

激光与光电子学进展

基于 CNN 的 QAM-PPM 混合调制端到端通信系统

张桐浩, 王旭东*, 吴楠

大连海事大学信息科学技术学院, 辽宁 大连 116026

摘要 针对应用于可见光通信的正交振幅调制(QAM)和脉冲位置调制(PPM)的混合调制系统结构及性能优化问题,提出了一种基于卷积神经网络(CNN)的混合调制端到端通信系统设计方案。该方案利用设计的损失函数分多个阶段训练神经网络来分别实现QAM调制以及PPM调制,并将二者结合实现混合调制。解调方面,为了提升脉冲识别准确度并降低运算复杂度,提出了一种通过改变CNN卷积核大小对接收信号进行脉冲识别的方法。仿真结果表明,在加性高斯白噪声和瑞利衰落信道下,对于采用不同脉冲时隙数及调制阶数的混合调制方式,所提技术方案表现出良好的泛化能力,并且当误符号率为 10^{-3} 时,相较传统解调方式,其误码性能改善范围为0.4 dB~2.8 dB。

关键词 光通信; 混合调制; 卷积神经网络; 自编码器; 误码性能

中图分类号 TN929.1 文献标志码 A

DOI: 10.3788/LOP202259.1706001

CNN-Based Hybrid QAM-PPM Modulation End-to-End Communication System

Zhang Tonghao, Wang Xudong*, Wu Nan

Information Science and Technology College, Dalian Maritime University, Dalian 116026, Liaoning, China

Abstract This paper introduces a hybrid modulation end-to-end communication system based on convolutional neural network (CNN) to optimize the structure and performance of the hybrid quadrature amplitude modulation (QAM) and pulse-position modulation (PPM) modulation system applied to visible light communication. This scheme used the designed loss function to train the network in multiple stages to realize QAM and PPM. Accordingly, the two modulations were combined to realize hybrid modulation. With regard to demodulation, a method for recognizing the pulse of the received signal by changing the kernel size of CNN is proposed to improve the pulse-recognition accuracy and reduce the calculation complexity. The simulation results show that under the additive white Gaussian noise and Rayleigh fading channels, the proposed technical scheme exhibits fine generalization ability for the hybrid modulation method with different pulse time slots and modulation levels. When the symbol error rate is 10^{-3} , the error performance improvement range is 0.4 dB–2.8 dB compared with the traditional demodulation method.

Key words optical communications; hybrid modulation; convolutional neural network; autoencoder; error performance

1 引言

全球移动终端的爆炸增长,无线通信需求的不断增加,可用射频频谱资源的减少,给5G以及今后的无线通信实现更高速率的传输带来了空前的挑战^[1]。为了应对这一挑战,许多研究人员将注意力转移到一种利用光束作为通信介质的可见光通信(VLC)技术领域^[2]。由于发光二极管(LED)的快速发展,使得VLC的发展极具潜力。利用LED作为发射机,光电检测器(PD)作为接收机,通过强度调制和直接检测(IM-DD)

技术^[3]可在VLC频谱提供的数百太赫兹带宽上实现高速率传输,并且光电检测器是相对便宜的通信接收器,所以VLC在某些应用方面被认为是射频通信的补充或替代,目前已成为备受关注的一类无线网络通信技术^[4]。然而商用的LED调制带宽有限,在一定程度上限制了VLC系统的传输速率,因此寻求高效可靠的VLC系统传输技术成为该领域的研究热点之一。

最早广泛应用于VLC的传统调制技术是开关控(OOK),但由于其在抗干扰能力和功率效率方面表现较差,逐渐被性能更优的脉冲位置调制(PPM)所取

收稿日期: 2021-11-16; 修回日期: 2021-12-27; 录用日期: 2022-01-12

基金项目: 国家自然科学基金(61371091)

通信作者: *wxd@dlnu.edu.cn

代。近年来,为了同时满足高功率效率和高频谱效率这一需求,相关学者提出了混合调制的概念^[5-9]。文献[5]和[6]研究了 M 进制脉冲位置调制(M -PPM)与 M 进制频移键控(M -FSK)以及偏振复用正交相移键控(PDM-QPSK)混合调制技术,获得了高灵敏度光传输效果。文献[7]介绍了一种基于正交频分复用(OFDM)和PPM的混合调制方案,与普通OFDM相比,具有较低的误码率下限并降低了峰值平均功率比(PAPR)。文献[8]提出了一种适用于室内可见光通信的高效混合调制方案,在提供灵活的多址接入功能基础上,通过参数选择,可以得到优于传统单一调制方式的误码性能。研究结果表明,混合调制具备设计参数选择的灵活性,并且在误码性能、功率利用率及频谱效率等方面具有良好的折中性。

由于传统的混合调制系统将发射机和接收机按照模块化进行设计,并不能保证系统的整体性能达到最优。受启发于深度学习在计算机视觉和自然语言处理领域取得的巨大成就,近年来,一些学者将深度学习引入到通信系统物理层的设计中,并在调制实现^[10]、调制信号识别^[11-12]和信道估计^[13]等技术上取得了一定的成果。通常,应用深度学习技术来优化整个系统的性能可以采用基于自编码器(AE)的端到端通信系统^[14]。文献[15]提出了一种基于卷积神经网络(CNN)的自编码器端到端通信系统(CNN-AE),该系统既继承了文献[14]系统可共同优化所有模块的特点,又提升了网络的泛化能力。文献[16]采用自编码器结构,提出了一种软二值化技术实现了基于OOK调制的恒定权重码(CWC),有效地解决了梯度消失问题。文献[17]利用全连接网络及其设计的减少闪烁激活单元(FRAU)解决了VLC领域实际应用中对于闪烁减少(亮度变化比人类感知更快)和维持一定照明水平的限制问题。文献[18]将CNN-AE结构引入到无线多进多出(MIMO)空时分组码(STBC)系统设计中,获得了优于基于全连接网络的STBC系统误码性能。

