引用本文：孙猷，张俊杰. 基于深度学习的水下无线光通信信噪比改善研究与实现[J]. 光通信技术，2021，45(1)：10–15.

基于深度学习的水下无线光通信信噪比改善研究与实现

孙 猷，张俊杰*

（上海大学 特种光纤与光接入网重点实验室，上海 200072）

摘要：复杂的水下环境造成了水下光信号的质量下降，为提升水下无线光通信系统信号信噪比，结合深度神经网络提出了一种信噪比改善方法，该方法通过信号频谱有效抑制了信号噪声。实验结果表明：针对 1 m 传输距离的水下无线光通信 16 阶正交振幅调制－正交频分复用（16QAM-OFDM）信号，该方法可以实现约 17 dB 的信噪比提升同时误码率降低至 1.709×10^{-3}，可应用于水下无线光通信系统中提升传输性能，且具备一定的泛化能力。

关键词：水下无线光通信；信噪比改善；深度学习；正交频分复用

中图分类号：TN91　**文献标志码**：A　**文章编号**：1002-5561(2021)01-0010-06

DOI：10.13921/j.cnki.issn1002-5561.2021.01.003　**开放科学(资源服务)标识码(OSID)**：

Research and implementation of signal to noise ratio improvement of underwater free space optical communication based on deep learning

SUN You, ZHANG Junjie*

(Key Laboratory of Specialty Fiber Optics and Optical Access Networks, Shanghai University, Shanghai 200072, China)

Abstract: The complex underwater environment results in the degradation of underwater optical signal quality. In order to improve the signal to noise ratio of underwater free space optical communication system, a signal to noise ratio improvement method based on deep neural network is proposed, which effectively suppresses the signal noise through the signal spectrum. For the underwater free space optical communication 16 order quadrature amplitude modulation-orthogonal frequency division multiplexing (16QAM-OFDM) signal with 1 m transmission distance, the experimental results show that the proposed scheme can improve the signal to noise ratio of about 17 dB and reduce the bit error rate to 1.709×10^{-3}, which can be applied to underwater free space optical communication system to improve the transmission performance and has certain generalization ability.

Key words: underwater free space optical communication; signal to noise ratio improvement; deep learning; orthogonal frequency division multiplexing

0 引言

与传统的水下通信相比，水下无线光通信凭借传输速率快和传输带宽高等优点，逐渐成为了一种全新的水下通信技术[1]。然而，在水下环境中，光束易受到海水的影响导致信号衰减（如海水吸收、散射以及多径效应），从而引起信号质量下降[2–3]。因此，对于信号信噪比的恢复十分重要。

为了提升水下无线光通信中的传输距离、传输速率和信号发射强度，提高信号探测精度。近年来，文献[4–7]提出了基于物理层的系统性能改进方案；2017 年，复旦大学团队[4]提出了基于低功耗 520 nm 绿光激光二极管的水下无线光通信系统；2018 年，上海光学精密机械研究所团队[6]提出了使用光子计数接收器为探测器的长距离水下无线光通信系统。以上研究验证了对物理层的应用改进可以起到提升性能的效果，但目前基于算法应用角度的性能改善方案极少。本项目组[8]近期提出了一种

收稿日期：2020–07–09。

基金项目：国家自然科学基金项目（批准号：61420106011、61601279、61601277）资助。

作者简介：孙猷（1995—），男，安徽宣城人，硕士研究生，现就读于上海大学通信与信息工程学院通信与信息系统专业，主要研究方向为水下无线光通信和数字信号处理算法研究及验证，曾获“第十三届中国研究生电子设计竞赛上海赛区三等奖”。



*** 通信作者**：张俊杰（E-mail: zjj@staff.shu.edu.cn）。

基于正交频分复用(OFDM)帧结构解决相位噪声的方案,系统信噪比提升 6 dB 左右。之后,本项目组[9]还提出了一种基于时域平均算法的方案,实现信噪比最大提升约 10.5 dB。但是,以上方案都改变了原有的 OFDM 帧结构,且造成了传输效率下降。因此,本文提出一种基于深度学习的水下无线光通信性能改善算法,利用神经网络自适应拟合数据的特性,在不改变 OFDM 帧结构的情况下实现对信号信噪比的有效恢复。

