

DOI:10.16136/j.joel.2023.01.0139

基于深度学习的 ACO-OFDM 自由空间光通信中信号检测

黎天翼¹, 黎明^{2*}, 周明欧², 林芸²

(1. 湖北师范大学 文理学院, 湖北 黄石 435002; 2. 湖北师范大学 物理与电子科学学院, 湖北 黄石 435002)

摘要:针对自由空间光通信(free-space optical communication, FSO)系统中大气湍流引起的光强起伏闪烁效应对正交幅度调制(quadrature amplitude modulation, QAM)信号影响很大,缺少实时信道信息时的最大似然(maximum likelihood, ML)检测器性能较差问题,本文提出了一种基于深度学习(deep learning, DL)的信号检测器。其网络框架采用了一个具有全连接层的深度学习神经网络(deep-learning neural network, DNN),实现了无导频的 ACO-OFDM 空间通信系统中信道盲估计、信道均衡和信号解调。仿真结果表明:在中强湍流大气信道下训练的 DNN 检测器,8QAM、16QAM 和 64QAM 等调制信号解调的误码率分别可以下降到在 2×10^{-5} 、 5×10^{-5} 和 5×10^{-4} 左右,具有优越性能和鲁棒性,能较好抑制大气湍流引起的信道衰落。

关键词:自由空间光通信; 大气湍流; 深度学习神经网络; 正交频分复用

中图分类号: TN929.1 **文献标识码:** A **文章编号:** 1005-0086(2023)01-0068-06

Signal detection in ACO-OFDM free-space optical communication systems based on deep learning

LI Tianyi¹, LI Ming^{2*}, ZHOU Mingou², LIN Yun²

(1. College of Arts and Science, Hubei Normal University, Huangshi, Hubei 435002, China; 2. College of Physics and Electronic Science, Hubei Normal University, Huangshi, Hubei 435002, China)

Abstract: By considering the influences of atmospheric turbulence which leads to performance degradation of the maximum likelihood (ML) detector for the quadrature amplitude modulation (QAM) signal. In this paper, a signal detector based on deep-learning neural network (DNN) is presented for ACO-OFDM free-space optical communication (FSO) systems. The proposed DNN detector with a fully connected layer realized the channel-blind estimation, channel equalization, and signal demodulation in the system without pilot. Results indicate that the performance of DNN detector is better, which is trained at moderate-strong turbulence regime, and the performance remains robustness when atmospheric turbulence gets stronger. For instance the bit error rate of 8QAM, 16QAM and 64QAM decrease to around 2×10^{-5} , 5×10^{-5} and 5×10^{-4} respectively.

Key words: free-space optical communication (FSO); atmospheric turbulence; deep-learning neural network (DNN); orthogonal frequency division multiplexing (OFDM)

0 引言

6G 时代“超大容量”导致移动通信系统频谱资源缺口尤为突出,而自由空间光通信(free-space optical communication, FSO)具有非无线电频谱,

同时具有高数据速率、低功率、抗干扰和频谱效率高等特点^[1]。但大气随机波动产生的大气湍流效应,会严重影响 FSO 系统的通信质量。正交频分复用(orthogonal frequency division multiplexing, OFDM)技术具有较高的频谱利用率、抗衰落和传

* E-mail: hbliming@qq.com

收稿日期: 2022-02-28 修订日期: 2022-04-14

基金项目: 国家自然科学基金(12104141)资助项目

输速率^[2]。非对称限幅光 OFDM (asymmetrically clipped optical OFDM, ACO-OFDM) 的信号是非负实数, 满足采用强度调制/直接检测 (intensity modulation with direct detection, IM/DD) 的自由空间通信系统传输要求, 是一种效率较高的单极化 OFDM 调制方式^[3]。