本文针对传统正交振幅调制(QAM)和PPM混合调制系统结构及性能优化问题,提出了一种CNN的解决方案。系统采用多个一维卷积层(Conv1D)构建编/解码器,软二值化技术的引入结合多阶段训练实现了QAM和PPM的混合调制/解调,通过对网络参数设计优化,提升了网络的泛化能力和收敛性。在加性高斯白噪声(AWGN)信道和瑞利衰落信道这两种传输环境下进行仿真实验分析,将不同混合调制方案与传统解调方式性能进行对比,并讨论了深度神经网络(DNN)和CNN系统实现的复杂度,验证了所提方案的可行性和提升误码性能的有效性,及其所具备的良好泛化性。

2 系统原理

2.1 系统模型

考虑以 M 进制的QAM信号对PPM信号 N 个时隙中的单个脉冲进行调制,即PPM信号起到一个“开关”的作用,把 M 进制的QAM信号加载到PPM的脉冲时隙上进行传输。数据比特流进入发射机处理后,前一部分比特经星座映射得到QAM信号,后一部分比特编码映射为发射脉冲的位置信息,再将QAM信号加载至PPM的脉冲时隙位置上形成QAM-PPM混合信号进行传输。接收端接收到混合信号经脉冲识别完成对QAM-PPM信号中PPM部分的信号检测并提取该时隙位承载的信号进行反映射以完成QAM部分信号的解调,至此实现了混合信号的解调。

由CNN构建的QAM-PPM混合调制系统模型如图1所示。系统由发送端(包含两个编码模块)、信道和接收端等部分组成。信源首先经过串并变换将输入的串行信息 s 分解成两个并行信息 s_1 和 s_2 ,两个并行信息均采用one-hot向量形式完成对应的比特映射。编码器1包含4个Conv1D,编码器2包含3个Conv1D和1个dot_sigma层,两个编码器的Conv1D层可以同时处理各自的符号序列 s_1 和 s_2 ,即编码器1可以同时处理

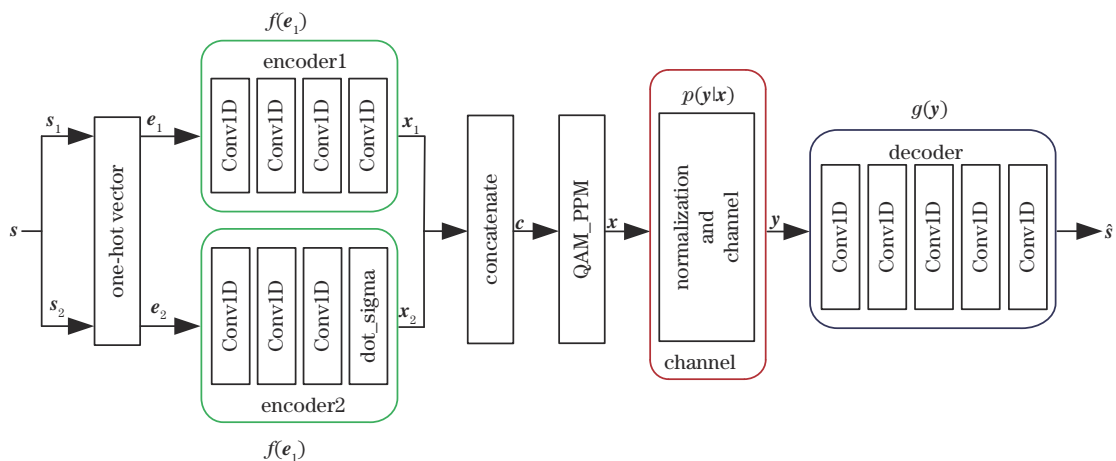


图1 CNN-AE架构下QAM-PPM混合调制系统框图

Fig. 1 Block diagram of QAM-PPM hybrid modulation system under CNN-AE architecture

$k_1 \times L$ 比特信息, 编码器 2 可以同时处理 $k_2 \times L$ 比特信息, 其中 k_1 和 k_2 分别为 QAM 信号和 PPM 信号每符号所携带的比特数, L 为序列的块长度。编码器 2 中 dot_sigma 层的作用是改变输入到 sigmoid 激活函数的自变量。图 2 展示了利用乘法器来实现该操作, 其中 \mathbf{b} 为编码器 2 最后一层 Conv1D 的输出, δ 为 sigmoid 函数的斜率, 通过改变 δ 并结合多阶段训练从而完成 PPM 调制。再利用合并层将发送端两个编码器的最后一层连接起来通过 QAM_PPM 层来实现 QAM-PPM 的混合调制, 此时的混合信号经复数操作后由星座点形式转换为复数形式。信道部分首先对 QAM-PPM 混合信号进行能量约束, 并利用条件转移概率来描述 AWGN 信道以及瑞利衰落信道, 再将其还原回星座点形式。接收端采用 5 个 Conv1D 层来解调 QAM-PPM 混合信号携带的 k 比特信息。




