

基于自编码器的多脉冲位置调制实现

林铸, 王旭东*, 吴楠

(大连海事大学 信息科学与技术学院, 辽宁 大连 116000)

摘要: 针对应用于可见光通信的多脉冲位置调制(MPPM)方式的性能优化问题, 提出了一种基于自编码器模型的 MPPM 传输设计方案。该方案分别利用全连接网络(DNN)和卷积神经网络(CNN)搭建自编码器模型, 编码器端通过采用多阶段训练策略和自定义损失函数调控, 实现了 MPPM 信源符号的生成; 解码器端通过全连接层或一维卷积层构建的网络完成信道和 MPPM 信号特征学习等功能。仿真结果表明: 基于自编码器的 MPPM 传输系统的误码性能可以达到且略优于传统最大似然序列检测性能。

关键词: 多脉冲位置调制; 深度学习; 自编码器; 可见光通信

中图分类号: TN929 **文献标志码:** A **文章编号:** 1002-5561(2022)02-0028-07

DOI: 10.13921/j.cnki.issn1002-5561.2022.02.006

开放科学(资源服务)标识码(OSID):



Realization of multi-pulse position modulation based on autoencoder

LIN Zhu, WANG Xudong*, WU Nan

(School of Information Science and Technology, Dalian Maritime University, Dalian Liaoning 116000, China)

Abstract: Aiming at the performance optimization problem of multi-pulse position modulation (MPPM) method applied to visible light communication, an MPPM transmission design scheme based on autoencoder model is proposed. The scheme uses fully connected network(DNN) and convolutional neural network(CNN) to build autoencoder models respectively. The encoder side realizes the generation of MPPM source symbols by adopting multi-stage training strategy and self-defined loss function regulation, the decoding end completes the functions of channel and MPPM signal feature learning through a network constructed by a fully connected layer or a one-dimensional convolution layer. The simulation results show that the bit error performance of MPPM transmission system based on self encoder can reach and slightly better than the performance of traditional maximum likelihood sequence detection.

Key words: multiple pulse position modulation, deep learning, autoencoder, visible light communication

0 引言

多脉冲位置调制(MPPM)作为一种改进的数字脉冲调制方式, 具有良好的功率效率和频谱效率, 在光无线通信领域得到了广泛研究^[1-3]。近年来的一些研究工作, 例如 MPPM 在复杂信道下的判决方式及性能分

析^[4]、针对 MPPM 衍生的调制方式性能研究^[5]以及基于 MPPM 的混合调制技术^[6]等, 都是为了探究一种高效、可靠的调制与接收方案。

深度学习作为新兴的神经网络算法, 其多样的网络结构和强大的问题解决能力, 引发了不同领域学者研究的热潮。在通信领域, 研究人员证实了深度学习应用于通信物理层的可能性^[7-8], 并通过将传统通信系统建模为自编码器(AE)模型, 结合神经网络层的数据处理特点, 提出了针对不同通信问题的自编码器解决方案, 如信道编码^[9]、数据同步^[10]和信道建模^[11]等。此外, 为了提升 AE 在通信领域的性能, 学者们也探讨了网络在端到端系统实现过程中的过拟合问题^[12]及其结构优化和应用问题^[13]。上述研究结果还进一步表明, 卷积神经网络(CNN)因其较强的特征提取能力和泛化性

收稿日期: 2021-11-24。

基金项目: 国家自然科学基金资助项目(批准号: 61371091)资助。

作者简介: 林铸(1998—), 男, 广西钦州人, 硕士研究生, 2020 年获得大连海事大学电子信息工程学士学位, 现就读于大连海事大学信息科学与技术学院信息与通信工程专业, 主要从事光无线通信脉冲调制方法及其基于神经网络实现方式的研究。