1 基于深度学习的水下无线光通信信号信噪比改善系统

1.1 网络结构

深度神经网络的结构图如图 1 所示。深度神经网络结构通常会比人工神经网络的结构层次更加深[10],用于增强网络对于数据的拟合能力。网络的每一层都有大量的神经元组成,每一个神经元的输入是由其前一层的输出经过非线性激活函数后的加权平均和得到的。非线性激活函数可以是 Tanh 函数:$f_T(x)=\frac{e^x-e^{-x}}{e^x+e^{-x}}$,或者是 ReLU 函数:$f_R(x)=\max(0,x)$。一个 N 层的深度神经网络模型通常含有 N 个神经元层级,其中第一层为输入层,最后一层为输出层,剩余的层级都叫作隐藏层。

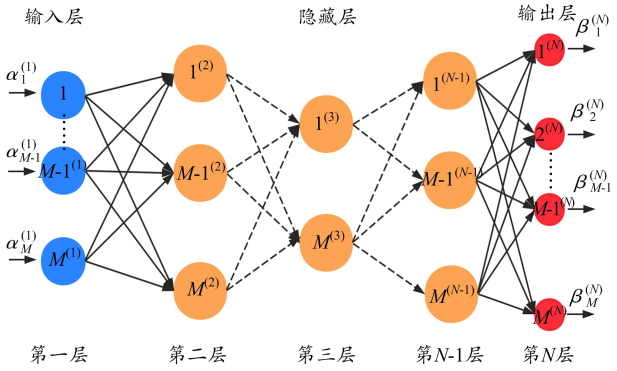

图 1 深度神经网络结构图

假定输入层(第一层)拥有 M 个神经元,即可以把输入向量定义为$\vec{\alpha}^{(1)}=\left[\alpha_1^{(1)},\cdots,\alpha_{M-1}^{(1)},\alpha_M^{(1)}\right]$,表示当前输入向量是由各神经元的输入组合而成的。第二层的第 m 个神经元的输入为:

$$\alpha_m^{(2)}=\sum_{i=1}^{M} w_{im}^{(1)}\alpha_i^{(1)}+bias^{(1)} \tag{1}$$

其中,$w_{im}^{(1)}$代表第一层第 i 个神经元和第二层第 m 个神经元之间的权重,$\alpha_i^{(1)}$代表第一层第 i 个神经元的输入,$bias^{(1)}$为第一层的神经元偏置。在每一层中,函数 $f(\cdot)$ 代表了激活函数,用于增添网络的非线性能力,那么第二层的第 m 个神经元的输出为 $\beta_m^{(2)}=f(\alpha_m^{(2)})$。相同地,用向量表示第二层的输出,即为$\vec{\beta}^{(2)}=\left[\beta_1^{(2)},\cdots,\beta_{m-1}^{(2)},\beta_m^{(2)}\right]$。因此,对于整个网络而言,其输出层的输出向量可以表示为:

$$\vec{\beta}^{(N)}=f^{N-1}(f^{(N-2)}(\cdots f^{(1)}(\vec{\alpha}^{(1)}))) \tag{2}$$

其中,$f^{(i)}$代表了第 i 层的激活函数,$\vec{\alpha}^{(1)}$为输入层即第一层神经元的输入,N 代表神经网络的层数。

1.2 系统结构

基于深度学习的水下无线光通信系统框图如图 2 所示。本文使用的系统和传统的 OFDM 水下光通信系统结构的区别在于:收发端之间构建了一个神经网络用于拟合和恢复信号频谱的信息。在发射端,首先通过 Matlab 程序产生伪随机序列,对数据串/并转换之后进行正交幅度调制(QAM)映射,然后使用傅里叶逆变换将信号从频域搬迁到时域,再通过增加循环前缀(CP)来消除符号间干扰(ISI),添加训练序列用于信道的估计和均衡。在信号发射前,离线程序通过削波降低峰值平均功率比(PAPR),继而将信号量化至合适的幅值区间。生成的 OFDM 信号首先储存到 Xilinx AX545 FPGA 的随机存取储存器(RAM)中,经过8 bit 位数、10 MS/s 采样率的数/模转换器(DAC)量化及一个 230 MHz 带宽的放大器后,利用发射波长为 405 nm 的蓝光发光二极管(LED)发射载有 OFDM 数据的光信

