

基于深度学习的空间脉冲位置调制多分类检测器

王惠琴 侯文斌 黄瑞 陈丹

Spatial pulse position modulation multi-classification detector based on deep learning

WANG Hui-qin, HOU Wen-bin, HUANG Rui, CHEN Dan

引用本文:

王惠琴, 侯文斌, 黄瑞, 陈丹. 基于深度学习的空间脉冲位置调制多分类检测器[J]. *中国光学*, 2023, 16(2): 415-424. doi: 10.37188/CO.2022-0106

WANG Hui-qin, HOU Wen-bin, HUANG Rui, CHEN Dan. Spatial pulse position modulation multi-classification detector based on deep learning[J]. *Chinese Optics*, 2023, 16(2): 415-424. doi: 10.37188/CO.2022-0106

在线阅读 View online: <https://doi.org/10.37188/CO.2022-0106>

您可能感兴趣的其他文章

Articles you may be interested in

空间激光通信最新进展与发展趋势

Latest developments and trends of space laser communication

中国光学 (中英文). 2018, 11(6): 901 <https://doi.org/10.3788/CO.20181106.0901>

基于数字相位恢复算法的正交相移键控自由空间相干光通信系统

Coherent free-space optical communication system with quadrature phase-shift keying modulation using a digital phase recovery algorithm

中国光学 (中英文). 2019, 12(5): 1131 <https://doi.org/10.3788/CO.20191205.1131>

空潜自由空间光通信的链路性能评估

Link performance evaluation for air-sea free-space optical communications

中国光学 (中英文). 2019, 12(2): 405 <https://doi.org/10.3788/CO.20191202.0405>

离焦对激光通信接收视场的影响分析

Analysis of the influence of defocus on the field of view of laser communication reception

中国光学 (中英文). 2018, 11(5): 822 <https://doi.org/10.3788/CO.20181105.0822>

基于空间光调制器的层析成像技术

Tomography technology based on spatial light modulator

中国光学 (中英文). 2019, 12(6): 1338 <https://doi.org/10.3788/CO.20191206.1338>

基于结构字典学习的图像复原方法

Image restoration approach based on structure dictionary learning

中国光学 (中英文). 2017, 10(2): 207 <https://doi.org/10.3788/CO.20171002.0207>

文章编号 2097-1842(2023)02-0415-10

基于深度学习的空间脉冲位置调制多分类检测器

王惠琴^{1*}, 侯文斌¹, 黄瑞¹, 陈丹²

(1. 兰州理工大学 计算机与通信学院, 甘肃 兰州 730050;
2. 西安理工大学 自动化与信息工程学院, 陕西 西安 710048)

摘要:为有效避免最大似然(ML)检测复杂的计算过程,根据空间脉冲位置调制(SPPM)信号的特点,将深度神经网络(DNN)与分步检测相结合,提出了一种基于深度学习的SPPM多分类检测器。在该检测器中,利用DNN建立接收信号与PPM符号间的非线性关系,并以此为准完成在线接收PPM符号的检测,从而有效避免了对PPM符号的穷搜索检测过程。结果表明,采用本文检测器后,SPPM系统在大幅降低检测复杂度的前提下,取得了近似最优的误比特性能,同时还克服了K均值聚类(KMC)分步分类检测所出现的错误平台效应。当PPM阶数为64时,本文方法较ML检测和线性均衡DNN检测器的计算复杂度分别降低了约95.45%、33.54%。

关键词:无线光通信;空间脉冲位置调制;深度学习;多分类检测器

中图分类号:TN929.12 文献标志码:A doi:10.37188/CO.2022-0106

Spatial pulse position modulation multi-classification detector based on deep learning

WANG Hui-qin^{1*}, HOU Wen-bin¹, HUANG Rui¹, CHEN Dan²

(1. School of Computer and Communication, Lanzhou University of Technology, Lanzhou 730050, China;
2. School of Automation and Information Engineering, Xi'an University of Technology, Xi'an 710048, China)

* Corresponding author, E-mail: 15117024169@139.com

Abstract: In order to effectively avoid high computational complexity when using Maximum Likelihood (ML) detection, a deep learning-based Spatial Pulse Position Modulation (SPPM) multi-classification detector is proposed by combining a Deep Neural Network (DNN) and step detection. In the detector, the DNN is used to establish a non-linear relationship between the received signal and the PPM symbols. Thereafter, the subsequent received PPM symbols are detected according to this relationship, so as to avoid the exhaustive search process of PPM symbol detection. The simulation results show that with the proposed detector, the SPPM system approximately achieves optimal bit error performance on the premise of greatly reducing detection complexity. Meanwhile, it overcomes the error platform effect caused by K-Means Clustering (KMC)

收稿日期:2022-05-27; 修订日期:2022-06-15

基金项目:国家自然科学基金资助项目(No. 61861026, No. 61875080); 甘肃省自然科学基金资助项目(No. 20JR5RA472); 陕西省科技计划产业研究项目(No. 2020GY-036); 西安科技局项目(No. GXYD14.21)

Supported by National Natural Science Foundation of China (No. 61861026, No. 61875080); Natural Science Foundation of Gansu Province (No. 20JR5RA472); Shaanxi Provincial scientific and technological research projects (No. 2020GY-036); Xi'an Science and Technology Bureau project (No. GXYD14.21)

step classification detection. When the PPM order is 64, the computational complexity of the proposal is about 95.45% and 33.54% lower than that of ML detectors and linear equalization DNN detectors, respectively.

