

激光与光电子学进展

基于自组织增量生成对抗网络的智能光通信

牟迪, 蒙文*, 刘文亚, 王翔, 赵尚弘

空军工程大学信息与导航学院, 陕西 西安 710077

摘要 首先,介绍了激光通信链路的优势;然后,基于生成对抗网络的端到端学习提高通信系统的实时性与全局优化性。最后,针对该系统离线学习模式训练过程中训练集不能包含所有情况导致的系统鲁棒性差问题,引入自组织增量学习方法改进端到端系统的线上增量训练。实验结果表明,随着线上训练的不断进行,端到端通信系统可以很好地模拟通道效应,且具有较强的实时性和鲁棒性。

关键词 激光通信;生成对抗网络;自组织增量神经网络

中图分类号 TN929.12;TP18

文献标志码 A

doi: 10.3788/LOP202158.1106001

Intelligent Optical Communication Based on Self-Organizing Incremental Generative Adversarial Network

Mu Di, Meng Wen*, Liu Wenya, Wang Xiang, Zhao Shanghong

School of Information and Navigation, Air Force Engineering University, Xi'an, Shaanxi 710077, China

Abstract In this article, first, the advantages of laser communication links are introduced. Then, end-to-end learning based on generative adversarial network improves the real-time and global optimization of the communication system. Finally, because of the lack of robustness in the system caused by the training set cannot contain all situations during the training process of the offline learning mode of the system, a self-organizing incremental learning method is introduced to improve online incremental training of the end-to-end system. Experiment results show that by implementing the self-organizing incremental learning method, the end-to-end communication system can simulate the channel effect efficiently, and it greatly improved the real-time optimization and robustness of the system.

Key words laser communication; generative adversarial network; self-organizing incremental neural networks

OCIS codes 060.4510; 060.4080

1 引言

无线激光通信系统具有带宽容量大、传输隐蔽性强、传输速率快、抗干扰能力强等优势^[1-2],受到了人们的广泛关注。激光通信信道主要为大气信道,受大气湍流的影响较大^[3-6],通常通过大孔径接收技术、功率冗余设计和基于信道状态信息(CSI)的自

适应方法对大气湍流效应进行补偿^[7-10]。但大气信道受天气影响变化较快,上述方法仍然存在实时性低、鲁棒性差等问题;且传统通信系统多为模块化设计,各个模块的设计目的不同,如信源编码是为了提升通信的有效性,信道编码是为了提升通信的可靠性,导致系统的性能难以达到全局最优。

为了提高光通信系统的实时性,深度学习技术

收稿日期: 2020-09-12; 修回日期: 2020-10-14; 录用日期: 2020-10-29

基金项目: 陕西省自然科学基金(2020JQ-483)

*E-mail: meng-wen_mw@126.com

被广泛应用于通信系统中^[9-14]。O’Shea等^[15]基于监督学习方式训练模型权重,以优化端到端的恢复精度;Dorner等^[16]将端到端方法应用于硬件缺陷的处理;Felix等^[17]在正交频分复用(OFDM)系统中采用了端到端学习方法;Ye等^[18]基于条件生成对抗网络(CGAN)完成了无明确CSI的端到端学习训练,且系统性能与传统通信系统相当。大气信道变化的随机性要求信道模型需具有很强的实时性,离线学习的端到端系统虽然有很好的反馈机制,实时性较强,但训练集不可能包含所有情况,导致离线训练在实际应用中的性能不理想,因此,还需研究在线增量训练的端到端模型。针对上述问题,本文引入自组织增量生成对抗网络(GAN)对端到端的通信系统进行在线增量训练,实现了实时性较强的端到

端通信。

2 在线端到端学习系统框架及算法

通信端到端学习系统的框架如图1(a)所示,其中, H 为信道噪声。信源发出信号后通过自动编码器生成编码信息并经过信道传输,自动解码器解码信息的同时向自动编码器反馈梯度信息,进而更新深度神经网络(DNN)的权重,以进行下一次训练^[12]。在线端到端学习系统的框架如图1(b)所示,首先,训练集数据经预处理后通过GAN进行初始学习,以构建初始端到端模型^[13];然后,采用自组织增量学习神经网络(SOINN)进行在线增量学习;最后,进行学习质量评估,损失函数变小则修改端到端模型,未变小则不修改模型继续进行在线增量学习^[14]。