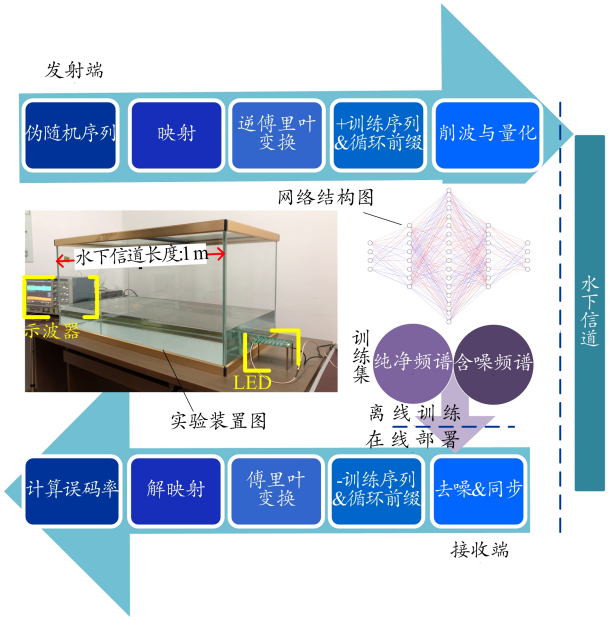

图 2 基于深度学习的水下无线光通信系统框图

号。光信号经过 1 m 传输距离的水下链路后抵达接收端。在接收端,系统采用具有 200~1100 nm 波长探测范围和 1 mm^2 探测面积的光电二极管(PIN)接收光信号,光信号完成光/电转换后,Tektronix DPO 7354C 数字荧光示波器以 100 MS/s 的采样率对信号进行采样,分析信号信噪比及误码率。

神经网络构建于信号收发机之间,其应用主要由 3 个基本步骤构成。第一步将发射端的时域 OFDM 纯净信号和接收端的 OFDM 含噪信号进行频谱分析得到其实部和虚部两部分数据;第二步将纯净信号作为标签,含噪信号作为样本,将其频谱的实部和虚部数据送入网络中进行训练,该网络由 2 个孪生网络组成,分别学习数据频域实部和虚部的数据特性,以此建立 1 个针对信号频域去噪的网络;第三步将网络输出的两部分数据整合成一个完整的频谱,进行快速傅里叶逆变换恢复成纯净的时域信号用于接收与解调。

在接收端接收到的信号经过准确同步后表示为:

$$y(n)=x(n)\otimes h(n)+w(n) \tag{3}$$

其中,$y(n)$代表接收信号,$\otimes$代表卷积运算,$h(n)$代表信道的冲击响应,$x(n)$代表发射信号,$w(n)$代表高斯白噪声。在去除循环前缀和离散傅立叶变换之后,接收到的频域信号为:

$$Y(k)=X(k)H(k)+W(k) \tag{4}$$

其中,$Y(k)$、$X(k)$、$H(k)$和 $W(k)$是 $y(n)$、$x(n)$、$h(n)$和 $w(n)$的离散傅立叶变换。在实际系统中,信号经傅里叶变换之后,通过信道均衡和解映射,最终通过比对原始发射序列计算误码率。

图 3 为本系统的 OFDM 信号时域与频域图,一帧 OFDM 信号的周期为 882.4 μs ((80+16+64×2+80×100)×0.1 μs=882.4 μs),因为关闭了 1 号和 31 号子载波,因此对应的信号带宽为 4.5 MHz。

