

## 深度学习辅助水下光通信信道估计和信号检测

石佳, 黄爱萍\*, 陶林伟

西北工业大学航海学院, 陕西 西安 710072

**摘要** 近年来,水下无线光通信(UWOC)技术因其高速数据传输能力而成为了研究热点,但水波的吸收和散射等因素使得 UWOC 信道变得十分复杂。对复杂的信道做出准确的信道估计(CE)和信号检测(SD)是目前高速 UWOC 面临的主要问题之一。针对这一问题,提出了一种在光正交频分复用系统中利用深度学习以端对端的方式对 UWOC 信道进行估计并直接检测的方案。首先根据在不同水域类型的 UWOC 信道下模拟生成的数据离线训练深度神经网络(DNN),然后使用 DNN 直接对信号进行补偿,该方案可以隐式地估计出信道状态信息并直接恢复传输数据。仿真结果表明,提出的信道估计和信号检测方案在复杂的 UWOC 信道环境中具有优越的性能,特别是在导频数量较少以及去除循环前缀时,深度学习方案比传统方案鲁棒性更好。

**关键词** 光通信; 水下无线光通信; 信道估计; 信号检测; 深度学习; 光正交频分复用

**中图分类号** TN929.1

**文献标志码** A

**DOI:** 10.3788/CJL202249.1706004

## 1 引言

目前,水下无线光通信(UWOC)技术因具有高速数据传输能力以及优越的传输容量而在水下通信中受到广泛的关注。将 UWOC 与水声通信相比较,水声通信技术利用声波在 kHz 量级的有限带宽内传输信息,传输延迟较大,而 UWOC 技术的数据传输速率可以达到 Gbit/s 量级<sup>[1-2]</sup>,同时保持较低的传输时延。此外,因为无线光波长较短,所以 UWOC 可携带的数据量更大。

光波在 UWOC 信道中传播时会受到吸收、散射等因素的影响<sup>[3-4]</sup>。吸收效应的过程是不可逆的,光能会转化为其他形式的能量,从而导致信号的衰减。在散射现象中,每个光子的发射方向随机变化,因此接收器捕获的能量减少。为了准确地评估出复杂的 UWOC 信道信息,已有许多学者对不同水域类型的吸收、散射和湍流效应进行了研究,并且表征出了它们的特征,这极大地提高了 UWOC 信道建模以及信道估计(CE)的准确性<sup>[5-9]</sup>。具体而言,Jaruwatanadilok<sup>[5]</sup>提出应用辐射理论进行 UWOC 信道建模和评估,详细说明了水下信道特性,包括颗粒物和海水的特性以及水下环境中的噪声。模拟了数据传输和接收信号波形,显示了符号间干扰对数据传输速率和传输距离的影响,并研究了相应的误码率性能,说明了距离的增加导致数据通信的局限性。黄爱萍等<sup>[6]</sup>提出应用蒙特卡

罗仿真的方法分析研究 UWOC 信道,仿真比较了典型的海水类型、浑浊度以及包括波束宽度和发散角、传输距离、接收孔径等因素在内的系统参数对接收光强的影响。Tang 等<sup>[7]</sup>利用双伽玛函数的封闭形式表达来对 UWOC 信道进行建模,仿真结果表明,对于衰减长度较大的系统,信道带宽会有所降低。而在这种情况下,光会受到很大的时延扩展,且对于不均衡的高比特率系统,符号间干扰会严重降低误码率性能。Ye 等<sup>[8]</sup>利用深度学习方法建立了光正交频分复用(OOFDM)系统中的 CE 模型,该模型基于将正交频分复用(OFDM)系统和无线信道视为黑匣子的模拟数据进行离线训练。仿真结果表明,当无线信道存在严重的失真和干扰时,深度学习方法更具优势,证明了深度神经网络(DNN)具有记忆和分析无线信道复杂特性的能力。Lu 等<sup>[9]</sup>设计了一种基于深度学习的 OOFDM 系统的联合方案,可实现信道分类、CE 和信号检测(SD)。利用设计的信道分类器在线识别水域类型,产生优化的估计组合权重以提高对 UWOC 信道 CE 和 SD 的性能,在进行离线训练后,该系统能够对多种混合水类型进行分类,并对接收到的信号进行有效检测。仿真结果表明,在 UWOC 信道下,该方案明显优于传统的估计方案,且不需要 UWOC 信道的任何先验信息。

然而,由于水下环境十分复杂,利用传统方法估计的信道状态信息通常不够准确,恢复出的信号误码率

收稿日期: 2021-11-18; 修回日期: 2021-12-27; 录用日期: 2022-01-10

基金项目: 水声对抗重点实验室基金(D5120190034)、中央高校基本科研业务费重点布局类基金(D5000210974)