Key words: optical wireless communication; spatial pulse position modulation; deep learning; multi-classification detector

1 引言

光空间调制(Optical Spatial Modulation, OSM)^[1]作为一种新型光多输入多输出(Optical Multiple Input Multiple Output, OMIMO)^[2]技术,在传统星座映射的基础上通过增加空间维(即光源索引)映射进一步提升了系统的传输速率。同时,因每个传输符号周期内仅采用单个光源发送信息,从而有效避免了 OMIMO 中存在信道间干扰和对同步要求高等问题。此外,它还可以利用接收分级来减弱信号的光强起伏,有效抵御大气湍流的影响^[3]。正是基于这些优势,近年来 OSM 技术引起了大量专家学者的关注,并已成为未来大规模 OMIMO 技术发展的方向和趋势^[4]。

目前,关于 OSM 的研究主要集中在调制映射方案的构建^[5-10]以及分析大气中各种因素(如大气湍流、衰减和瞄准误差等)对系统性能的影响上^[11]。其中,有关调制映射方案的构建,学者们除了采用开关键控(On-off Keying, OOK)^[5]、脉冲幅度调制^[6]、脉冲位置调制(Pulse Position Modulation, PPM)^[7]以及正交振幅调制^[8]等构建光空间调制外,还与复用、天线选择、功率分配、星座优化等其他技术相结合构建了各种增强型空间调制,旨在大幅提升系统的性能^[9-10]。由此可见,OSM 技术为提升无线光通信(Wireless Optical Communication, WOC)系统的性能,实现大容量、高可靠性和低功耗的数据传输提供了一种有效的手段。

然而,由于光束裸露于大气中,所以当其在信道中传播时,不可避免地会受到各种大气因素(如大气湍流、大气衰减)的影响^[11]。这将造成接收端信噪比(Signal to Noise Ratio, SNR)下降,进而影响信号的正确判决。因此,如何从接收端的弱信号中正确检测出发送符号是一个难题,尤其是在 OSM 系统中这一问题更为突出。这是因为它不仅需要检测出传统调制符号,而且还需要检测

出光源索引号。目前,在 OSM 中主要采用传统译码方法恢复出发送的原始信息比特。但现有方法均存在一定的局限性,例如,采用最大似然(Maximum Likelihood, ML)检测时,计算开销较大;采用线性检测和压缩感知检测^[12]时,系统误码性能不理想,而且其应用场景还受到限制;采用球型译码算法时,初始半径的选取对其性能的影响较大等等。因此,就 OSM 技术而言,研究可靠性高、复杂度低且应用范围广泛的译码算法是其走上实用化的关键。

近年来,深度学习(Deep Learning, DL)^[13]以其优良的识别与分类能力为信号检测提供了新的解决思路。其中,Baek 等人^[14]针对射频领域中传统 MIMO 系统的信号检测问题,提出了一种深度神经网络(Deep Neural Network, DNN)检测器,该检测器能够取得近似 ML 检测的误比特性能。后来,该团队还分别提出了基于卷积神经网络以及递归神经网络的 MIMO 信号检测器,为深度学习在信号检测中的应用奠定了基础。基于此,文献 [15] 针对广义空间调制,利用多个子 DNN 结构实现了天线索引号和星座符号的并行检测。研究表明,在非标准高斯噪声条件下,该检测器可获得优于 ML 检测的误比特性能。

相比于射频通信,WOC 中关于 DL 译码算法的研究起步较晚。2020 年,Amirabadi M 等人^[16]针对 WOC 系统,提出了一种适合于 OOK 调制的 DNN 检测器。该检测器在未知信道状态信息(Channel State Information, CSI)的情况下,取得了近似最优的误比特性能,但其仅适用于处理二分类问题。随着研究的不断深入,清华大学 Wang 等人^[17]提出了一种适用于广义光空间调制的线性均衡 DNN 检测器。与 ML 检测相比,该检测器以部分误码性能为代价换取了较低的译码复杂度。但由于线性均衡的引入,其并不适用于探测器数目小于光源数目的通信系统。后来,Thien 等人^[18]基于迫零(Zero Forcing, ZF)均衡和

信号的能量特征,提出了一种适用于正交频分复用-索引调制的 DNN 多分类检测器,并就网络参数对系统性能的影响进行了讨论,但该检测器同样受限于探测器数目大于光源数目的系统。

综上所述,目前将深度学习用于光信号检测的研究才刚刚开始,其相关理论还不够成熟,而且现有深度学习检测方法还存在误比特性能不理想、应用场景受限等问题。针对上述问题,本文将 DNN 引入空间脉冲位置调制(Spatial Pulse Position Modulation, SPPM)系统中,并依据 SPPM 的信号特点,提出了一种基于深度学习的 SPPM 多分类检测器,旨在保证系统性能的前提下大幅降低译码复杂度。

2 相关理论

2.1 大气湍流模型

当光束经过半径远小于其自身尺寸的湍流时,会产生散射、衍射和反射等,从而造成接收光强的随机起伏,该效应严重影响 WOC 系统性能^[19]。目前,描述湍流信道中光强起伏分布的模型主要有对数正态模型^[16]、负指数模型^[16]、Gamma-Gamma(G-G)模型^[11]和指数威布尔(Exponential Weibull, EW)模型^[20]。相比于其他模型,G-G 和 EW 模型能更准确地描述湍流对光强的影响。

2.1.1 G-G 湍流模型

G-G 湍流模型能够准确描述由弱到强的湍流下,点接收光强起伏的统计特性。在该模型中,信道衰落系数 $h(h > 0)$ 的概率密度函数为^[16]

$$f_{G-G}(h) = \frac{2(\alpha_G \beta_G)^{\frac{\alpha_G + \beta_G}{2}}}{\Gamma(\alpha_G) \Gamma(\beta_G)} h^{\frac{\alpha_G + \beta_G}{2} - 1} \times K_{\alpha_G - \beta_G} \left(2 \sqrt{\alpha_G \beta_G h} \right), \quad (1)$$

式(1)中, $\Gamma(\cdot)$ 为 Gamma 函数, $K_\mu(\cdot)$ 为第二类 μ 阶修正贝塞尔函数, α_G 表示大尺度散射系数, β_G 表示小尺度散射系数。在平面波中 α_G 、 β_G 分别为^[21]

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

$$\beta_G = \left[\exp \left\{ \frac{0.51 \sigma_p^2}{\left(1 + 0.69 \sigma_p^{12/5} \right)^{5/6}} \right\} - 1 \right]^{-1}, \quad (3)$$

其中, σ_p^2 表示 Rytov 方差。弱湍流条件下平面波的 Rytov 方差为^[21]

$$\sigma_p^2 = 1.23 \left(\frac{2\pi}{\lambda} \right)^{7/6} C_n^2 Z^{11/6}, \quad (4)$$