图 2 dot_sigma 层具体结构

Fig. 2 Specific structure of dot_sigma layer

2.2 信号模型

假设信源发送符号序列长度为 L , 其中每符号 s 包含两部分, 即 $s = [s_1, s_2]$, 携带比特信息 $k = k_1 + k_2$ 。前一部分符号 s_1 含有 $k_1 = \log_2 M$ 比特, 将 $L \times \log_2 M$ 个比特数据流映射为一个独热编码 (one-hot) 矩阵 $\mathbf{e}_1 \in \mathbb{R}^{L \times M}$, 经编码器 1 完成 QAM 信号的星座点映射, 输入矩阵 \mathbf{e}_1 映射为矩阵 $\mathbf{x}_1 \in \mathbb{R}^{L \times 2}$, 在神经网络中用两个实数表示一个复信号。后一部分符号 s_2 携带 $k_2 = \lfloor \log_2 N \rfloor$ 比特信息, 将 $L \times k_2$ 个比特流编码为一个独热矩阵 $\mathbf{e}_2 \in \mathbb{R}^{L \times 2^k}$, 经编码器 2 的 Conv1D 层完成对 PPM 脉冲位置信息的映射, 再通过调节控制 sigmoid 函数斜率 δ 并结合 dot_sigma 层来改变 sigmoid 函数的输出特性, 进而收敛到单位阶跃函数以提供二进制输出, 并结合多阶段训练来产生 PPM 信号, 输入矩阵 \mathbf{e}_2 映射为矩阵

$\mathbf{x}_2 \in \mathbb{R}^{L \times N}$, 使 sigmoid 激活函数输出特性改变的实现过程表示为

$$[\mathbf{x}_2]_i = \frac{1}{1 + \exp\{-\delta[\mathbf{b}]_i\}}, i=1, 2, \dots, N. \quad (1)$$

利用 Concatenate 层将编码器 1 的输出 \mathbf{x}_1 和编码器 2 的输出 \mathbf{x}_2 合并成一个矩阵, 上述过程用矩阵 $\mathbf{c} \in \mathbb{R}^{L \times (N+2)}$ 表示。再通过 QAM_PPM 层将 M 进制的 QAM 信号加载到 PPM 的开区间 (脉冲时隙) 上进行传输, 从而产生 QAM-PPM 的混合调制信号, 此时矩阵映射为 $\mathbf{x} \in \mathbb{R}^{L \times N}$ 。混合后的 QAM-PPM 复信号 \mathbf{x} 经过信道时进行能量约束并受到噪声的影响, 当信道环境为加性高斯白噪声时, 在接收端收到的信号 \mathbf{y} 表示为

$$\mathbf{y} = \mathbf{x} + \mathbf{n}. \quad (2)$$

由于 \mathbf{x} 为复信号, 所以加性噪声 \mathbf{n} 也应转换为复数形式, 进一步得到

$$\mathbf{y} = (\mathbf{x}_r + \mathbf{n}_r) + j(\mathbf{x}_i + \mathbf{n}_i), \quad (3)$$

式中: \mathbf{n}_r 和 \mathbf{n}_i 都是均值为 0、方差为 $1/2\sigma_n^2$ 独立于信号的加性高斯白噪声。接收端根据接收到的受噪声污染的信号 \mathbf{y} 估计出符号 $\hat{\mathbf{s}}$, 使其与信源发送符号 \mathbf{s} 尽可能地接近, 表示为 $\hat{\mathbf{s}} \in \mathbb{R}^{L \times 2^k}$ 。在传输环境为瑞利衰落信道情况下, 信号主要受到信道的乘性干扰与高斯白噪声的加性干扰, 接收端接收的信号 \mathbf{y} 表示为

$$\mathbf{y} = \mathbf{h}\mathbf{x} + \mathbf{n}, \quad (4)$$

式中: \mathbf{h} 为信道衰落系数矩阵; \mathbf{n} 为加性高斯白噪声。接收端通过一维卷积层对接收信号进行信道均衡处理, 再根据每层之间的逐步特征提取, 将受到信道失真影响的信号进行恢复。整个过程利用自编码器完成了端到端 QAM-PPM 混合调制系统数据恢复的任务。

3) 损失函数

根据文献 [16] 提出的设计思想, 本文针对 PPM 信号具有单个脉冲数量限制的特征, 可以将损失函数设计为

$$J(\Theta) = \frac{1}{X} \sum_{j=1}^X L(\mathbf{s}^{(j)}, \hat{\mathbf{s}}^{(j)}) + \frac{\lambda}{X} \sum_{j=1}^X \left\{ \sum_{i=1}^N [\mathbf{x}_{2(j)}]_i - 1 \right\}^2, \quad (5)$$

式中: Θ 是网络的超参数; X 是训练系统样本数。 $L(\mathbf{s}^{(j)}, \hat{\mathbf{s}}^{(j)})$ 对应的展开式为

$$L(\mathbf{s}^{(j)}, \hat{\mathbf{s}}^{(j)}) = \mathbf{s}^{(j)} \log_2 \hat{\mathbf{s}}^{(j)} + (1 - \mathbf{s}^{(j)}) \log_2 (1 - \hat{\mathbf{s}}^{(j)}), j=1, 2, \dots, X, \quad (6)$$

式中: λ 是平衡符号恢复性能和单个脉冲约束的非负参数。 λ 的取值要合适, λ 太大会导致二分类交叉熵 (BCE), 即损失函数前一部分不能充分最小化, 而 λ 太小将无法满满足单个脉冲的限制。经大量仿真实验证明, 当 $\lambda = 0.03$ 时可以较好地平衡该损失函数, 通过最小化损失函数来优化网络参数, 评估系统模型的准确率。