通信作者: \*appleagz1@163.com

较高,很难满足 UWOC 场景中所需的性能及成本要求。文献[8-9]虽引入了深度学习方法,但文献[8]中的方法是针对大气信道所提出的,在 UWOC 环境下并不适用,文献[9]将深度学习引入到 UWOC,但并未考虑到在 OOFDM 系统中导频数量以及循环前缀等因素对深度学习检测方法性能的影响。

本文提出一种利用 DNN 以端对端的方式来解决 UWOC 系统中具有挑战性的 CE 和 SD 问题的方案。首先,该方案使用 OOFDM 系统作为系统模型,并采用文献[6-7,10]中所提出的经典 UWOC 信道作为信道模型。然后,根据 UWOC 的信道特性搭建 DNN 模型并利用在不同水域类型的 UWOC 信道下模拟生成的数据离线训练 DNN。该方案将 UWOC 系统中的 CE 和 SD 部分相结合并利用 DNN 来完成,DNN 可直接估计并检测出发送信号。最后进行仿真,比较了在不同水域类型下 DNN 方案的性能表现,并研究了 OOFDM 系统中导频数量、循环前缀(CP)和传输距离对 DNN 方案检测性能的影响。

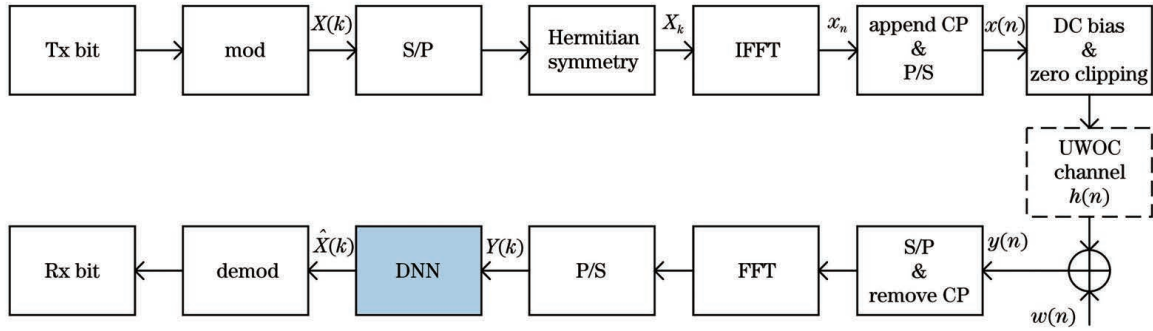


图 1 基于 DNN 的 DCO-OFDM 系统

Fig. 1 DCO-OFDM system based on DNN

式(1)经过 IFFT 后  $\mathbf{X}$  转换为离散的时域信号  $\mathbf{x}$ , 表达式为

$$x_n = \frac{1}{N} \sum_{k=0}^{N-1} X_k \exp\left(\frac{j2\pi kn}{N}\right), \quad (2)$$

式中:  $x_n$  表示第  $n$  个时域符号。

在加入循环前缀、并串转换(P/S)之后,将离散样本  $\mathbf{x}$  转换为串行序列  $x(n)$ 。接下来添加 DC 偏置使信号均为正值,再将信号通过 UWOC 信道传输到接收端,其中 DC 偏置  $B_{DC}$  的表达式如下:

$$B_{DC} = \mu \sqrt{E\{x^2(t)\}}, \quad (3)$$

式中:  $\mu$  为常数系数,本文取  $\mu=3$ ;  $E\{\sim\}$  为期望运算;  $x(t)$  为时域 OOFDM 信号。

在添加 DC 偏置之后仍有少量负数,此时需要再设置一个零削波判断将小于 0 的数字强行置零。

在接收端,得到时域信号  $y(n)$ , 表达式为

$$y(n) = x(n) \otimes h(n) + w(n), \quad (4)$$

式中:  $\otimes$  是卷积算子;  $h(n)$  是 UWOC 的信道脉冲响应;  $w(n)$  为加性高斯白噪声。

然后在串并(S/P)转换、去除 CP 并进行快速傅里叶变换(FFT)和 P/S 之后,接收到的频域信号为

## 2 系统模型

### 2.1 OOFDM 系统模型

本文使用具有直流偏置的光正交频分复用系统(DCO-OFDM)<sup>[11-12]</sup>,如图 1 所示。发射端发射的比特向量信号经过正交幅度调制(QAM)<sup>[13-14]</sup>并映射到特定星座生成  $X(k)$ , 然后进行串并转换(S/P)得到复数符号流  $\mathbf{X}=[X_0 X_1 \dots X_{N-1}]$ , 其中  $N$  为 OOFDM 系统的子载波数量,图 1 中的 mod 即为映射功能。由于无线光通信通常使用强度调制/直接检测机制,所以经快速傅里叶逆变换(IFFT)处理之后的输出信号应为实值,则  $\mathbf{X}$  具体结构如下:  $X_0=0, X_1 \sim X_{N/2-1}$  的符号个数为  $N/2-1$ , 而  $X_{N/2} \sim X_{N-1}$  应满足 Hermitian 对称约束<sup>[15]</sup>, 表达式为