随着移动通信技术的演进, 基于数学模型求解的信号处理复杂度指数级升高, 同时存在可扩展性、实时性和动态环境适应性较差等问题。人工智能技术在解决许多复杂问题方面发挥关键作用, 其应用于通信领域既带来了挑战, 也带来了机遇。近年来, 针对深度学习 (deep learning, DL) 在物理层信号处理的研究, 主要集中在调制识别 (也称为调制分类)^[4]、信道估计与均衡^[5,6]、信号检测^[7]、信道编码和解码^[8]、定位和波束形成等^[9]方面。各种基于人工智能算法和基于 DL 算法被提出来解决通信中存在的非线性问题。信号检测的全局次优解可以通过现有的基于 DL 模型获得^[10,11]。

近来在 OFDM 无线通信系统信号检测中应用 DL 技术成为研究热点。前馈神经网络、卷积神经网络、循环神经网络和深度强化学习等深度学习神经网络 (deep-learning neural network, DNN) 在物理层信号处理均有广泛用^[10]。文献[6]分别设计了二维残差神经网络 (ResNet) 和生成对抗神经网络 (GAN), ResNet 估计信道参数来代替导频辅助的 LS 和 MMSE 方法, 及 GAN 网络恢复发射信号, 仿真结果验证了这两种网络对参数随机的变化都具有鲁棒性。文献[12]提出基于 DNN 的 OFDM 信号检测器, 达到了接近最优的性能, 但需要基于信道先验信息来对接收信号预处理。设计二维卷积神经网络, 借助导频信号或解调参考信号估计似然比, 相对传统 LDPC 软解码提高了系统性能^[13]。DNN 的复杂度低, 响应速度快, 可以建模复杂的多维非线性关系^[14], 是一种使用最广泛的 DL 技术, 能够替代传统方法解决光通信中一些多维非线性问题。

正交幅度调制 (quadrature amplitude modulation, QAM) 的 OFDM 通信系统, 对接收信号信道估计和 FFT 变换后, 再进入 DNN 网络解调^[6,14-16]。针对 FSO 系统中大气湍流引起的光强起伏闪烁效应对 QAM 调制信号影响很大, 和 ACO-OFDM 的非负实数信号特点, 本文提出了一种网络结构简单易于实现的 DNN 信号检测框架, 实现无导频的空间通信系统中信道盲估计、信道均衡和信号解调, 从而获得更小的系统复杂度和更优的性能。

1 ACO-OFDM 空间通信系统

1.1 信道模型

考虑到大气衰减、大气湍流和指向误差等因素对信号传输过程衰减的影响, 信道增益 h 可表示为^[1]:

$$h = h^l h^a h^p, \quad (1)$$

式中, h^l 是因能量被大气吸收而造成的信道衰减分量, h^a 和 h^p 是互相独立的随机变量, 分别表示大气湍流和指向误差的信道衰减。

激光在大气湍流中传输而引起光强起伏, 传输路径上湍流引发的衰减 h^a 是随机的, 从弱至强湍流区的光强起伏较好符合 Gamma-Gamma 分布。衰落 h^a 分布可表示为^[1]:

$$f_{h^a}(h^a) = \frac{2(\alpha\beta)^{(\alpha+\beta)/2}}{\Gamma(\alpha)\Gamma(\beta)} h^{(\alpha+\beta)/2-1} K_{\beta-\alpha}(2\sqrt{\alpha\beta h^a}), h > 0, \quad (2)$$

式中, $\Gamma(\cdot)$ 为 Gamma 函数, $K(\cdot)$ 为第二类贝塞尔函数, α 表示小尺度湍流引起的光强起伏参数, β 表示大尺度湍流引起的光强起伏参数。参数直接和大气条件有关, 在平面波情况下 α 和 β 分别表示为^[1]:

$$\alpha = \left[\exp\left(\frac{0.49\sigma_R^2}{(1+1.11\sigma_R^{12/5})^{7/6}}\right) - 1 \right]^{-1}, \quad (3)$$

$$\beta = \left[\exp\left(\frac{0.51\sigma_R^2}{(1+0.69\sigma_R^{12/5})^{5/6}}\right) - 1 \right]^{-1}, \quad (4)$$

式中, $\sigma_R^2 = 1.23C_n^2 k^{7/6} z^{11/6}$, 是 Rytov 方差。 C_n^2 为大气折射率结构常数, z 是激光传输距离, $k = 2\pi/\lambda$ 是波数。一般认为: $\sigma_R^2 < 0.3$ 处于弱湍流区, $\sigma_R^2 > 1$ 处于强湍流区。