3 系统实现

1) 网络结构参数设计

对应图 1 的自编码器网络结构, 具体实现参数由表 1 给出, 其中 B 为最小批处理量 (Mini-Batch)。编码器 1 的 Conv1D 层将 \mathbf{s}_1 的 one-hot 向量从 2^{k_1} 维空间映射到 256 维空间, 传统的符号星座点是在二维空间设计

表 1 自编码器网络结构参数
Table 1 Parameters for autoencoder network structure

Layer type	Activation function	Output dimension
Input	None	$(B, L, 2^{k_1} + 2^{k_2})$
s_1	None	$(B, L, 2^{k_1})$
s_2	None	$(B, L, 2^{k_2})$
E ₁ _Conv1D	elu	$(B, L, 256)$
E ₁ _Conv1D	elu	$(B, L, 256)$
E ₁ _Conv1D	elu	$(B, L, 256)$
E ₁ _Conv1D	linear	$(B, L, 2)$
E ₂ _Conv1D	relu	$(B, L, 64)$
E ₂ _Conv1D	relu	$(B, L, 64)$
E ₂ _Conv1D	linear	(B, L, N)
dot_sigma	sigmoid	(B, L, N)
Concatenate	None	$(B, L, 2+N)$
QAM_PPM	None	(B, L, N)
Normalization	None	(B, L, N)
Channel	None	$(B, N \times L, 2)$
Conv1D	elu	$(B, L, 256)$
Conv1D	elu	$(B, L, 256)$
Conv1D	elu	$(B, L, 256)$
Conv1D	elu	$(B, L, 256)$
Conv1D	softmax	$(B, L, 2^k)$

的,星座映射方案并不是最优的,而 Conv1D 层可以在更高维空间寻找最优解,针对信道环境找到最优的 QAM 信号星座点映射方案;编码器 2 的 Conv1D 层将 s_2 的 one-hot 向量从 2^{k_2} 维空间映射到 64 维空间,有利于找到最适合传输 PPM 脉冲的时隙位置,激活函数采用不同于编码器 1 的指数线性单元激活函数 (elu),选择线性整流函数 (relu),最后再通过 dot_sigma 层可改变斜率的 sigmoid 激活函数以保证 PPM 信号脉冲的非负性。QAM 信号混合前需将符号从 256 维压缩成 2 维,表征 PPM 信号的符号要从 64 维降至和 PPM 时隙数相等的维度,即 N 维。QAM_PPM 层进行符号混合操作以实现 QAM-PPM 调制。解码器的任务是基于所学习的信号特征对每个接收信号 y 的 2^k 种情况进行分类。解码器的 Conv1D 层首先将接收信号 y 解压回 256 维空间,以便提取足够的信息进行分类,最后一层采用 softmax 激活函数依概率大小来进行软判决。

2) 输出二值化处理

图 3 绘出了不同斜率 δ 取值下对应的 sigmoid 函数特性。可以看出, δ 值越大, sigmoid 函数与单位阶跃函数就越接近。当 δ 足够大时,可以得到严格的 0、1 二值化输出。但当 δ 很大时,直接对网络进行训练会导致梯度消失现象,因此需要采用多阶段训练方法来训练本系统,每个阶段的 δ 值逐渐增加,并将上一阶段训练保存的权重加载到下一个阶段继续训练。




图 3 不同 δ 值的 sigmoid 函数特性

Fig. 3 Characteristics of sigmoid function with different δ values

3) 训练、验证样本产生及参数取值

训练集和验证集是用 randint 函数随机产生的二进制比特序列再利用 reshape 函数对数据进行处理。以前一部分输入数据 s_1 为例,后一部分输入数据 s_2 同理。首先通过 randint 函数产生维度大小为 $(X, k_1 \times L)$ 的 0 或 1 序列,然后使用 reshape 函数使序列维度变换为 (X, L, k_1) ,其维度含义表示为 X 个二进制消息序列 s_1 ,每个 s_1 的块长度大小为 L 。最后将两部分输入数据用 concatenate 函数拼接起来整体作为标签数据,其维度为 (X, L, k) ,目的是将传统混合调制系统两路并行的解调结构优化成一路串行比特流,进而实现对两部分数据的解码,并且此方案还解决了脉冲丢失、QAM 信号无法解调的问题。训练系统使用 25600 个样本,其中 70% 数据作为训练集,即 17920 个样本,剩余的 30% 数据作为验证集,即 7680 个样本,测试系统使用 128000 个数据,Mini-Batch 的大小设置为 128,即完成一轮 epoch 训练需要 200 次的最小批处理。

本文通过误符号率 (SER) 评估系统误码性能,序列块长度 L 设置为 1,优化器采用 Adam,初始学习率设置为 0.001,当损失值不下降时,学习率自动减少为当前的 0.1。训练过程分为 7 个阶段,每个阶段的 epoch 为 50,各个阶段 δ 的取值分别为 1、8、32、128、256、512、1000,仿真表明,当 $\delta=1000$ 时,编码器 2 可产生二进制输出。表 1 中除接收端第一层 Conv1D 以外,其他每个 Conv1D 层的卷积核大小和步长均被设置为 1,对每个输入的独立信源符号进行单独处理,而且每个 Conv1D 层后都接有 Batch_Normalization 层,因此可以加速网络收敛到最优点。接收端第一个 Conv1D 层的卷积核大小为 N ,步长为 1,目的是让 CNN 从 N 组数据中“自行选择”一组数据视为搭载 QAM 信号的脉冲,并将 QAM 信号提取出来以便后面的 Conv1D 层对其进行解调,无需进行传统平方率检波法中的平方和计算来实现接收信号的脉冲识别。