$$X_k = X_{N-k}^*, \quad k = N/2, \dots, N-1, \quad (1)$$

式中:  $(\cdot)^*$  表示共轭运算;  $X_k$  表示第  $k$  个子载波所容纳的符号。

$$Y(k) = X(k)H(k) + W(k), \quad (5)$$

式中:  $Y(k), X(k), H(k), W(k)$  分别是  $y(n), x(n), h(n), w(n)$  进行 FFT 之后的结果。

图 1 中的  $\hat{X}(k)$  在 3.1 小节中有介绍。此外,我们假设 UWOC 系统中的第一个 OOFDM 符号由接收器已知的训练导频构成,剩余的 OOFDM 符号包含发送数据。信道可看作由大量的帧构成,其中每一帧都是跨越导频块和数据块的恒定跨度。

### 2.2 信道模型

针对 UWOC 信道的特性<sup>[16]</sup>, 本文采用文献[6-7, 10]中所提出的经典 UWOC 信道模型来描述水下的吸收和散射效应。

用  $c(\lambda)$  来描述吸收和散射的总衰减效应, 表达式为

$$c(\lambda) = a(\lambda) + b(\lambda), \quad (6)$$

式中:  $\lambda$  为光波长;  $a(\lambda)$  为吸收衰减系数;  $b(\lambda)$  为散射衰减系数。

信道模型表示为  $h(z)$ , 其表达式为

$$h(z) = \exp(-cz), \quad (7)$$

式中:  $c$  为总衰减效应;  $z$  为传输距离。

仿真中用到的具体信道参数信息在第 4 节实验仿真中说明。

### 3 基于深度神经网络的信道估计和信号检测

深度学习在计算机视觉<sup>[17]</sup>、自然语言处理<sup>[18]</sup>以及语音识别<sup>[19]</sup>等方面已取得了长足的进展。Schmidhuber<sup>[20]</sup>详细地介绍了有关深度学习和 DNN 的知识。本文利用深度学习方法建立 DNN 模型,实现对 UWOC 系统的准确 CE 和 SD。下面对提出的 DNN 模型以及模型训练的具体参数和细节进行阐述。

#### 3.1 深度神经网络模型

DNN 通常由输入层、隐藏层和输出层构成,其中




图 2 DNN 模型  
Fig. 2 DNN model

此外,为了加入非线性因素以提高 DNN 对模型的表达能力,还需要加入激活函数。本文在 DNN 的隐藏层使用 ReLU 函数作为激活函数,输出层使用 Sigmoid 函数将前面的输出映射到区间(0,1)。DNN 模型的设计分为两个阶段:离线训练阶段和在线部署阶段。离线训练阶段将在 3.2 小节详细介绍。在在线部署阶段,如图 1 中所示,DNN 模型的输出可直接用于恢复传输数据。

#### 3.2 模型训练

图 1 中的  $\hat{X}(k)$  为 DNN 模型在线部署阶段的输




图 3 DNN 离线训练  
Fig. 3 Off-line training of DNN

每一层由多个神经元组成,每个神经元的输出是其前一层神经元加权和非线性函数。常用的非线性函数有 Sigmoid 函数<sup>[21]</sup>和整流线性单元(ReLU)<sup>[22]</sup>,分别定义为  $f_S(a) = \frac{1}{1+e^{-a}}$  和  $f_R(a) = \max(0, a)$ 。

假设网络的输出层输出为  $y$ ,则其数学表达式为

$$y_i^{(l)} = f(\omega_i^{(l)} y^{(l-1)} + b_i^{(l)}), \quad (8)$$

式中: $l$  表示网络层数; $i$  表示层的节点; $\omega_i$  和  $b_i$  分别为网络权重系数和偏置系数。

本文设计的 DNN 模型共五层,中间三层为隐藏层,如图 2 所示,从左往右每层神经元数分别是 256、500、250、120、5。

出。为了最小化  $X(k)$  和  $\hat{X}(k)$  之间的误差,本文采用  $L_2$  作为 DNN 模型的损失函数,公式为

$$L_2 = \frac{1}{N} \sum_k [\hat{X}(k) - X(k)]^2, \quad (9)$$

式中: $\hat{X}(k)$  为 DNN 模型恢复的信号; $X(k)$  为模型训练的标签; $N$  为样本个数。

模型训练的优化器选择方面,本文选取具有收敛速度快、内存占用小等优点的 Adam 优化器。

离线训练时,DNN 模型使用在模拟 UWOC 信道下生成的数据进行训练,如图 3 所示。 $X(k)$  是

经映射后的发送数据,  $Y(k)$  是接收端在发送数据经 UWOC 信道后所接收到的数据, 它们分别作为 DNN 模型的标签和输入组成训练数据集。DNN 通过这些训练数据学习 UWOC 信道的特性后, 可直接在线部署到 OOFDM 系统中用于恢复传输数据。