式(4)中, λ 表示波长, C_n^2 表示大气折射率结构常数, Z 表示通信距离。

2.1.2 EW 湍流模型

大量实验结果表明,增大接收孔径能够有效削减探测器平面上的光强起伏,而且随着湍流强度的增强,接收孔径平均效应更加明显^[22]。当考虑接收孔径平均效应时,不同湍流强度下 EW 湍流模型的拟合效果优于 G-G 湍流模型。其信道衰落系数 $h(h > 0)$ 的概率密度函数为^[20]

$$f_{EW}(h; \beta_E, \eta, \alpha_E) = \frac{\alpha_E \beta_E}{\eta} \left(\frac{h}{\eta} \right)^{\beta_E - 1} \exp \left[- \left(\frac{h}{\eta} \right)^{\beta_E} \right] \times \left\{ 1 - \exp \left[- \left(\frac{h}{\eta} \right)^{\beta_E} \right] \right\}^{\alpha_E - 1}, \quad (5)$$

式(5)中, $\alpha_E = 3.931 \times \left(\frac{D}{\rho} \right)^{-0.519}$, $\beta_E = (\alpha_E S.I.)^{-(6/11)}$,它们为形状参数。其中, ρ 为大气相干半径, D 为光电探测器的接收孔径大小, $S.I.$ 为大气闪烁指数。 $\eta = \left[\alpha_E \Gamma \left(1 + \frac{1}{\beta_E} \right) \xi(\alpha_E, \beta_E) \right]^{-1}$ 为尺度参数,其中, $\xi(\alpha_E, \beta_E) = \sum_{i=0}^{\infty} \frac{(-1)^i (i+1)^{-(\beta_E+1)/\beta_E} \Gamma(\alpha_E)}{i! \Gamma(\alpha_E - i)}$ 。

2.2 SPPM 原理

SPPM 是将空间移位键控与 PPM 相结合的一种光空间调制技术。它利用每符号周期内光脉冲的时隙位置和光源索引号同时传递信息,因而具有较高的能量效率和良好的误码性能。其基本原理为:待传输的信息比特流首先被分成比特块。其中,一部分比特被映射为激活光源的索引号,另一部分被映射为 L-PPM 调制符号。映射后的 PPM 符号由激活光源发送出去。设发射的 SPPM 信号为^[23]

$$\mathbf{x}_{l,s} = \mathbf{x}_s \mathbf{x}_l. \quad (6)$$

式(6)中, $\mathbf{x}_l = \left[0, \dots, 0, \overset{l_{th}}{A_m}, 0, \dots, 0 \right]$ 表示 PPM 符号,是一个 $1 \times L$ 维的向量。其中, A_m 为发送光脉冲的幅度, $1 \leq l \leq L$ 为光脉冲的时隙位置, L 为 PPM

调制阶数。 $\mathbf{x}_s = \left[0, \dots, 0, \overset{s}{1}, 0, \dots, 0 \right]^T$ 表示光源索引号映射向量, 是一个 $N_r \times 1$ 维的向量。其中, $[\cdot]^T$ 表示转置运算, 非零元素的位置即 $1 \leq s \leq N_r$, 表示激活光源的索引号, N_r 为光源数目。

经过大气信道传播后的调制信号 $\mathbf{x}_{t,s}$ 由光电探测器接收, 假设接收到的信号为

$$\mathbf{y} = \delta \mathbf{H} \mathbf{x}_{t,s} + \boldsymbol{\psi}, \quad (7)$$

式(7)中, δ 为光电转换效率; \mathbf{H} 为 $N_r \times N_r$ 维的信道衰落矩阵, N_r 为探测器数目, \mathbf{H} 中的每个元素 h 均服从 G-G 或 EW 分布; $\boldsymbol{\psi}$ 是服从均值为 0、方差为 σ_{ψ}^2 的加性高斯白噪声^[24]。

在 SPPM 系统中, 通常采用 ML 检测来恢复原始发送的信息比特。虽然 ML 检测能获得优良的误码性能, 但是其计算复杂度较大, 尤其是在采

用高阶调制的系统中, 其实现难度更大。因此, 通常将其作为衡量其他检测算法性能好坏的依据。

3 SPPM 多分类检测器

由于 L -PPM 调制在每符号周期内仅在一个时隙上发送光脉冲, 那么 PPM 符号 \mathbf{x}_l 的特征维度为 L 。由 SPPM 的映射规则可知, 在任意符号周期内总有一个 PPM 符号被发送, 而接收信号 \mathbf{y} 实际上是受到大气湍流和高斯噪声影响的 PPM 符号^[23]。因此, \mathbf{y} 的特征维度与 PPM 符号相同, 即均为 L 。依据该特征, 本文将 DNN 与分步检测相结合, 提出了一种基于深度学习的 SPPM 多分类检测器。在该检测器中, 首先利用 DNN 模型检测出 PPM 符号, 之后, 再以穷搜索的方式检测光源索引号, 其系统结构如图 1 所示。

