能有效改善低功率用户的接收

机灵敏度,提升系统的总体传输性能。

用户接入的公平性是光接入网络的重要考虑因素。为了对比 CNN 和 SIC 解调算法的接入公平性,定义了一个简化的公平性指数(FI),可表示为

$$X_{FI} = \frac{(\sum_{i=1}^N P_{BERi})^2}{N \sum_{i=1}^N P_{BERi}^2}, \quad (9)$$

式中, P_{BERi} 为用户*i*的接收机灵敏度。FI利用用户的接收机灵敏度衡量用户间传输性能的差异性,当用户间的接收机灵敏度相近时,FI接近1;当用户间的接收机灵敏度差异较大时,FI会减小。结合仿真结果可计算基于SIC和基于CNN接收方案的系统公平性指数,计算结果如表2所示。可以发现:两种接收方案下FI的变化趋势是一致的,当 $X_{PDR} = 10, 4$ 时,基于CNN的系统公平性指数优于基于SIC的方案;当 $X_{PDR} = 8, 6$ 时,基于CNN的系统公平性指数接近基于SIC的方案,原因是CNN对于接收机灵敏度在不同PDR下的改善程度不同;当 $X_{PDR} = 8$ 时,系统的FI最高,此时两个用户的服务质量相近;当 $X_{PDR} = 4$ 时,FI最低,两个用户的服务质量相差较大。

表2 不同接收机的系统公平性指数

Table 2 System fairness index of different receivers

PDR	FI for SIC-based method	FI for CNN-based method
4	0.9869	0.9882
6	0.9959	0.9957
8	0.9998	1.0000
10	0.9904	0.9942

5 结 论

针对下一代光接入网大容量、低成本的需求,提出了一种基于PD-NOMA和CNN的扩容PON方案。传统功率域复用系统主要采用SIC解调算法,依赖信道估计精度,存在差错传播效应,限制了该技术在扩容PON中的进一步应用。因此,引入修正的CNN模型实现用户侧信号的信道估计、信道均衡和解映射的一体化接收。仿真对比了传统SIC算法和CNN模型的BER性能以及系统公平性。仿真结果表明,当BER为 10^{-3} 、用户均使用4-QAM、PDR分别为10、8、6时,CNN对于传输距离为60 km的用户1接收机灵敏度分别提升了0.5 dB、0.6 dB、0.5 dB,对于传输距离为20 km的用户2接收机灵敏度分别提升了1.7 dB、1.8 dB、0.6 dB。在系统公平性方面,基于CNN的接收方案在PDR为10和4时,能有效降低远近用户的性能差异,灵活调节系统公平性。目前,本方案采用4QAM-OFDM仿真验证其可行性,未来将继续研究高阶调制(16-QAM及以上)功率复用信号在扩容PON

中的离线实验实现和基于神经网络的预均衡技术,以实现大容量低成本接入。

参 考 文 献

- [1] Nettet D. NG-PON2 technology and standards[J]. Journal of Lightwave Technology, 2015, 33(5): 1136-1143.
- [2] Kani J I, Bourgart F, Cui A N, et al. Next-generation PON-part I: technology roadmap and general requirements [J]. IEEE Communications Magazine, 2009, 47(11): 43-49.
- [3] Talli G, Townsend P D. Hybrid DWDM-TDM long-reach PON for next-generation optical access[J]. Journal of Lightwave Technology, 2006, 24(7): 2827-2834.
- [4] Ullah S, Ullah R, Khan A, et al. Optical multi-wavelength source for single feeder fiber using suppressed carrier in high capacity LR-WDM-PON[J]. IEEE Access, 2018, 6: 70674-70684.
- [5] Qian D Y, Cvijetic N, Hu J Q, et al. A novel OFDMA-PON architecture with source-free ONUs for next-generation optical access networks[J]. IEEE Photonics Technology Letters, 2009, 21(17): 1265-1267.
- [6] Chen Y X, Li J H, Zhu P K, et al. Novel MDM-PON scheme utilizing self-homodyne detection for high-speed/capacity access networks[J]. Optics Express, 2015, 23(25): 32054-32062.
- [7] Luo Y Q, Zhou X P, Effenberger F, et al. Time- and wavelength-division multiplexed passive optical network (TWDM-PON) for next-generation PON stage 2 (NG-PON2)[J]. Journal of Lightwave Technology, 2013, 31(4): 587-593.
- [8] Kumari M, Sharma R, Sheetal A. Performance analysis of high speed backward compatible TWDM-PON with hybrid WDM-OCDMA PON using different OCDMA codes[J]. Optical and Quantum Electronics, 2020, 52(11): 1-59.
- [9] 马子洋, 吴琼琼, 李启华, 等. 超密集波分复用无源光网络的研究进展[J]. 激光与光电子学进展, 2021, 58(5): 0500006.
Ma Z Y, Wu Q Q, Li Q H, et al. Ultra-dense wavelength division multiplexing passive optical network [J]. Laser & Optoelectronics Progress, 2021, 58(5): 0500006.
- [10] Wu Q, Feng Z, Tang M, et al. Digital domain power division multiplexed dual polarization coherent optical OFDM transmission[J]. Scientific Reports, 2018, 8: 15827.
- [11] Lin B J, Ye W P, Tang X, et al. Experimental demonstration of bidirectional NOMA-OFDMA visible light communications[J]. Optics Express, 2017, 25(4): 4348-4355.
- [12] Dai L L, Wang B C, Yuan Y F, et al. Non-orthogonal multiple access for 5G: solutions, challenges, opportunities, and future research trends[J]. IEEE Communications Magazine, 2015, 53(9): 74-81.
- [13] 郝少伟, 李勇军, 赵尚弘, 等. 基于非正交多址接入的