1.3 网络参数

网络使用 Tesnorflow 框架进行搭建。数据集利用

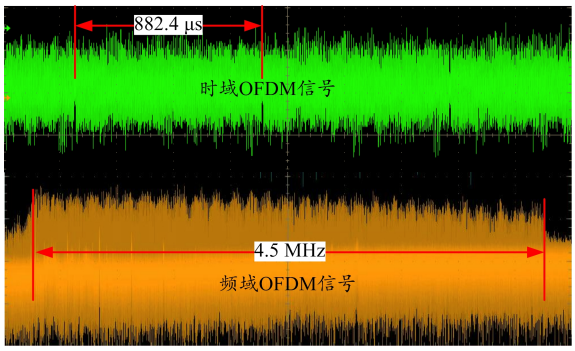

图 3 水下无线光通信 OFDM 信号时域与频域图

1 m 水下信道的 OFDM 信号频谱构建,以 100 帧为 1 组,每组数据集包含 100 组数据,训练集 4 组,验证集 1 组。一帧 OFDM 信号时域长度为 8224 点,80 点零序列为同步序列,144 点为 2 个 64 点训练序列及 16 点循环前缀,剩余 8000 点为 100 组 80 点的 OFDM 符号,每一段数据序列包含 64 点符号及 16 点循环前缀。网络设计为 5 层的全连接网络,考虑到数据的长度和网络的处理能力,本文设计网络为 1 层 1024 维的输入层和输出层,2 层 2048 维的隐藏层和 1 层 4096 维的隐藏层。整个网络隐藏层的激活函数均为 ReLU 函数,以降低网络梯度计算量。层与层之间添加了 Dropout 层与 Batchnormlization 层,防止模型过拟合,并消除数据的误差。学习率设置为指数衰减:

$$lr_d=lr_{\text{initial}}\times d^{s_{\text{global}}/s_d} \tag{5}$$

其中,lr_{initial} 表示初始学习率,d 代表衰减系数,s_{global} 表示全局步长,s_d 表示衰减步长。初始学习率设置为 0.001,衰减系数为 0.99,衰减步长为 1 万步。神经元参数初始化使用的是均值为 0、方差为 0.01 的截断正态分布。网络优化器使用的是 RMSprop 优化器,利用均方误差(MSE)作为网络的损失函数:

$$MSE=\frac{1}{n}\sum_{i=1}^{n}(y_i-\hat{y}_i)^2 \tag{6}$$

其中,n 代表样本数量;y_i 代表监督数据,在本网络中即为纯净信号频谱;$\hat{y}_i$ 代表预测数据,即网络恢复出的频谱。

2 实验结果与分析

为了进一步证明深度学习在水下无线光通信 OFDM 信号信噪比改善的性能,本文将网络部署于水下实验链路中,利用水下的实验数据对网络进行了训练,通过一些实验结果对比信号经过神经网络恢复与直接采集时的性能。

2.1 深度学习算法对于水下光通信信噪比改善验证

神经网络恢复和直接从水下信道采集的 16QAM 格式 OFDM 信号的各子载波的信噪比对比情况如图 4 所示。由于在 OFDM 信号收发系统中 DAC、PIN 和低通滤波器等硬件的影响,系统存在明显的滚降特性(即高子载波的信号幅度较低子载波的更低,故高子载波信号的信噪比相较于低子载波也更低)。恢复前的信号整体信噪比为 2.7 dB,而恢复后的信号整体信噪比为 19.8 dB。由图 4 可知,恢复后的各子载波信号信噪比较恢复前提升约 17 dB。同时,可以明显地看出

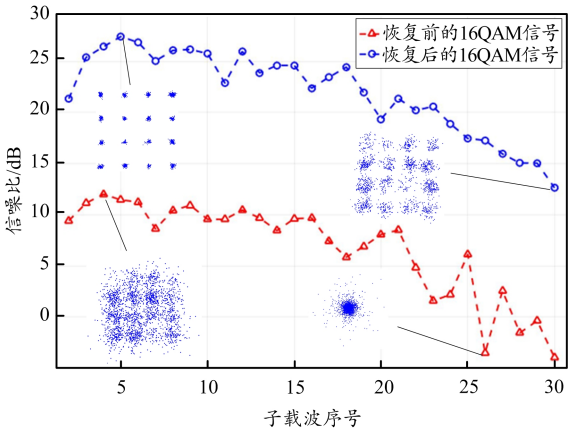

图 4 恢复后信号与恢复前信号各子载波信噪比

恢复后 16QAM 信号的星座图各星座点较为清晰。

图 5 为恢复前、后的 16QAM 信号各子载波误码率曲线图。从各子载波误码率的曲线观察可知,在恢复前,前 15 号子载波的误码率约为 0.1;受到信道滚降特性的影响,误码率随着载波数增加而逐渐增加到 0.4。恢复后的信号在 24 号载波前无误码,随着载波数增加,误码率增长峰值为 0.035。实验结果表明:信号恢复前的总误码率为 0.1711,恢复后的总误码率为 1.709×10^{-3},低于前向纠错码(FEC)门限。