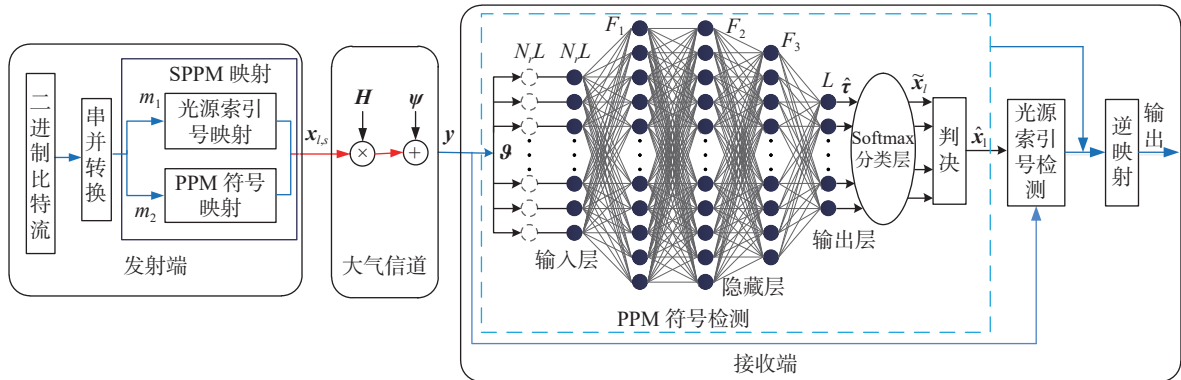


图 1 基于深度学习的 SPPM 多分类检测器

Fig. 1 Deep learning-based SPPM multi-classification detector

在图 1 中, 由于 PPM 符号 \mathbf{x}_l 本身就是一个独热 (one-hot) 向量, 因此在发射端无需 one-hot 编码^[14]。所提检测器由输入层、三个隐藏层、输出层及 Softmax 分类层构成。其中, 每层的神经元数目分别为 $N_r L$ 、 F_1 、 F_2 、 F_3 、 L 、 L 。隐藏层采用的激活函数均为 ReLU 函数, 即 $f_{\text{ReLU}}(x) = \max(0, x)$; 输出层采用的激活函数为 Sigmoid 函数, 即 $f_{\text{Sigmoid}}(x) = \frac{1}{1 + e^{-x}}$ ^[18]。假设隐藏层及输出层的网络参数为 $\boldsymbol{\theta}(\mathbf{w}_1, \mathbf{b}_1, \mathbf{w}_2, \mathbf{b}_2, \mathbf{w}_3, \mathbf{b}_3, \mathbf{w}_4, \mathbf{b}_4)$, 其中, $\mathbf{w}_1 \in \mathbb{R}^{F_1 \times N_r L}$ 、 $\mathbf{w}_2 \in \mathbb{R}^{F_2 \times F_1}$ 、 $\mathbf{w}_3 \in \mathbb{R}^{F_3 \times F_2}$ 和 $\mathbf{w}_4 \in \mathbb{R}^{L \times F_3}$ 分别表示各层之间的权重系数, $\mathbf{b}_1 \in \mathbb{R}^{F_1}$ 、 $\mathbf{b}_2 \in \mathbb{R}^{F_2}$ 、 $\mathbf{b}_3 \in \mathbb{R}^{F_3}$ 和 $\mathbf{b}_4 \in \mathbb{R}^L$ 分别表示各层神经元的偏置。那么, DNN 输出层的输出向量可表示为^[17]

$$\hat{\mathbf{x}} = f_{\text{Sigmoid}}(\mathbf{w}_4 f_{\text{ReLU}}(\mathbf{w}_3 f_{\text{ReLU}}(\mathbf{w}_2 f_{\text{ReLU}}(\mathbf{w}_1 \boldsymbol{\theta} + \mathbf{b}_1) + \mathbf{b}_2) + \mathbf{b}_3) + \mathbf{b}_4), \quad (8)$$

式(8)中, $\boldsymbol{\theta}$ 为检测器的输入向量。

本文检测器的信号检测过程可分为离线训练以及在线检测两个阶段。在离线训练时, 无需 CSI, 只需输入不同信噪比下的接收信号及其对应的 PPM 符号 (\mathbf{y}, \mathbf{x}_l) 即可完成对本文检测器的训练。在线检测时, 利用该检测器分别对相应信噪比下的在线接收 PPM 符号进行检测, 之后, 再通过穷搜索的方法完成对光源索引号的检测。具体过程如下。

在离线训练阶段, 将随机生成的二进制信息比特经 SPPM 调制后发送至接收端, 接收端收集不同信噪比下的接收信号和 PPM 符号作为训练

集。由于 DNN 是一种有监督的学习方法,所以在训练样本送入检测器之前,首先依据 PPM 符号与接收信号间的关系给接收信号贴标签。然后,将接收信号矩阵 \mathbf{y} 按列转换成 $1 \times N, L$ 维向量 $\boldsymbol{\theta}$ 送入检测器。此时, DNN 的输出向量 $\hat{\mathbf{r}}$ 可依据式(8)得到。

为了便于训练误差的计算,需要将 DNN 的 L 个输出值转换成概率值。因此,引入 Softmax 分类层对其进行指数归一化,具体方法为^[25]

$$\hat{g}_j = e^{\hat{r}_j} \left(\sum_{i=1}^L e^{\hat{r}_i} \right)^{-1}, \quad 1 \leq j \leq L, \quad (9)$$

式(9)中, $\hat{g}_j \in [0 \sim 1]$ 且有 $\sum_{j=1}^L \hat{g}_j = 1$ 。那么, Softmax 分类层的输出向量可表示为 $\hat{\mathbf{x}}_l = [\hat{g}_1, \hat{g}_2, \dots, \hat{g}_L]$ 。

为更准确描述网络实际输出 $\hat{\mathbf{x}}_l$ 与期望输出(实际发送符号 \mathbf{x}_l)之间的误差,本文以训练批次的平均损失 $R(\boldsymbol{\theta})$ 来衡量该差值,并采用适合于多分类问题的交叉熵损失函数 $r(\mathbf{x}_l, \hat{\mathbf{x}}_l)$ 来判断训练结果的优劣^[26]。其中

$$R(\boldsymbol{\theta}) = \frac{1}{\text{Batch_size}} \sum_{i=1}^{\text{Batch_size}} [r^{(i)}(\mathbf{x}_l, \hat{\mathbf{x}}_l)], \quad (10)$$

$$r(\mathbf{x}_l, \hat{\mathbf{x}}_l) = - \sum_{j=1}^L g_j \log(\hat{g}_j), \quad (11)$$

式中, $\mathbf{x}_l = [g_1, g_2, \dots, g_L]$ 为 PPM 符号的另一种表示形式; Batch_size 为批处理大小,即每个 Batch 包含的训练样本数目; Batch 为训练批次的数目,且 Batch=训练样本总数/Batch_size; $r^{(i)}(\cdot, \cdot)$ 表示第 i 个批处理的交叉熵损失函数。

在获得训练批次的平均损失 $R(\boldsymbol{\theta})$ 之后,检测器依据交叉熵损失值不断调整网络参数 $\boldsymbol{\theta}$, 直至获得最优的网络参数。在网络参数的调整过程中,选取计算开销较小的随机梯度下降(Stochastic Gradient Descent, SGD)优化器来优化网络,网络参数 $\boldsymbol{\theta}$ 的调整过程为^[26]

$$\boldsymbol{\theta}^{(t+1)} = \boldsymbol{\theta}^t - \nu \nabla_{\boldsymbol{\theta}} \tilde{R}(\boldsymbol{\theta}^t), \quad (12)$$

