

文章编号: 1002-1582(2026)01-0068-07

基于对偶学习的高效可见光通信非线性均衡器

宋锐^{1,2*}, 邓春丽¹, 李志良¹, 刘宏立²

(1. 张家界航空工业职业技术学院 航空电气工程系, 湖南 张家界 427000)

(2. 湖南大学 电气与信息工程学院, 湖南 长沙 410082)

摘 要: 针对室内可见光通信 (VLC) 中由 LED 动态非线性和信道衰落所引起的信号失真问题, 提出一种基于对偶学习的非线性均衡方法。通过搭建 PAM4 调制 VLC 仿真系统, 结合 LED 非线性模型与 NLOS 信道以模拟失真特性, 设计了基于对偶神经网络结构的均衡器, 利用正向均衡与反向映射网络实现双向约束, 并借助对偶一致性损失提升在有限训练样本下的均衡性能。实验结果表明, 方法显著降低了系统误码率, 在相同训练符号数量下, 误码率较传统均衡方法最多可降低 2 个数量级; 与传统神经网络均衡器相比, 达到 FEC 阈值所需训练序列长度最大可减少 62.5%, 能够在显著提升 VLC 系统传输可靠性的同时, 大幅降低均衡器训练开销。

关 键 词: 可见光通信; 非线性均衡; 神经网络; 对偶学习

中图分类号: TN929

文献标识码: A

Efficient nonlinear equalizer for visible light communication based on dual learning

SONG Rui^{1,2*}, DENG Chunli¹, LI Zhiliang¹, LIU Hongli²

(1. Department of Aeronautical Electrical Engineering, Zhangjiajie Institute of Aeronautical Engineering, Zhangjiajie 427000, China)

(2. College of Electrical & Information Engineering, Hunan University, Changsha 410082, China)

Abstract: To address signal distortion caused by LED dynamic nonlinearity and channel fading in indoor visible light communication (VLC) systems, a nonlinear equalization method based on dual learning is proposed. A PAM4-modulated VLC simulation system is constructed, incorporating an LED nonlinearity model and a non-line-of-sight (NLOS) channel to emulate distortion characteristics. A dual neural network structure is designed, which employs a forward equalization network and a backward mapping network to achieve bidirectional constraints, and utilizes a dual consistency loss to enhance equalization performance under limited training samples. Experimental results show that the proposed method significantly improves the bit error rate (BER) performance of the system. Under the same number of training symbols, the BER can be reduced by up to two orders of magnitude compared to conventional equalization methods. Compared to traditional neural network equalizers, the required training sequence length to achieve the FEC threshold is reduced by up to 62.5%, effectively enhancing the transmission reliability of the VLC system while substantially reducing the training overhead.

Keywords: visible light communication; nonlinear equalization; neural network; dual learning

0 引 言

基于强度调制—直接检测 (Intensity Modula-

tion and Direct Detection, IM/DD) 的室内可见光通信 (Visible Light Communication, VLC) 系统因结构简单、成本低, 成为未来室内无线通信的

收稿日期: 2025-06-17; 收到修改稿日期: 2025-09-15

基金项目: 湖南省自然科学基金资助项目 (2022JJ60088); 湖南省教育厅科学研究资助项目 (24C1329)

作者简介: 宋锐 (1977—), 男, 副教授, 从事半导体照明和可见光通信研究。

* 通讯作者: zjjsongrui@163.com

重要方案^[1-3]。然而,其信号传输受双重损伤影响:一是LED器件非线性及低通特性导致的信号畸变与符号间串扰(Inter-Symbol Interference, ISI)^[4,6],二是室内非视距(Non-Line of Sight, NLOS)传播引发的多径效应ISI,二者导致系统性能下降^[7]。

VLC系统的接收端常采用均衡算法补偿信号失真,现有方案分为预均衡与后均衡^[8-10]。预均衡需信道状态信息(Channel State Information, CSI),实现成本高且易提升信号峰均比;后均衡通过接收端自适应均衡器补偿损伤,无需信道估计,但非线性损伤要求均衡器具备非线性处理能力^[9]。多层神经网络虽在非线性补偿中性能优于传统均衡器^[11-15],却面临信道记忆长度较大时训练序列过长的问题^[16-19],实现成本高。信道记忆长度过长会导致多级调制信号的符号间干扰模式数量指数激增。若训练序列过短,神经网络模型将难以充分捕捉这些特征,从而发生欠拟合,导致性能下降。

