

激光与光电子学进展

面向 6G 太赫兹无线通信的关键机器学习技术综述(特邀)

周雯*, 徐思聪

复旦大学通信科学与工程系电磁波信息科学教育部重点实验室, 上海 200433

摘要 太赫兹技术作为 6G 时代的核心通信技术,可以有效解决频段资源日益稀缺的窘境,以满足流量、连接数急剧增长的需求,实现更大的传输带宽。现有机器学习算法如深度神经网络、卷积神经网络和长短期记忆网络等,均可以有效缓解 6G 传输系统中的强非线性效应,是实现 6G 太赫兹无线通信的重要手段。介绍了应用于光子毫米波和太赫兹无线传输系统的不同深度学习范式,讨论了应用光子技术办法产生超高速 THz 波无线信号的国内外主要进展及技术路线对比,并且对较为经典的或是目前最新的应用于太赫兹通信系统中的人工智能技术进行了介绍,同时对未来大速度、高容量的太赫兹通信技术的发展提出了展望。

关键词 太赫兹无线通信; 6G; 人工智能; 机器学习; 神经网络; 光纤通信

中图分类号 TN913

文献标志码 A

DOI: 10.3788/LOP232104

An Overview of Key Machine Learning Technologies in 6G-Oriented Terahertz Wireless Communication Systems (Invited)

Zhou Wen*, Xu Sicong

Key Laboratory for Information Science of Electromagnetic Waves, Ministry of Education, Department of Communication Science and Engineering, Fudan University, Shanghai 200433, China

Abstract As the core communication technology in the 6G era, terahertz technology can effectively address the challenge of increasingly diminishing frequency band resources. It caters to the rapidly growing demand for traffic and connections while enabling large transmission bandwidth. Machine learning algorithms, such as deep neural networks, convolutional neural networks, and short-term memory networks, play a pivotal role in mitigating strong nonlinear effects within 6G transmission systems and are crucial tools for realizing 6G terahertz wireless communication. This review delves into diverse deep learning paradigms implemented in the photonic millimeter wave and terahertz wireless transmission systems. It highlights the notable strides made in leveraging photonic technology for generating ultra-high-speed terahertz wave wireless signals on domestic and international fronts. The paper provides a comparative analysis of different technical approaches. Additionally, the review offers a comprehensive view of traditional and emerging artificial intelligence technologies applied to terahertz communication systems. Finally, it outlines future development directions for terahertz communication technology, focusing on achieving high-speed and high-capacity performance.

Key words terahertz wireless communication; 6G; artificial intelligence; machine learning; neural network; optical fiber communication

1 引言

随着下一个十年的到来,世界对高质量图像、实时联合通信和传感器应用的需求日益增长,无线数据流量正在飞速增长。无线移动通信不仅深刻变革了人们

的生活方式,更成为社会经济数字化和信息化水平加速提升的新引擎。作为关键支撑,从大数据和机器学习(ML)到 5G 甚至 6G 的各种技术都成为了研究热点。如表 1 所示,相较于 4G 和 5G,6G 将带来全新水平的速率、时延、覆盖范围和移动性等特征,6G 也将在智

收稿日期: 2023-09-12; 修回日期: 2023-10-18; 录用日期: 2023-10-23; 网络首发日期: 2023-10-25

基金项目: 国家重点研发计划(2018YFB1801703)、国家自然科学基金(62127802)

通信作者: *zwen@fudan.edu.cn

能化、用户体验、可扩展性和易于部署等维度上引入全新特性。美国电信行业解决方案联盟(ATIS)于

表 1 6G 与 4G、5G 需求的对比

Table 1 Comparison of the requirements among 6G, 4G, and 5G

Parameter	4G	5G	6G
Peak rate	1 Gbit/s	10 Gbit/s	1 Tbit/s
End-to-end delay	100 ms	10 ms	1 ms
THz communication	-	Limited	Widely
Artificial intelligence	-	Partly	Totally
Automatic drive	-	Partly	Totally
Extended reality	-	Partly	Totally
Maximum frequency	6 GHz	90 GHz	3 THz

2020 年 10 月启动了“Next G”联盟倡议,提出 6G 倡议。我国于 2021 年 3 月 12 日正式发布了《中华人民共和国国民经济和社会发展第十四个五年规划和 2035 年远景目标纲要》,明确提出要前瞻布局 6G 网络技术储备。预计到 2030 年以后,无线应用将需要更高的数据速率(高达 1 Tb/s)、极低的端到端延迟(<1 ms)、极高的端到端可靠性(99.99999%)。为解决海陆空天覆盖等地域受限的问题,6G 将向更高频段扩展以获取更大传输带宽如毫米波、太赫兹、可见光等,以满足流量、连接数急剧增长的需求。其中,太赫兹通信(100 GHz~3 THz)是电子学向光学的过渡,它有效解决了频段资源日益稀缺的窘境,已被认为是 6G 时代的核心通信技术。未来 3~5 年将成为 6G 潜在关键技术的窗口期,发展太赫兹通信正当其时,是抢占通信领域技术制高点和培育产业基础的关键。

由表 1 可知,6G 速率要求在 5G 基础上最高提升 10~100 倍。频谱带宽是满足一定网络速率要求的基础,目前,5G 频谱已扩展到毫米波频段,为满足 6G 超高速率要求,各国将目标指向了太赫兹。太赫兹频段(100 GHz~3 THz)由于其巨大的带宽、良好的指向性和短波长,已被认为是 6G 时代探索更大带宽、全新频谱资源最具潜力的技术。近来,诺基亚贝尔在太赫兹频段超高速无线传输研究中取得丰硕成果,通过创新的空中接口、基于人工智能(AI)的无线接收机和多层多输入多输出(MIMO)等一系列技术,在测试环境下,220 GHz 频段太赫兹概念样机实现了超过 200 Gbit/s 的高速无线传输,这将积极推动 6G 时代沉浸式 XR(Extended reality)、全息呈现等元宇宙应用。由此看出,THz 波信号产生、多维复用传输以及先进的人工智能信号接收是实现大容量 THz 波通信的关键技术。一般来说,产生太赫兹波有两种方法,分别是电和光的方式^[1-2]。然而,如果使用电气的方式来产生太赫兹信号,其传输速度受制于电气设备的带宽上限。相反,用于实现宽带太赫兹无线信号生成的光子生成技术已被认为是移动通信的关键解决方案^[3-9]。最近,本团队已经取得了大量高速太赫兹通信和联合感应的成

果^[10-28]。然而,一些技术问题,尤其是涉及到太赫兹带宽的快速大气衰减,会导致基带信噪比(SNR)受限,这阻碍了高速和长距离的太赫兹无线传输。

众所周知,除了大面积的大气损耗外,光子辅助的太赫兹传输系统的另一个主要制约因素是非线性^[29],它来源于以下方面:1)光纤中的大光功率;2)包括调制器和光电二极管(PD)在内的光电元器件;3)无线信道中的高功率放大器(HPA);4)下变频中混频器的非线性损伤。尽管传统的数字信号处理(DSP)算法已被广泛用于无线通信来克服色散(CD)、频率偏移^[30]、相位噪声^[31]等,但其很难处理宽带太赫兹通道中的低信噪比和强非线性效应。另一方面,目前的无线网络在很大程度上依赖于定义 6G 物理层的数学模型。这样的数学模型通常不能准确表示太赫兹系统。因此,相比用于搭建 6G 无线网络的数学模型,ML 将更精确地模拟系统。在 6G 中,更先进的人工智能训练方法被引入,包括人工神经网络(ANN)^[32-33]、深度神经网络(DNN)^[34-35]、卷积神经网络(CNN)^[36-37],以及长短期记忆(LSTM)网络和门循环单元(GRU)等著名的递归神经网络(RNN)模型^[38-39]。