式(12)中, t 表示迭代次数且有 $\text{Epoch} = \frac{t}{\text{Batch}}$ 。其中, Epoch 为轮次。 $\nu > 0$, 表示学习率, $\nabla_{\boldsymbol{\theta}} \tilde{R}(\cdot)$ 表示损失函数的梯度。在训练过程中,检测器以学习率 ν 为步长、以 $\nabla_{\boldsymbol{\theta}} \tilde{R}(\boldsymbol{\theta}^t)$ 为更新准则不断调整网络

参数 $\boldsymbol{\theta}$, 使得交叉熵损失值达到最小,从而获得最优的网络参数 $\boldsymbol{\theta}$ 。

在线检测阶段,将接收信号送入训练好的 DNN 检测器,并得到 PPM 符号的估计值。在其判决过程中,将 Softmax 分类层输出向量 $\hat{\mathbf{x}}_l$ 中最大值设为 A_m , 其余判为 0, 即可得到 PPM 符号 $\hat{\mathbf{x}}_l$ 。在获得 $\hat{\mathbf{x}}_l$ 的基础上,再通过穷搜索的方法完成光源索引号的检测,即

$$\hat{\delta} = \arg \min_{\mathbf{x}_l \in V} \|\mathbf{y} - \delta \mathbf{H} \mathbf{x}_l\|_F^2, \quad (13)$$

式(13)中, V 为所有可能的光源索引号映射向量集合。

最后,对计算所得的 $\hat{\mathbf{x}}_l$ 和 $\hat{\delta}$ 进行逆映射即可恢复出发送的信息比特。

4 系统性能分析

为验证本文多分类检测器的性能,采用蒙特卡罗方法仿真分析了系统的误比特性能及其译码复杂度,并与近年来其他信号检测方法^[17, 23]进行了对比,其结果如图 2~图 6。仿真条件为:(1)假设接收端 CSI 已知,本文采用的两种湍流模型参数见表 1。若无特殊说明,信道条件为 G-G 信道下的中等湍流。(2)系统的瞬时功率为 1, $\delta = 0.5$ 。(3)由于大气信道的随机性和时变性,导致接收信号的信噪比发生随机起伏。因此,本文在发送端随机生成部分二进制比特数据进行传输,经过特定的信道后,收集不同信噪比下 2×10^5 个接收信号及其对应的 PPM 符号作为训练集,收集 5×10^4 个信号作为测试集。此时,信噪比的范围为 $[0, 5, \dots, 35]$ 。多分类检测器的超参数依据训练精度(损失函数)不断进行调整,并最终确定,本文检测器的超参数设置如表 2 所示。为方便识别,系统参数统一用 (N_t, N_r, L) 来标注。

表 1 湍流模型参数

Tab. 1 Turbulence model parameters

湍流模型	G-G信道 ^[1]			EW信道($D=25$ mm) ^[20]			
参数	α_G	β_G	σ_p^2	α_E	β_E	η	Rytov方差
弱湍流	11.6	10.9	0.2	3.67	1.97	0.73	0.317
中等湍流	4.0	1.9	1.6	5.37	0.81	0.33	2.202
强湍流	4.2	1.4	3.5	5.50	0.74	0.29	15.851

表 2 多分类检测器的超参数

Tab. 2 Hyperparameters of the multi-classification detector

超参数	值
各隐藏层神经元数目	$F_1=64, F_2=98, F_3=48$
Batch	1.25×10^4
Batch_size	2^4
轮次Epoch	50
激活函数	Relu+Sigmoid
损失函数	Cross Entropy Loss
优化器	SGD
学习率	0.001

4.1 误比特性能分析

为了说明本文方法的优势, 分别对 $N_r < N_t$ 和 $N_r > N_t$ 两种情况仿真研究 SPPM 系统的性能, 并与采用线性均衡 DNN 检测器^[17]、K 均值聚类(K-Means Clustering, KMC)分步分类检测^[23]、ML 检测时的性能进行对比分析, 其结果如图 2 和图 3 所示。

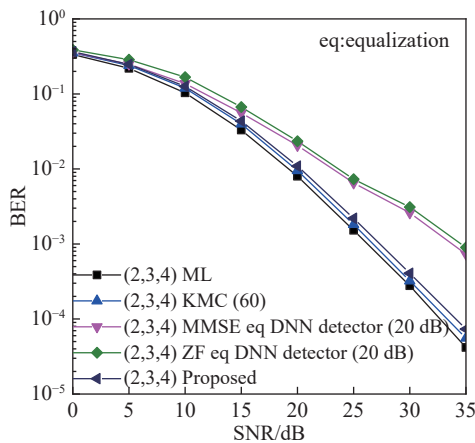


图 2 不同检测方法时 (2,3,4)-SPPM 系统的误比特性能

Fig. 2 Bit error performance of a (2,3,4)-SPPM system with different detection methods

图 2 为不同检测方法时, (2,3,4)-SPPM 系统的误比特性能。此时, 线性均衡 DNN 检测器采用 $SNR = 20$ dB 下的训练数据训练模型, 并将其用于所有信噪比下接收信号的在线检测。由图 2 可知: 本文所提的多分类检测器能够取得近似最优的误比特性能, 较采用线性均衡 DNN 检测器时系统的误比特性能有大幅提升。例如, 当系统的误比特率(Bit Error Rate, BER)达到 10^{-3} 时, 本




图 3 不同检测方法时两种 SPPM 系统的误比特性能

Fig. 3 Bit error performances of two SPPM systems with different detection methods

文方法较线性均衡 DNN 检测器的信噪比改善了约 7.5 dB, 仅比 ML 检测恶化了约 0.5 dB。

图 3 所示为不同检测方法时两种 SPPM 系统的误比特性能, 此时, 采用的系统分别为 (8,4,4)-SPPM 系统和 (8,3,16)-SPPM 系统。由图 3 可知: (1)与线性均衡 DNN 检测器相比, 本文方法可适用于光源数目大于探测器数目的通信系统, 应用范围更广。例如, 在 (8,4,4)-SPPM 系统中, 本方法仍表现出良好的误比特性能, 而此时线性均衡 DNN 检测器出现了较大的误比特损失; (2)当 PPM 调制阶数较大时, 本文方法有效避免了 KMC 分步分类检测所出现的错误平台效应。例如, 在 (8,3,16)-SPPM 系统中, 当 $SNR = 35$ dB 时, 本文方法的误比特率已达到 10^{-3} , 能够满足通信需求, 而此时 KMC 分步分类检测的误比特率仍大于 10^{-1} 。