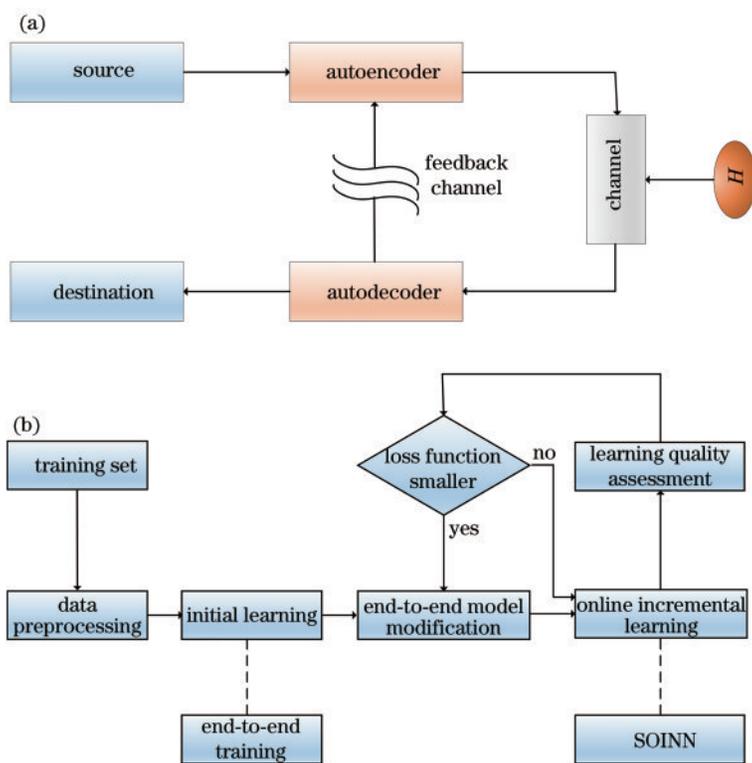


图1 在线学习系统的流程图。(a)端到端通信系统;(b)在线增量式端到端学习系统

Fig. 1 Flow chart of the online learning system. (a) End-to-end communication system; (b) online incremental end-to-end learning system

2.1 端到端初始训练

端到端的训练流程包括训练接收器、训练发生器、训练信道生成器和判别器^[5]。训练网络为GAN^[19-20],是一种新型分布式学习生成方法,可用于通信系统学习通道效应^[17],其结构框图如图2所示。其中,生成器(G)学习输入样本并生成近似样本,使鉴别器将其误判为真实输入样本;鉴别器(D)

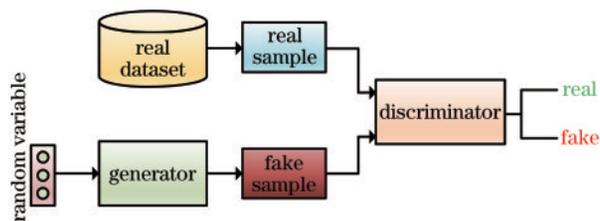


图2 GAN的结构

Fig. 2 Structure of the GAN

负责鉴别样本数据来自真实数据或生成器生成的数据,即在生成器和鉴别器之间引入博弈论^[21-23]。学习训练期间,生成器生成类似输入的假样本,并与真实样本一起训练鉴别器,最大化鉴别器的鉴别能力^[24];同时鉴别器将鉴别信息反馈给生成器,使其生成更接近真实样本的假样本^[25]。训练过程中出现平衡状态时训练结束,平衡时鉴别器不能比随机猜测更好地区分真实样本和生成的假样本。生成器 G 和鉴别器 D 均为 DNN,优化目标可表示为^[26]

$$\min_G \max_D V(D, G) = E_{x \sim p_r} \{ \log [G(x)] \} + E_{x \sim p_g} \{ \log [1 - D(x)] \}, \quad (1)$$

式中, p_r 为真实样本分布, p_g 为生成器生成的样本分

布, $G(x)$ 为生成器的输出, $D(x)$ 为鉴别器的输出, $E(\cdot)$ 为数学期望, x 为输入样本。

初始端到端系统的训练学习过程如图 3 所示,在训练期间,系统随机生成发送信号,并从信道集中随机采样获得瞬时 CSI。其中, s 为未进行编码的输入信号, \hat{S} 为接收器端的输出信号, h 为信道干扰。基于训练集的数据和控制变量法,用 GAN 对接收器、发射机和信道生成器进行迭代训练,完成初始端到端模型的建立,初始训练的具体步骤如下。

1) 训练接收器:由于接收器处可直接计算损失函数,很容易进行训练,进而获得损失函数的梯度。对于时变信道,直接将输入信号 x , 接收信号 y 作为输入,接收器可自动推断信道条件并执行信道估计和检测,无需明确估计信道。