在大容量、长距离的太赫兹系统中,有三个关键特征,即大的自由空间损耗、低信噪比和高频段。为了提高接收机的灵敏度和缓解检测器的带宽压力,可以利用高阶调制信号的相干检测技术提供的强大的噪声鲁棒性和线性检测能力,来保证数字相干系统的非线性信道补偿能力^[40-42]。与直接检测相比^[43-44],同相(I)路和正交(Q)路之间的相位信息可以得到有效的恢复。然而,目前 DNN 和其他 ML 框架的实现使用实数(RV)而不是复数(CV)。在无线通信场景中,现有神经网络方案将多电平正交幅度调制(m -QAM)的实部和虚部分开,并分别输入到两个实值训练网络中,通过舍弃固有的相位信息,应用实数的激活函数和实数的权重值来更新神经网络^[45-47]。由于相干检测的中频(IF)信号是复值的,所以建立复数神经网络很重要,它提供了一个比 RV 模型更受约束的系统^[48]。Trabelsi 等^[49]提到,复数神经网络(CVNN)的主要优势在于它能更好地表示信号处理中的相位信息。

一般来说,深度学习算法被认为是一种数据驱动的方法,这意味着大量的数据被用来训练作为黑盒子的神经网络。所以,计算复杂度会随着决策变量的数量呈指数级增长。它造成了网络可解释性和设计方面的学习困难。相反,传统的建模方法是指用于给定任务的、基于领域知识或物理机制的方法。例如,一些优秀的线性均衡器,如迫零均衡器^[50]、恒模算法(CMA)^[51]和最小均方算法(DD-LMS)均衡器^[52],都能降低计算复杂度,但这些线性均衡器提供的性能远不如深度学习算法。因此,传统的模型方法与深度神经网络的数据驱动学习能力相结合,能建立一个模型驱动的深度学习方法。这种建模方法使得该模型降低了

对训练数据的依赖程度,提高了泛化性能。模型驱动的深度神经网络(DL)已经成功地应用于图像重建^[53]、稀疏信号恢复^[54-56],以及最近的无线通信^[57-58]。

本文探讨了应用于光子毫米波(mm-wave)和太赫兹无线传输系统的不同深度学习范式,其中包括实数和复数的神经网络(NN)算法。考虑到相位恢复和宽带太赫兹相干检测系统的强非线性,复数训练将是未来 6G 移动无线网络的一个有前途的方向。为了进一步提高训练精度、速度并且抑制过拟合,提出了一种联合模型驱动的 NN 均衡算法,该算法与 Blind CMA 盲均衡相结合。由于采用了先进的传统的 DSP 步骤和 ML 算法,其成功地实现了单信道 10 Gbaud PS-64QAM THz 传输 200 m 的无线距离。实验结果表明,考虑到软判决纠错编码(SD-FEC),有效数据率为 44 Gbit/s,开销为 25%,在所提复杂训练方法的帮助下,接收器的灵敏度得到了明显的提高。本文组织结构如下:第二节讨论了应用光子技术办法产生超高速 THz 波无线信号的国内外主要进展及技术路线对比;第三节展示了宽带太赫兹无线通信的非线性效应的理论模型;第四节主要描述了宽带太赫兹无线通信的人工智能技术;第五节介绍了一种新型的基于平衡机器学习的复数神经网络非线性均衡技术;第六节进行了总结,并提出了对发展未来大速度、高容量的太赫兹通信技术的展望。

2 应用光子技术办法产生超高速 THz 波无线信号的国内外主要进展及技术路线对比

综上所述,利用新型的光子技术法产生超高速 THz 波无线信号,能有效克服电子器件的带宽限制,将 THz 无线通信和光纤通信两种技术进行融合,光纤 THz 无线融合接入系统有效地综合了低损耗光纤通信在通信带宽和传输距离方面以及 THz 无线通信在移动性和无缝覆盖方面的优势,可满足 6G 技术实现宏观和微观人类通信的无缝连接要求。6G 网络“智慧”的需求要求具备超低时延、智能分析能力、安全可靠的服务以及高能效的网络部署,目前,国内外研究员致力于从光子 THz 信道建模、THz 空分复用 MIMO 传输、空/时/频多维域智能均衡以及深度网络结构优化等方面来提高 THz 无线网络的传输容量、距离、可靠性及复杂度等性能。首先是使用经典 DSP 算法技术路线,一方面,就空分复用而言,采用偏振复用和天线极化复用等多种空分复用技术,能够急剧地减少达到给定容量所需的 THz 发射功率,并仍保持它们的独立性,可以成倍地增加系统传输容量。另一方面,通过在接收端采用经典的 DSP 均衡算法,可以缓解相位和频率噪声。另一技术路线为近年来逐渐发展起来的非线性均衡技术路线。在过去数十年里,后端均衡的算法还是聚焦在线性均衡技术,对于未来大容量、远距离的光载太赫兹无线通信系统来说,由于较强的非线性效应的

存在,这些算法远不能满足太赫兹高灵敏度接收的要求。因此在 6G 中,引入了更先进的人工智能训练方法^[59-67],包括深度学习、联合学习和可解释人工智能。基于 ANN、DNN、CNN 以及著名的递归神经网络——长短时记忆网络模型等各种技术进行非线性均衡。本文将对这两种技术路线进行深入分析和对比。

2.1 经典 DSP 算法技术路线

2.1.1 国外研究现状

基于无线空间环境下 THz 波段传输的低复杂度、高效的经典数字信号处理算法对于 THz 波无线信号的恢复处理至关重要。主要包括:单信道的外差接收算法标准算法,包括下变频、色散补偿、极化分离、频偏和相偏补偿等一系列算法;多信道光外差相干探测算法,包括信道解复用方法、多信道联合均衡算法研究、波分复用信道串扰抑制等。在非线性失真以及补偿算法方面,主要研究包括:非线性补偿的机理(需要同时补偿各种非线性效应);非线性均衡算法优化,通过步长分布与参数优化,降低计算次数,简化计算时间等;正交相移键控(QPSK)、16QAM 和其他高级调制的非线性补偿方式以及最佳算法等;器件带宽限制对 THz 信号产生的损伤以及克服相应滤波效应的算法;高频谱传输,在外差接收时是否能够做到和零差相干接收相同的频谱效率,采用先进的算法实现高频谱效率的接收。在光载无线系统的均衡算法方面,通常对于该系统产生的频率偏移、相位噪声等线性噪声,采用多模算法(MMA)和两级前馈载波相位恢复(CPR)处理。其中 CPR 被认为对于光子学辅助 THz 接收机的性能至关重要。为进一步优化 CPR 算法,德国帕德博恩大学 Pfau 等^[68]早在 2009 年提出了改进的盲相位搜索(BPS)方法,带有滑动窗平均滤波器,以减少加性噪声的影响以及量化降噪滤波器,测试相位分辨率。由于高阶平方 QAM 信号的非均匀分布导致 CPR 算法不易执行,2010 年英国国家物理实验室 Fatadin 等^[69]在执行 M 次幂之前采用 QPSK 分割方法用于将 QAM 调制符号统一转换为 QPSK 星座分布。2019 年,德国卡尔斯鲁厄理工学院 Harter 等^[70]在对光子太赫兹信号进行下变频接收后,主要利用定时恢复、恒模均衡、频偏补偿和载波相位恢复等算法对信号进行解调恢复。2022 年,瑞典 RISE 研究院 Pang 等^[71]给出了分别针对于单载波脉冲幅度调制(PAM)信号和多载波正交频分复用技术(OFDM)在光载无线 ROF 传输系统中的主要均衡技术,认为对于 PAM 信号线性均衡,可采用单独前馈均衡器(FFE)或与判决反馈均衡器(DFE)相结合。对于 DMT 信号均衡,将信号经过 FFT 转换后再采用频域线性均衡器(FDE)进行均衡。

2.1.2 国内研究现状

在光载无线系统的均衡算法方面,在时域均衡方面,2018 年,复旦大学 Li 等^[72]利用查找表和 CMA 线性均衡等先进数字信号处理技术,解决了 D 波段光载无