针对上述挑战,本文提出一种基于对偶学习的非线性均衡器设计方法。与传统单一信号恢复模型不同,该方法构建了两个对偶的神经网络:一个用于信号均衡,从接收信号中恢复原始发送信号;另一个用于信道模拟,根据原始信号预测受损的接收信号。通过引入对偶一致性约束,构建出一个端到端的无监督学习框架,从而显著降低对训练序列长度的依赖。此外,所提方法与模型结构无关,可灵活嵌入现有各类深度学习均衡器中。实验结果表明,该方法在室内VLC系统中显著提升了非线性均衡性能,为缓解信号失真提供了有效解决方案,对推动VLC技术的实际应用具有重要价值。

1 室内可见光通信非线性信道模型

LED器件的非线性调制特性主要源于两个方面:(1)电压-电流及电流-光强的非线性转换特性;(2)输出光强对历史驱动状态中电荷积累与空穴电流的依赖性。其中,前者构成无记忆的静态非线性(Static Nonlinearity, SN),可通过建立电流-光强转换关系实现线性化建模^[4-7];后者表现为具有记忆性的动态非线性(Dynamic Nonlinearity, DN),其信号损伤与历史传输符号呈非线性关联^[4]。在通信系统建模中,仅考虑SN时可采用Wiener模型描述LED非线性特性^[4-7];而当动态非线性的记忆效应显著(如输出光强受电荷积累影响),则需采用Volterra级数模型对其记忆性非线性进行建模^[4]

$$P_{Tx}(t) = \sum_{n=0}^{\infty} \frac{1}{n!} \int_{-\infty}^{\infty} d\bar{\tau} h_n(\bar{\tau}) \prod_{i=1}^n x(t - \tau_i) \quad (1)$$

式中 $\bar{\tau} = (\tau_1, \dots, \tau_n)$, $h_n(\bar{\tau})$ 为 n 阶非线性核。文献表明二阶Volterra级数模型能够表征LED器件由于电荷积累和空穴电流的依赖性导致的非线性^[4]。其中一阶核 $h_1(\tau_1)$ 描述LED器件的低通效应;二阶核 $h_2(\tau_1, \tau_2)$ 描述LED器件的二阶非线性效应。本文采用Volterra级数模型对LED的非线性调制特性进行建模。

图1(a)为室内可见光通信链路示意图。基带调制信号添加直流偏置后将传输信号加载至LED器件上。光信号在室内环境中,通过视距(Line of Sight, LOS)和非视距(Non-Line of Sight, NLOS)信道传输^[2]。室内VLC信道的单位脉冲响应为

$$h(t) = h_{LOS}(t) + h_{NLOS}(t) \quad (2)$$

式中,视距链路响应 $h_{LOS}(t)$ 为和非视距链路响应 $h_{NLOS}(t)$ 分别为

$$h_{LOS}(t) = \frac{A(m+1)}{2\pi d^2} T_s(\varphi) g(\varphi) \cos^m(\varphi) \cos(\phi_{Rx}) \delta(t) \quad (3)$$

$$h_{NLOS}(t) = \frac{A(m+1)}{2\pi d_1^2 d_2^2} \rho_i dA_i \cos^m(\varphi) \cos(\alpha_i) \cos(\beta_i) T_s(\varphi) g(\varphi) \cos(\phi_{Rx}) \delta(t - \tau_i) \quad (4)$$

如图1(b)室内可见光通信系统信道模型所示,其中 A 表示PD的有效接收面积; dA_i 表示反射体面积; α_i 和 β_i 为光波在第 i 个反射体处的入射角及出射角; d_1 和 d_2 分别表示光源与反射体,反射体与PD之间的直线距离; τ_i 表示第 i 条光信号传播路径上的传播延迟; ρ 表示反射体的反射系数; m 为光源的朗伯系数; $T_s(\phi)$ 和 $g(\phi)$ 分别是光滤波器和会聚透镜增益, ϕ 为LED出射角度。在接收端光强信号通过光电探测器(Photodetector, PD)转换为电信号。接收端光信号强度可以被写为