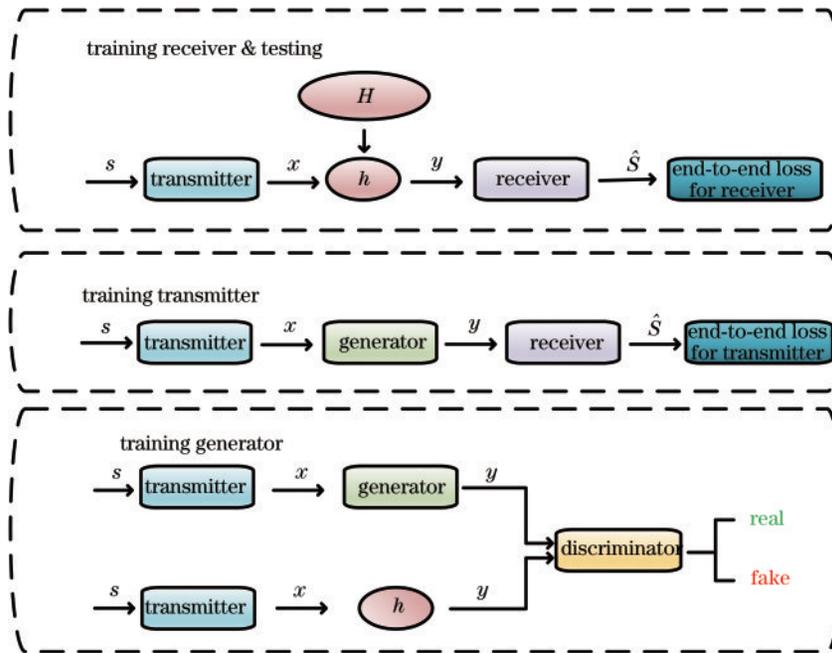


图 3 初始训练流程图

Fig. 3 Flow chart of the initial training

2) 训练发射机:发射机的训练类似于接收器,在接收器处计算端到端损失,并将梯度函数反向传递给发射机,基于随机梯度下降(SGD)法更新权重,且接收器的权重保持不变。

3) 训练信道生成器和判别器:用接收器和发射机一起训练信道生成器。利用来自发射机的编码信号通过实际信道获得实际数据,同时从通过信道发生器的编码数据获得伪数据,进而训练信道生成器和判别器。

2.2 SOINN 算法

SOINN 算法是一种基于竞争学习的神经网络

模型^[27-28],与自组织映射(SOM)算法不同,SOINN 算法没有固定的拓扑结构,可根据输入数据自适应调整网络拓扑^[29-30]。SOINN 算法中的神经元可看作是某个特征空间中的向量,其权重是该空间中对应该位置的坐标;输出的神经元可以反映输入数据的分布和拓扑结构。神经元动态调整机制能保证神经网络的规模远小于原始数据,具有良好的数据压缩特性^[31],可用于在线学习,有效降低存储和计算开销,因此,实验用 SOINN 算法对 GAN 进行在线增量式无监督学习。但 SOINN 算法存在两个问题^[32]:1) 双层在线学习模式很难确定结束第一层

学习,开始第二层学习的时间;2)不能很好地分离高密度区域。为了解决这些问题,对 SOINN 算法进行改进,采用单层网络减小训练难度,并通过网络去噪技术获得更好的训练效果。训练过程主要分为神经元分布、拓扑学习和网络去噪^[30]三个步骤。

1) 神经元分布

SOINN 算法中的神经元可当作某个特征空间中的向量,其权值 w 是神经元在该空间中的坐标表示。神经元分布的本质是一种矢量量化过程,用尽可能少的神经元对输入数据进行编码,从而获得数据的分布特征。假设输入数据为 x_i , 初始神经元集合为 N , 将集合 N 中与 x_i 最近的神经元分别作为获胜者 w_1 和第二获胜者 w_2 , 可表示为

$$\begin{aligned} w_1 &= \arg \min_{i \in N} \|W_i - x_i\| \\ w_2 &= \arg \min_{i \in N} \|W_i - x_i\| \end{aligned} \quad (2)$$

式中,下标 i 为输入数据的次序, W_i 为初始神经元集合 N 中第 i 个神经元的位置。计算 w_1 和 w_2 的相似度阈值 (Similarity threshold) σ_1 和 σ_2 , 相似度阈值即神经元的半径, 定义 $\sigma_i = \max_{j \in N_i} \|W_i - W_j\|$, 其中, N_i 为节点 i 的邻居节点集合, 若 N_i 为空, 则 $\sigma_i = \min_{j \in N} \|W_i - W_j\|$ 。通过输入数据与获胜者的距离判断是否生成新神经元, 若 $\|x_i - w_1\| > \sigma_1$ 或 $\|x_i - w_2\| > \sigma_2$, 则将 x_i 作为新神经元节点。输入向量作为一个新节点插入网络, 以表示新类的第一个节点; 否则, 输入样本位于获胜神经元半径内, 将两单元相连, 不会生成新的神经元, 如图 4 所示。