线系统中存在的线性和非线性噪声。2020 年浙江大学 Jia 等^[73]在时域内交叉线性均衡(LE)导频,通过在相应子载波上平均导频响应来估计每个子载波的线性信道响应。然后利用最小二乘算法对频域信号进行 ROF 信道补偿。2022 年,复旦大学 Ding 等^[74]对捕获的太赫兹数字信号进行离线 DSP 处理,包括 I/Q 正交化、21 抽头

数 CMA 均衡、频偏估计、基于主成分的混合相位估计和盲相位搜索算法、二阶 Volterra 非线性均衡,以及 61 抽头直接判决-最小均方误差算法(DD-LMS)均衡。

2.1.3 经典 DSP 算法技术路线总结

通过上述分析,表 2 和表 3 分别总结了国内外经典数字信号处理算法技术路线的实验成果。

表 2 国外 THz 经典数字信号处理算法技术路线研究对比

Table 2 Typical research on international classical DSP algorithms technology in THz system

Year	Agency	Frequency /THz	Modulation	Data rate	Distance /m	Main DSP techniques	Ref.
2009	Paderborn University of Germany	-	m-QAM	-	-	BPS	[68]
2022	National Physical Laboratory of British, NPL	-	QPSK	-	-	QPSK partition scheme	[69]
2019	Karlsruher Institut für Technologie of Germany	0.310	QPSK	10 Gbit/s on a single channel/30 Gbit/s on multiple channels	58	Time recovery, CMA, FOE, CPE	[70]
2022	RISE Research Institutes of Sweden	0.3-0.5	PAM4/ PAM8/ DMT	32 Gbit/s	0.5	Matched RRC filtering, clock recovery, symbol-spaced adaptive equalization, and 2-stage feedforward CPR processing	[71]

表 3 国内 THz 经典数字信号处理算法技术路线研究对比

Table 3 Typical research on domestic classical DSP algorithms technology in THz system

Year	Agency	Frequency /THz	Modulation	Data rate	Distance /m	Main DSP techniques	Ref.
2018	Fudan University	0.275	64QAM	1.056 Tbit/s	3.1	Look-up-table (LUT) and CMA	[72]
2018	Shanghai Institute for Advanced Communication and Data Science	0.45	QPSK	13 Gbit/s	3.8	Electrical-to-optical conversion	[11]
2020	Zhejiang University	0.32-0.38	64QAM-OFDM	612.65 Gbit/s	2.8	Linear equalization (LE)	[73]
2022	Fudan University	0.325	16QAM	6.4 Tbit/s	54	CMA, FOE, CPE, DD-LMS, and Volterra equalizer	[74]

从以上的方案可以看出,后端均衡的算法还是聚焦在线性均衡技术,对于未来大容量、远距离的光载太赫兹无线通信需求来说,由于存在较强的非线性效应,这些算法远不能满足太赫兹高灵敏度接收的要求。

2.2 非线性均衡算法技术路线

2.2.1 国外研究现状

为了克服非线性效应,在频域方面,英国雷丁大学 Hong 等^[75]在 2014 年提出了一种适用于 Hammerstein 信道的非线性复值神经网络单载波频域均衡方案,可以通过频域中通常的单抽头线性均衡以及时域中获得的逆 B 样条神经网络模型来实现信道的非线性均衡。在时域方面,早在 2009 年,法国尼斯大学 Fernandes^[76]提出了多输入多输出 Volterra 通信系统中的信道估计和信息恢复技术,将其应用在光载无线 ROF 系统的信道估计和均衡方面。美国佐治亚理工学院 Liu 等^[77-78]

分别在 2017 和 2018 年提出了采用时域人工神经网络 ANN 可以有效解决光载毫米波传输系统的非线性问题,因为它的激活函数具有较强的非线性拟合能力。2018 年,印度阿斯特拉罕工程建筑学院 Ganesh 等^[79]提出了一种基于深度学习的端到端单载波通信系统,其发送机和接收机的时域信息都由全连接神经网络构成,通过端到端的训练优化,实现了优于传统算法的性能。

2.2.2 国内研究现状

2022 年,复旦大学 Wang 等^[80]搭建了 W 波段 4.6 km 光子毫米波系统,针对 MIMO 传输链路造成的偏振极化串扰噪声,采用 MIMO Volterra 算法来解决噪声问题。在频域方面,2021 年电子科技大学柏果等^[81]通信抗干扰技术国家重点实验室设计了基于深度学习的单载波频域均衡算法,应用在无线通信系统中具有鲁

棒的信道泛化能力。2023 年,复旦大学 Wang 等^[82]提出了适用于 MIMO 太赫兹传输系统的 SC-FDE 神经网络非线性均衡算法,实现了单通道超过 300 Gbit/s 的光载太赫兹无线传输。

另外在先进的数字处理算法结合神经网络方面,突破传统机器学习在空间、时间、频率等单一维度的网络学习机制,建立非线性均衡的端到端多子任务空/时/频多域模型构架,通过子任务分解提升整体网络训

练性能;最后在网络结构优化方面,适配现有高阶调制与脉冲整形技术,生成高效训练序列降低信号冗余,采用迭代剪枝和彩票假设剪枝等高效复数神经网络剪枝技术,结合可调权重的损失函数进一步降低网络复杂度,优化网络性能。

2.2.3 均衡算法技术路线总结

通过上述分析,表 4 和表 5 分别总结了国内外非线性均衡算法技术路线的实验成果。

表 4 国外非线性均衡算法技术路线研究对比

Table 4 Typical research on international nonlinear equalization technology in THz system

Year	Agency	Frequency / THz	Modulation	Data rate	Distance / m	Main DSP techniques	Ref.
2014	University of Reading	-	64QAM	-	-	1 B-spline neural network based nonlinear SC-FDE scheme	[75]
2009	Université Nice Sophia Antipolis	-	-	-	-	MIMO Volterra	[76]
2017	Georgia Institute of Technology	0.06	BPSK	5 Gbit/s	10000	Adaptive activated ANN equalizer	[77]
2018	Georgia Institute of Technology	0.06	16QAM	-	0.8	Complex-valued multi-level artificial neural network nonlinear equalizer	[78]
2018	Amrita School of Engineering	-	BPSK	-	-	Deep Learning Network	[79]

表 5 国内非线性均衡算法技术路线研究对比

Table 5 Comparison of domestic nonlinear equalization technology in THz system

Year	Agency	Frequency / THz	Modulation	Data rate	Distance	Main DSP techniques	Ref.
2009	Fudan University	0.325	16QAM	6.4 Tbit/s	20 km and 54 m (wireless)	171-kernel second-order Volterra nonlinear equalization (VNLE)	[74]
2022	Fudan University	0.0885	PDM-PS-64QAM	110 Gbit/s	4.6 km	MIMO-Volterra equalizer	[80]
2021	National Key Laboratory of Science and Technology on Communications of UESTC	-	QPSK	-	-	Deep learning-based SC-FDE	[81]
2023	Fudan University	0.32	16QAM	320 Gbit/s	20 km and 3 m (wireless)	MIMO-SCFDE equalizer	[82]

结合国内外研究现状可以看到:

1)国内外有关 THz 波无线通信系统,引起了世界各国学者的广泛兴趣,成为了一个新的研究热点,并迅速发展。光电子太赫兹通信技术能满足未来 6G 高速数据传输和通信的应用需求,无论对科技发展,还是对民生日常应用都有着巨大的发展潜力和应用前景。

2)国内外有关太赫兹波产生与传输方式呈现多样性,可以利用光纤通信中的光学调制方法达到很高的传输速率,如偏振复用(PDM)和波分复用(WDM)技术,这两种光学调制方法可以使通信系统在传统调制方式如 QAM 调制的基础上,实现系统容量多倍增长。但是传输距离仍因为大气传输损耗大,局限在百米量