* 通信作者: 王旭东(1967—), 男, 博士, 教授, 主要研究方向为光无线通信调制技术、可见光无线通信及定位技术、基于人工智能的无线通信物理层设计。



能,应用在通信系统中可以更好地提升系统的数据处理能力,改善系统的可靠性。

可见光通信(VLC)作为目前光无线通信的热点之一,有学者将深度学习应用于 VLC 技术中^[14-16]。文献[14]在 VLC 系统模型下通过全连接神经网络(DNN)构建了 AE 网络,学习了进行正交振幅调制/解调的方法。针对 VLC 调光功能,文献[15]提出了一种多阶段训练策略使得 AE 编码输出端能够二值化输出,进而实现了光脉冲的强度控制。文献[16]借助了竞争性神经网络的思想,实现了光脉冲的控制。

针对 MPPM 技术优化的问题,本文提出一种基于 AE 的 MPPM 传输方案(下文简称“AE-MPPM”),设计基于 DNN 和 CNN 的 AE-MPPM 系统网络结构。

1 系统网络结构及信号模型

1.1 系统网络结构

MPPM 系统结构如图 1 所示,比特序列经过串/并变换后根据编码映射规则形成 MPPM 编码符号,通过发送滤波器进行脉冲成形。接收端对接收信号进行匹配滤波,然后进行软判决接收解码。不同于固定门限的硬判决方式,软判决根据 MPPM 符号的特点和接收信号幅值间的相关性进行判决,即在接收的有噪信号中,通过检测 n 个时隙中前 p 个最大幅度样值所对应的时隙来判定脉冲所处位置。

本文设计的 AE-MPPM 采用 AE 结构,分别用编码器、信道和解码器替代传统结构中的不同功能模块,构成一个端到端的 AE 模型,包括 DNN、CNN。其中,通过 DNN 实现的系统(DNN-AE-MPPM)结构参数如表 1 所示, k 表示信源中每符号含有的比特数。

DNN-AE-MPPM 系统中的编码器由 2 层 Dense 构成,激活函数分别为 Relu 和 Change_sigmoid,后者

表 1 DNN-AE-MPPM 系统网络结构参数

层(类别)	输出矩阵形状	激活函数
Dense	(batch_size, 2048)	Relu
Dense	(batch_size, n)	Change_sigmoid
Channel_Layer	(batch_size, n)	—
Dense	(batch_size, 2048)	Relu
Dense	(batch_size, 2^k)	Softmax

为自定义函数,是具有 0~1 之间可变斜率的变形 Sigmoid 函数。编码过程如下:首先,数据输入神经网络前进行独热编码(One-hotCode);其次,用 2048 个神经元节点对输入数据源扩张,使数据在更大范围内寻找映射可能;然后,通过 n 个神经元节点的输出,将数据压缩至与目标符号长度一致;最后,通过 Change_sigmoid 映射成 MPPM 发送符号。经过信道层后,译码器采用 2 层 Dense 对接收信号进行处理,激活函数分别为 Relu 和 Softmax,后者可以概率的方式预测 AE 输出信号的类别。

虽然 DNN 的整体学习能力较强,但数据特征的提取能力较弱,在完成不同比特信源的映射学习时需要改变神经元的数量。为了得到一个相对更为固定的自编码器结构,且进一步提升 AE-MPPM 的性能和网络训练效率,本文用卷积层替代全连接层,即搭建基于 CNN-AE-MPPM 系统网络。CNN-AE-MPPM 系统网络结构参数如表 2 所示。其中, L 表示每一帧信息中包含的符号个数。

编码器和译码器分别由 3 层一维卷积层(Conv1D)构成,激活函数也是前 2 层采用 Relu,后一层分别采用 Change_sigmoid 和 Softmax。在发送端,采用 2 层具有 256 个滤波器的一维卷积层进行信源特征提取后,进入下一层被 n 个滤波器进行数据压缩,




图 1 MPPM 系统结构

表 2 CNN-AE-MPPM 系统网络结构参数

层(类别)	卷积核 个数	卷积核 大小	步长	激活函数	输出矩阵 形状
Conv1D	256	1	1	Relu	(L,256)
Conv1D	256	1	1	Relu	(L,256)
Conv1D	n	1	1	Change_sigmoid	(L,n)
Channel_Layer	—	—	—	—	(L,n)
Conv1D	256	1	1	Relu	(L,256)
Conv1D	256	1	1	Relu	(L,256)
Conv1D	2^k	1	1	Softmax	(L, 2^k)