2) 拓扑学习

假设神经元连接关系集合 $C \subset N \times N$, 当 x_i 为

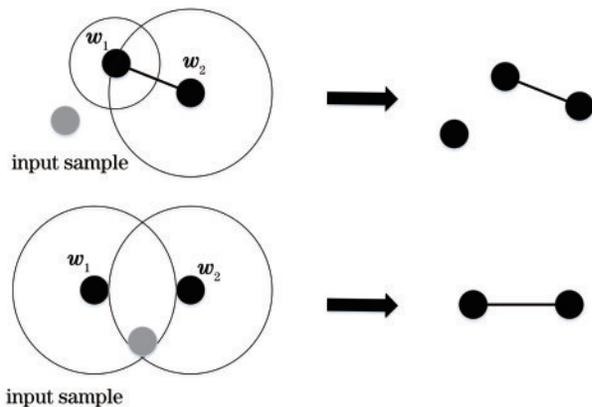


图 4 神经元学习的两种情况

Fig. 4 Two cases of the neuron learning

新神经元时, 将神经元集合更新为 $N = N \cup N_i$ 。若 w_1 和 w_2 不存在连接, 则将获胜者和第二获胜者建立连接添加到 C 中, 此时, $C = C \cup \{(w_1, w_2)\}$ 。新添加的边设置为年龄 0, 用获胜者神经元的边年龄作为顶点, 增加 1。即 $X_{age}^{(w_1, a)} = X_{age}^{(w_1, a)} + 1$, 其中, a 为 w_1 周围的邻居神经元。

如果输入样本被判断为获胜者 w_1 或第二获胜者 w_2 的同一集群, 则获胜者及其相邻节点的权重向量可表示为

$$\begin{aligned} w_1 &= w_1 + \epsilon(t) (x_i - w_1) \\ w_2 &= w_2 + \epsilon(t) \lambda (x_i - w_2) \end{aligned} \quad (3)$$

式中, $\epsilon(t)$ 为神经元获胜时间的倒数, λ 通常为 0.01。

3) 网络去噪

实际训练过程中, 输入数据集中经常伴有噪声, 且噪声数据与数据集中的数据差异较大, 导致 SOINN 算法学习过程中会生成不必要的节点, 降低了训练准确性, 增加了训练时间。为了避免这类问题, 首先, 周期性查找并删除处于低密度区域的部分节点; 然后, 删除两个距离较近的节点及其相关的连接。定义节点 i 的密度 $D(i)$ 为

$$D(i) = \frac{1}{(1 + d_i)^2} \quad (4)$$

式中, $d_i = \frac{\sum_{j \in N_i} \|W_i - W_j\|}{|N_i|}$ 为节点 i 及其邻居节点距离的平均值, $|N_i|$ 为相邻节点的数量。节点的删除操作使 SOINN 算法在噪声环境下具有一定的鲁棒性, 而参数 λ 决定了 SOINN 算法的去噪频率。学习完 λ 个样本后, 若神经元 i 和 j 的连接年龄大于定义的阈值, 即 $X_{age}^{(i, j)} > X_{agemax}$, 则删除连接。其中, X_{agemax} 为预定义阈值参数。最后, 执行神经元去噪操作, 即删除低密度区域的神经元。

在训练初期设置相对较大的 λ 和 X_{agemax} , 以保证较快的训练速度; 当网络分类准确率下降时, 设置较小的 λ 和 X_{agemax} , 以删除更多先前学习的节点, 并插入更多新节点, 适应网络环境的变化, 降低噪声数据的影响。实验最终设置的初始 $\lambda = 100$, $X_{agemax} = 30$; 分类准确率下降时, $\lambda = 25$, $X_{agemax} = 20$ 。

在训练初期设置相对较大的 λ 和 X_{agemax} , 以保证较快的训练速度; 当网络分类准确率下降时, 设置较小的 λ 和 X_{agemax} , 以删除更多先前学习的节点, 并插入更多新节点, 适应网络环境的变化, 降低噪声数据的影响。实验最终设置的初始 $\lambda = 100$, $X_{agemax} = 30$; 分类准确率下降时, $\lambda = 25$, $X_{agemax} = 20$ 。

4) 目标函数

假设数据流样本为 x_i , 进行非监督学习时的学习目标为最小化重构误差, 可表示为

$$L(t) = \frac{1}{2} \sum_{i=1}^k \sum_{i \in N} \mu_i(t) d_i^2(t), \quad (5)$$

式中, k 为输入数据的数量, $d_i^2(t) = \|\mathbf{x}_i - \mathbf{w}_i\|^2$ 为输入和神经元之间的欧几里得距离, $\mu_i(t)$ 为更新步长, 介于 0 和 1 之间, 输入 \mathbf{x}_i 与 \mathbf{w}_i 的距离越近, $\mu_i(t)$ 的值越大。