图 4 所示为湍流对系统误比特性能的影响, 此时采用的系统为 (8,3,4)-SPPM 系统, 湍流分布模型为 G-G 和 EW 两种, 湍流模型参数见表 1。由图 4 可知: (1)在两种湍流模型中, 中强湍流条件下系统的误比特性能均优于弱湍流条件下的。这是因为中强湍流条件下散射更为丰富, 信道衰落系数的差异性更加显著; (2)在 G-G 信道中, 中等和强湍流条件下系统所取得的误比特率较为接近, 而当信道衰落系数服从 EW 分布时, 在中等和强湍流下系统的误比特性能呈现出一定的差异性, 即系统在强湍流下所取得的误比特性能更好。

图 5 为 PPM 阶数(分类数目)对系统误比特性能的影响, 图中标注了系统的传输速率及频谱

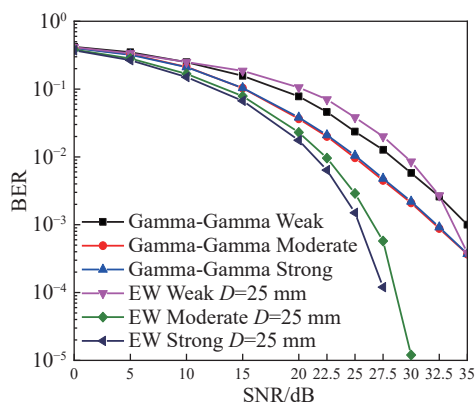


图 4 湍流对系统误比特性能的影响

Fig. 4 Effect of turbulence on the bit error performance of the system

效率。由图 5 可得: (1) 当同一信噪比下系统的误比特率相同时, 相对于采用最小均方误差 (Minimum Mean Square Error, MMSE) 均衡 DNN 检测器的系统, 采用本文方法的系统能够获得更高的传输速率。例如, $SNR = 30$ dB 且 $BER = 5 \times 10^{-3}$ 时, 采用本文方法的 (8,3,8)-SPPM 系统比采用 MMSE 均衡 DNN 检测器的 (2,3,4)-SPPM 系统的传输速率提高了 3 bpcu。(2) 随着 PPM 阶数的增加, 系统的误比特性能出现先改善后恶化的现象。例如, 当 $BER = 10^{-3}$ 时, (4,3,4)-SPPM 系统与 (4,3,2)-SPPM 系统相比所需信噪比改善了约 0.5 dB, 而此时 (8,3,16)-SPPM 系统的信噪比较 (8,3,8)-SPPM

系统恶化了约 3 dB。出现该现象的原因是调制增益和分类精度下降的共同作用, 即 $L < 8$ 时, 调制增益占主导作用; $L > 8$ 时, 分类精度下降占主导作用; (3) 结合图 3 可知, 当 $L < 16$ 时, 在本文算法下系统均能够取得近似最优的误比特性能。




图 5 PPM 阶数对系统误比特性能的影响

Fig. 5 Influence of PPM order on the system's bit error performance

4.2 计算复杂度分析

计算复杂度是衡量信号检测算法性能优劣的又一重要指标。在此, 以浮点运算数量 (Flops) 作为算法复杂度的衡量标准, 对本文方法的复杂度进行计算分析, 并将其与 ML 检测、KMC 分步分类检测^[23] 以及线性均衡 DNN 检测器^[17] 的复杂度进行比较, 其结果如表 3 所示。

表 3 各算法计算复杂度

Tab. 3 Computational complexity of each algorithm

检测算法	计算复杂度/Flops
ML 检测	$N_i L (2N_i N_r L + 2N_r L - 1)$
KMC 分步分类检测 ^[23]	$N_i (2N_i N_r L + 2N_r L - 1) + L (3N_r L - 1)$
线性均衡 DNN 检测器 ^[17]	$2((N_r L)^2 + N_r L F_1 + F_1 F_2 + F_2 F_3 + F_3 \log_2(N_r L)) + \log_2(N_r L)$
DNN 多分类检测器	$2(N_r L F_1 + F_1 F_2 + F_2 F_3 + F_3 L + N_r^2 N_r L + N_r N_r L) + 3L - N_i - 1$

4.2.1 ML 检测

由 ML 检测准则可知, 对某一 SPPM 信号 $\mathbf{x}_{l,s}$ 而言, 计算 $\mathbf{y} - \delta \mathbf{H} \mathbf{x}_{l,s}$ 需要 $2N_i N_r L$ 次浮点运算, 求取 F-范数需要 $2N_r L - 1$ 次浮点运算。SPPM 信号的所有可能结果有 $N_r L$ 种, 因此 ML 检测的复杂度为

$$Com_{ML} = N_i L (2N_i N_r L + 2N_r L - 1) \quad (14)$$

4.2.2 DNN 多分类检测器

由于本文多分类检测器只需进行一次离线训练就可实现长时在线信号检测, 因此只需考虑在线检测时的译码复杂度, 具体计算过程如下。

由 DNN 多分类检测器的结构可知, 隐藏层以及输出层的浮点运算次数分别为 $2N_r L F_1$ 、 $2F_1 F_2$ 、 $2F_2 F_3$ 和 $2F_3 L$ 。依据式 (9), Softmax 分类层需要 $3L - 1$ 次浮点运算。因此, 检测 PPM 符号

的复杂度为 $2(N_r L F_1 + F_1 F_2 + F_2 F_3 + F_3 L) + 3L - 1$ 。

在获得 PPM 符号后,由式(13)可知,对单个光源索引号的检测复杂度与 ML 检测相同,而所有可能的光源索引号映射向量有 N_r 种,因此检测光源索引号的复杂度为 $N_r(2N_r N_r L + 2N_r L - 1)$ 。