4 性能分析

本节对前述基于 CNN 的 QAM-PPM 混合调制自编码器系统 (简称 CNN-AE-QAM-PPM) 性能进行仿真分析, 设接收端比特能量信噪比为 E_b/N_0 , 传输环境分别选取 AWGN 信道和瑞利衰落信道, 考察不同 QAM-PPM 混合调制方案的 SER 性能以及网络的收敛性和泛化能力。并与现有的传统 QAM-PPM 混合调制系统性能进行比较, 在图中以 expert 表示传统 QAM-PPM 混合调制系统在软判决方式下的性能, 同时还对比了 CNN 和 DNN 实现方案的运行效率及误码性能。

实验 1 为 AWGN 信道固定进制 PPM 搭载不同阶

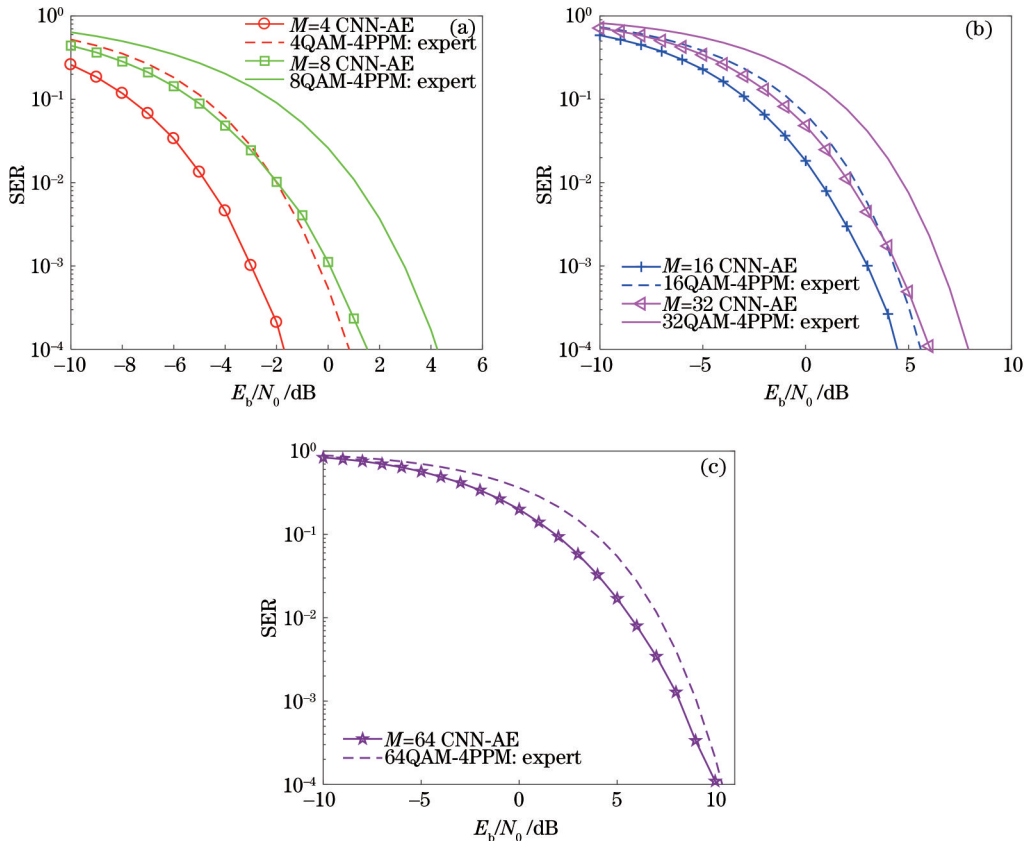


图 4 不同阶数时 SER 性能的比较。(a) $M=4, 8$; (b) $M=16, 32$; (c) $M=64$

Fig. 4 Comparison of SER performance at different orders. (a) $M=4$ and 8; (b) $M=16$ and 32; (c) $M=64$


为了进一步验证 CNN-AE-QAM-PPM 系统良好的泛化能力, 图 4(c) 给出了在更高调制阶数情况下 $M=64$, 即 64QAM-4PPM 在 AWGN 信道下的 SER 性能。从图 4 可以看出, 所提系统的误码性能依旧优于传统 QAM-PPM 混合调制系统, 当 SER 为 10^{-3} 时, 可获得 0.8 dB 的提升, 证明了本系统良好的泛化性。进一步观察可以看出, 受限于 CNN-AE 网络结构复杂度, 其对高阶调制的最佳映射学习能力会受到影响, 故而体现在误码性能改善效果不如低阶调制上。该问题可以通过提高算力, 适当增加网络结构复杂度来

解决。

数 QAM 方案性能比较。设定 PPM 信号时隙数固定不变 ($N=4$), 分别用不同调制阶数的 QAM 信号 ($M=4, 8, 16, 32, 64$) 与之组合, 将不同混合调制方案的 SER 性能进行对比。图 4(a) 和图 4(b) 分别给出了 AWGN 信道下 CNN-AE-QAM-PPM 系统在 $M=4, 8$ 以及 $M=16, 32$ 时的 SER 性能。可以看出, CNN-AE-QAM-PPM 系统性能有显著提高。当 SER 为 10^{-3} 时, 4QAM-4PPM、8QAM-4PPM、16QAM-4PPM 和 32QAM-4PPM 四种调制方案的误码性能分别提高了 2.6 dB、2.8 dB、1.3 dB、2 dB, 这是由于本系统使用 256 个卷积核的 CNN 不局限于在二维空间寻找映射方式, 它可以在 256 维空间来学习最优的星座映射方式。