级,还有进一步提升的空间。因此探索在超高速率、长距离光载太赫兹无线传输系统中高接收灵敏度的数字信号处理算法是一个重要的研究课题。

3)国内外关于光子 THz 波无线通信融合系统的线性和非线性深度学习算法虽然发展迅速并取得了阶段性成果,但也存在一些不足之处,非线性均衡方式主要在时域或频域进行,空域均衡还存在技术空白,算法结构比较单一,性能提升有限。特别对于 MIMO 空分复用传输技术而言,建立空-时-频多维域的联合非线性均衡也是一个重要的研究课题。

4)国内外关于太赫兹波的调制格式呈现多样性,但不同的调制格式在传输过程中会出现不同的问题,

如概率整形(PS)技术在通过深度学习均衡后会出现类不平衡现象,影响深度学习算法性能。如何将传统的数字信号处理技术和机器学习算法相结合,以及解决通信过程中的特定问题是一个重要的研究课题。

3 宽带太赫兹无线通信的非线性效应的理论模型

如图 1 所示,一般来说,光外差拍频方案具有在发送端灵活选择太赫兹频率的特性,因此可采用光外差拍频方案来产生宽带太赫兹矢量信号。在发射端,由外部腔体激光器(ECL)发射的连续光波(CW)经 I/Q 调制器调制,携带了基带矢量数据。这里,I/Q 调制器的 I 和 Q 路分别由经过电放大器(EA)放大的 m -QAM 信号的 I 路和 Q 路驱动。调制的光束随后经 EDFA 放大并通过标准单模光纤(SSMF)传输,然后通过光耦

合器(OC)与本地振荡器(LO)耦合。值得注意的是,耦合的光束被传输到天线集成光混合器模块(AIPMs),以产生并传输 THz 信号。这里,AIPMs 的工作频率范围为 300~2500 GHz,是 UTC-PD 和一个弓形或对数周期天线的集成。经过无线传输,接收端天线接收到太赫兹信号,然后该信号通过一个集成混频器/放大器/倍增器链(IMAMC)下变频为中频信号。IMAMC 通常集成了一个混频器、一个放大器和一个倍频器,其工作频率范围为 330~500 GHz。最后,中频信号由低噪声放大器(LNA)放大,并由数字存储示波器(DSO)捕获。可以发现,非线性效应来自于发射端的 EA、ECL 和部分光电器件,如调制器和光电二极管,它会影响到矢量 m -QAM 太赫兹信号的生成和无线传输。接下来,建立这些器件在光子辅助 THz 系统中的相关非线性理论模型。

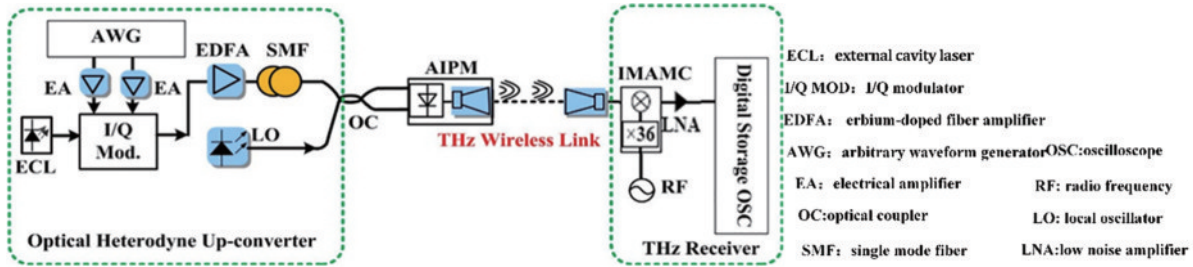


图 1 宽带太赫兹无线传输的实验装置^[83]

Fig. 1 Experimental device for wideband terahertz wireless transmission^[83]

3.1 激光器线宽

激光线宽,也称激光光源发射光谱的半峰全宽,即达到峰值一半高度(有时也取 $1/e$),所对应的两个频率中间的宽度。激光器线宽越小,意味着产生激光的单色性越好,相位或频率噪声也就越小。在半导体激光器的自然线宽理论中,FP 激光器和 DFB 激光器的线型公式相似,具有以下形式:

$$L(\nu) = 2 \int_0^{\infty} \cos(2\pi\nu\tau) \exp(-A_p A |\tau| - B_M \tau^2) d\tau, \quad (1)$$

式中: $\nu = (\omega - \omega_L)/2\pi$, ω_L 是激光器的生成频率; $A_p A = D_0/P$, $B_M = (D_1 + D_2\sqrt{P})^2$, D_0, D_1, D_2 是由折射率 n 或 n_{ef} 表示的函数。自然线宽可表示为

$$\Delta^2 \nu = \Delta^2 \nu^{(c)} T [(mW) A/P + B] F_N(P^{(c)}/P, k), \quad (2)$$

式中: $T [Aq(mW)/P^{(c)} + B]$ 是桥函数; $\Delta \nu^{(c)}$ 是特征线宽; $P^{(c)}$ 是特征激光器功率; k 是激光器的非线性参数; q 是反输出。

$$F_N(q, k) = 1 / \left\{ \int_0^{\infty} \exp[-xq - x^2(k/\sqrt{q})^2] dx \right\}, \quad (3)$$

$$J_{th}(T_e) = J_{th}(T_r) \exp[(T_e - T_r)/T_0], \quad (4)$$

式中: T_r 是房间温度 (300 K); $J_{th}(T_e)$ 是在某个温度 T_e 下测量的阈值电流密度; T_0 是表征激光器稳定性的特征温度 (T_0 越高,激光器的温度稳定性就越好)。

同时,由注入电流引起的温度变化不仅影响阈值




图 2 利用理论曲线模拟出反输出功率的函数的 Fabry-Pérot 半导体激光器的自然线宽的实验曲线^[83]

Fig. 2 Experimental curve of natural linewidth of Fabry-Pérot semiconductor laser using the theoretical curve to simulate the function of inverse output power^[83]

电流,而且还影响激光输出波长。

图 3 显示了带有本征半导体量子阱的高功率激光器的波长漂移与归一化电流 (J/J_{th}) 的关系。峰值波长是随着工作电流和工作温度漂移的。随着工作电流的增加,激光输出光束的波长也逐渐增加,即出现了红移。

在实验过程中,采用光学锁相环技术可以抑制激光器的相位噪声。光学锁相环原理和传统的锁相环系统原理相似,即利用电反馈控制结合电光相位调制的

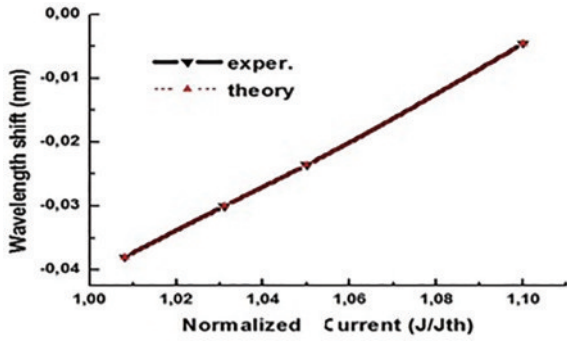


图 3 波长漂移 $\Delta\lambda$ 与归一化电流 (J/J_{th}) 之间的关系^[83]

Fig. 3 Relationship between wavelength drift $\Delta\lambda$ and normalized current (J/J_{th})^[83]

方法实现对光信号频率和相位的锁定。由于使用两束激光外差来产生太赫兹波,所以本征激光的线宽越窄,产生的太赫兹波的相位噪声就越小。

研究表明,半导体激光器的饱和效应是非常小的,对于半导体激光器来说,饱和效应是可以忽略不计的。自然线宽展宽和波长漂移是半导体激光器的主要非线性机制,两者都与激光腔内增益介质的有效折射率有关,而增益介质的折射率是入射强度的函数,包括一阶和二阶。因此,半导体激光器的线宽是场强的函数。在 THz 通信系统中,因为采用两束激光外差拍频技术来产生太赫兹波,所以激光器的相干性比较高。激光的线宽和稳定波长越窄,相干性越好,产生的太赫兹波的相位噪声越小。为了抑制太赫兹传输系统中激光器的相位噪声,在设备上采用了锁相技术来获得稳定的激光^[84],并在接收端算法中采用载波相位恢复算法来补偿系统中的相位噪声,进一步降低激光器相位噪声对传输信号的影响。