在典型的沿海水域类型<sup>[10]</sup>下, 当 OOFDM 系统的导频数为 64 时, 离线训练的精度曲线如图 4 所示。可以看出随着迭代次数 epoch 的增加, 训练集和验证集的精确度不断提高, 最后在接近 1 时趋于稳定。图 4 的训练精度曲线表明, 本文所建立的 DNN 模型对 UWOC 信道特性具有强大的学习能力。




图 4 DNN 训练精度曲线  
Fig. 4 Training accuracy curve of DNN

## 4 仿 真

本节将对上文所提出的 DNN 模型进行仿真和性能评估。选取了传统的最小二乘 (LS) 和最小均方误差 (MMSE) 估计方法<sup>[23-24]</sup> 作为对比。

### 4.1 仿真设置

仿真过程中使用的主要系统参数均在表 1 中列出, 调制方式采用 16QAM<sup>[13-14]</sup>, 该调制方式将传输数据以特定方式分布在  $4 \times 4$  的星座图上, 然后以欧氏距离为判决门限将数据就近映射在 16 个特定点上。

表 1 仿真中使用的系统参数

Table 1 System parameters used in simulation

Parameters	Value
Transmission distance under water type 1 (coastal) /m	15
Transmission distance under water type 2 (clear) /m	20
Number of OOFDM symbols in one frame	5
DC-bias of DCO-OFDM	0.18
Number of OOFDM subcarriers	192
Modulation constellation	16QAM

基于文献[6-7, 10]所建立的 UWOC 信道模型的主要模拟参数在表 2 中列出, 其中不同水域类型的衰减、吸收和散射系数以花括号的形式表示。此外, 模型的训练和测试均使用典型的沿海和清澈水域类型。

表 2 仿真中使用的 UWOC 信道参数

Table 2 UWOC channel parameters used in simulation

Parameters	Value
Number of water types for training	2
Training water type 1 (coastal), $\{c_1, a_1, b_1\}$	$\{0.179, 0.219, 0.398\}$
Training water type 2 (clear), $\{c_2, a_2, b_2\}$	$\{0.114, 0.037, 0.151\}$
Test water type 1 (coastal), $\{c_1, a_1, b_1\}$	$\{0.179, 0.219, 0.398\}$
Test water type 2 (clear), $\{c_2, a_2, b_2\}$	$\{0.114, 0.037, 0.151\}$

### 4.2 仿真结果

本文进行了以下仿真来证明所提出的 DNN 方法 CE 和 SD 方案的性能。首先使用表 2 中列出的两种水域类型数据训练和测试提出的 DNN 模型, 然后将 DNN 模型在不同信噪比 (SNR) 下的误码率 (BER) 性能与传统的 LS 和 MMSE 估计方法的 BER 性能进行比较。

图 5 是在两种不同水域类型下 DNN 方法与传统方法的 BER 曲线。导频符号的大量插入会消耗系统的时频资源, 减少有效数据的传输, 严重影响系统性能, 因此, 导频的数量需要兼顾数据传输效率和开销等因素, 本文选取的仿真导频数分别为 64 和 8。

在水域类型 1 的 BER 曲线中可以看到, 当导频数量为 64 时, 本文提出的 DNN 方法性能优于传统

的 LS 方法并且与 MMSE 方法性能相当。为了提高频谱利用率, 将导频数量减少到 8, 此时传统的 MMSE 方法性能明显下降, 而 DNN 方法的性能明显好于两种传统方法。例如: 当 SNR 为 65 dB, 导频数为 64 时, 本文所提出的 DNN 方法的 BER 为  $7.02 \times 10^{-4}$ , 而传统方法中效果较好的 MMSE 方法 BER 为  $1.16 \times 10^{-3}$ ; 当导频数为 8 时, DNN 方法的 BER 为  $8.98 \times 10^{-3}$ , MMSE 方法的 BER 为  $3.41 \times 10^{-2}$ 。

从水域类型 2 的 BER 曲线中可以看出, 当导频数为 64 时, DNN 方法性能略差于 MMSE 方法但好于 LS 方法, 而当导频数减少到 8 时, DNN 方法的性能明显好于两种传统方案。此外, 因为水域类型 2 相比水域类型 1 更加清澈, DNN 从训练数据中更深入全面地