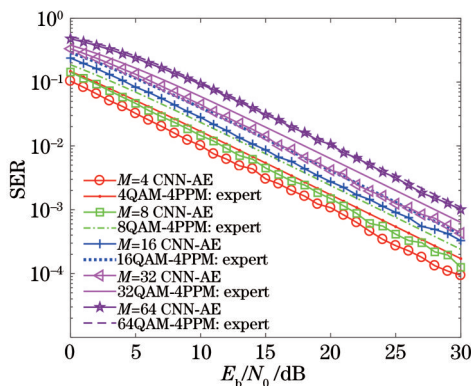
解决。

实验 2 为 AWGN 信道固定阶数 QAM 搭载不同进制 PPM 方案性能比较。设定 QAM 信号调制阶数固定不变 ($M=4$), 将其搭载在不同时隙数的 PPM 信号上 ($N=8, 10$), 同样将所提系统的 SER 与传统混合调制系统进行对比。图 5 给出了 SER 性能对比结果。从图 5 可以看出, 当 SER 为 10^{-3} 时, CNN-AE-QAM-PPM 系统性能分别提升了 1.9 dB 和 2.4 dB。原因在于相较传统混合调制系统进行 PPM 符号映射采用的随机选择方式, 自编码器的卷积神经网络可以学习到

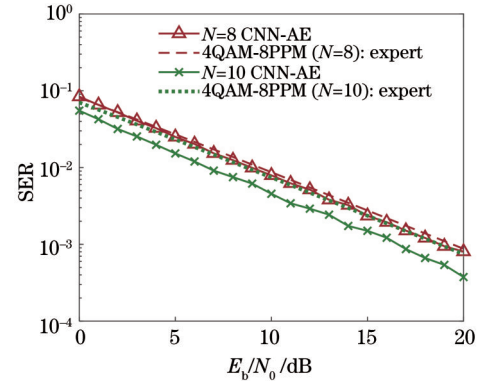
图 5 $N=8, 10$ 时 SER 性能比较Fig. 5 Comparison of SER performance when $N=8$ and 10

最佳的脉冲位置映射方案,提升 PPM 的可靠性。从图 5 还可以观察到,当混合信号含有相同比特时,增大时隙数可以提升混合调制系统的误码性能,对于时隙数由 8 增大到 10,当 SER 为 10^{-3} 时,传统混合调制和 CNN-AE-QAM-PPM 的性能分别提升了 0.9 dB 和 1.4 dB。这是因为时隙数增大使得可选择的脉冲所处位置增加了,但代价是牺牲了一定的有效性。

实验 3 为瑞利衰落信道固定时隙 PPM 搭载不同阶数 QAM 方案性能比较。将 PPM 信号时隙数固定为 4, 分别将 4QAM、8QAM、16QAM、32QAM、64QAM 与其进行组合。观察图 6 可以得出结论,所提系统在此类混合调制方案下可以适应传输环境更为恶劣的瑞利衰落信道。分别在 $M=4, 8, 16, 32, 64$ 情况下,对比传统混合调制系统,当 SER 为 10^{-3} 时,误码性能分别提升了 2.1 dB、2.5 dB、1.2 dB、1.6 dB、0.4 dB。这一结果说明,借助于 CNN 强大的特征提取能力,编码器发射机可以适应不同信道变化,学习到有效的星座映射,同时译码器接收机能够在信道受损后识别区分不同的符号。但由于 CNN-AE 网络结构复杂度方面的限制,当 $M=64$ 时,系统误码性能改善效果依旧不如低阶调制,与 AWGN 信道情况相同。

图 6 $M=4, 8, 16, 32, 64$ 时 SER 性能比较Fig. 6 Comparison of SER performance when $M=4, 8, 16, 32, \text{ and } 64$

实验 4 为瑞利衰落信道固定阶数 QAM 搭载不同时隙 PPM 方案性能比较。图 7 展示了将 4QAM 分别搭载在时隙数为 8 和 10 的 PPM 信号上的 SER。从图 7 可以看出,当 SER 为 10^{-3} 时, CNN-AE-QAM-PPM 相较于传统混合调制系统的误码性能分别提升了 1 dB 和 2.2 dB。这说明,虽然信道环境变得更加复杂,但是 CNN 依旧可以更好地选择脉冲所处的时隙位置,并且可以从受到严重干扰的信号中识别出脉冲。

图 7 $N=8, 10$ 时 SER 性能比较Fig. 7 Comparison of SER performance when $N=8$ and 10

上述实验结果对比说明, CNN-AE-QAM-PPM 方案可以优化混合调制系统整体性能并且具有很强的泛化能力,可以适应各种不同的混合调制方式以及不同的信道环境。

实验 5 为网络特性分析。为了更进一步说明该系统良好的泛化性以及 CNN 架构的快速收敛性,图 8 和图 9 分别绘出了 CNN-AE-QAM-PPM 系统在 AWGN 信道和瑞利衰落信道下训练集和验证集的损失函数,选取 4QAM-8PPM 以及 64QAM-4PPM 两种调制方式为例。在 AWGN 信道下:当 $M=4, N=8$ 时,从图 8(a) 可以看出,收敛发生在第 50 次 epoch 之后,也就是第 1 个训练阶段结束之后;当 $M=64, N=4$ 时,从图 8(b) 可以看出,在第 2 个训练阶段结束之后损失函数收敛。当信道环境为瑞利衰落信道时,从图 9 可以看出,两种混合调制方案的损失函数均在两个训练阶段内收敛。尽管在两种信道下采用了不同类别的混合调制方案,但所提系统依旧可以在较少的训练次数内快速收敛,验证了该系统良好的泛化能力。对比两图中的 (a) 和 (b) 可以发现, 64QAM-4PPM 混合调制方案要比 4QAM-8PPM 混合调制方案收敛得慢,这是因为当数据速率较高时, CNN 的学习过程进一步复杂化,所提系统需要更多的数据来获得全面的知识。此外,训练集损失函数和验证集损失函数匹配得很好,这说明通过适当设计 CNN 模型可以解决过拟合问题。