3.2 电放大器

本文使用 VPI 软件对 73.5 GHz 的光子-毫米波框架进行仿真。图 4 描述了以 73.5 GHz 为中心的 16QAM、64QAM 和 256QAM 的毫米波 (MMW) 信号的输入/输出功率特性和 EVM 性能^[85]。调制器驱动的电放大器与毫米波结构性能的关系、不同调制格式的 EVM 与 EA 输入功率的关系都有相同的趋势。低 EA 输入的传输特性是恒定的,其增益等于小信号增益 G_0 。随着 EA 输入功率的增加,调制深度增加,信号功率增加,信号质量改善。当 EA 进入非线性范围时,进一步增加输入功率,信号的保真度仍然被优化。然而,它也引入了由非线性放大引起的增益压缩。最佳性能点是通过在增益(由增加 EA 输入功率引起)和信号压缩(由非线性操作引起)之间取得平衡来实现的。继续增加 EA 功率,信号的保真度会向非线性饱和的方向迅速下降。

由于高阶调制具有更多的电平振幅,随着 EA 输入功率的增加,高阶调制信号将遭受更早、更严重的压缩破坏。随着调制阶数的增加,高阶调制的理想工作点趋向于较低的 EA 输入功率。ROF 系统中的电子放

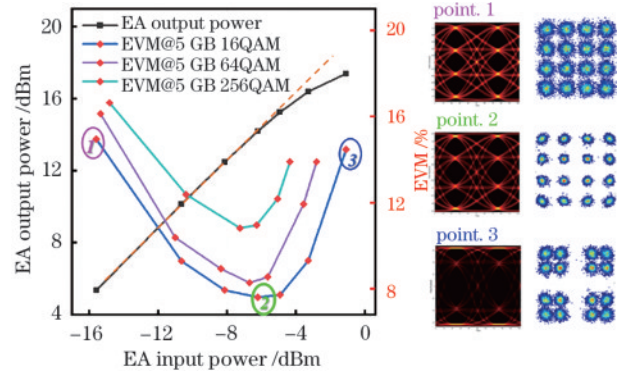


图 4 16QAM、64QAM 和 256QAM 调制格式下 EVM 随 EA 输入功率的变化曲线^[85]

Fig. 4 Variation curves of EVM and EA output power with EA input power under 16QAM, 64QAM, and 256QAM modulation formats^[85]

大器都具有类似的非线性工作特性。然而,不仅由 EA 驱动的调制器本身会引入非线性,而且其输出在后续调制中也起着关键作用。

3.3 MZM

电光效应的实验发现,晶体材料的折射率与外加电场有着复杂的关系,可近似为 $\Delta n \sim (R|E| + \gamma|E|^2)$,其中:第一项与 E 呈线性关系,称为 Pockels 效应;第二项与 E 呈平方关系,称为 Kerr 效应。理想情况下,调制器工作在一阶波克尔效应线性区域内。由于铌酸锂晶体与外加电场有二次关系,即克尔效应,当外加电场强度增加到一定程度时,克尔效应变得更加明显,这导致了电场强度对晶体折射率产生影响。这不再是一个简单的线性变化,所以 MZM 本质上是一个非线性调制器。为了使调制器有效地工作,加载的信号应尽可能地落在 MZM 的高线性区域内,这可以通过调整信号的峰值和 MZM 的配置电压来控制。当信号的振幅进入 MZM 的高非线性区域时,信号将严重失真,从而降低系统的误码性能。

图 5 是 MZM 调制曲线^[86],强度调制器是一个非线性器件,其输入和输出满足下式中的余弦关系,

$$E_{out}(t) = E_{in}(t) \cdot \cos[(V_{driver} + V_{bias})/2V_{\pi}] \quad (5)$$




图 5 典型的 MZM 传输曲线^[86]

Fig. 5 Typical MZM transfer curve^[86]

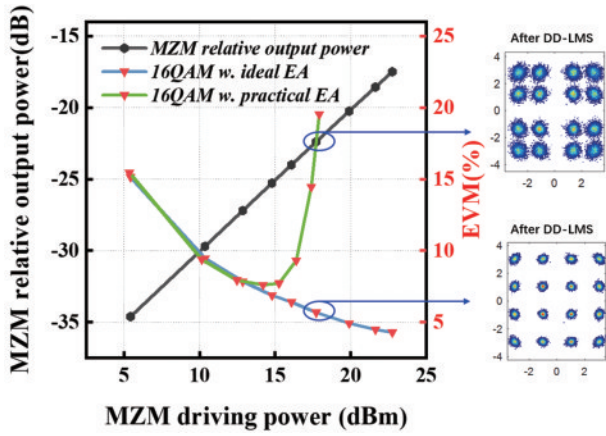


图6 理想或实用的EA辅助的16QAM信号EVM和MZM相对输出功率曲线与MZM驱动功率的关系^[85]
 Fig. 6 Ideal or practical EA-aided 16QAM signal EVM and MZM relative output power curves versus MZM driving power^[85]

在73.5 GHz光子-毫米波框架的模拟中^[85],图6给出了MZM相对输出功率与驱动电压的关系。在实际的毫米波传输实验中,由于EA输出范围的限制,MZM的驱动功率不会工作在非线性区域。事实上,




图7 16QAM、64QAM和256QAM调制格式下EVM和PD输出功率随PD输入功率的变化曲线^[85]
 Fig. 7 Variation curves of EVM and PD output power with PD input power under 16QAM, 64QAM, and 256QAM modulation formats^[85]

4 宽带 THz无线通信的 AI技术

众所周知,THz无线传输过程中通常会经历大气损失和自由空间损耗。因此,如图8所示,对于大容量、长距离的THz无线系统来说,相干检测至关重要,其具有高接收灵敏度和能获取相位信息的优点。通常,先进的DSP算法包括CD补偿、恒模算法均衡、频率偏移估计(FOE)、CPR和误码率(BER)判决。但 these 方法只对线性问题有意义,而对缓解非线性噪声则无能为力。在图8中,人工智能技术已被广泛地应用于数字信号处理领域。它们最大的特点是使用非线性

即使MZM本身是线性工作的,其驱动功率已经包含了实际EA的非线性参与。此外,从理论上讲,MZM的偏置电压工作在推-挽(push-pull)点上,但在实际的实验方案中,由于器件的限制和系统的偏差,最佳位置并不是像理想情况那样,工作于理论值,而是略有偏移。由于电压偏移引入了直流电(DC)成分,信号的信噪比降低,星座点被压缩到边缘。EA的非线性主要影响到EA的高输入功率范围。相比之下,偏置点的非线性补偿主要集中在低输入功率的EA上。

3.4 光电探测器

在同一个73.5 GHz的毫米波仿真中^[85],图7说明了16QAM、64QAM和256QAM调制格式下的PD特性曲线和EVM性能。作为一种广泛使用的光电转换器件,商用pin-PD器件具有成熟的制造工艺,可以支持带宽达100 GHz的平坦响应。然而,pin二极管的优异性能会被空间电荷效应造成的非线性饱和的固有缺陷严重影响。当考虑到高入射光功率时,响应性下降,PD进入饱和状态^[87]。更高阶调制格式需要更高的信噪比来恢复信号,但更高的入射功率会导致PD的非线性退化。调制格式越高,星座图的边缘点就越向内压缩,变形就越严重。

激活函数,能够有效地缓解光纤、光电设备、电放大器、功率放大器等产生的非线性效应。然而,所应用的深度学习被认为是一种纯数据驱动的方法^[88-90]。这种模式显然减少了对数学模型的依赖,就神经框架的设计和实现而言,通常需要巨大的计算资源和相当长的时间。在未来的工作中,如何将经典的DSP数学模型引入深度神经网络的构建和学习过程是一个有趣的话题,这将是B5G/6G物理层的发展方向。