假设跟踪误差在水平和竖直方向上是独立且符合相同的高斯分布, 光斑中心偏离接收中心距离满足瑞利分布, h^p 概率分布:

$$f_{h^p}(h^p) = \frac{\gamma^2}{H_0^2} (h^p)^{\gamma-1}, 0 \leq h^p \leq H_0, \quad (5)$$

式中, $\gamma = \frac{\omega_{z_{\rho_1}}}{2\sigma_s^2}$, 是在接收端的等效束腰半径与跟踪标准差之比。 $\omega_{z_{\rho_1}}$ 可由以下关系式计算:

$$\begin{aligned} v &= \sqrt{A}/(\sqrt{2}\omega_z), \\ \omega_{z_{\rho_1}}^2 &= \omega_z^2 \sqrt{\pi} \operatorname{erf}(v)/2v \exp(-v^2), \\ H_0 &= \operatorname{erf}(v). \end{aligned} \quad (6)$$

式中, $\operatorname{erf}(\cdot)$ 是误差函数, ω_z 是在距离光源 z 的束腰半径。

1.2 ACO-OFDM

ACO-OFDM 牺牲了一些频谱利用率, 其原理是奇数子载波包含信息, 偶数子载波为零, 将 OFDM 信号转化为非负实数传输单极性的信号传输, ACO-OFDM 系统原理如图 1 所示。首先将比特流串并转

换后, QAM 调制到奇数子载波且厄米对称, 调制后频域信号 $\mathbf{X}_{\text{mapping}}$ 为:

$$\mathbf{X}_{\text{mapping}} = [0 \ X_1 \ 0 \ \dots \ X_{\frac{N}{2}-1} \ 0 \ X_{\frac{N}{2}+1} \ \dots \ 0 \ X_{N-1}], \quad (7)$$

$$X_{N-i} = X_i^* \quad i = 0, 1, \dots, N-1, \quad (8)$$

式中, N 为子载波数, $*$ 表示共轭运算。 $\mathbf{X}_{\text{mapping}}$ IFFT 变换为时域信号 \mathbf{x}_{IFFT} , 经循环保护间隔、数模转换和非对称限幅等处理后, 得到 ACO-OFDM 信号 $X_{\text{ACO}}(t)$, 最后调制成光信号传输。再将接收信号输入到

M -QAM 解调器, 解调出二进制序列。采用最大似然 (maximum likelihood, ML) 检测的误码率 (bit error rate, BER) 为^[3]:

$$P_{b, \text{QAM}} = \frac{2(\sqrt{M}-1)}{\sqrt{M} \log_2 M} \operatorname{erfc} \left[\sqrt{\frac{3}{2(M-1)} \gamma_{\text{SNR}}(h)} \right], \quad (9)$$

式中, $\gamma_{\text{SNR}}(h)$ 为信噪比, 表示 M -QAM 解调器输入的符号能量和噪声功率谱密度之比。在 Gamma-Gamma 信道中的平均误码率可以表示为:

$$\bar{P}_{b, \text{QAM}} = \int_0^\infty P_{b, \text{QAM}} \circ f(h) dh. \quad (10)$$