使输出符号长度与目标符号长度一致, 并通过 Change_sigmoid 映射为 MPPM 发送符号。在接收端, 接收信号经 2 层 Conv1D 处理后, 以 Softmax 给出预测各信号类别的概率。

1.2 MPPM 符号的实现



根据 MPPM 的脉冲特性, 其编码比特序列需具有严格的 0、1 二值性, 且能够满足恒定的 0、1 比例。但是, 神经网络的输出值主要依靠激活函数调控, 而激活函数同时也影响着神经网络反向传播的梯度, 如果直接对编码器的输出采用阶跃函数强制二值化, 则该激活函数的导数几乎为 0, 从而导致梯度消失, 且反向传播无法进行参数更新, 致使训练失败。为此, 本文采用一种多阶段训练策略, 即通过改变特定参数对神经网络进行多段训练, 进而可以解决训练阶段梯度消失的问题。

激活函数选用 Sigmoid, 即有

$$f(x) = \frac{1}{1 + e^{-\frac{x}{\delta}}} \quad (1)$$

其中, δ 为硬度值, 表征了 Sigmoid 函数在 0~1 间的陡峭程度。Sigmoid 函数通常取值为 1, 但为了实现二值化, δ 需要不断增大。为了区别于普通 Sigmoid 函数, 本文称之为 Change_sigmoid。Change_sigmoid 函数在 $x \rightarrow 0$ 附近斜率变大, 激活区间变小, 极限情况下则称为阶跃函数。

不同 δ 值时的 Change_sigmoid 激活函数和信源采用 (5,2)-MPPM 信源符号如图 2 所示。可以看出, 当 $\delta=1$ 时, Change_sigmoid 斜率相对较小, 大部分输出值都不为 0 或 1, 故当前硬度值不能保证输出完全二值化; 当 $\delta=4$ 时, 随着斜率增大输出效果有所改善, 但仍有部分值无法完成有效映射 (如第 21 ns 时隙); 当 $\delta=$

(a) 不同 δ 值时的 Change_sigmoid 激活函数(b) 不同 δ 值时, 信源采用 (5,2)-MPPM 信源符号图 2 不同 δ 值时的 Change_Sigmoid 激活函数和信源采用 (5,2)-MPPM 信源符号

1000 时, Change_sigmoid 可以等效为阶跃函数, 输出结果完全映射为 0、1 序列, 达到完全二值化。

多阶段训练策略步骤如下: 首先, 通过多次调整 δ 的取值, 使 AE 在多个阶段内进行训练, 由于 Change_sigmoid 硬度值较低时的激活空间较大, 此时可以保证训练基本完成, AE 得到较为充分的学习优化。然后, 通过逐步增大 Change_sigmoid 的硬度值, 使神经网络的权重进一步得到更新, 并将编码器输出中处于 (0, 1) 之间的点逐渐映射到 0 或者 1 上, 训练完成后即可输出 0、1 序列。训练阶段可以分为 7 段, δ 的取值分别为 1、8、32、128、256、512 和 1000。每进入下一阶段训练之前, 应先对前一阶段的训练结果进行保存, 即保存神经网络的整体权重和偏差; 进入到下一阶段后, 读取训练结果, 再改变 δ , 完成当前阶段的训练。重复这一过程, 直到完成所有 δ 值的训练。

多阶段训练能够保证 0、1 序列的输出, 但 MPPM 每个符号中映射为对应位置脉冲的比特 1 的个数需要靠目标函数进行调控。为此, 构造的损失函数为

$$C_{\text{loss}} = -[y \log(\hat{y}) + (1-y) \log(1-\hat{y})] + \frac{\lambda}{J} \sum_{j=1}^J \left[\sum_{i=1}^n (s_{(j)})_i - p \right]^2 \quad (2)$$