$$P_{Rx}(t) = P_{Tx}(t) * h(t) + n(t) \quad (5)$$

式中, $n(t)$ 表示加性高斯白噪声,符号 $*$ 表示卷积运算。根据上述分析,室内VLC系统非线性是由LED器件非线性和室内多径信道的综合作用的结果。图1(c)对比了仅考虑LED静态非线性和LED动态非线性下,10Mbaud的脉冲幅度调制4电平(Pulse Amplitude Modulation 4-level, PAM4)调制信号的接收眼图的区别。仿真中所采用的LED器件参数基于Luxeon公司已发表的商用蓝光LED器件模型^[18]。可以看出,LED器件的非线性效应不仅导致多级调制格式幅度的非线性映射,同时带来了时钟偏斜的信号损伤。尽管减小调制信号摆幅能够降低非线性响应带来的影响,但是这种方案会降低系统信噪比,从而影响系统容量。




图 1 室内可见光通信系统框图及信号损伤来源

2 基于对偶学习的非线性均衡器设计

受 LED 非线性与室内 NLOS 信道共同作用，可见光通信信道呈现记忆性与非线性特征。接收端可通过非线性均衡器补偿此类损伤，神经网络均衡器虽凭借强大非线性拟合能力表现优异，且能够获得更好的非线性均衡性能^[13-20]。尽管深度学习均衡器在补偿 VLC 系统非线性失真方面展现出卓越性能，但其实际应用面临一个显著挑战：高昂的训练复杂度和过长的训练序列需求。该问题的根源在于信道记忆效应与调制阶数共同构成的“维度灾难”。对于一个记忆长度为 L 的信道，其输入序列的可能组合数为 M^L ，其中 M 为调制阶数（例如，对于 PAM4 调制， $M=4$ ）。深度神经网络凭借其强大的非线性映射能力，理论上可以拟合这一极其复杂的判决函数，但其前提是训练数据必须足够充分地覆盖这片庞大的状态空间。若训练序列过短，模型将难以学习到绝大多数可能的符号间串扰模式，导致泛化能力急剧下降，从而需要更长的训练序列来确保收敛和性能。

为此，本文提出基于对偶学习（Dual Learning, DL）的均衡器模型（如图 2（a）所示），包含前向模型 F 与逆向模型 B 两个神经网络。在正向模型中， s 表示发送的时域数字信号窗口，长度为 $2w$ ， r 表示时域接收数字信号窗口，长度也为 $2w$ 。设发射机当前正在发送第 j 个符号，则 s 和 r 可以分别表示为

$$\begin{aligned} s &= [a_j - w, a_j - w + 1, \dots, a_j, \dots, a_j + w] \\ r &= [b_j - w, b_j - w + 1, \dots, b_j, \dots, b_j + w] \end{aligned} \quad (6)$$

式中， a_j 为第 j 个发送符号，其长度为发送符号的过采样率； b_j 为第 j 个接收符号，其长度为接收符号的过采样率。可以用联合概率分布 $P(s, r)$ 来表示发送信号 s 与接收信号 r 之间的关系。在对偶学习

模型中，正向模型的输入为 s ，经过训练后其输出 r_p 期望与 r 尽可能接近。正向模型可以看作是一个室内 VLC 信道模拟器，即输入发送信号，预测经过信道后的接收信号。而反向模型的输入为 r ，经过训练后其输出 s_p 期望与 s 接近。反向模型可以看作是接收信号均衡器，即输入接收信号，预测原始发送信号。设前向和反向模型的参数分别为 θ, ϕ 。假设前向和反向模型均为理想的，根据全概率公式有

$$P(r|s; \theta)P(s) = P(s|r; \phi)P(r) \quad (7)$$

式中给出了对偶一致性约束的概率表示形式。该式的数学含义为：如果前向模型和反向模型均是完美的，则等号两侧计算联合概率分布 $P(s, r)$ 的结果应当一致。该约束可以为模型训练提供额外的监督信息。值得注意的是，上述推导过程并未引入任何关于模型结构的额外假设，因此该方法可适用于不同结构的神经网络均衡器。