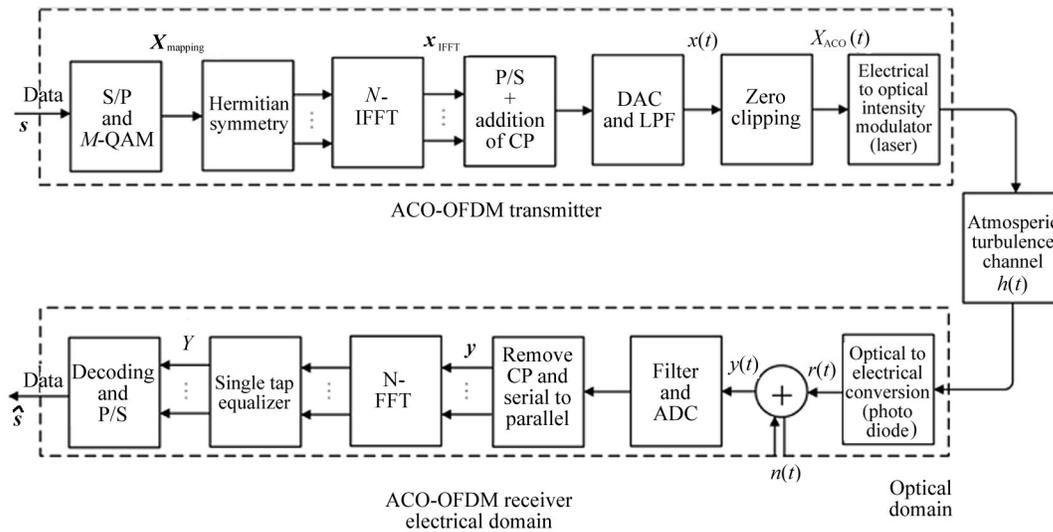


图 1 ACO-OFDM 自由空间光通信系统

Fig. 1 The ACO-OFDM FSO system

2 DL 信号检测算法

2.1 DNN 结构

本文设计的 DNN 信号检测器, 实现接收信号的

FFT 变换、信道均衡和解调。网络结构主要由 1 个输入层、3 个隐藏层和 1 个输出层组成, 如图 2 所示。输入层数据为 1 个 OFDM 符号接收信号, 维度为子载波数 N ; 输出层为一个 OFDM 符号估计比

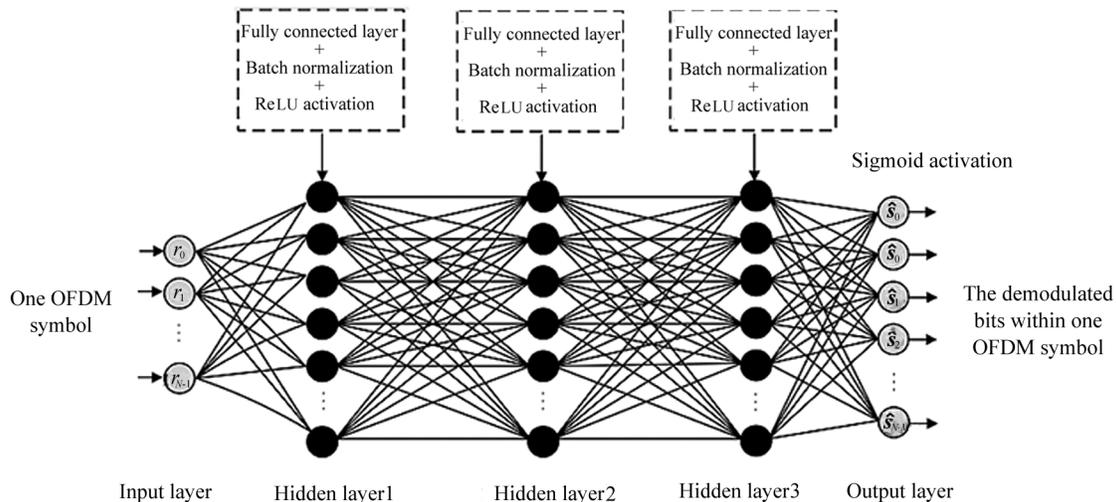


图 2 DNN 信号检测器

Fig. 2 DNN signal detector

特,维度为 $N \times M$, M 为 QAM 调制码元的比特数,各层数据维度分别为 $128, 256 \times M, 128 \times M, 64 \times M$ 和 $16 \times M$ 。DNN 中每层由多个神经元组成,每个神经元的输出是前一层神经元线性加权和,再加上偏置,最后通过激活函数非线性输出,即:

$$\hat{\mathbf{s}} = f_{\text{Sigmoid}}^{\text{out}}(\mathbf{W}_{\text{out}}, f_{\text{ReLU}}^3(\cdots f_{\text{ReLU}}^1(\mathbf{W}_1 \mathbf{y} + \mathbf{b}_1)) + \mathbf{b}_{\text{out}}), \quad (10)$$