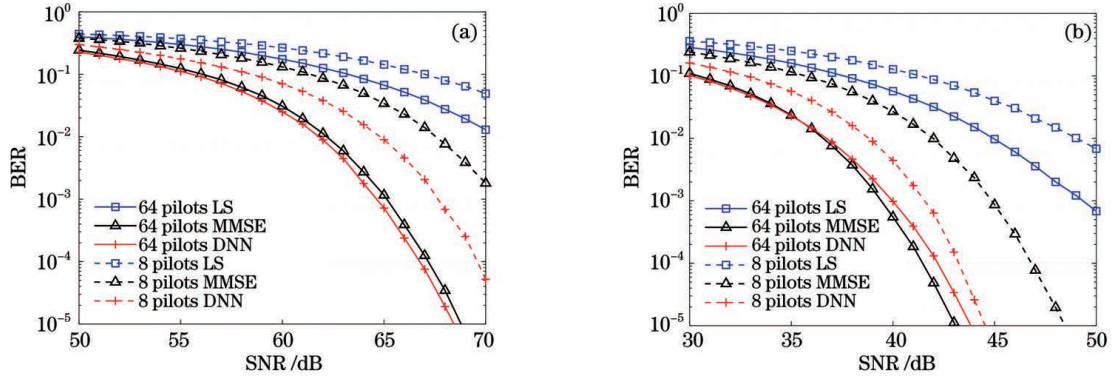


图 5 不同水域下 DNN 方法和传统方法的 BER 曲线。(a) 水域类型 1; (b) 水域类型 2

Fig. 5 BER curves of DNN and traditional methods in different water types. (a) Water type 1; (b) water type 2

学习到 UWOC 信道的特性,所以在减少导频数量后性能下降并不明显。这表明 DNN 方法的鲁棒性比传统方法更好。

在 OOFDM 系统中,通常会加入 CP 以消除符号间干扰,但这同时也会增加带宽并带来能量损失。图 6 对不同水域类型下 DNN 方法与传统方法去除 CP 后的 BER 性能进行了比较。如图 6 所示,无论在水域类型 1 还是水域类型 2,在去除 CP 后,传统的 LS 和

MMSE 方法性能下降明显,均不能有效地评估信道,而 DNN 方法仍然有效。具体而言,在水域类型 1 中,去除 OOFDM 系统 CP 后,两种传统方法的精度都在 SNR 超过 60 dB 后开始趋于饱和,当 SNR 为 70 dB 时,两种传统方法中效果较好的 MMSE 方法 BER 为  $4.70 \times 10^{-2}$ ,而 DNN 方法的 BER 为  $6.87 \times 10^{-3}$ ,DNN 方法的性能明显好于两种传统方法。这再次表明 DNN 方法具有更强的鲁棒性。

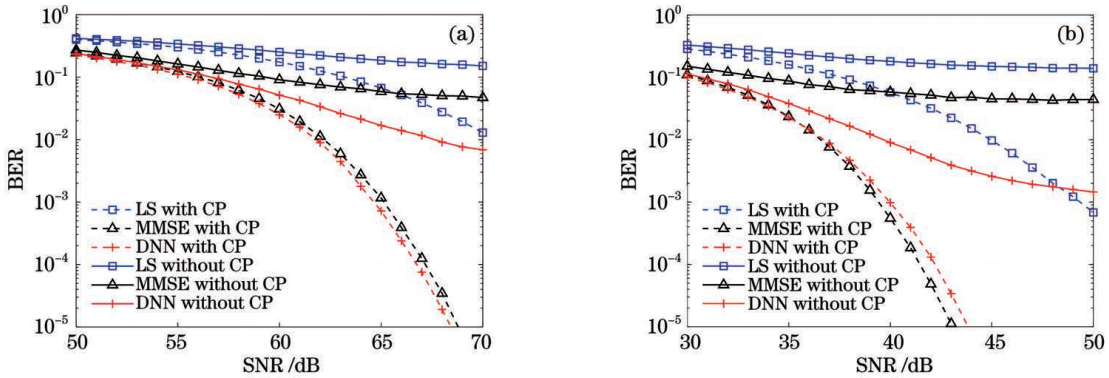


图 6 去除 CP 后的 BER 曲线。(a) 水域类型 1; (b) 水域类型 2

Fig. 6 BER curves with CP removed. (a) Water type 1; (b) water type 2

在水下环境中,随着传输距离的增加,光信号由于吸收和散射效应产生能量损失。为了表征不同距离下 DNN 方法的性能,本文分别将传输距离设为 12 m 和 15 m 进行仿真,结果如图 7 所示。当传输距离为 12 m 时 DNN 方法的性能远好于 LS 方法但稍差于

MMSE 方法,而当传输距离为 15 m 时,DNN 方法的性能已经赶超 MMSE 方法。例如:当 SNR 为 57 dB,传输距离为 12 m 时,DNN 方法的 BER 为  $1.31 \times 10^{-4}$ ,MMSE 方法的 BER 为  $6.90 \times 10^{-5}$ ;而当 SNR 为 67 dB,传输距离为 15 m 时,DNN 方法的 BER 为  $7.54 \times 10^{-5}$ ,MMSE 方法的 BER 为  $1.25 \times 10^{-4}$ 。这表明,基于 DNN 的 CE 和 SD 方案在长距离 UWOC 方面具有很高的研究价值。