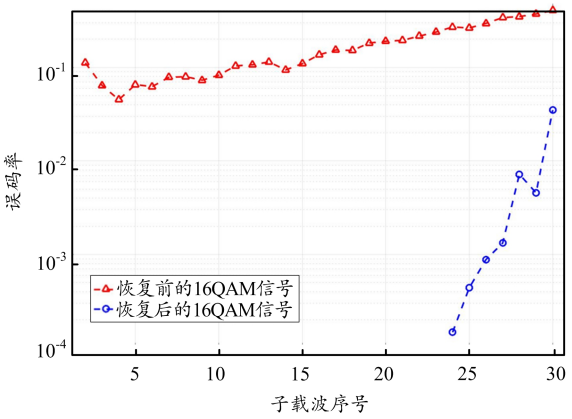

图 5 恢复前、后信号各子载波误码率

为了验证网络对于水下无线光通信弱信号信噪比改善不受调制格式的影响,本文分别采用二进制相移键控(BPSK)、正交相移键控(QPSK)、8QAM 和 16QAM 这 4 种调制格式进行网络性能测试,不同调制格式下的网络性能如图 6 所示。对于恢复前、后信号信噪比提升均为 17 dB 左右,由此可证明在网络训练拟合的情况下,该种网络对于信号信噪比的提升不受调制格式的影响,具备一定的泛化能力。

2.2 与传统算法性能对比

本文对提出的深度学习算法与项目组之前提出

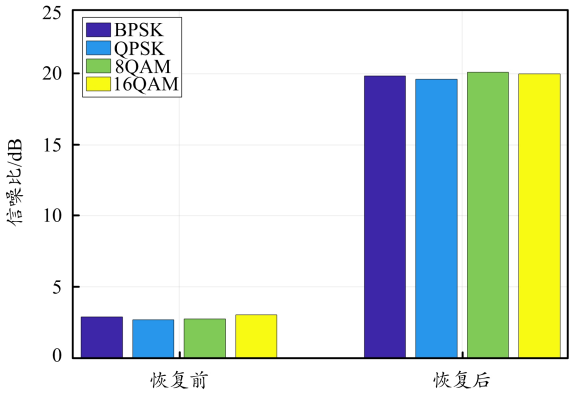

图 6 不同调制格式下网络性能

的一种时域平均算法的信噪比增益进行了对比,如图 7 所示(图中 2 倍、4 倍、8 倍和 16 倍为时域平均算法)。时域平均算法是在时域范围内以 OFDM 帧结构为单位进行了叠加运算进而消除噪声,提升了信号信噪比,信噪比增益随着平均倍数逐次递增。与仿真结果类似的是,以 2 次幂每倍增一次平均次数,恢复后的信噪比增益约为 3 dB。虽然深度学习算法的复杂度较时域平均算法高,但 BPSK、QPSK 2 种调制格式下的 OFDM 信号信噪比增益也高,分别为 16.7 dB 和 16.6 dB,比时域平均算法中 16 倍平均情况下的 10.7 dB 和 10.5 dB 信噪比增益分别提升了 56.1%和 58.1%,达到了更好的恢复效果。图 8 为 QPSK 信号在恢复前、经过时域平均算法中 16 倍平均恢复后和深度学习算法恢复后的星座图。在时域平均的算法中,由于信号噪声只是在时域上进行了压缩,幅度误差得到了削弱而没有对相位误差进行削弱,进而可以观察到此时星座图轮廓呈现椭圆形。本文提出的深度学习算法消除了部分原先时域平均算法中未消除的相位误差,超出了 16 倍时域平均算法 6.1 dB 信噪比,故此时星座图中的星座点位置较理想,位置更加聚拢。