实验 6 为系统复杂度分析。为了进一步说明所提系统的优势,将本系统与 DNN 实现方案在运行效率以

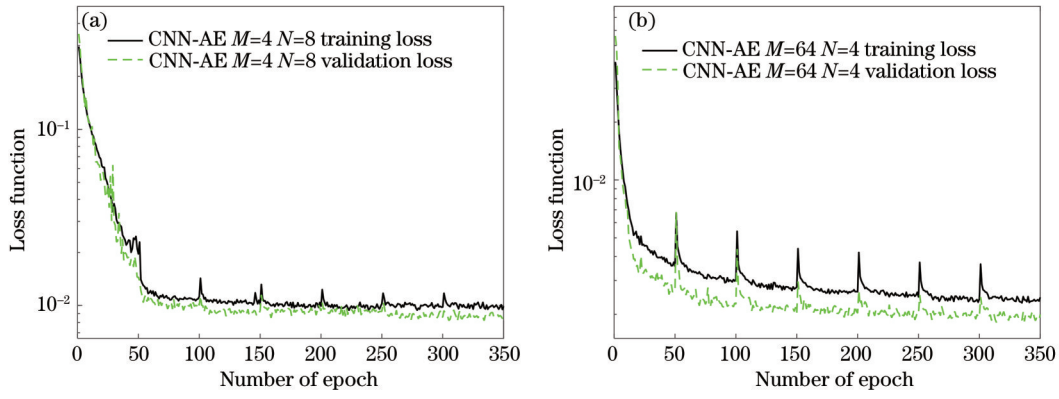


图 8 两种调制方式在 AWGN 信道下训练集和验证集的损失函数。(a) $M=4$ 和 $N=8$; (b) $M=64$ 和 $N=4$
 Fig. 8 Loss functions of training set and validation set for two modulation schemes under AWGN channel. (a) $M=4$ and $N=8$; (b) $M=64$ and $N=4$

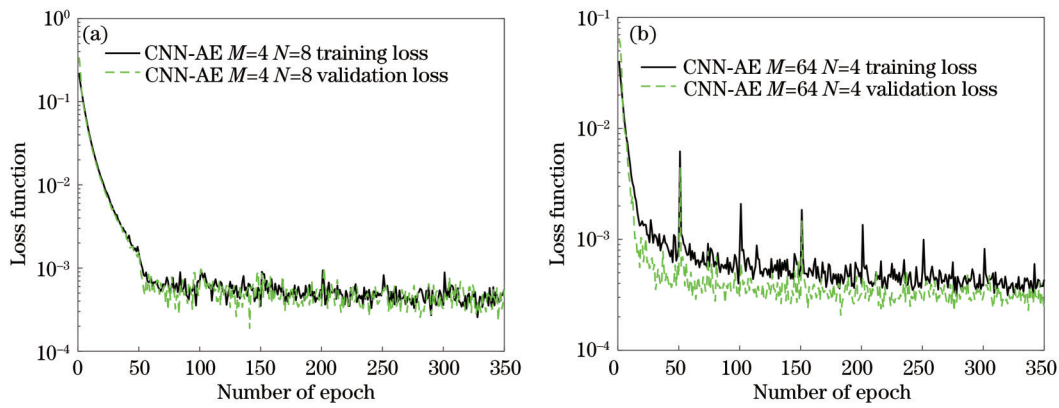


图 9 两种调制方式在瑞利衰落信道下训练集和验证集的损失函数。(a) $M=4$ 和 $N=8$; (b) $M=64$ 和 $N=4$
 Fig. 9 Loss functions of training set and validation set for two modulation schemes under Rayleigh channel. (a) $M=4$ and $N=8$; (b) $M=64$ and $N=4$

及误码性能这两方面进行综合比较。选取 4QAM-4PPM、16QAM-4PPM 和 64QAM-4PPM 在 AWGN 和瑞利信道下进行测试, GPU 型号为 GTX 960M。从表 2 的数据以及图 10 和图 11 的误码性能对比可以看出, 在 DNN 和 CNN 训练参数相同的情况下, DNN 的误码性能与 CNN 相差不大, 但在信道环境恶劣的条件下进行高数据速率传输, DNN 在大信噪比范围内出现了地板效应, 泛化能力不如 CNN。而且采用 CNN 可以节约一半左右的训练时间, 这是由于 CNN

表 2 DNN 和 CNN 系统复杂度比较

Table 2 System complexity comparison between DNN and CNN

System	Learned modulation	Training parameter	Training time /s
DNN-AE-QAM-PPM	4QAM-4PPM	345762	14067
	16QAM-4PPM	361170	14131
	64QAM-4PPM	422802	14580
CNN-AE-QAM-PPM	4QAM-4PPM	345762	7201
	16QAM-4PPM	361170	7333
	64QAM-4PPM	422802	7556