图 2（b）给出了对偶模型的每次训练迭代过程中的四个步骤：

步骤 1 为前向模型的单独训练。选取数据集样本 (s_i, r_i) ，将 s_i 当作前向模型的输入并得到预测输出 r_p ，通过最小化均方误差损失函数使得前向模型能够模拟信道传输函数输出接收信号。该阶段的损失函数可以表示为

$$\text{Loss}_1(s_i, r_i) = \|F(s_i) - r_i\|^2 \quad (8)$$


步骤 2 为逆向模型的单独训练。将 r_i 当作前向模型的输入并得到输出 s_p ，通过计算 s_i 与 s_p 的均方误差损失函数使得反向模型在给定接收信号的条件能够正确地恢复出发送信号，该阶段的损失函数可以表示为

$$\text{Loss}_2(s_i, r_i) = \|B(r_i) - s_i\|^2 \quad (9)$$


步骤 3 为基于发送信号起点的对偶训练。如

图 2 (b) 中步骤 3 所示, 将前向模型和逆向模型串联后可以得到一个级联模型^[16]。经步骤 1、2 训练后, 前向模型和反向模型可分别模拟信道响应及消除信号畸变; 此时任意信号输入该级联模型, 输出仍为原信号。该训练方法被称为对偶循环一致性原理^[16]。值得注意的是这是一个无监督的学习过程, 无需成对的训练数据, 即 $\tilde{s}$ 是由随机生成的比特序列产生的发送信号。该阶段的损失函数可以表示为

$$\text{Loss}_3(\tilde{s}) = \|B(F(\tilde{s})) - \tilde{s}\|^2 \quad (10)$$



(a) 正向和反向模型



(b) 对偶学习训练步骤

图 2 对偶学习均衡器模型及其训练流程

3 仿真及实验

为探究所提对偶学习模型的有效性, 在 MATLAB 软件中搭建如图 3 (a) 的室内可见光通信模型。在该模型中, 室内尺寸为 $4\text{m} \times 4\text{m} \times 3\text{m}$, LED 光源在室内模型顶部。为了计算光信号传输过程中的反射, 将室内模型的边界划分为了 $0.1 \times 0.1\text{m}^2$ 的反射体, 并且只计算由于一次反射所导致的多径效应。具体的仿真系统参数为: 反射率 0.05, 反射面积 $0.1 \times 0.1\text{m}^2$, LED 发光角度 150° , LED 位置 $(0, 0, 3\text{m})$ 、 $(4\text{m}, 0, 3\text{m})$ 、 $(0, 4\text{m}, 3\text{m})$ 、 $(4\text{m},$

步骤 4 为基于接收信号起点的对偶训练, 如图 2 (b) 步骤 4 所示, 将逆向模型和前向模型串联得到另一个级联模型。以接收信号 r_i 为起点, 通过比较级联模型输出 r_p 与 r_i 的均方误差为前向/反向模型提供训练反馈。与训练步骤 3 有所区别的是, 步骤四无法随机生成一个接收信号用于训练, 因此这个阶段的训练还是有监督的。该训练阶段的损失函数可以表示为

$$\text{Loss}_4(r_i) = \|F(B(r_i)) - r_i\|^2 \quad (11)$$

$4\text{m}, 3\text{m})$, LED 3-dB 带宽 10MHz, 调制格式 8Mbaud PAM4, 接收机位置 $(2\text{m}, 2\text{m}, 0\text{m})$, 均衡器窗口长度 $(2w=24)$ 。图 3 (b) 为仿真流程: 二进制比特串经格雷映射生成 PAM4 符号, 经升余弦滤波器 (滚降系数为 0.35) 成形后加直流偏置, 由 LED 调制为光强信号; 经 LOS 与 NLOS 信道传输后, 光电探测器检测信号, 再经符号同步、去直流、均衡及解映射恢复原始比特流, 计算系统误码率。图 3 (c) 为调制信号经 LED 及信道传输后的眼图, 信号经 LED 时受其非线性影响畸变, 经多径传输引入码间串扰。