图 7 不同传输距离下的 BER 曲线

Fig. 7 BER curves at different transmission distances

### 4.3 复杂度分析

以浮点运算的数量(FLOPs)作为衡量指标比较以上三种估计方案的计算复杂度。在 LS 方案中,每个复数除法施加 11 次浮点运算,所以在一个 OOFDM 符号中,浮点运算数  $N_{LS}^F = 11N + 11N = 11 \times 192 \times 2 = 4224$ ,其中  $N$  为 OOFDM 子载波数。在 MMSE 方案中,由于存在自相关矩阵计算和矩阵求逆运算<sup>[25]</sup>,一个 OOFDM 符号的浮点运算数为  $N_{MMSE}^F =$

$4.8 \times 10^6$ <sup>[26]</sup>。对于 DNN 方案,浮点运算数由下式计算<sup>[27]</sup>:

$$N_{\text{DNN}}^{\text{F}} = 2(N_{\text{in}}^{\text{F}} - 1)N_{\text{out}}^{\text{F}}, \quad (10)$$

式中: $N_{\text{in}}^{\text{F}}$ 和 $N_{\text{out}}^{\text{F}}$ 分别是 DNN 输入和输出的神经元数量。

表 3 总结了各估计方案的计算复杂度。与传统的 MMSE 方案相比,在训练和测试过程中使用相同的水域类型时,DNN 方案以更少的运算量提供了更好的误码性能,这是因为 MMSE 方案调用了高复杂度的矩阵求逆操作,增加了计算难度。

表 3 各种方案的复杂度比较

Table 3 Complexity comparison of various schemes

Scheme	FLOPs per OOFDM symbol
LS	$4.224 \times 10^3$
MMSE	$4.80 \times 10^6$
DNN	$2.56 \times 10^3$

## 5 结 论

本文为 UWOC 系统设计了一种基于 DNN 的 OOFDM 系统 CE 和 SD 方案。所提出的 DNN 模型在几种经典的水域类型下进行离线训练之后,就可在部署到 OOFDM 系统中来实现对接收信号的估计和恢复。仿真结果表明,相比于传统的估计方法,本文所设计的 DNN 方法主要具有以下两点优势:

(1) 提出的 DNN 方法在不同 UWOC 信道下的 CE 和 SD 性能表现优越。例如,在水域类型 1(沿海)中,当 SNR 为 65 dB,导频数量为 64 时,DNN 方法的 BER 为  $7.02 \times 10^{-4}$ ,传统方法中效果较好的 MMSE 方法 BER 为  $1.16 \times 10^{-3}$ ,DNN 方法的性能优于两种传统方法。

(2) DNN 方法除了在检测的准确率方面有优势以外,还具有更强的鲁棒性。例如:在水域类型 1 中,当 SNR 为 65 dB 时,导频数量由 64 减少到 8,DNN 方法的 BER 上升了  $8.28 \times 10^{-3}$ ,而传统方法中性能较好的 MMSE 方法 BER 上升了  $3.29 \times 10^{-2}$ ;由图 6(a)不难看出,在去除 CP 后,DNN 方法的 BER 上升了  $1.61 \times 10^{-2}$ ,而 MMSE 方法的 BER 上升了  $5.75 \times 10^{-2}$ 。

本文为 UWOC 的 CE 和 SD 问题提出了一种新的研究思路,并对其可行性进行了仿真验证,仿真结果证明了 DNN 模型处理 UWOC 系统 CE 和 SD 问题的强大能力。在下一步的研究工作中,将收集真实的 UWOC 信道信息重新对 DNN 模型进行训练和改进,以获得更好的检测性能。