接下来,本文首先演示了一种与级联多模算法(CMMA)盲均衡算法相结合的模型驱动的机器学习算法,然后介绍了一些典型的实数NN方法,如DNN、

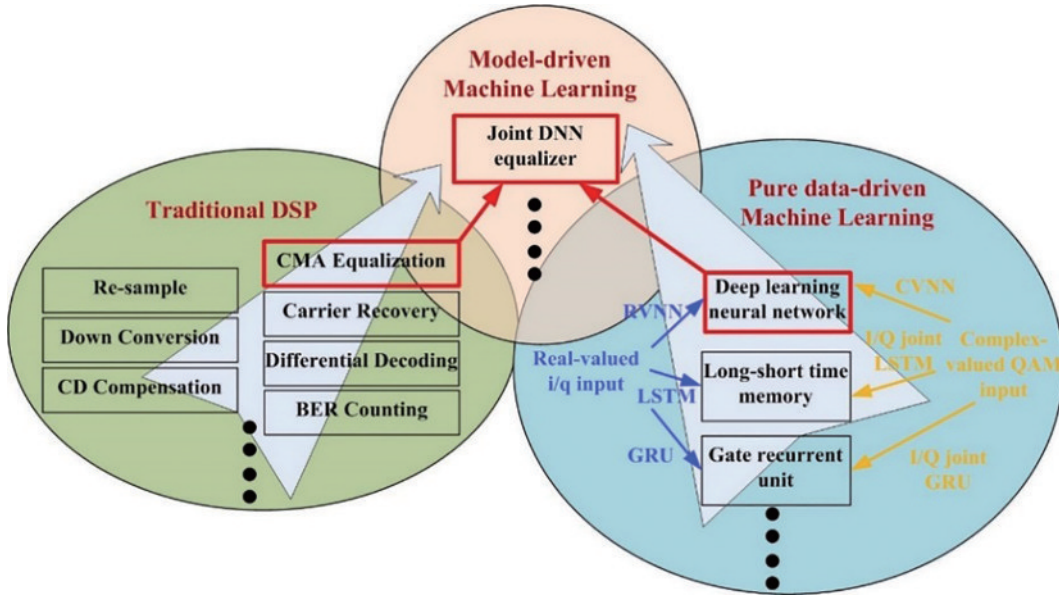


图 8 不同数字信号处理均衡方案的示意图,包括传统数字信号处理、模型驱动的机器学习、纯数据驱动的机器学习方案^[83]
 Fig. 8 Schematic diagrams of different DSP equalization schemes, including traditional DSP, model-driven machine learning, and pure data-driven machine learning schemes^[83]

LSTM、dual-GRU 和具有复数激活函数的复数 NN。值得注意的是, CVNN 对 THz 相干检测起着重要作用,因为它可以保留 I 路和 Q 路数据之间的相位信息。

4.1 模型驱动的机器学习算法

经典的数据驱动深度学习将标准的深度神经网络作为目标任务学习的黑箱。然而,就神经框架的设计和实现而言,这种范式显然减少了对数学模型的依赖,这通常需要巨大的计算资源和相当长的时间。相反地,模型驱动深度学习在图像科学、MIMO 检测等领域得到了广泛的研究和应用^[91-94],它将传统的基于数学知识或物理机制的建模方法与数据驱动的学习相结合。本课题组成功地将传统的 DSP 模型与纯数据驱动的深度学习方法联合起来,实现了更好的误码率判决和更快的训练速度^[95]。

4.1.1 联合 DNN 均衡器 (J-DNN equalizer)

从图 9 可以看出, NN 均衡的两种主要分类算法,包括盲 NN 均衡和自适应 NN 均衡。图 9(a) 显示了自适应 NN 均衡的方案^[32,79-80],其损失函数为 $J_n = \frac{1}{2} \sum_{n=1}^S (T_n - O_n)^2$,其中, T_n 表示预测值, O_n 表示 NN 自适应均衡器后的输出值。然而,它有很大的局限性,包括训练序列过长、冗长的训练时间、潜在的过拟合效应和缓慢的收敛速率。图 9(b) 显示了神经网络内置的盲均衡算法的示意图,这是一种自我恢复的均衡方法,不需要满足训练序列一定长度的要求就能成功扩大带宽。例如, CMA 盲均衡可以与 NN 算法^[96]整合,其损失函数定义为 $J_{n,CMA} = \frac{1}{2} \sum_{n=1}^Q (R_1 - |O_n|)^2$,其中 R_1 定义了恒模信号(如 OOK 和 QPSK)。对于非线性信道

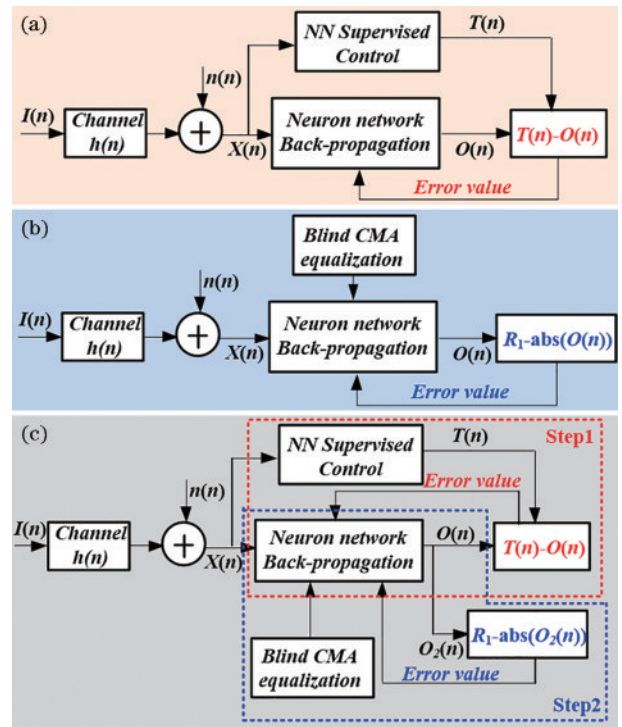


图 9 NN 均衡器的示意图^[92]。(a) 自适应 NN 均衡; (b) 基于 NN 的 CMA 盲均衡; (c) 本文提出的 J-DNN 均衡器
 Fig. 9 Schematic diagrams of NN equalizers^[92]. (a) Adaptive NN equalization; (b) CMA blind equalization based on NN; (c) proposed J-DNN equalizer

的均衡, 剩余均方误差 (MSE) 是一个难以突破的障碍。如图 9(c) 所示, 本文提出了一种新的联合 DNN (J-DNN) 均衡器, 以克服盲 NN 均衡和自适应 NN 均衡方法的缺点。

本课题组设计的延迟抽头联合 DNN 均衡器 (J-

DNN equalizer) 的结构如图 10 所示。所提出的 J-DNN 是一个聚焦时延神经网络(FTDNN),这意味着它的输出既依赖于当前的输入,也依赖于以前的输入。因此“延迟抽头”意味着输入权重值与抽头延迟线相连,允许网络对输入的时间序列有有限的动态响应。在实验中, $X(n)=[x(n), x(n-1), \dots, x(n-M+1)]$ 是一个内存长度为 M 的输入向量。从本质上讲,所提出的 J-DNN 是分两个阶段处理的。第一个训练过程,如图 10 中红色虚线框内所示,用来初始化神经网络。在这个例子中,“误差函数”被用来计算训练期间预期输出 T_n 和实际输出 O_n 的差值。之后,将测试集 $S_x(n)$ 送入神经网络,采用盲 CMMA 方法,以产生更好的均衡效果。最终训练了蓝色框中所描述的 DNN 网络。所设计的 J-DNN 包括一个单一的 DNN,在 DNN 盲均衡过程中,权重值的优化取决于盲均衡算法所产生的成本函数。因此,J-DNN 可以提高无线系统对无线传输信道变化的适应性,同时减少对训练样本数的需求。