图 3 室内可见光通信仿真模型及仿真结果

在通信信号均衡中,全连接神经网络(Fully Connected Neural Network, FC-NN)与卷积神经网络(Convolutional Neural Network, Conv-NN)是两类常用模型。二者输入输出均为长度 $2w$ 的信号窗口。在本文中,FC-NN共包括8层,并采用维度递减策略构建深层网络:前4层的维度分别为 $2w, w, w/2, w/4$;后4层维度为 $w/4, w/2, w, 2w$ 。该方法可以实现平衡深度与复杂度的同时实现非线性映射。Conv-NN采用类似结构,但是层间连接替换为卷积/反卷积核^[17,19],其层间连接由三元组 (k, s, f) 表示(k 为卷积核长度, s 为步长, f 为卷积核数目)。前5层间的卷积核参数分别为 $(3, 2, 16), (3, 2, 32), (3, 2, 32), (3, 1, 4)$ 。即信号首先通过卷积操作将维度压缩至 $w/4$ 。后3层间通过反卷积核将信号维度恢复至 $2w$,其参数分别为 $(3, 2, 32), (3, 2, 32), (3, 2, 16)$ 。在进行前向推理时,FC-NN的计算复杂度为1.53kFlops;而Conv-NN的计算复杂度为1.92kFlops。本文所提出的对偶学习均衡器模型通过Pytorch深度学习框架实现,优化器采用Adam,初始学习率设置为0.001。

为验证所提均衡算法有效性,仿真对比了近年VLC室内系统中典型的线性与非线性均衡算法:包括硬判决(Hard Decision, HD),迫零均衡器(Zero-Forcing Equalizer, ZFE)、极大似然均衡器(Maximum Likelihood Estimator, MLE)以及基于最小均方(Least Mean Square, LMS)准则的自适应均衡算法,包括判决反馈均衡器(Decision Feedback Equalizer, DFE)和沃尔特拉非线性均衡器(Volterra Nonlinear Equalizer, VNLE)^[12]。同时,还对比了已报道的基于深度学习的非线性均衡算法,包括深度神经网络(Deep Neural Network, DNN),卷积神经网络(Convolutional Neural Network, CNN)及长短期记忆网络(Long Short-Term Memory, LSTM)^[14-15, 20]。为了对比公平,所有均衡器阶数统一设为 $2w$,训练符号长度设置为 1×10^5 ,以对比非线性均衡性能。本文所提出的模型的训练使用GPU(Nvidia RTX3090)进行加速。FC-NN和Conv-NN在训练过程中模型的损失函数如图4(a)和(b)分别所示。在100轮训练中,FC-NN和Conv-NN使用对偶训练的耗时为96s和127s。

图5(a)对比对偶学习均衡器与传统算法误码性能:0~8dB信噪比(Signal-to-Noise Ratio, SNR)下,对偶学习全连接网络(Dual Learning Fully-Connected Neural Network, DL-FC-NN)和对偶

学习卷积网络(Dual Learning Convolutional Neural Network, DL-Conv-NN)性能优于ZFE、MLE、DFE及VNLE;0~2dB时各算法误码率(Bit Error Rate, BER)均高于 10^{-2} ,此时传输系统的BER主要来源于噪声;当 $\text{SNR} > 4\text{dB}$ 时,DFE、VNLE等非线性算法优于ZFE、MLE线性算法。达到前向纠错(Forward Error Correction, FEC)阈值时,DL-FC/Conv较DFE分别获1.2dB/1.5dB信噪比增益,较VNLE提升0.2dB/0.5dB。相较于已报道的基于深度学习的非线性均衡算法,在0~2dB的SNR条件下,DNN、CNN及LSTM模型的性能与本文提出的模型性能接近;当SNR进一步提高至FEC阈值时,与DNN、CNN和LSTM模型相比,DL-FC-NN和DL-Conv-NN模型均取得了0.2dB/0.2dB/0.4dB的信噪比增益。




图4 全连接神经网络和卷积神经网络均衡器对偶学习训练曲线

图5(b)、(c)进一步分析了对偶学习机制对均衡性能的影响:低SNR(0~2dB)时对偶学习机制增益不显著;在3~8dB的SNR区间内,对偶学习机制对误码性能的提升随SNR增大而增强;当误码率达到FEC阈值时,对偶学习机制可使全连接/卷积模型分别获0.8dB/2.2dB信噪比增益。

图6(a)、(b)对比了高信噪比条件(8dB)下不同训练序列长度时,对偶学习机制对两类神经网络均衡器性能的影响。如图所示,当训练序列较短时,对偶学习机制显著降低误码率;随训练序列长度增加,其性能增益逐渐衰减。在达到相同FEC纠错阈值时,全连接/卷积神经网络均衡器引入该机制后,训练序列长度分别减少80%(至 5×10^4)和41%(至 3.5×10^4)。