2.3 计算复杂度

对于在线算法而言, 计算复杂度和存储开销是评价算法性能最重要的 2 个指标^[24]。

1) 计算复杂度: SOINN 算法的计算复杂度主要包括隐藏层和输出层两部分。若学习到的神经元数量为 s , 则输出层的计算复杂度为 $O(s)$ 。隐藏层的神经元分布阶段计算复杂度为 $O(n \times d \times s)$, 其中, n 为输入样本数, d 为特征数目。网络去噪过程需要扫描所有神经元节点, 计算复杂度为 $O(s)$ 。SOINN 算法的总体计算复杂度为 $O(n \times d \times s + s) \approx O(n \times d \times s)$, 每次输入一个样本的计算复杂度为 $O(d \times s)$ 。

2) 存储开销: SOINN 在线算法需要存储模型各层参数, 输入层 $\mathbf{x}_i \in \mathbf{R}^{d \times n}$, 隐藏层 $\Phi(\mathbf{x}_i) \in \mathbf{R}^{d \times k}$, 输出层 $\mathbf{W} \in \mathbf{R}^{k \times 1}$, 其存储开销为 $d \times n + d \times k + k \times 1$ 。在线算法需要存储 p 个初始的神经元中心及其权重, 其存储开销为 $2 \times p$, 总存储开销为 $d \times n + d \times k + k \times 1 + 2 \times p$ 。

3 仿真实验

大气信道是激光通信的一个重要信道, 首先通过 MNIST 手写数据集对传统 GAN、WGAN (Wasserstein GAN) 进行训练, 测试其训练速度及稳定性; 然后, 给出了信号在对数正态信道 (Log) 和 Gamma-Gamma (G-G) 信道这两个常见大气信道模型中的传输过程, 传输时采用传统通信方法、GAN 方法和自组织增量 GAN 方法的传输误码率 (BER) 曲线。实验的环境参数、模型参数和自由空间光通信 (FSO) 仿真参数如表 1~表 3 所示, 权重由 SGD 算法更新, 训练的批量大小为 360。训练集和测试

表 1 实验的环境参数

Table 1 Environmental parameters of the experiment

Category	Parameter
Operating system	Windows10, 64 bit
Processor	Intel i7 9700K
GPU	GTX 1060
RAM	16 GB DDR4 1600 MHz
Anaconda3	5.2.0

表 2 模型的参数

Table 2 Parameters of the model

Parameter	Value
Transmitter hidden layers	32, 32
Learning rate	0.0005
Receiver hidden layers	32, 32
Learning rate	0.0005
Generator hidden layers	128, 128, 128
Discriminator hidden layers	32, 32, 32
Learning rate	0.0001

表 3 FSO 系统及信道参数

Table 3 Parameters of FSO system and channel

Parameter	Symbol	Value
Link distance /km	L	100
Laser wavelength /nm	λ	1550
Photoelectric conversion efficiency	R_p	1
Receiver diameter /mm	D_r	200
Refraction parameters	C_n^2	2.7×10^{-13}
Rytov variance (Log)	σ_{R1}	0.24
Rytov variance (G-G)	σ_{R2}	1.7

集采用 Foursquare 数据集。

3.1 MNIST 手写数据集的训练

训练时采用 MNIST 手写数据集对 GAN 和 SOINN-GAN 进行训练。MNIST 是最常见的手写数据集, 包含 60000 张用于训练和 10000 张用于测试的手写数字图像, 每张图像包含 28×28 个像素点。为简单起见, 将每张图像都转换为 $784 \times (28 \times 28)$ 个特征的一维 numpy 数组^[17]。随机抽取 20000 个训练集数据作为本次训练的训练集, 取 4000 个测试集数据作为测试集, 对 GAN 及 SOINN-GAN 进行训练, 测试其训练速度和稳定性, 其准确率和损失函数曲线如图 5 所示。可以发现, 随着训练样本的增加, GAN 和 SOINN-GAN 训练的准确率逐渐上升, 在前 5000 个样本的训练过程中, GAN 的准确率略高于 SOINN-GAN; 当训练样本数大于 5000 时, SOINN-GAN 的准确率比 GAN 的准确率高; 当训练样本数大于 5000 时, SOINN-GAN 的损失函数比 GAN 的损失函数小, 且 SOINN-GAN 的损失函数还在不断下降。综上所述, 样本足够多的情况下, SOINN-GAN 的训练效果更好, 在线增量学习的实时性更强, 训练完成后仍可以改变现有模型, 而线下训练不具备这种实时更新性质。