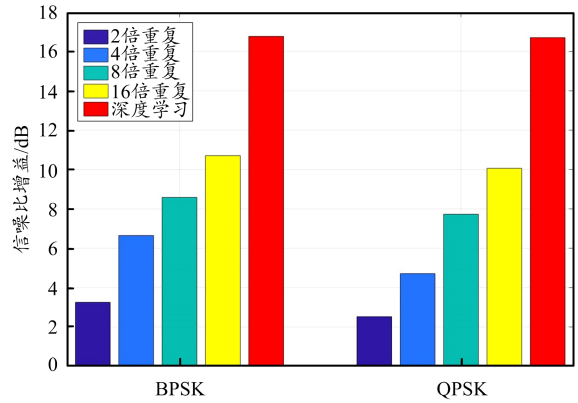

图 7 深度学习算法与时域平均算法的信噪比增益对比

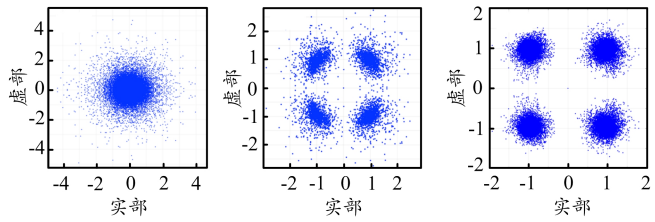

(a) 恢复前　(b) 时域平均算法16倍重复恢复后　(c) 深度学习算法恢复后

图 8 QPSK 信号星座图

2.3 网络性能分析

在上述实验中，系统只使用了符合当前算法的 OFDM 帧数进行实验。然而，在实际应用场景下，随着复杂度的增加，收发机之间传输的 OFDM 信号帧数将发生变化，因此测试在面对多种不同帧数条件下的网络性能尤为重要。OFDM 帧数同时也是决定本模型训练集和验证集大小的关键因素，由于网络是对频域中的 OFDM 信号实部和虚部数据进行拟合，且不同的 OFDM 帧数产生的频域信号是不同的，因此针对不同 OFDM 帧数的情况需要对网络进行重新训练。不同 OFDM 帧数时的网络性能如图 9 所示。当系统需要不同帧数的 OFDM 信号进行传输时，将网络以对应帧数 OFDM 信号对网络进行重新训练，便可在系统接收端进行信号恢复。由图 9 可知，在采用 1~1000 帧共 10 种不同 OFDM 帧数进行实验时，网络的性能未出现较大波动，以信号帧数为 100 帧时为例，信噪比提升了 16.5 dB。以此验证了深度学习算法的性能不受 OFDM 帧数即数据集的大小影响。

2.4 复杂度分析

算法复杂度是衡量网络性能的重要指标，因此本文对提出的深度学习网络复杂度进行了分析。采用一个 5 层的全连接神经网络，神经网络算法复杂度是和每一层的神经元数量相关的，因此选用网络中的乘法器数量来衡量该指标。假设一个 5 层的网络中输入层的神经元数量为 N_{in}，对于隐藏层的神经元数量分别为 $N_{hidden1}$、$N_{hidden2}$ 和 $N_{hidden3}$，输出层的神经元数量为 N_{out}，那么输入层与第一个隐藏层之间的乘法器个数为 $N_{in}\times N_{hidden1}$，第一个隐藏层和第二个隐藏层之间的乘法器数量为 $N_{hidden1}\times N_{hidden2}$。以此类推，最后一个隐藏层和输出层之间的乘法器数量为 $N_{hidden3}\times N_{out}$。因此，将所有乘法器的数量相加便可以得到此神经网络的乘法器数量总和：

$$N_{DNN}=N_{in}\times N_{hidden1}+N_{hidden1}\times N_{hidden2}+N_{hidden2}\times N_{hidden3}+N_{hidden3}\times N_{out} \tag{7}$$

由于本文采用的神经网络输入层和隐藏层之间的激活函数均为 ReLU 函数，计算复杂度很低，因此忽略了激活函数的计算量。在实验中，本文设计的网络为对称结构，输入层和输出层均为 1024 维，中间包含 2 个 2048 维隐藏层和 1 个 4096 维隐藏层，对于本系统设计的网络，其浮点运算次数（FLOPs）为 20.97152×10^6。

对于时域平均算法而言，其更注重于计算数值求和平均的过程，因此选用加法复杂度和乘法复杂度来综合衡量该算法的复杂度。其复杂度可表示为：

$$N_{AVE}=F\times(R\times S+R)+F\times(S+1) \tag{8}$$

其中，F 表示帧数，R 表示时域平均的重复次数，S 表示一帧 OFDM 信号内的符号数。

2 种算法复杂度计算表如表 1 所示。时域平均算法的复杂度与信号的帧数成正比，同时也受到重复次数和符号个数的影响，当重复次数和符号个数同时增大时，其计算量会呈幂增长级上升，而深度学习的复杂度只与网络结构有关。因此，时域平均算法适用数据量少的情况，而当数据量较大时，使用深度学习算法可以更高效地实现更好的效果。