式中, \mathbf{y} 和 $\hat{\mathbf{s}}$ 分别为 DNN 的输入和输出数据, $f_{\text{ReLU}}^L(a) = \max(0, a)$ 为 L 隐含层的 ReLU 激活函数, $f_{\text{Sigmoid}}^{\text{out}}(a) = 1/(1 + e^{-a})$ 为输出层的 Sigmoid 激活函数, \mathbf{W} 和 \mathbf{b} 分别隐含层或输出层的权重和偏置量。训练阶段最小化损失函数和正则化获取模型参数最优化,则模型估计损失函数为:

$$\mathbf{J}(\boldsymbol{\theta}) = \frac{1}{K} \sum_{k=1}^K (\hat{\mathbf{s}}(k) - \mathbf{s}(k))^2, \quad (11)$$

式中, $\mathbf{s}(k)$ 和 $\hat{\mathbf{s}}(k)$ 分别为第 k 个发送和预测信息, K 为训练样本集中的总样本数, $\boldsymbol{\theta} = \{\mathbf{W}, \mathbf{b}\}$ 为模型参数。

2.2 模型训练

DL 信号检测器输入 1 个 OFDM 符号接收信号,输出 1 个符号的信息比特。训练 DNN 模型时并不需要任何信噪比(signal-to-noise ratio, SNB)、信道状态信息(channel state information, CSI)等参数。

在训练 DNN 网络模型时,首先生成仿真数据集,包含输入接收和标签数据集。利用式(2)–(5)信道统计模型,采用蒙特卡罗(Monte Carlo)方法仿真得到信道数据集。在每次生成数据时,首先生成 1 个随机数据序列 \mathbf{s} 作为发送信息,生成相应的 ACO-OFDM 帧 $X_{\text{ACO}}(t)$, 然后与随机信道卷积,最后加入白噪声得到接收信号 $\mathbf{y}(t)$ 。图 3 为接收信号星座图,每行图的大气湍流 Rytov 方差 σ_r^2 分别为 0.007、0.071 和 0.985,每列比特信噪比 E_b/N_0 分别为 5 dB 和 15 dB。大气信道数据集样本数为 3×10^6 个,将其划分为训练集、验证集和测试集,比例为 6 : 2 : 2。

$\mathbf{y}(t)$ 和 \mathbf{s} 分别为 DNN 网络输入数据和标签数据,在训练过程中调整网络参数 $\boldsymbol{\theta} = \{\mathbf{W}, \mathbf{b}\}$,使得损失函数 $\mathbf{J}(\boldsymbol{\theta})$ 最小。DNN 网络训练超参数包括样本大小与批量大小比、层类型、层数、神经元数量、激活函数、损失函数、优化器、学习率和迭代次数等。样本大小与批量(batch)大小的比例非常重要,因为一次性将整个数据输入到 DNN 中会导致欠拟合,而将其分成多个批次有助于 DNN 更好地理解数据结构。层数和神经元数应通过实验和测试进行调整。实际上,层数和神经元数的选择高度依赖于模型的非线性程度和维数。高度非线性系统需要更多的神经

元,而平滑系统需要更少的神经元。DNN 有多种激活函数,其选择需要实验和测试。tanh, Sigmoid, ReLU 等激活函数在基于 DL 的光通信应用中表现出较好的效果^[17]。使用文献[16, 17]中先验知识有助于定义一个短尺寸的网格,并显著减少超参数调优时间,训练参数设置如表 1 所示。