图7通过调节非线性核 $h_2(\tau_1, \tau_2)$ 相对于线性核 $h_1(\tau_1)$ 的强度比例,揭示了高信噪比($\text{SNR} = 8\text{dB}$)条件下,不同非线性强度对本论文所提出的均衡方法相较于相同阶数的线性前向反馈均衡器(Feed Forward Equalizer, FFE)的性能增益影响。可以看出,在非线性核强度处于 10^{-3} 到1的范围内时,非线性均衡能够带来显著的误码率(BER)




图5 非线性均衡器误码性能对比

性能提升。需要指出的是, LED 器件的非线性强度不仅受偏置点选择和驱动信号摆幅的影响, 通常还与其器件结构设计密切相关, 是否需要采用非线性均衡需要综合考虑上述因素^[18]。




图6 训练序列长度对神经网络均衡器误码性能的影响




图7 不同非线性强度下对偶学习均衡器与线性均衡器误码率对比

实验平台如图 8 (a) 所示, 由一个尺寸为 $1\text{m} \times 1\text{m} \times 1.2\text{m}$ 的房间模型、发射模块和接收模块组成。发射模块中, 采用任意波形发生器 (Rigol DG5252, 采样率为 1GSa/s) 产生驱动信号, 用以驱动四个 LED (CREE XPE Q5) 发射通信信号。实验采用 PAM4 调制格式, 波特率为 8Mbaud 。发射端的数字信号处理流程如下: 首先在计算机中生成随机 0/1 比特序列, 经格雷映射转换为符号后, 通过滚

降系数为 0.35 的升余弦滚降滤波器进行脉冲成形。每一帧发送信号包括用于时钟同步的导频符号序列和长度为 2×10^5 的数据符号序列。接收模块包括光电探测器 (LSSAPD-500-C1) 和跨阻放大器 (OPA657), 用于将光信号转换为电信号。该电信号由实时示波器 (DHO900, 采样率为 1.25GSa/s) 进行采样, 之后在计算机中完成数字信号处理, 包括重采样和符号同步, 最终每个符号降采样为 8 个采样点。随后, 通过截断方式将数据划分为训练序列和测试序列, 以用于评估不同均衡算法的性能。为了验证对偶学习机制的有效性, 实验同时训练了相同的神经网络均衡器模型, 但是不包括对偶学习步骤, 用于消融实验。




图8 房间模型及实验测试平台

图 9 对比了训练序列长度 $2 \times 10^4 \sim 1 \times 10^5$ 时各非线性均衡器误码性能: 由于非线性均衡能力更强, 无论是否采用对偶学习, 神经网络均衡器, 包括 DNN、CNN 及 LSTM 性能均优于传统 DFE 和 VNLE。当训练序列为 2×10^4 时, DL-FC-NN/DL-Conv-NN 均衡器误码率分别为 2.6×10^{-3} 和 4.1×10^{-3} , 较未采用对偶学习的同模型 (2.1×10^{-2} 、 9.6×10^{-3}) 显著降低。训练序列长度增至 1×10^5 时, 对偶学习模型与其他神经网络模型性能接近。达 FEC 阈值时, 对偶学习可使 FC-NN/Conv-NN 均衡器所需训练序列长度减少 62.5% 和 25%。在本文的实验条件下, 可分别减低模型训练时长 60s 和 31.8s。




图9 不同均衡器及训练序列长度条件下的误码率

4 结 论

本文提出一种基于对偶学习的室内可见光通信非线性均衡方法，通过构建双向神经网络模型（信道模拟器与信号均衡器）及对偶一致性约束框架，实现了对LED动态非线性与室内多径信道损伤的高效补偿。该方法突破传统单模型依赖大量训练数据的局限，通过对偶学习机制的无监督正则化作用，显著提升了神经网络均衡器的泛化能力与训练效率。