综上,本文多分类检测器的计算复杂度为

$$Com_{DNN} = 2(N_r L F_1 + F_1 F_2 + F_2 F_3 + F_3 L + N_r^2 N_r L + N_r N_r L) + 3L - N_r - 1 \quad (15)$$

由表 3 可知,4 种译码算法的计算复杂度均与 N_r 、 N_r 和 L 有关,而本文方法的分类数目只与 L 有关。因此,在图 6 中给出了各检测算法复杂度与 PPM 阶数 L 之间的关系,此时 $N_r = 8$, $N_r = 3$ 。由图 6 可知,在采用高阶 PPM 调制的系统中,本文方法的复杂度更具优势。例如,当 $L = 64$ 时,ML 检测算法的计算复杂度为 1.76896×10^6 ,而本

文方法的复杂度仅为 8.0503×10^4 ,译码复杂度降低了约 95.45%。此外,当 PPM 阶数 $L \leq 32$ 时,本文检测器与线性均衡 DNN 检测器几乎具有相同的计算复杂度;但当 $L \geq 64$ 时,前者的复杂度远低于后者。例如, $L = 64$ 时,线性均衡 DNN 检测器的计算复杂度为 1.21129×10^5 ,本文方法的复杂度降低了约 33.54%。另外,当 $L \geq 128$ 时,其复杂度已明显低于 KMC 分步分类检测。结合图 3 可知,本文方法有效避免了错误平台效应,而且在高阶调制系统中也能够表现出良好的误比特性能。

5 结 论

本文将深度神经网络与 OSM 中的信号检测相结合,提出了一种基于深度学习的 SPPM 多分类检测器。所提出的检测器实现了对 PPM 符号的精确估计,有效避免了传统译码方法对 PPM 符号进行穷搜索检测的过程,同时,通过分步检测有效降低了译码复杂度。结果表明,本文方法在误比特性能、计算复杂度和适用范围等方面均取得较好的结果。例如,所提检测器较 ML 检测的计算复杂度大大降低,且在 PPM 阶数小于 16 时能取得近似最优的误比特性能。同时,它还有效克服了 KMC 分步分类检测和线性均衡 DNN 检测器应用场景受限的不足。当 PPM 阶数为 64 时,本文方法较 ML 检测和线性均衡 DNN 检测器的计算复杂度分别降低了约 95.45%、33.54%。另外,本文所提方法也可用于广义光空间调制等。

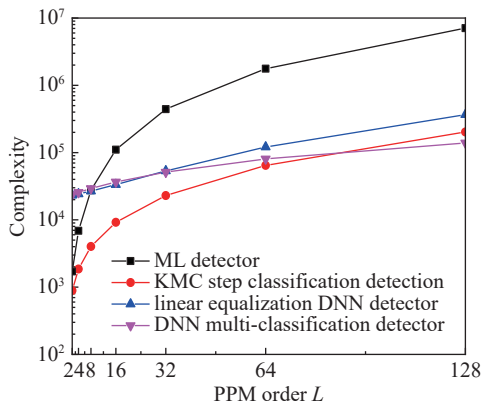


图 6 算法复杂度与 PPM 阶数 L 的关系

Fig. 6 Relationship between algorithm complexity and PPM order L

参考文献:

- [1] LI Y Y, YANG P, DI RENZO M, *et al.*. Precoded optical spatial modulation for indoor visible light communications[J]. *IEEE Transactions on Communications*, 2021, 69(4): 2518-2531.
- [2] REN Y X, WANG ZH, XIE G D, *et al.*. Atmospheric turbulence mitigation in an OAM-based MIMO free-space optical link using spatial diversity combined with MIMO equalization[J]. *Optics Letters*, 2016, 41(11): 2406-2409.
- [3] HAJJARIAN Z, FADLULLAH J, KAVEHRAD M. MIMO free space optical communications in turbid and turbulent atmosphere[J]. *Journal of Communications*, 2009, 4(8): 524-532.
- [4] ZHONG X, CHEN CH, FU SH, *et al.*. OFDM-based generalized spatial modulation for optical wireless communication[C]. *Proceedings of the IEEE 16th Conference on Industrial Electronics and Applications*, IEEE, 2021: 1311-1316.
- [5] ANANDKUMAR D, SANGEETHA R G. A survey on performance enhancement in free space optical communication system through channel models and modulation techniques[J]. *Optical and Quantum Electronics*, 2021, 53(1): 1-39.
- [6] YU S Y, GENG CH, ZHONG J, *et al.*. Performance analysis of optical spatial modulation over a correlated Gamma-Gamma turbulence channel[J]. *Applied Optics*, 2022, 61(8): 2025-2035.