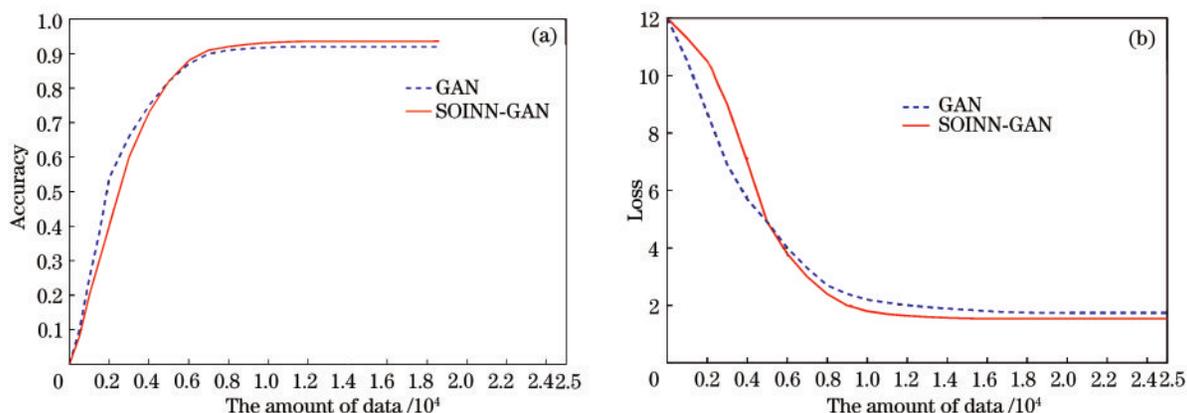


图 5 不同网络的准确率和损失函数曲线。(a)准确率;(b)损失函数

Fig. 5 Accuracy and loss function curves of different networks. (a) Accuracy; (b) loss function

3.2 Log 和 G-G 信道

Log 和 G-G 信道都属于大气信道,信道输出可表示为 $y_n = h_n \cdot x_n + n$, 其中, h_n 为信道衰落系数, $n \sim G_{\text{Gauss}}(0, 1)$, G_{Gauss} 为高斯分布。Log 信道属于大气弱湍流, Rytov 方差为 σ_{R1} ; G-G 信道属于大气中强湍流, Rytov 方差为 σ_{R2} , 传统 GAN 和 SOINN-GAN 在 Log 和 G-G 信道的 BER 如图 6 所示, 其中, 传统通信方式采用二进制相移键控(BPSK)。可以发现, 无论

在 Log 信道还是 G-G 信道中, 传统 GAN 和 SOINN-GAN 都可以得到与传统通信方式类似的 BER 曲线。但随着信噪比(SNR)的增大, SOINN-GAN 的 BER 性能明显好于传统 GAN, 即 SOINN-GAN 可以很好地模拟通道效应; 且随着 SNR 的增加, 其 BER 性能明显优于传统 GAN, 这表明 SOINN-GAN 的训练效果更好, 且在线增量学习可随着训练情况不断完善初始模型, 从而适应各种信道, 鲁棒性更强。