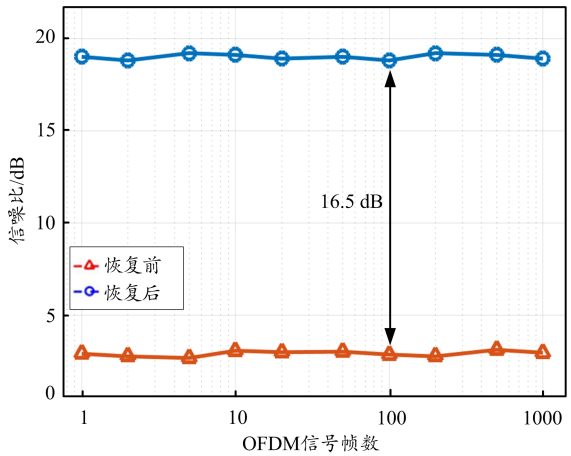

图 9 不同 OFDM 帧数下网络性能

表 1 2 种算法复杂度计算表

算法	复杂度公式	实验中实际数量
时域平均	$N_{AVE}=F\times(R\times S+R)+F\times(S+1)$	$N_{AVE}=F\times(16\times100+16)+F\times(100+1)=1.717F\times10^3$。（16 倍重复时）
深度学习	$N_{DNN}=N_{in}\times N_{hidden1}+N_{hidden1}\times N_{hidden2}+N_{hidden2}\times N_{hidden3}+N_{hidden3}\times N_{out}$	$N_{DNN}=1024\times2048+2048\times4096+4096\times2048+2048\times1024=20971520=20.97152\times10^6$

3 结束语

本文提出了一种基于深度学习的水下无线光通信信噪比改善系统,对恢复信号和原始信号的各子载波信噪比和误码率进行了对比,分析了网络在不同OFDM帧数下的性能和算法复杂度。实验结果表明:针对1 m传输距离的水下无线光通信16QAM-OFDM信号,各子载波的信号信噪比提升约为17 dB,同时在4种不同调制格式下均表现出了相同的性能结果;与此同时,本文提出的算法中对于BPSK和QPSK信号的信噪比增益较时域平均算法分别提升了56.1%和58.1%,验证了深度学习算法性能不受OFDM帧数影响。与传统的信号去噪方法相比,所提算法可以对信号频谱进行自适应滤波去噪,不受信号和噪声频谱重叠的影响,对实时信号信噪比改善系统的设计起到了借鉴意义。

参考文献:

[1] KAUSHAL H, KADDOUM G. Underwater optical wireless communication[J]. IEEE Access, 2016(4): 1518–1547.

[2] OUBEI H M, DURAN J R, JANJUA B, et al. 4.8 Gbit/s 16-QAM-OFDM transmission based on compact 450-nm laser for underwater wireless optical communication[J]. Optics Express, 2015, 23(18): 23302–23309.

[3] CHITHRA K, SIREESHA N, THANGAVEL C, et al. Underwater communication implementation with OFDM [J]. Indian Journal of Geo-Marine Sciences, 2015, 44(2): 259–266.

[4] LIU X Y, YI S Y, ZHOU X L, et al. 34.5 m underwater optical wireless communication with 2.70 Gbps data rate based on a green laser diode with NRZ-OOK modulation[J]. Optics Express, 2017, 25(22): 27937–27947.

[5] CHEN Y F, KONG M W, ALI T, et al. 26 m/5.5 Gbps air-water optical wireless communication based on an OFDM-modulated 520 nm laser diode [J]. Optics Express, 2017, 25(13): 14760–14765.

[6] HU S Q, MI L, ZHOU T H, et al. 35.88 attenuation lengths and 3.32 bits/photon underwater optical wireless communication based on photon counting receiver with 256-PPM [J]. Optics Express, 2018, 26(17): 21685–21699.

[7] JIANG R, SUN C M, ZHANG L, et al. Deep learning aided signal detection for SPAD-based underwater optical wireless communications[J]. IEEE Access, 2020(8): 20363–20374.

[8] QIN D L, LI Y C, SUN Y, et al. High fidelity underwater wireless optical communication with a phase-conjugated frame structure[J]. Applied Optics, 2020, 59(13): 4000–4007.

[9] SUN Y, QIN D, XIONG X, et al. Experimental verification of the 10dB IEVM performance enhancement for underwater wireless optical communication system with a simple time-domain averaging methodology[C]//Asia Communications and Photonics Conference, November 2–5, 2019, Chengdu, China. Chengdu: IEEE, 2019: 1–3.

[10] 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 Letter, 2018, 7(1): 114–117.