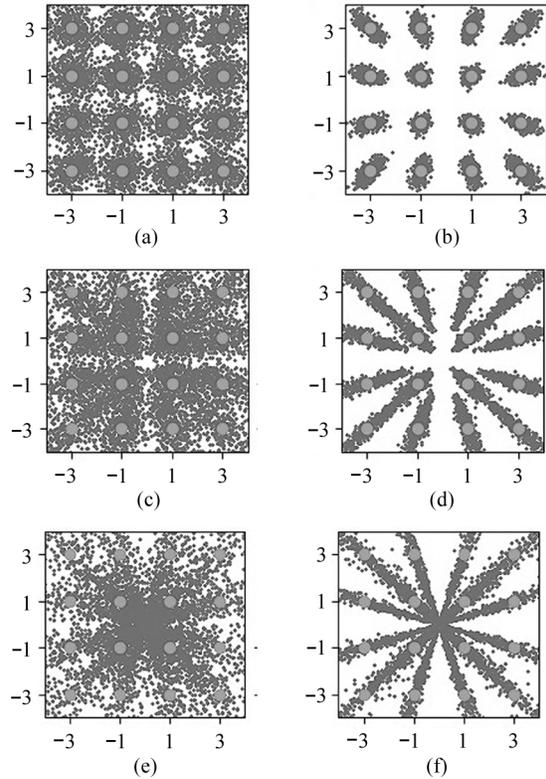


图 3 接收信号星座图(Bit SNR,左列 5 dB,右列 15 dB):

(a)(b) 极弱湍流; (c)(d) 弱湍流; (e)(f) 中强湍流

Fig. 3 Constellation diagram of received signal (Bit SNR, left column: 5 dB; right column: 15 dB):

(a)(b) Very weak turbulence; (c)(d) Weak turbulence;

(e)(f) Moderate-strong turbulence

表 1 训练参数

Tab. 1 Simulation parameters

Parameter	Value
Number of subcarriers	64
Dataset size	3×10^6
Activation function	ReLU, Sigmoid
Loss function	MSE Loss
Optimizer	Adam
Number of iterations	$2^{12}, 2^{14}$
Training data percentage	60%
Batch size	100
Validation data percentage	20%
Test data percentage	20%

3 实验结果

在 ACO-OFDM FSO 系统中进行仿真实验,验证基于 DL 算法的信号检测器误码率性能,并与基于式(9)的 ML 解调算法进行比较。在测试过程,采用与训练过程相同的模型参数来评价基于 DNN 的检测器误码率,利用测试集交叉验证来研究模型鲁棒性。分析了在 8QAM、16QAM 和 64QAM 等调制下,表征大气信道参数 Rytov 方差在 0.007、0.071 和 0.985 的 DNN 检测器误码率性能。

图 4 比较了在 3 个数据集下训练 16QAM 调制的 DNN 模型鲁棒性。训练集(train_a、train_b 和 train_c)和测试集(test_a、test_b 和 test_c)的 δ_r^2 均分别为 0.007、0.071 和 0.985。训练数据集和测试数据大气信道参数相同时,DNN 检测器具有较好解调性能。二者大气信道参数相差增大,其解调性能也下降。当测试集的 Rytov 方差为 0.985 时,3 个 DNN 检测器的解调性能差别更为显著。其主要原因是训练数据集中隐含有信道先验信息,DNN 网络能够在离线训练阶段学习到信道的分布情况,因此能够获得较好的估计性能。仿真结果也表明,本文的 DNN 网络能够学习到信道的变化特征。当在训练集 train_c($\delta_r^2=0.985$)时,DNN 检测器对 3 个测试集的误码性能较均衡,有较好鲁棒性。

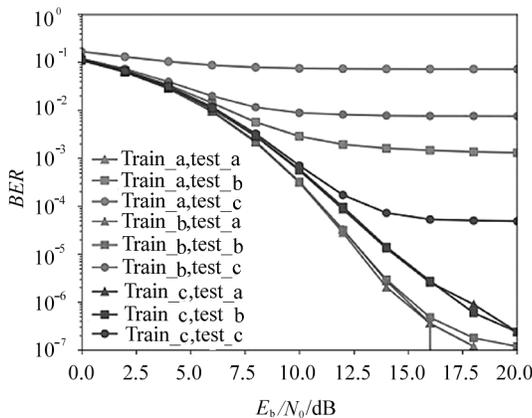


图 4 3 种大气湍流强度下训练 DNN 检测器性能
Fig. 4 The performance of DNN detector trained in three atmospheric turbulence regime

图 5 分析了在训练集 train_c 下训练 8QAM、16QAM 和 64QAM 等的 DNN 检测器误码性能。使用 ML 算法解调 3 个测试集信号,其对测试集 test_a 在 8QAM 和 16QAM 下信号解调都有很好性能,当大气信道湍流非常弱时,LM 算法有较好表现,但测