其中, 等式右边第一项为二分类交叉熵的计算公式, y 与 $\hat{y}$ 分别表示真实值与预测值; 第二项为码重控制量。 J 表示训练用的数据量, 在单次训练时, 如果采用 DNN, 则 J 等于 batch_size; 如果采用 CNN, 则 J 等于 batch_size × 每帧信息符号数, 即 batch_size × L 。 p 表示单个符号的脉冲数量, $s_{(j)}$ 表示编码器输出的第 j 个 MPPM 符号序列, $(s_{(j)})_i$ 则表示 $s_{(j)}$ 序列的第 i 个值。

损失函数通过式(2)中第二项对 MPPM 编码进行调控, 它计算了目标码重与当前生成符号码重的平方差, 并受权重因子 λ 影响, λ 越大, 则生成的符号受到码重限制越大, 但当取值较大时容易导致损失函数无法收敛, 影响系统性能。反之, λ 越小, 则生成符号受到码重的限制也会减小, 码重可能不完全满足要求。多次实验结果表明, 当 $\lambda=1$ 时可以保证 AE-MPPM 的误码性能和生成符号的准确性。

1.3 信号模型

本文采用 (n, p) -MPPM 的 VLC 系统, MPPM 信号的表达式为

$$s_{\text{mppm}}(t) = \frac{nP_{\text{avg}}}{p} \sum_{l=0}^{n-1} s_l \text{rect}\left(t - \frac{T_{\text{sy}}}{n} l\right) \quad (3)$$

其中, t 为当前 MPPM 符号的发送时间, P_{avg} 为符号平均能量, $s_l = \{s_0, s_1, \dots, s_{n-1}\}$ 表示由 MPPM 编码器生成的时隙序列具体值, l 为当前 MPPM 符号序列中的具体时隙位置, $\text{rect}(t)$ 表示单位幅度矩形脉冲, T_{sy} 表示符号持续时间。经过信道传输后得到的接收信号为

$$r(t) = s_{\text{mppm}}(t) + n_{\text{sh}}(t) + n_{\text{th}}(t) \quad (4)$$

其中, $n_{\text{th}}(t)$ 为热噪声, 可视为加性高斯白噪声, 服从 $N(0, \sigma^2)$ 。 $n_{\text{sh}}(t)$ 为霰弹噪声, 其概率密度函数可表示为

$$p(n_{\text{sh}}) = \begin{cases} \frac{1}{\Psi \sigma \sqrt{2} \pi} e^{-\frac{x^2}{2\Psi^2 \sigma^2}}, & s_l = 1 \\ 0, & s_l = 0 \end{cases} \quad (5)$$

其中, Ψ 表示霰弹噪声系数; σ^2 与高斯白噪声的方差一致, 可由信噪比计算得到。所以, 仅在 s_l 为 1 的位置 (即存在脉冲的位置) 才会受到霰弹噪声影响。

1.4 信道层设计

对于 AE-MPPM 的信道层, 在训练初期, 编码器的

输出端并不是严格的 0、1 序列, 而是系统训练编码的随机值, 无法直接统计出训练时脉冲的数量, 功率分配和噪声加载执行困难。因此, 本文采用的解决步骤如下:

①输出归一化。对编码器的输出序列 s 用新的变量 o 进行储存, 并对 o 通过式(6)进行归一化处理, 帮助确定当前条件下输出符号的脉冲位置。其中, s' 为序列 o 中某一时隙上的具体值。

$$s' = \frac{s' - \max(o)}{\max(o) - \min(o)} \quad (6)$$

②门限硬判决。对归一化后的 s' 进行四舍五入处理, 相当于设立 0.5 的判决门限。处理后的 o 表征了当前状态下 s 的脉冲位置, 判决得到“1”的位置即为脉冲位置。

③峰值功率系数确定。对判决后的结果进行统计, 根据统计结果得出当前编码器输出的脉冲数 p , 然后得到脉冲功率峰值系数 n/p 。

④脉冲信号生成。将功率峰值系数加载到 s 中由步骤②得到的脉冲位置上, 其它数据不变, 得到发送信号 s_{mppm} 。

⑤噪声加载。根据 s_{mppm} 计算出噪声方差, 并完成噪声的叠加。

在此信道层中, 无需对编码器输出的脉冲数量进行强制限制, 仅需根据神经网络的输出计算结果, 即可配合损失函数动态调整输出的脉冲数, 这样不会过多干扰神经网络输出的有效信息, 使系统拥有更好的泛化性和鲁棒性。在计算脉冲数量时, 也可以统计脉冲的位置, 方便霰弹噪声的添加。