参考文献：

- [1] 马瑞. 基于自注意力神经网络的室内可见光定位方法[J]. 光学技术, 2025, 51(1): 108—115.
Ma Rui. Indoor visible light positioning method based on self-attention neural network[J]. Optical Technique, 2025, 51(1): 108—115.
- [2] 刘杰徽, 何英, 胡锋, 等. 基于PIN的水下可见光双向语音通信试验研究[J]. 光通信研究, 2022, (3): 65—71.
Liu Jiehui, He Ying, Hu Feng, et al. Experimental research on underwater visible light two-way voice Communication based on PIN[J]. Study on Optical Communications, 2022, (3): 65—71.
- [3] 贾科军, 雷蕾, 蒯莹, 等. 基于记忆多项式的Volterra混合均衡器设计与研究[J]. 光通信研究, 2024(3): 40—48.
Jia Kejun, Lei Lei, Lan Ying, et al. Design and study of memory polynomial-based Volterra hybrid equalizer[J]. Study on Optical Communications, 2024(3): 40—48.
- [4] Deng X, Mardankorani S, Wu Y, et al. Mitigating LED non-linearity to enhance visible light communications[J]. IEEE Transactions on Communications, 2018, 66(11): 5593—5607.
- [5] Lu H, Jin J, Wang J. Alleviation of LED nonlinearity impact in visible light communication using companding and predistortion[J]. IET Communications, 2019, 13(7): 818—821.
- [6] Turan B, Narmanlioglu O, Koc O N, et al. Measurement based non-line-of-sight vehicular visible light communication channel characterization[J]. IEEE Transactions on Vehicular Technology, 2022, 71(9): 10110—10114.
- [7] Lin B, Yang J, Nie K, et al. NLOS visible light positioning and communication based on LoRa modulation[J]. Optics Express, 2024, 32(14): 24128—24143.
- [8] Wang L, Wang X, Kang J, et al. A 75-Mb/s RGB PAM-4 visible light communication transceiver system with pre-and post-equalization[J]. Journal of Lightwave Technology, 2021, 39(5): 1381—1390.
- [9] Zhang G, Hong X, Fei C, et al. Sparsity-aware nonlinear equalization with greedy algorithms for LED-based visible light communication systems[J]. Journal of Lightwave Technology, 2019, 37(20): 5273—5281.
- [10] 成院波, 查海朋, 保贤, 等. LED非线性幅度分解多项式预失真[J]. 光通信研究, 2024, (4): 108—114.
Cheng Yuanbo, Zha Haipeng, Bao Xian, et al. Amplitude factorization polynomial pre-distortion for nonlinear LED[J]. Study on Optical Communications, 2024, (4): 108—114.
- [11] Miao P, Chen G, Cumanan K, et al. Deep hybrid neural network-based channel equalization in visible light communication[J]. IEEE Communications Letters, 2022, 26(7): 1593—1597.
- [12] Zhou Y, Wei Y, Hu F, et al. Comparison of nonlinear equalizers for high-speed visible light communication utilizing silicon substrate phosphorescent white LED[J]. Optics Express, 2020, 28(2): 2302—2316.
- [13] 贺锋涛, 王乐莹, 王晓波, 等. 基于改进的AdaBoost无线光通信信号检测算法[J]. 激光技术, 2023, 47(5): 659—665.
He Fengtao, Wang Leying, Wang Xiaobo, et al. Signal detection algorithm of wireless optical communication based on the improved AdaBoost[J]. Laser Technology, 2023, 47(5): 659—665.
- [14] Zou P, Zhao Y, Hu F, et al. Enhanced performance of MIMO multi-branch hybrid neural network in single receiver MIMO visible light communication system[J]. Optics Express, 2020, 28(19): 28017—28032.
- [15] Haigh P A, Ghassemlooy Z, Rajbhandari S, et al. Visible light communications: 170 Mb/s using an artificial neural network equalizer in a low bandwidth white light configuration[J]. Journal of Lightwave Technology, 2014, 32(9): 1807—1813.
- [16] Chen H, Liu X, Fan Z, et al. Dual-Learning based neural networks for short-reach optical communications[C]//2021 Conference on Lasers and Electro-Optics (CLEO). IEEE, 2021: 1—2.
- [17] Ulkar M G, Baykas T, Pusane A E. VLCnet: Deep learning based end-to-end visible light communication system[J]. Journal of Lightwave Technology, 2020, 38(21): 5937—5948.
- [18] Stepniak G, Siuzdak J. Influence of lighting LED design parameters on the dynamic nonlinear response[J]. Journal of Lightwave Technology, 2021, 40(4): 954—960.
- [19] Lin B, Lai Q, Ghassemlooy Z, et al. A machine learning based signal demodulator in NOMA-VLC[J]. Journal of Lightwave Technology, 2021, 39(10): 3081—3087.
- [20] Lu X, Lu C, Yu W, et al. Memory-controlled deep LSTM neural network post-equalizer used in high-speed PAM VLC system[J]. Optics Express, 2019, 27(5): 7822—7833.