试集 test_b、test_c 在 3 种调制方式下解调性能都较差,说明大气信道参数对 ML 解调算法性能有较大影响,其鲁棒性较差。如图 5 仿真结果表明,当比特信噪比(E_b/N_0)小于 10 dB 时,DNN 检测器对 3 个测试集信号的误码性能基本一致,受大气信道湍流影响较小。当测试集 test_c 信号 E_b/N_0 大于 15 dB 时,DNN 检测器解调性能不再随 E_b/N_0 变化,8QAM、16QAMb 和 64QAM 等调制的误码率分别降低到 2×10^{-5} 、 5×10^{-5} 和 5×10^{-4} 左右。DNN 检测器在 3 种调制下其误码性能稳定,且对大气湍流有较强鲁棒性。

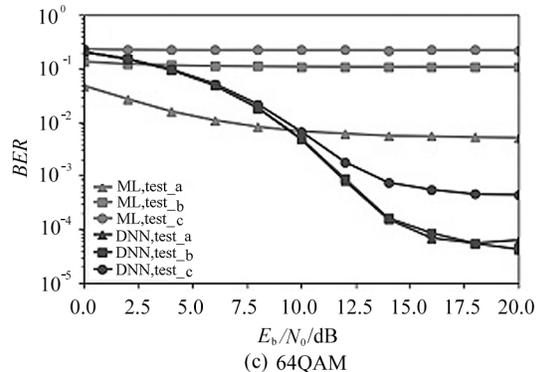
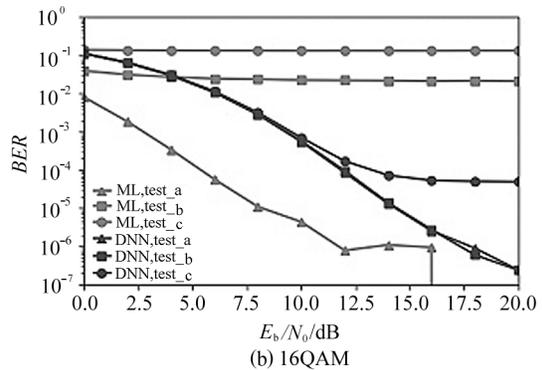
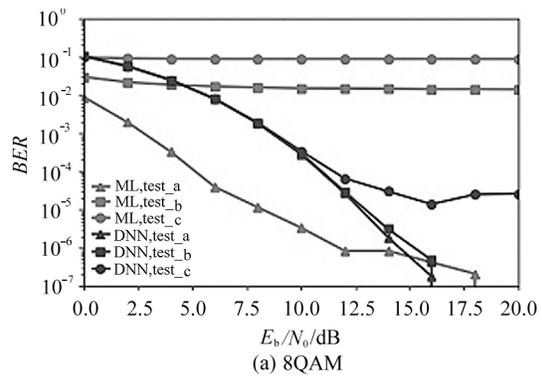


图 5 DNN 检测器性能
Fig. 5 Performance of the DNN detector

4 结论

OFDM 是现代无线系统中广泛应用的一种调制方案。FSO ACO-OFDM 系统的性能在很大程度上

取决于所采用的有效地信道估计和可靠的信号检测方法。本文提出了一种 DNN 的信号检测框架,实现无导频的 FSO 系统中信道盲估计、信道均衡和信号解调,最后通过计算机仿真分析了在大气弱湍流、中强湍流两种情况下,信噪比、调制阶数对误码性能的影响。结果表明在中强湍流大气信道下训练的 DNN 检测器具有优越性能和鲁棒性。本文提供了一类在 DL 架构下设计 OFDM FSO 系统信号检测器思路,利用信号已有的大气信道先验认知,寻求一种能够更有利于 DL 的表达形式,最终实现更好的算法性能。

参考文献:

- [1] LI M, HUANG Y, CAO Y, et al. Outage performance for mobile MIMO free-space optical systems [J]. *Journal of Optoelectronics • Laser*, 2014, 25(7): 1310-1314.
黎明, 黄勇, 曹阳, 等. 移动平台上空间光通信系统性能研究 [J]. *光电子 • 激光*, 2014, 25(7): 1310-1314.
- [2] ZHAO L, LEI Z Y, KE X Z, et al. Performance of FSO-OFDM based on QAM [J]. *Infrared and Laser Engineering*, 2011, 40(7): 1323-1327.
赵黎, 雷志勇, 柯熙政, 等. 基于 QAM 的 FSO-OFDM 系统性能分析 [J]. *红外与激光工程*, 2011, 40(7): 1323-1327.
- [3] JIA K J, JIN B, HAO L, et al. Performance analysis of DCO-OFDM and ACO-OFDM systems in indoor visible light communications [J]. *Chinese Journal of Lasers*, 2017, 44(8): 0806003.
贾科军, 靳斌, 郝莉, 等. 室内可见光通信中 DCO-OFDM 和 ACO-OFDM 系统性能分析 [J]. *中国激光*, 2017, 44(8): 0806003.
- [4] THIEN H T, HUA C, PHAM Q V, et al. MCNet: An efficient CNN architecture for robust automatic modulation classification [J]. *IEEE Communications Letters*, 2020, 24(4): 811-815.
- [5] NGUYEN D H. Neural network-optimized channel estimator and training signal design for MIMO systems with few-bit ADCs [J]. *IEEE Signal Processing Letters*, 2020, 27(7): 1370-1374.
- [6] YI X M, ZHONG C J. Deep learning for joint channel estimation and signal detection in OFDM systems [J]. *IEEE Communications Letters*, 2020, 24(12): 2780-2784.
- [7] NGUYEN N T, LEE K. Deep learning-aided tabu search detection for large MIMO systems [J]. *IEEE Transaction on Wireless Communication*, 2020, 19(6): 4262-4275.
- [8] HONKALA M, KORPI D, HUTTUNEN J. DeepRx: Fully convolutional deep learning receiver [J]. *IEEE Transactions on Wireless Communications*, 2021, 20(6): 3925-3940.
- [9] EIBIR A M, COLERI S. Federated learning for hybrid beamforming in mm-Wave massive MIMO [J]. *IEEE Communications Letters*, 2020, 24(12): 2795-2799.
- [10] PHAM Q V, NGUYEN N T, THIEN H T, et al. Intelligent radio signal processing: a survey [J]. *IEEE Access*, 2021, 7(6): 1-30.
- [11] HAN Y, WANG Z Y, GUO Q, et al. Deep learning-based detection for moderate-density code multiple access in IoT networks [J]. *IEEE Communications Letters*, 2020, 24(1): 122-125.
- [12] LUONG T V, KO Y, VIEN N A, et al. Deep learning-based detector for OFDM-IM [J]. *IEEE Communications Letters*, 2019, 8(4): 1159-1162.
- [13] HONKALA M, KORPI D, HUTTUNEN J. DeepRx: fully convolutional deep learning receiver [J]. *IEEE Transactions on Wireless Communications*, 2021, 20(6): 3925-3940.
- [14] AMIRABADI M A. Deep learning for channel estimation in FSO communication system [J]. *Optics Communications*, 2019, 459: 124989.
- [15] PHAM Q V, THIEN H T, ALAZAB M, et al. Sumrate maximization for UAV-assisted visible light communications using NOMA: Swarm intelligence meets machine learning [J]. *IEEE Internet of Things Journal*, 2020, 7(10): 10375-10387.
- [16] ZHU Z, ZHANG J, CHEN R, et al. Autoencoder-based transceiver design for OWC systems in log-normal fading channel [J]. *IEEE Photonics Journal*, 2019, 11(5): 1-12.
- [17] AMIRABADI M A, NEZAMALHOSSEINI S A, KAHAEI M H. Deep learning based detection technique for FSO communication systems [J]. *Physical Communication*, 2020, 43: 101229.

作者简介:

黎明 (1970—), 男, 博士, 教授, 硕士生导师, 主要从事空间光通信和人工智能方面的研究。