2 性能分析

2.1 参数设定

AE-MPPM 仿真传输实验均采用固定信噪比训练方法, 损失函数优化器选择 Adam, batch_size 取值均为 64。固定训练信噪比通常选取能够使损失函数收敛在 10^{-2} 左右时的值, 这样可以保证 AE-MPPM 具有较好的泛化性。对于 epochs 和学习率, 每个阶段训练的 epochs 设定需要与所使用的学习率关联。学习率设为 0.001 时, 每阶段 epochs 设为 20; 而学习率设为 0.0001 时, 每阶段 epochs 就需要提升到 30, 以保证该阶段内损失函数能够收敛。前者虽然具有较快训练速度, 但容易导致损失函数呈阶梯状变化; 后者训练时间较长, 但能够保证损失函数相对平稳。

2.2 仿真分析

本文对 AE-MPPM 方案的系统性能进行仿真分析。

林铸, 王旭东, 吴楠: 基于自编码器的多脉冲位置调制实现

仿真场景一: 多阶段训练策略下损失函数收敛性分析。以(5,2)-CNN-AE-MPPM为例。训练时,生成数据量为12800,训练集占70%,测试集占30%。选择每阶段epochs为30,学习率为0.0001,在比特信噪比为0 dB时训练,霰弹噪声系数 $\Psi=0$ 。

训练集和验证集损失函数如图3所示。绿色线条为未使用训练策略的 C_{Loss} ,表示直接采用硬度值 $\delta=1000$ 的Change_Sigmoid函数(看作阶跃函数)进行训练,得到的训练集 C_{Loss} 表明:该条件下的编码器输出二值化方法会导致梯度消失, C_{Loss} 收敛在较大值,无法正常训练;红色线条为多阶段训练策略时AE模型的训练集 C_{Loss} ,采用该策略后AE的 C_{Loss} 可以收敛到较小值;蓝色线条为AE模型验证集 C_{Loss} ,该值主要与训练集 C_{Loss} 对比以衡量模型的过拟合情况,结果显示其收敛值明显低于训练集 C_{Loss} ,说明超参数设定合理,模型训练时不存在过拟合问题。




图3 (5,2)-CNN-AE-MPPM 损失函数

仿真场景二: 以DNN-AE-MPPM为例,分析全连接层神经元规模对误码性能的影响。在信源比特 $k=3$ 的情况下,对信源采用(5,2)-MPPM的编码方案。超参数选取与仿真场景一一致。在测试性能时,测试数据样本量为 3.2×10^5 ,通过DNN-MPPM-AE系统传输后统计误符号率。分别选取 2^k 、1024、2048和4096个节点与传统软判决接收的误符号率进行对比,如图4所示。可以看出,当神经元节点取 2^k 时,节点数过少,网络的拟合能力差,导致AE-MPPM误符号率明显偏高;当选取1024和2048个节点时,其性能在高信噪比部分的差距比较明显,前者的误符号率曲线在高信噪比下与传统的软判决理论曲线几乎重合,而后的性能则有明显提升。但是,继续增大Dense层节点数量并不一定能继续改善网络性能,4096个节点下的DNN-




图4 DNN不同神经元节点数的性能对比

AE-MPPM性能在高信噪比部分反而变差了,因为当DNN网络的神经元节点过多时,会导致因学习能力过强出现过拟合现象,AE泛化能力降低。从仿真结果可知,2048个神经元节点适用于(5,2)-AE-MPPM,但具体针对不同输入比特信源和不同映射方案,且需要根据仿真结果调整神经元数量,才可以使AE模型的性能达到最优。