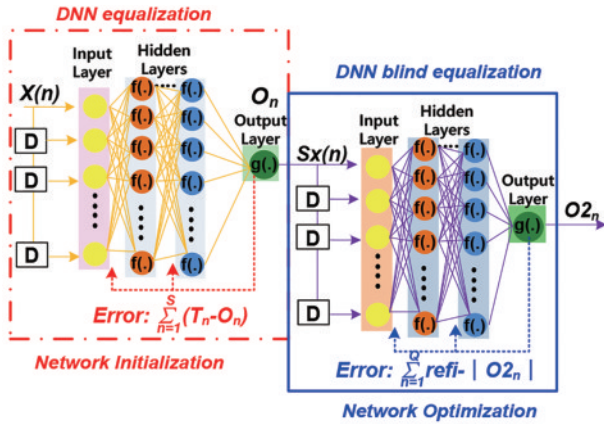


图 10 延迟抽头联合 DNN 均衡器的结构^[95]

Fig. 10 Architecture of the proposed delay-tap joint DNN equalizer^[95]

增加 DNN 中隐藏层的数量可以提高其判决精度。然而,它也引入了几个严重问题,包括更大的计算负荷和更长的训练时间。图 11 描述了 20 Gbaud PAM-8 信号的误码率与光输入功率的关系。输入和输出神经元的数量分别被设置为 171 和 1。可以考虑 4 种情况: 1) 只有一个隐藏层的 DNN(171-60-1),表示在单个隐藏层中有 60 个神经元。2) 有两个隐藏层的 DNN(171-60-60-1),表示每个隐藏层有 60 个神经元。3) 有三个隐藏层的 DNN(171-60-60-60-1),意味着每个隐藏层有 60 个神经元。4) J-DNN 结构只有一个隐藏层,有 60 个神经元(171-60-1)。所有神经网络的训练数据大小为 16000,迭代历时为 400。很明显,随着 DNN 中隐藏层的增加,误码率性能得到了改善。而在 J-DNN 均衡算法中,在情况 4 中的低信噪比要求下,误码率急剧下降。此外,本文设计的 J-DNN 在复杂性和训练速度方面有绝对的优势,因为只有一个隐藏层和相同数量的节点。

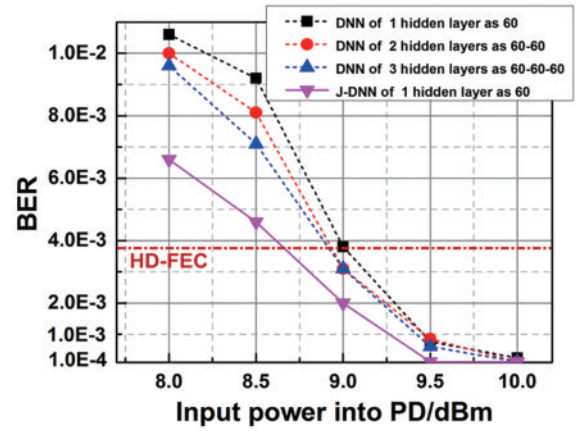


图 11 当 DNN 有 1、2、3 个隐藏层时,BER 性能与进入 PD 的光功率的关系(实线对应的是 J-DNN 中只有一个隐藏层的情况)^[95]

Fig. 11 BER performance vs the optical power into PD when there are 1, 2, and 3 hidden layers in DNN, respectively (solid line corresponds to the scenario when there is only one hidden layer in J-DNN)^[95]

4.2 纯数据驱动的机器学习算法

众所周知,深度学习已经引起了很多人的关注,并且在处理分类和预测问题上有很大的潜力,特别是在通信信号处理的应用上。它通过多层之间的非线性组合,将无监督的特征学习和有监督的特征学习相结合。因此,DL 的效果要比传统的多层神经网络好。传统的人工神经网络采用由输入层、隐藏层和输出层组成的三层结构,其连接可以通过各层的节点进行。在信道均衡任务中实施的 NN 算法不断演化为 ANN^[97]、DNN^[98]、CNN^[99]、LSTM^[100] 等。接下来,将详细介绍各种基于 NN 的均衡器,包括实数神经网络(RVNN)和 CVNN。

4.2.1 RVNN

1) 传统的带 softmax 层的 DNN 均衡器

假设复数的基带信号在数字检测系统中通过 DSP 算法(如 FOE 和 CPR 步骤)进行处理,然后得到由复数信号转换的实数数字信号。众所周知, N 级分类是 N 阶调制信号均衡。因此,四阶均衡也可以认为是多分类,对于 16QAM 或 PAM4 信号,分类指数 $M=4$ 。图 12 中,采用了一个 DNN 均衡器,其输出层为 softmax 层,由真正的全连接层组成。 $X(n)=[x(n), x(n-1), \dots, x(n-N_0+1)]^T$ 是具有 N_0 存储长度的输入矩阵乘以隐藏层中的权重值 $w_{i_{l-1}j_l}^l$,其中 l 是第 l 个隐藏层, i_{l-1} 和 j_l 分别是前 $(l-1)$ 个隐藏层中的第 i 个神经元和当前第 l 个隐藏层中的第 j 个神经元。第 l 个隐藏层之后的各种非线性神经元的输出相加为

$$h_{j_l}^L = f \left\{ \sum_{i_{l-1}}^{N_{l-1}} w_{i_{l-1}j_l}^L \cdot f \left\{ \sum_{i_{l-2}}^{N_{l-2}} w_{i_{l-2}j_{l-1}}^{L-1} \dots \right. \right. \\ \left. \left. f \left[\sum_{i_1=1}^{N_1} \omega_{i_1 j_2}^2 \cdot f \left(\sum_{i_0=1}^{N_0} \omega_{i_0 j_1}^1 x_i \right) \right] \right\} \right\}, \quad (6)$$

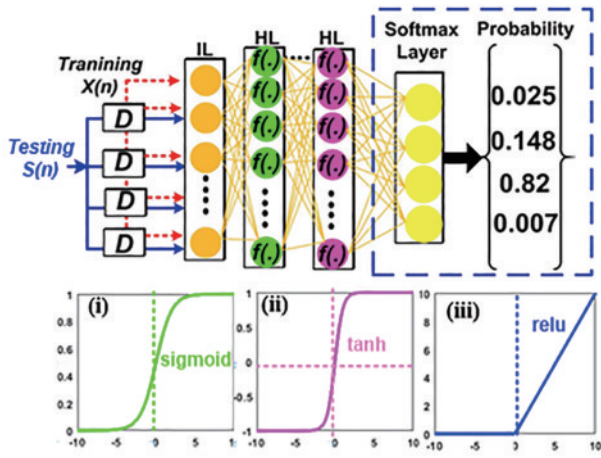


图 12 带有 softmax 层的自适应 DNN 均衡器的说明^[101]。

(a) Sigmoid; (b) tanh; (c) ReLU

Fig. 12 Illustration of adaptive DNN equalizer with softmax layer^[101]. (a) Sigmoid; (b) tanh; (c) ReLU

式中:第 l 个隐藏层的节点数为 N_l ; x_t 是 DNN 结构的输入向量; $f(\cdot)$ 代表隐藏层之间的映射函数; sigmoid、tanh 和 ReLU 是三个最常用的映射函数,如图 11(a)~(c)所示。考虑到爆炸梯度问题、梯度消失问题和收敛率,ReLU 比其他激活函数更具竞争力^[102],因为它是一个线性最大函数。关于 4 分类调制信号均衡问题,softmax 函数是一个广义的 logistic 函数,将长度为 T 的实数信号序列转换为长度为 4 的概率向量。显然,输出向量 $[p_0^t, p_1^t, p_2^t, p_3^t]^T$ ($t=1, 2, \dots, P$) 的和等于 1。第 t 个符号的概率为

$$p_v^t = \text{softmax}(z_v^t) = \frac{\exp(z_v^t)}{\sum_{v'=0}^3 \exp(z_{v'}^t)}, (v \in 0, 1, 2, 3), (7)$$