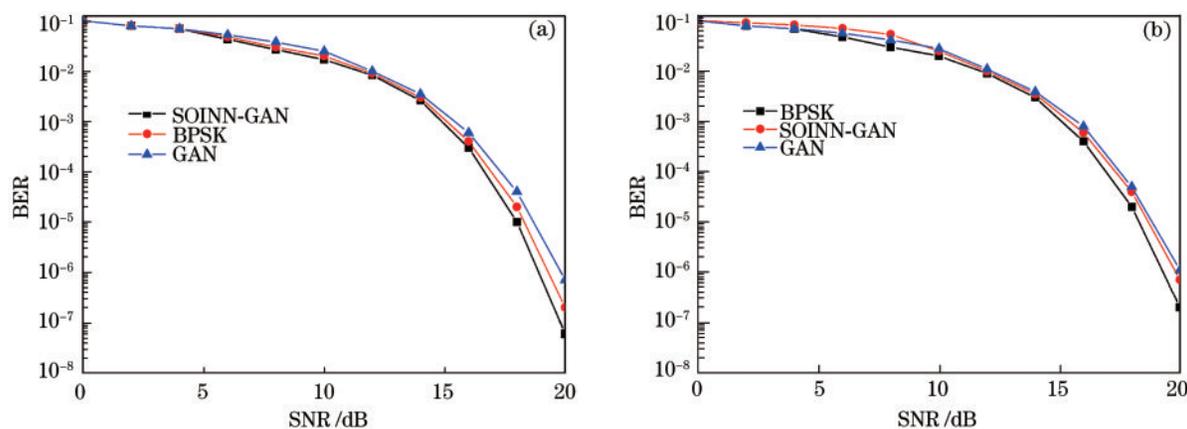


图 6 不同信道的 BER 曲线。(a) Log 信道;(b) G-G 信道

Fig. 6 BER curves of different channels. (a) Log channel; (b) G-G channel

4 结 论

激光通信通常要求信号传输具有较强的实时性和鲁棒性, 对 MNIST 手写数据集的训练结果表明, 相比传统 GAN, SOINN-GAN 具有更好的实时性。对 Log 和 G-G 信道的传输 BER 仿真结果表明, 相比传统 GAN, SOINN-GAN 可以很好地模拟信道效应, 实现端到端通信, 且存在降噪操作, 鲁棒性较好。

参 考 文 献

- [1] Hunt B R, Iler A L, Bailey C A, et al. Synthesis of atmospheric turbulence point spread functions by sparse and redundant representations[J]. Optical Engineering, 2018, 57(2): 024101.
- [2] Jin Y C, Chen X B, Mao X R, et al. Influence of modulation degree on performances of visible light communication system[J]. Chinese Journal of Lasers, 2019, 46(5): 0506001.

- 靳永超, 陈雄斌, 毛旭瑞, 等. 调制度对可见光通信系统性能的影响[J]. 中国激光, 2019, 46(5): 0506001.
- [3] Zeng Y, Zhang R. Energy-efficient UAV communication with trajectory optimization[J]. IEEE Transactions on Wireless Communications, 2017, 16(6): 3747-3760.
- [4] Heine F, Sánchez-Tercero A, Martín-Pimentel P, et al. Status of tesat laser communication activities [J]. Proceedings of SPIE, 2020, 11272: 1127204.
- [5] Li F, Wu Y, Hou Z H. Analysis and experimental research on bit error rate for free-space optical communication systems through turbulent atmosphere [J]. Acta Optica Sinica, 2012, 32(6): 0606002.
- 李菲, 吴毅, 侯再红. 湍流大气光通信系统误码率分析与实验研究[J]. 光学学报, 2012, 32(6): 0606002.
- [6] Lazer N, Teen Y P A. Free space optical communication and laser beam propagation through turbulent atmosphere: a brief survey[C]//2019 International Conference on Recent Advances in Energy-efficient Computing and Communication (ICRAECC), March 7-8, 2019, Nagercoil, India. New York: IEEE Press, 2019: 1-6.
- [7] Alfredsson A F, Agrell E, Karlsson M, et al. Pilot distributions for joint-channel carrier-phase estimation in multichannel optical communications[J]. Journal of Lightwave Technology, 2020, 38(17): 4656-4663.
- [8] Basudewa M I, Bagaskara Z H, Damita S A, et al. Bit error rate performance analysis for free space optic communication[J]. IOP Conference Series: Materials Science and Engineering, 2020, 850: 012056.
- [9] Zou P, Zhao Y H, Hu F C, et al. Research status of machine learning based signal processing in visible light communication[J]. Laser & Optoelectronics Progress, 2020, 57(1): 010001.
- 邹鹏, 赵一衡, 胡昉辰, 等. 基于机器学习的可见光通信信号处理研究现状[J]. 激光与光电子学进展, 2020, 57(1): 010001.
- [10] Alnajjar S H, Ali M H, Abass A K. Enhancing performance of hybrid FSO/fiber optic communication link utilizing multi-channel configuration[J/OL]. Journal of Optical Communications, (2019-03-05) [2020-09-08]. <https://www.degruyter.com/document/doi/10.1515/joc-2018-0193/html>.
- [11] Kamalian-Kopae M, Vasylychenkova A, Kotlyar O, et al. Artificial neural network-based equaliser in the nonlinear Fourier domain for fibre-optic communication applications[C]//The European Conference on Lasers and Electro-Optics 2019, June 23-27, 2019, Munich Germany. Washington, D. C.: OSA, 2019: ci_1_4.
- [12] Liu J M, Wang P P, Zhang X K, et al. Deep learning based atmospheric turbulence compensation for orbital angular momentum beam distortion and communication[J]. Optics Express, 2019, 27(12): 16671-16688.
- [13] Xu M M, Bu X Z, He Z L, et al. Atmospheric turbulence interference compensation for missile-borne infrared attitude measurement[J]. Infrared Physics & Technology, 2019, 97: 69-73.
- [14] Pappu C S, Carroll T L, Flores B C. Simultaneous radar-communication systems using controlled chaos-based frequency modulated waveforms[J]. IEEE Access, 2020, 8: 48361-48375.
- [15] O'Shea T, Hoydis J. An introduction to deep learning for the physical layer[J]. IEEE Transactions on Cognitive Communications and Networking, 2017, 3(4): 563-575.
- [16] Dörner S, Cammerer S, Hoydis J, et al. On deep learning-based communication over the air[J]. 2017 51st Asilomar Conference on Signals, Systems, and Computers, October 9-November 1, 2017, Pacific Grove, CA, USA. New York: IEEE Press, 2017: 1791-1795.
- [17] Felix A, Cammerer S, Dörner S, et al. OFDM-autoencoder for end-to-end learning of communications systems[C]//2018 IEEE 19th International Workshop on Signal Processing Advances in Wireless Communications (SPAWC), June 25-28, 2018, Kalamata, Greece. New York: IEEE Press, 2018: 1-5.
- [18] Ye H, Li G Y, Juang B H F, et al. Channel agnostic end-to-end learning based communication systems with conditional GAN[C]//2018 IEEE Globecom Workshops (GC Wkshps), December 9-13, 2018, Abu Dhabi, United Arab Emirates. New York: IEEE Press, 2018: 1-5.
- [19] Arjovsky M, Bottou L. Towards principled methods for training generative adversarial networks[EB/OL]. (2017-01-17) [2020-09-10]. <https://arxiv.org/abs/1701.04862>.
- [20] Xiang Y, Bao C C. A parallel-data-free speech enhancement method using multi-objective learning cycle-consistent generative adversarial network[J]. IEEE/ACM Transactions on Audio, Speech, and Language Processing, 2020, 28: 1826-1838.
- [21] Hu L Q, Kan M N, Shan S G, et al. Duplex generative adversarial network for unsupervised