## 参 考 文 献

- [1] Hanson F, Radic S. High bandwidth underwater optical communication[J]. *Applied Optics*, 2008, 47(2): 277-283.
- [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] Cox W C. Simulation, modeling, and design of underwater optical communication systems[D]. Raleigh: North Carolina State University, 2012
- [4] Jamali M V, Nabavi P, Salehi J A. MIMO underwater visible light communications: comprehensive channel study, performance analysis, and multiple-symbol detection[J]. *IEEE Transactions on Vehicular Technology*, 2018, 67(9): 8223-8237.
- [5] Jaruwatanadilok S. Underwater wireless optical communication channel modeling and performance evaluation using vector radiative transfer theory[J]. *IEEE Journal on Selected Areas in Communications*, 2008, 26(9): 1620-1627.
- [6] 黄爱萍, 张莹璐, 陶林伟. 蒙特卡洛仿真的水下激光通信信道特性[J]. *红外与激光工程*, 2017, 46(4): 226-231. Huang A P, Zhang Y L, Tao L W. Monte Carlo simulation on channel characteristics of underwater laser communications[J]. *Infrared and Laser Engineering*, 2017, 46(4): 226-231.
- [7] Tang S J, Dong Y H, Zhang X D. Impulse response modeling for underwater wireless optical communication links[J]. *IEEE Transactions on Communications*, 2014, 62(1): 226-234.
- [8] 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*, 2018, 7(1): 114-117.
- [9] Lu H Y, Jiang M, Cheng J L. Deep learning aided robust joint channel classification, channel estimation, and signal detection for underwater optical communication[J]. *IEEE Transactions on Communications*, 2021, 69(4): 2290-2303.
- [10] Gabriel C, Khalighi M A, Bourennane S, et al. Monte-Carlo-based channel characterization for underwater optical communication systems[J]. *Journal of Optical Communications and Networking*, 2013, 5(1): 1-12.
- [11] Dissanayake S D, Armstrong J. Comparison of ACO-OFDM, DCO-OFDM and ADO-OFDM in IM/DD systems[J]. *Journal of Lightwave Technology*, 2013, 31(7): 1063-1072.
- [12] 胡秀寒, 周田华, 贺岩, 等. 基于数字信号处理机的水下光通信收发系统设计与分析[J]. *中国激光*, 2013, 40(3): 0305003. Hu X H, Zhou T H, He Y, et al. Design and analysis of underwater optical communication transceiver system based on digital signal processor[J]. *Chinese Journal of Lasers*, 2013, 40(3): 0305003.
- [13] 李汐, 张春蕾, 王欢. 基于概率整形的 16QAM/OFDM-RoF 系统研究[J]. *激光与光电子学进展*, 2021, 58(9): 0906008. Li X, Zhang C L, Wang H. 16QAM/OFDM-RoF system based on probabilistic shaping[J]. *Laser & Optoelectronics Progress*, 2021, 58(9): 0906008.
- [14] 李韦萍, 孔森, 余建军. 基于偏振复用光调制器产生 PDM-16QAM 射频信号[J]. *光学学报*, 2020, 40(23): 2306002. Li W P, Kong M, Yu J J. Generation of PDM-16QAM radio frequency signal based on a polarization multiplexing optical modulator[J]. *Acta Optica Sinica*, 2020, 40(23): 2306002.
- [15] Azim A W, le Guennec Y, Maury G. Hermitian symmetry free optical-single-carrier frequency division multiple access for visible light communication[J]. *Optics Communications*, 2018, 415: 177-185.
- [16] 张莹璐, 王英民, 黄爱萍. 米氏理论上悬浮粒子对水下激光传输的影响[J]. *中国激光*, 2018, 45(5): 0505002. Zhang Y L, Wang Y M, Huang A P. Influence of suspended particles based on Mie theory on underwater laser transmission [J]. *Chinese Journal of Lasers*, 2018, 45(5): 0505002.
- [17] Krizhevsky A, Sutskever I, Hinton G E. ImageNet classification with deep convolutional neural networks [J]. *Communications of the ACM*, 2017, 60(6): 84-90.
- [18] Cho K, van Merriënboer B, Gulcehre C, et al. Learning phrase representations using RNN encoder-decoder for statistical machine translation [EB/OL]. (2014-06-03) [2021-03-05].

- <https://arxiv.org/abs/1406.1078>.
- [19] Weng C, Yu D, Watanabe S, et al. Recurrent deep neural networks for robust speech recognition[C]//2014 IEEE International Conference on Acoustics, Speech and Signal Processing, May 4-9, 2014, Florence, Italy. New York: IEEE Press, 2014: 5532-5536.
- [20] Schmidhuber J. Deep learning in neural networks: an overview [J]. *Neural Networks*, 2015, 61: 85-117.
- [21] Glorot X, Bordes A, Bengio Y. Deep sparse rectifier neural networks [C] // Proceedings of the Fourteenth International Conference on Artificial Intelligence and Statistics, April 11-13, 2011, Fort Lauderdale, USA. Cambridge: JMLR, 2011: 315-323.
- [22] LeCun Y, Bottou L, Orr G B, et al. Efficient BackProp[M]// Montavon G, Orr G B, Müller K R. *Neural networks: tricks of the trade. Lecture notes in computer science*. Heidelberg: Springer, 2012, 7700: 9-48.
- [23] 张宇. 基于快速最小二乘法的两步随机相移算法研究[J]. *光学学报*, 2021, 41(3): 0312003.
- Zhang Y. Two-step random phase shifting algorithms based on fast least-squares method[J]. *Acta Optica Sinica*, 2021, 41(3): 0312003.
- [24] Li Y, Cimini L J, Sollenberger N R. Robust channel estimation for OFDM systems with rapid dispersive fading channels [J]. *IEEE Transactions on Communications*, 1998, 46(7): 902-915.
- [25] Petzold T J. *Volume scattering functions for selected ocean waters [R]*. San Diego: Defense Technical Information Center, 1972.
- [26] Zhang J, Wen C K, Jin S, et al. Artificial intelligence-aided receiver for a CP-free OFDM system: design, simulation, and experimental test[J]. *IEEE Access*, 2019, 7: 58901-58914.
- [27] Molchanov P, Tyree S, Karras T, et al. Pruning convolutional neural networks for resource efficient inference[EB/OL]. (2016-11-19) [2021-03-06]. <https://arxiv.org/abs/1611.06440>.