仿真场景三: CNN-AE-MPPM在不同信源比特下的误码性能估计。在信源比特 k 为2、3、4这三种情况下,本文采用的MPPM映射方式分别为(4,2)、(5,2)和(6,3)。训练时,超参数选取与仿真场景一一致,并加入传统的MPPM软判决接收误符号率曲线进行对比,结果如图5所示。蓝色线条由采用软判决接收的传统MPPM系统得到,红色线条由CNN-AE-MPPM得到,绿色线条由DNN-AE-MPPM得到,线条上的不同标记对应不同信源比特下采用的不同映射方案。整体来看,三者的误符号率曲线变化趋势相似,但从放大子图可以看出,在低信噪比部分,CNN-AE-MPPM在相同信噪比下的误符号率略优于传统系统,这得益




图5 AE-MPPM与传统方法的误符号率

于非线性接收机对信号的有效接收。传统的软判决接收是根据符号间的相关性进行接收符号的判决; 而神经网络, 是通过大量的非线性处理提取接收信号中的重要特征, 并根据该特征最大概率地还原出发送信号, 尤其是 CNN。而且, 这种方法可以认为神经网络在一定程度上隐式地获得了信道信息, 并根据信道信息调整编码和接收策略, 这是其性能优于传统判决方式的原因之一。

同时, 在低信噪比部分, CNN 的性能与 DNN 的几乎一致, 但在高信噪比部分则容易出现差异, 如 (4, 2)-MPPM 的性能曲线所示, DNN 的误符号率曲线会劣于传统软判决接收, 其余 2 种符号 DNN 会趋向于与传统曲线相重合; 而 CNN-AE-MPPM 对 3 种符号的传输都能保持较好的性能提升。这是由于 DNN 的拟合能力过强, 因此在低信噪比下进行系统训练时, 可以保证系统在低信噪比部分的性能较优, 但高信噪比部分只依靠系统的泛化性能, 相较传统方法的性能提升不明显; 而且, 与 DNN-AE-MPPM 相比, CNN 的结构更为稳定, 在仿真情况内不需要改变卷积层的滤波器个数, DNN 则需要根据当前仿真结果考虑是否增加或减少神经元个数以避免欠拟合或过拟合的出现。

仿真场景四: AE-MPPM 在霰弹噪声下的误码性能估计。基于以上仿真, 本文分析霰弹噪声 AE-MPPM 性能的影响。本次仿真与仿真场景二的参数基本一致, 仅改变了霰弹噪声系数, 分别令 $\Psi=\sqrt{5}$ 、 $\sqrt{10}$ 和 $\sqrt{20}$, 并对应采用 5 dB、7 dB 和 8 dB 的信噪比训练。为了解决 DNN-AE-MPPM 的过拟合问题, 在该仿真中, 神经元规模分别采用 1024、2048、2048, CNN-MPPM-AE 结构不需要改变。以 (5, 2)-MPPM 为例, 对比误码性能变化, 仿真结果如图 6 所示。可以看出, 由于信道模型中加入了霰弹噪声的影响, 在低信噪比部分, AE-MPPM 的误符号率均优于传统的软判决接收; 在高信噪比部




图 6 (5, 2)-AE-MPPM 引入霰弹噪声误码性能对比

分, AE-MPPM 也能保持一定的性能提高或与软判决接收误符号率曲线拟合。通过对比 CNN 与 DNN 的差异可知, 在霰弹噪声系数较小时, 二者的误码性能相差不多, 且在高信噪比部分 DNN 依然容易出现泛化性较差的问题。在 $\Psi=\sqrt{20}$ 时, CNN 在低信噪比部分性能要明显优于 DNN, 但高信噪比部分中 DNN 更优, 二者误符号率曲线的交点横坐标约等于训练信噪比, 说明在该条件下 DNN 获得的特征更倾向于高信噪比部分, 而 CNN 则更倾向于低信噪比部分。由图 6 可知, 虽然 CNN 与 DNN 各占优势, 但从实际应用角度出发, 常需要解决信噪比较低时的信号传输问题, 因此 CNN-MPPM-AE 的性能更佳。同时, 从网络模型角度讨论, CNN 搭建的模型适用范围更广, 泛化性能更优。