- 星间可见光通信最优功率分配研究[J]. 中国激光, 2021, 48(7): 0706002.
- Hao S W, Li Y J, Zhao S H, et al. Optimal power allocation for intersatellite visible light communication based on nonorthogonal multiple access[J]. Chinese Journal of Lasers, 2021, 48(7): 0706002.
- [14] Lin B J, Lai Q W, Ghassemlooy Z, et al. A machine learning based signal demodulator in NOMA-VLC[J]. Journal of Lightwave Technology, 2021, 39(10): 3081-3087.
- [15] Lin B J, Ghassemlooy Z, Tang X, et al. Experimental demonstration of an NOMA-PON with single carrier transmission[J]. Optics Communications, 2017, 396: 66-70.
- [16] Sarmiento S, Mendinueta J M D, Altabás J A, et al. Optical power budget enhancement in 50 Gb/s IM-DD PONs with NOMA-CAP modulation and SOA-based amplification[C]//2019 21st International Conference on Transparent Optical Networks (ICTON), July 9-13, 2019, Angers, France. New York: IEEE Press, 2019: 18994346.
- [17] Li H Y, Huang Z T, Xiao Y, et al. Solution for error propagation in a NOMA-based VLC network: symmetric superposition coding[J]. Optics Express, 2017, 25(24): 29856-29863.
- [18] Tan Y Z, Zhou J R, Qin J Y. Novel channel estimation for non-orthogonal multiple access systems[J]. IEEE Signal Processing Letters, 2016, 23(12): 1781-1785.
- [19] Feng N. Considerations of SSII mitigation in power-domain non-orthogonal multiple access (NOMA)-PON [C]//Asia Communications and Photonics Conference (ACPC) 2019, November 2-5, 2019, Chengdu, China. Washington, D.C.: OSA, 2019: M4A.92.
- [20] 朱子岳, 赵梦鑫, 张一尘, 等. 高速 IM-DD 模分复用通信系统中基于神经网络的 MIMO 均衡技术[J]. 光学学报, 2021, 41(14): 1406003.
- Zhu Z Y, Zhao M X, Zhang Y C, et al. MIMO equalization technology based on neural network in high-speed IM-DD mode division multiplexing transmission system[J]. Acta Optica Sinica, 2021, 41(14): 1406003.
- [21] Khan F N, Zhong K P, Zhou X, et al. Joint OSNR monitoring and modulation format identification in digital coherent receivers using deep neural networks[J]. Optics Express, 2017, 25(15): 17767-17776.
- [22] 毛远宏, 马钟, 贺占庄. 采用卷积神经网络的红外和可见光图像块匹配[J]. 红外与激光工程, 2021, 50(5): 20200364.
- Mao Y H, Ma Z, He Z Z. Infrared-visible image patches matching via convolutional neural networks[J]. Infrared and Laser Engineering, 2021, 50(5): 20200364.
- [23] Zhang S, Yaman F, Nakamura K, et al. Field and lab experimental demonstration of nonlinear impairment compensation using neural networks[J]. Nature Communications, 2019, 10: 3033.
- [24] Karanov B, Chagnon M, Thouin F, et al. End-to-end deep learning of optical fiber communications[J]. Journal of Lightwave Technology, 2018, 36(20): 4843-4855.
- [25] Yi L L, Liao T, Huang L Y, et al. Machine learning for 100 Gb/s/ λ passive optical network[J]. Journal of Lightwave Technology, 2019, 37(6): 1621-1630.
- [26] Jana D P, Gupta S. Machine learning enabled detection for QPSK-PD-NOMA system employing single mode fiber[C]//2020 National Conference on Communications (NCC), February 21-23, 2020, Kharagpur, India. New York: IEEE Press, 2020: 19510231.
- [27] Lin B J, Yang H, Wang R, et al. Convolutional neural network-based signal demodulation method for NOMA-PON[J]. Optics Express, 2020, 28(10): 14357-14365.