## Deep Learning Aided Channel Estimation and Signal Detection for Underwater Optical Communication

Shi Jia, Huang Aiping<sup>\*</sup>, Tao Linwei

*School of Marine Science and Technology, Northwestern Polytechnical University, Xi'an 710072, Shaanxi, China*

### Abstract

**Objective** At present, underwater wireless optical communication (UWOC) is widely concerned in underwater communication because of its high transmission efficiency and excellent transmission capacity. For underwater acoustic communication, the transmission delay is large because of the limited bandwidth of sound wave in kilohertz frequency region. UWOC technology can achieve the data transmission rate of Gbit/s, while maintaining low transmission delay. In addition, UWOC can carry more data because of the shorter wavelength of light. However, light wave propagation in UWOC channel is affected by absorption, scattering and other factors. The absorption effect is irreversible, and the light energy is converted into other forms of energy, causing the signal to decay. In scattering, the direction in which each photon is emitted varies randomly, so that the energy captured by the receiver is reduced. In order to accurately evaluate the complex UWOC channel information, many scholars have studied the absorption, scattering and turbulence effects in different water areas and characterized these effects. This greatly improves the accuracy of UWOC channel modeling and channel estimation. However, due to the complexity of underwater environment, the channel state information estimated by traditional methods is usually not accurate enough and the recovered signals have high bit error rate (BER). Based on the above research, this paper designs a scheme of underwater optical communication channel estimation (CE) and signal detection (SD) aided by deep learning method.

**Methods** This paper presents an end-to-end solution to the challenging CE and SD problems in UWOC systems using a deep neural network (DNN). Firstly, the scheme uses optical orthogonal frequency division multiplexing (OOFDM) system as the system model, and classical UWOC channel as the channel model. Then the DNN model is built according to the channel characteristics of UWOC and the DNN is trained off-line using the simulated data under different UWOC channels. The scheme combines CE and SD in UWOC system and uses DNN, and it can directly estimate and detect the transmitted signal. Finally, the performance of DNN scheme is compared with those of traditional methods including least squares (LS) and minimum mean square error (MMSE) in different water areas, and the influence of pilot number, cyclic prefix (CP) and transmission distance on the detection performance of DNN scheme in OOFDM system is discussed.

**Results and Discussions** In this paper, the following simulations are carried out to prove the performance of the proposed DNN method CE and SD scheme. The DNN model proposed is trained and tested using two types of water body data, and the BER performance of DNN under different signal-to-noise ratios (SNRs) is compared with those of traditional LS and MMSE estimation methods. When the number of pilots is 64, the BER performance of the proposed DNN method is better than that of the traditional LS method and comparable to that of the MMSE method. However, when the pilot number is reduced to 8, in order to improve the spectral efficiency, the performance of the MMSE method is significantly reduced, and the performance of DNN method is better than those of the two traditional methods (Fig. 5). In OOFDM

system, CP is usually added to eliminate the inter-symbol interference, but it also increases the bandwidth and energy loss. In the following simulation, we remove CP and compare the performance of DNN method with traditional methods in different water areas. The simulation results show that the traditional LS and MMSE methods cannot evaluate the channel effectively any more, while the DNN method is still effective (Fig. 6). In the underwater environment, with the increase of the transmission distance, the energy loss of the optical signal is caused by the absorption and scattering effects. In order to characterize the performance of the DNN method at different transmission distances, the transmission distance is set to 12 m and 15 m respectively in simulation. When the transmission distance is 12 m, the performance of DNN method is much better than LS method but slightly worse than MMSE method. When the transmission distance is 15 m, the DNN method outperforms the MMSE method (Fig. 7). It is shown that DNN-based CE and SD scheme has high research value in long-distance UWOC.

**Conclusions** In this paper, a CE and SD scheme of OOFDM system based on DNN is designed for UWOC system. After the DNN model is trained off-line under several classic water types, it can be deployed in OOFDM system to estimate and restore the received signal. Simulation results show that the DNN method presented in this paper performs well in CE and SD under different UWOC channels. In addition, DNN method has advantages in detection accuracy, and it is also more robust in comparison with traditional LS and MMSE methods. The DNN model is proven powerful in dealing with CE and SD in UWOC system. The proposed method is a new approach to studying CE and SD in UWOC, and its feasibility is verified by simulation.

**Key words** optical communications; underwater wireless optical communication; channel estimation; signal detection; deep learning; optical orthogonal frequency division multiplexing