3 结束语

针对 MPPM 的性能优化问题, 本文提出了一种基于 AE 模型的 MPPM 传输方案。该方案分别采用 CNN 与 DNN 搭建 AE 模型, 通过应用多阶段训练策略与自定义损失函数, 使 AE 完成了信源 MPPM 符号的发送与接收。仿真结果表明: 在多种仿真条件下, MPPM-AE 误码性能可以达到且略优于传统最大似然序列检测性能。对比 2 种 AE-MPPM, 且综合网络的泛化性和 AE 的误码性能可知, CNN-MPPM-AE 要略优于 DNN-MPPM-AE。基于 AE 模型的 MPPM 传输方案为通过深度学习解决 VLC 的高效传输问题提供了一种设计思路。

参考文献:

- [1] SUGIYAMA H, NOSU K. MPPM: A method for improving the band Utilization efficiency in optical PPM [J]. Journal of Lightwave Technology, 1989, 7(3): 465-472.
- [2] JOSE L H R, GONZALEZ N G, ALVAREZ J C G. Experimental validation of Inverse MPPM modulation for dimming control and data transmission in visible light communications [J]. IEEE Latin America Transactions, 2021, 19(2): 280-287.
- [3] SONG J, CAO T, ZHANG H. Performance analysis of a low-complexity nonorthogonal multiple access scheme in visible light communication downlinks using pulse modulations [J]. IEEE Intelligent and Converged Networks, 2021, 2(1): 50-65.
- [4] LI A, WANG W, WANG P, et al. SER performance investigation of a MPPM relay-aided FSO system with three decision thresholds over EW fading channel considering pointing errors [J]. Optics Communications, 2021, 487(4): 126803-126811.
- [5] WANG T, HAO Z, LI H, et al. Error rate performance of differential multi-pulse position modulation [J]. Cluster and Computing, 2019, 229

林铸,王旭东,吴楠:基于自编码器的多脉冲位置调制实现

(22): 14615–14623.

[6] 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):264–276.

[7] 张静,金石,温朝凯,等. 基于人工智能的无线传输技术最新研究进展[J]. 电信科学,2018,34(8):46–55.

[8] OSHEA T, HOYDIS J. An introduction to deep learning for the physical layer [J]. IEEE Transactions on Cognitive Communications & Networking, 2017, 3(4): 563–575.

[9] KIM H, JIANG Y, RANA R, et al. Communication algorithms via deep Learning [C]//6th International Conference on Learning Representations (ICLR), April 30–May 3, 2018, Vancouver, USA. Ithaca: arXiv, 2018: 24–42.

[10] SEBASTIAN D, SEBASTIAN C, JAKOB H, et al. Deep learning based communication over the air [J]. IEEE Journal of Selected Topics in Signal Processing, 2018, 12(1): 132–143.

[11] AOUDIA F A, JAKOB H. End-to-End learning of communications systems without a channel model [C]//52nd Asilomar Conference on Signals, Systems, and Computers, October 28–31, 2018, Pacific Grove, USA.

Piscataway: IEEE, 2019: 28–31.

[12] ZHANG H, ZHANG L, JIANG Y. Overfitting and underfitting analysis for deep learning based end-to-end communication systems [C]//11th International Conference on Wireless Communications and Signal Processing(WCSP), October 23–25, 2019, Xi'an, China. Piscataway: IEEE, 2019: 23–25.

[13] 王旭东,林彬,张凯尧,等. 一种改进的 CNN 端到端自编码器通信系统[J]. 电讯技术,2020,60(2):147–152.

[14] PRITIG P, MONETTE H K, AHMED F H. Visible light communication using deep learning techniques [C]//39th Sarnoff Symposium, September 24–25, 2018, Newark, USA. Piscataway: IEEE, 2018: 1–6.

[15] HOON L, INKYU L, TONY Q S Q, et al. Binary signaling design for visible light communication: a deep learning framework[J]. Optics Express, 2018, 26(14): 18131–18143.

[16] ULKAR M G, BAYKAS T, PUSANE A E. VLCnet: Deep learning based end-to-end visible light communication system [J]. Journal of Light-wave Technology, 2020, 38(21): 5937–5948.