- domain adaptation[C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, June 18-23, 2018, Salt Lake City, UT, USA. New York: IEEE Press, 2018: 1498-1507.
- [22] Chiaroni F, Rahal M C, Hueber N, et al. Learning with a generative adversarial network from a positive unlabeled dataset for image classification[C]//2018 25th IEEE International Conference on Image Processing (ICIP), October 7-10, 2018, Athens, Greece. New York: IEEE Press, 2018: 1368-1372.
- [23] Zhang J, Peng Y X, Yuan M K. SCH-GAN: semi-supervised cross-modal hashing by generative adversarial network[J]. *IEEE Transactions on Cybernetics*, 2020, 50(2): 489-502.
- [24] Fournier N, Guillin A. On the rate of convergence in Wasserstein distance of the empirical measure[J]. *Probability Theory and Related Fields*, 2015, 162(3/4): 707-738.
- [25] Baum D S, Hansen J, Salo J, et al. An interim channel model for beyond-3G systems: extending the 3GPP spatial channel model (SCM)[C]//2005 IEEE 61st Vehicular Technology Conference, May 30-June 1, 2005, Stockholm, Sweden. New York: IEEE Press, 2005: 3132-3136.
- [26] Goodfellow I J, Pouget-Abadie J, Mirza M, et al. Generative adversarial nets[J]. *NIPS'14: Proceedings of the 27th International Conference on Neural Information Processing Systems*, December 8, 2014, Cambridge, MA, United States. Cambridge: MIT Press, 2014, 2: 2672-2680.
- [27] Wang Z H, Wu S, Liu C, et al. The regression of MNIST dataset based on convolutional neural network[M]//Hassanien A E, Azar A T, Gaber T, et al. *The international conference on advanced machine learning technologies and applications (AMLTA2019)*. Advances in intelligent systems and computing. Cham: Springer, 2019, 921: 59-68.
- [28] Duchi J C, Hazan E, Singer Y, et al. Adaptive subgradient methods for online learning and stochastic optimization[J]. *Journal of Machine Learning Research*, 2011, 12(61): 2121-2159.
- [29] Yang Z, Chen W, Wang F, et al. Improving neural machine translation with conditional sequence generative adversarial nets[C]//Proceedings of the 2018 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies, Volume 1 (Long Papers), June 1-6, 2018, New Orleans, Louisiana. Stroudsburg, PA, USA: Association for Computational Linguistics, 2018: 1346-1355.
- [30] Lu H Q, Zhao W, Xie X P. Communication capacity of a free space laser communication system in atmospheric turbulent and disperse channels[J]. *Chinese Optics Letters*, 2011, 9(s1): s10603.
- [31] Xie Y P, Lei T, Yang C W, et al. Beam wander relieved optical switch using Bessel beams in turbulent atmosphere[J]. *Chinese Optics Letters*, 2019, 17(9): 090602.
- [32] Wang X Y, Casiraghi G, Zhang Y, et al. A Gaussian process-based self-organizing incremental neural network[C]//2019 International Joint Conference on Neural Networks (IJCNN), July 14-19, 2019, Budapest, Hungary. New York: IEEE Press, 2019: 1-8.