图 10 AWGN 信道 CNN 和 DNN 的 SER 性能比较
 Fig. 10 Comparison of SER performance of AWGN channel CNN and DNN

的权值共享特性使其在反向传播过程中更新的参数量少, 故而提高了系统的运行效率。进一步观察这三种混合调制方案可以发现, 虽然他们对应的训练参数成千上万地增加, 但其带来的训练时间的增加程度相比网络参数的增大程度并不是很明显, 若采用更高算力的 GPU 进行训练, 则系统的训练时间会进一步地减少。




图 11 瑞利衰落信道 CNN 和 DNN 的 SER 性能比较

Fig. 11 Comparison of SER performance of Rayleigh channel CNN and DNN

5 结 论

为了优化传统混合调制系统结构和整体性能,本文提出了一种针对 QAM-PPM 混合调制的 CNN 端到端自编码器通信系统设计方案,网络采用一维卷积层来学习 QAM 信号的星座映射,并结合在多阶段训练过程中改变 sigmoid 函数斜率的方法来学习 PPM 调制,利用自定义层实现了 QAM-PPM 混合调制。损失函数中能量约束和平衡参数的引入,改善了网络收敛性能,提升了网络学习能力和泛化性。仿真结果表明,得益于所提解调方案,本系统在加性高斯白噪声及瑞利衰落信道下均可以获得优于传统 QAM-PPM 混合调制的误码性能,并且相比 DNN 方案,采用 CNN 的训练效率更高,泛化能力更强。

参 考 文 献

- [1] Wang T J, Yang F, Song J, et al. Dimming techniques of visible light communications for human-centric illumination networks: state-of-the-art, challenges, and trends[J]. *IEEE Wireless Communications*, 2020, 27(4): 88-95.
- [2] Ndjiongue A R, Ngatched T M N, Dobre O A, et al. VLC-based networking: feasibility and challenges[J]. *IEEE Network*, 2020, 34(4): 158-165.
- [3] Vappangi S, Mani V V. Performance analysis of DST-based intensity modulated/direct detection (IM/DD) systems for VLC[J]. *IEEE Sensors Journal*, 2019, 19(4): 1320-1337.
- [4] Jovicic A, Li J Y, Richardson T. Visible light communication: opportunities, challenges and the path to market[J]. *IEEE Communications Magazine*, 2013, 51(12): 26-32.
- [5] Liu X, Chandrasekhar S, Wood T H, et al. M-ary pulse-position modulation and frequency-shift keying with additional polarization/phase modulation for high-sensitivity optical transmission[J]. *Optics Express*, 2011, 19(26): B868-B881.
- [6] Liu X, Wood T H, Tkach R W, et al. Demonstration of record sensitivities in optically preamplified receivers by combining PDM-QPSK and M-ary pulse-position modulation[J]. *Journal of Lightwave Technology*, 2012, 30(4): 406-413.
- [7] Khallaf H S, Shalaby H M H, Kawasaki Z. Proposal of a hybrid OFDM-PPM technique for free space optical communications systems[C]//2013 IEEE Photonics Conference, September 8-12, 2013, Bellevue, WA, USA. New York: IEEE Press, 2013: 287-288.
- [8] 王旭东, 刘莹, 吴楠, 等. 用于 VLC 的混合多维无载波幅度相位-多脉冲位置调制方案[J]. *中国激光*, 2020, 47(6): 0606004.
Wang X D, Liu Y, Wu N, et al. Hybrid multi-dimensional CAP-MPPM modulation scheme for VLC systems[J]. *Chinese Journal of Lasers*, 2020, 47(6): 0606004.
- [9] 于梦晗, 郭宏翔, 刘宇畅, 等. 改进的 MPPM-QPSK 光通信系统两模均衡算法[J]. *光学学报*, 2021, 41(19): 1906004.
Yu M H, Guo H X, Liu Y Y, et al. Improved two modulus equalization algorithm for MPPM-QPSK optical communication system[J]. *Acta Optica Sinica*, 2021, 41(19): 1906004.
- [10] 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, June 25-28, 2018, Kalamata, Greece. New York: IEEE Press, 2018: 18054197.
- [11] Huang H J, Guo S, Gui G, et al. Deep learning for physical-layer 5G wireless techniques: opportunities, challenges and solutions[J]. *IEEE Wireless Communications*, 2020, 27(1): 214-222.
- [12] Wang Y, Liu M, Yang J, et al. Data-driven deep learning for automatic modulation recognition in cognitive radios[J]. *IEEE Transactions on Vehicular Technology*, 2019, 68(4): 4074-4077.
- [13] He H T, Wen C K, Jin S, et al. Deep learning-based channel estimation for beamspace mmWave massive MIMO systems[J]. *IEEE Wireless Communications Letters*, 2018, 7(5): 852-855.
- [14] 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.
- [15] Wu N, Wang X D, Lin B, et al. A CNN-based end-to-end learning framework toward intelligent communication systems[J]. *IEEE Access*, 2019, 7: 110197-110204.
- [16] Lee H, Lee I, Quek T Q S, et al. Binary signaling design for visible light communication: a deep learning framework[J]. *Optics Express*, 2018, 26(14): 18131-18142.
- [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] 王旭东, 吴楠, 王旭. 基于卷积神经网络自编码器结构的空时分组传输方案[J]. *电讯技术*, 2020, 60(7): 746-752.
Wang X D, Wu N, Wang X. A transmission scheme of CNN-based autoencoder for STBC systems[J]. *Telecommunication Engineering*, 2020, 60(7): 746-752.