- [7] 张悦,王惠琴,曹明华,等.无线光通信中的增强型光空间调制[J].*光学学报*,2020,40(3):0306001.
ZHANG Y, WANG H Q, CAO M H, *et al.*. Enhanced optical spatial modulation in wireless optical communication[J].
Acta Optica Sinica, 2020, 40(3): 0306001. (in Chinese)
- [8] INOUE K. Analysis of BER degradation owing to multiple crosstalk channels in optical QPSK/QAM signals[J].*IEICE Transactions on Communications*, 2021, E104.B(4): 370-377.
- [9] BHOWAL A, KSHETRIMAYUM R S. Advanced optical spatial modulation techniques for FSO communication[J].*IEEE Transactions on Communications*, 2021, 69(2): 1163-1174.
- [10] 徐宪莹,岳殿武.可见光通信中正交频分复用调制技术[J].*中国光学*,2021,14(3):516-527.
XU X Y, YUE D W. Orthogonal frequency division multiplexing modulation techniques in visible light communication[J].*Chinese Optics*, 2021, 14(3): 516-527. (in Chinese)
- [11] KUMAR D A, SANGEETHA R G. Power series based gamma-gamma fading MIMO/FSO link analysis with atmospheric turbulence and pointing errors[J].*Optical and Quantum Electronics*, 2021, 53(9): 505.
- [12] 王惠琴,宋梨花,曹明华,等.湍流信道下光空间调制信号的压缩感知检测[J].*光学精密工程*,2018,26(11):2669-2674.
WANG H Q, SONG L H, CAO M H, *et al.*. Compressed sensing detection of optical spatial modulation signal in turbulent channel[J].*Optics and Precision Engineering*, 2018, 26(11): 2669-2674. (in Chinese)
- [13] XIE Y H, TEH K C, KOT A C. Deep learning-based joint detection for OFDM-NOMA scheme[J].*IEEE Communications Letters*, 2021, 25(8): 1-27.
- [14] BAEK M S, KWAK S W, JUNG J Y. Implementation methodologies of deep learning-based signal detection for conventional MIMO transmitters[J].*IEEE Transactions on Broadcasting*, 2019, 65(3): 636-642.
- [15] SHAMASUNDAR B, CHOCKALINGAM A. A DNN architecture for the detection of generalized spatial modulation signals[J].*IEEE Communications Letters*, 2020, 24(12): 2770-2774.
- [16] AMIRABADI M A, KAHAEI M H, NEZAMALHOSSEINI S A. Deep learning based detection technique for FSO communication systems[J].*Physical Communication*, 2020, 43: 101229.
- [17] WANG T J, YANG F, SONG J. Deep learning-based detection scheme for visible light communication with generalized spatial modulation[J].*Optics Express*, 2020, 28(20): 28906-28915.
- [18] LUONG T V, KO Y, VIEN N A, *et al.*. Deep learning-based detector for OFDM-IM[J].*IEEE Wireless Communications Letters*, 2019, 8(4): 1159-1162.
- [19] 周畅,于笑楠,姜会林,等.基于APD自适应增益控制的近地无线激光通信信道大气湍流抑制方法研究[J].*中国激光*,2022,49(4):0406002.
ZHOU CH, YU X N, JIANG H L, *et al.*. Atmospheric turbulence suppression methods for near the earth wireless laser communication channels based on avalanche photodiode adaptive gain control[J].*Chinese Journal of Lasers*, 2022, 49(4): 0406002. (in Chinese)
- [20] BARRIOS R, DIOS F. Exponentiated Weibull model for the irradiance probability density function of a laser beam propagating through atmospheric turbulence[J].*Optics & Laser Technology*, 2013, 45(1): 13-20.
- [21] PHAM H T T, DANG N T. Performance improvement of spatial modulation-assisted FSO systems over Gamma-Gamma fading channels with geometric spreading[J].*Photonic Network Communications*, 2017, 34(2): 213-220.
- [22] 劳陈哲,孙建锋,周煜,等.多孔径接收相干合束系统性能研究[J].*中国激光*,2019,46(7):0705003.
LAO CH ZH, SUN J F, ZHOU Y, *et al.*. Performance of coherent beam combining system with multiple aperture receiver[J].*Chinese Journal of Lasers*, 2019, 46(7): 0705003. (in Chinese)
- [23] 王惠琴,侯文斌,彭清斌,等.基于K均值聚类的SPPM分步分类检测算法[J].*通信学报*,2022,43(1):161-171.
WANG H Q, HOU W B, PENG Q B, *et al.*. Step-by-step classification detection algorithm of SPPM based on K-means clustering[J].*Journal on Communications*, 2022, 43(1): 161-171. (in Chinese)
- [24] 霍婷婷,张冬冬,施祥蕾,等.基于碳纳米薄膜/砷化镓范德华异质结的高性能自驱动光电探测器研究[J].*中国光学*,2022,15(2):373-386.
HUO T T, ZHANG D D, SHI X L, *et al.*. High-performance self-powered photodetectors based on the carbon nanomaterial/GaAs vdW heterojunctions[J].*Chinese Optics*, 2022, 15(2): 373-386. (in Chinese)
- [25] 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.

- [26] AMIRABADI M A, KAHAEI M H, NEZAMALHOSENI S A. Low complexity deep learning algorithms for compensating atmospheric turbulence in the free space optical communication system[J]. *IET Optoelectronics*, 2022, 16(3): 93-105.

作者简介:



王惠琴(1971—),女,甘肃渭源人,博士,教授,博士生导师,2006年于西安理工大学获得博士学位,1996年至今在兰州理工大学计算机与通信学院任教,主要从事无线光通信理论与技术方面的研究。E-mail: 15117024169@139.com

《中国光学》征稿启事

《中国光学》为双月刊,A4开本;刊号:ISSN 2095-1531/CN 22-1400/04;国内外公开发行,邮发代号:国内 12-140,国外 BM6782。

- | | |
|-----------------|----------------|
| ★ 荷兰 Scopus 数据库 | ★ 中国精品科技期刊 |
| ★ 美国《乌利希国际期刊指南》 | ★ 中国科技核心期刊 |
| ★ 美国《化学文献》 | ★ 中国光学学会会刊 |
| ★ 波兰《哥白尼索引》 | ★ 中国科技论文与引文数据库 |
| ★ 俄罗斯《文摘杂志》 | ★ 中国期刊全文数据库 |
| ★ 美国工程索引(Ei)数据库 | ★ 万方数字化期刊全文数据库 |
| ★ 美国 ESCI 数据库 | ★ 中国科技期刊数据库 |
| | ★ 中国光学期刊网数据库 |

主要栏目:微纳光学、信息光学、集成光电子、光谱学和光谱仪器、激光技术与应用、光学功能材料、光学设计与工艺、大气与空间光学、光学仪器与测试、综述、前沿动态、产业资讯、科普教学、实验室介绍、自然科学基金项目进展、前沿热点访谈、热点论文等。

发稿类型:学术价值显著、实验数据完整的原创性论文;研究前景广阔,具有实用、推广价值的技术报告;有创新意识,能够反映当前先进水平的阶段性研究简报;对当前学科领域的研究热点和前沿问题的专题报告;以及综合评述国内外光学技术研究现状、发展动态和未来发展趋势的综述性论文。

欢迎投稿、荐稿。

主管单位:中国科学院

主办单位:中国科学院长春光学精密机械与物理研究所

协办单位:激光与物质相互作用国家重点实验室

编辑出版:《中国光学》编辑部

投稿网址: <http://chineseoptics.net.cn>

邮件地址: chineseoptics@ciomp.ac.cn; zgxcn@126.com

联系电话:0431-86176852; 0431-84627061 传 真:0431-84627061

编辑部地址:长春市东南湖大路 3888 号(130033)