式中: $z^t = [z_0^t, z_1^t, z_2^t, z_3^t]^T$ 是时间 t 的输入向量,进入输出 softmax 层。在多元分类任务中,交叉熵(CE)经常被用作损失函数

$$L_{\text{loss}} = - \sum_v s_v^t \ln p_v^t = - s_u^t \ln p_u^t - \ln p_u^t, \begin{cases} s_v^t = 0 (v \neq u) \\ s_v^t = 1 (v = u) \end{cases} (8)$$

从式(8)的输出中得到符合后项传播算法的梯度更新结果,允许相关的权重向量被迭代更新,直到达到目标历时或误差值。

2) LSTM 均衡器

LSTM 通道的均衡过程如图 13(a)所示。LSTM 神经网络的第一层可以看作批量归一化层,实现了输入数据向量的初始化和归一化。然后,根据输入数据的特征构建和训练 LSTM 神经网络的模型。为了保证误码判决的准确性,将 LSTM 神经网络的输出送入全连接层,然后到 softmax 层,在输出端对矢量信号进行分类,然后计算每一类的概率。值得注意的是,丢弃层位于全连接层和 softmax 层之间,因为它随机丢弃神经元以防止过拟合。图 13(b)说明了 LSTM 隐藏单元的结构,它有三个门(输入门、输出门和遗忘门)和一个存储单元。传输信息通过 sigmoid 激活函数被置于遗忘门的控制之下。根据先前的输出 h_{t-1} 和当前的输入 x_t ,可以根据下式计算出 $f_t \in [0, 1]$ 的值,它决定是否保

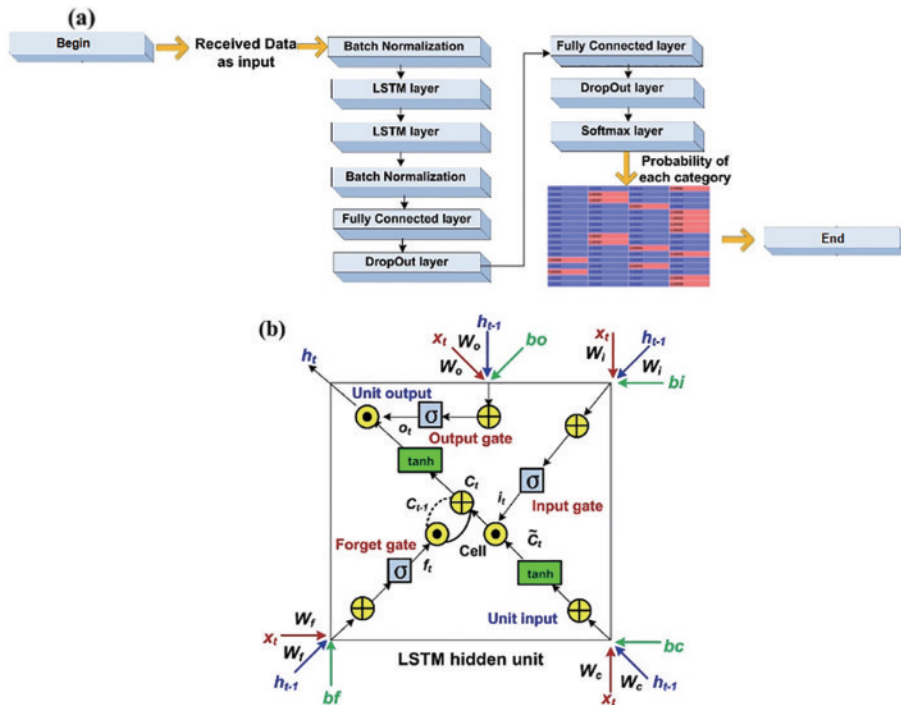


图 13 LSTM 通道的均衡过程^[101]。(a)流程图;(b) LSTM 隐藏单元的指定框架示意图

Fig. 13 LSTM channel equalization procedure^[101]. (a) Flowchart; (b) schematic diagram of the specified framework of LSTM hidden unit

留前一个隐藏层的输出 C_{t-1} 。

$$f_t = \sigma(W_f \times [h_{t-1}, x_t] + b_f) \in [0, 1], \quad (10)$$

$$i_t = \sigma(W_i \times [h_{t-1}, x_t] + b_i), \quad (11)$$

$$\tilde{C}_t = \tanh(W_c \times [h_{t-1}, x_t] + b_c), \quad (12)$$

式中: b_f, b_i, b_c 为偏差向量; $[h_{t-1}, x_t]$ 表示向量 h_{t-1} 与向量 x_t 组合而成的矩阵。LSTM 网络中的关键参数是 f_t , 它可以防止梯度爆炸或消失。输入向量通过输入门得到更新, 并利用式(11)的结果来决定是否接受输入数据。此外, 根据式(12)通过 tanh 层产生的新的候选值可以被引入单元状态。

接下来, 结合式(11)和式(12), 产生更新的值,

$$C_t = f_t \times C_{t-1} + i_t \times \tilde{C}_t. \quad (13)$$

最终, 得到了输出门的值

$$o_t = \sigma(W_o \times [h_{t-1}, x_t] + b_o) \times \tanh(C_t). \quad (14)$$

输出值 o_t 决定了更新后的值 C_t 是否会被用作下一次的输入。有三个门的 LSTM 均衡器使用反向传播 (BP) 算法来更新门的权重值, 直到达到指定的历时或误差阈值。

图 14 评估了当光输入功率固定在 7.7 dB 时, LSTM 均衡在 45Gbaud PAM-4 信号上的性能^[101], 以及传统 DNN 均衡器和所提 J-DNN 均衡器的性能。这里, 训练数据集的历时数和数量分别被指定为 300 和 12000。结果显示, 具有大量神经元单元的传统 DNN 均衡器可轻微地减少的误码率, 因为过度的迭代训练产生的过拟合效应损害了神经网络的生成能力。然而, 随着每个隐藏层中神经元数量的增加, J-DNN 均衡器的有效性得到了提高, 这要归功于它的反过拟合特性。对于输入隐藏层的数据量为 301 的 LSTM, 误码率曲线出现波动, 当最佳神经元数量为 300 时, 误码




图 14 普通 LSTM 均衡器、DNN 均衡器和 J-DNN 均衡器的 BER 性能与隐藏层中的神经元数量的关系^[101]

Fig. 14 Relationship between BER performance and the neuron cells in hidden unit in a regular LSTM equalizer, DNN equalizer, and J-DNN equalizer, respectively^[101]

率达到最低的 1×10^{-4} 。因此得出结论, 所提 LSTM 均衡器由于能够保持时间序列信息, 在接收机灵敏度方面具有优势。然而, 值得注意的是, 在设计真正的无线通信应用时, 必须考虑到 LSTM 均衡器的计算复杂度问题。

3) 基于 GRU 的非线性均衡方案

GRU 的原理表示为

$$\begin{cases} z_t = \sigma(W_z x_t + U_z h_{t-1}) \\ r_t = \sigma(W_r x_t + U_r h_{t-1}) \\ \tilde{h}_t = \tanh(r_t \circ U h_{t-1} + W x_t) \\ h_t = (1 - z_t) \circ \tilde{h}_t + z_t \circ h_{t-1} \end{cases}, \quad (15)$$

式中: $W_z/U_z, W_r/U_r$ 和 W/U 分别是更新门、复位门和输入的权重矩阵; x_t 和 h_t 代表 GRU 在时序 t 的输入数据和隐藏状态; \circ 表示两个矩阵或向量之间的 Hadamard 积。与传统的循环神经网络 RNN 相比, GRU 由两个关键部分组成以提高性能: 复位门 r_t 和更新门 z_t 。在复位门中, 最后一个时序的隐藏状态 $h_{(t-1)}$ 被乘以权重矩阵 U_r , 输入数据 x_t 也被另一个权重矩阵 W_r 所乘。这两个乘积相加, 然后由 sigmoid 函数激活, 将结果压缩在 0 和 1 之间。然后, 复位门 r_t 和隐藏状态 $h_{(t-1)}$ 的 Hadamard 乘积对上一个时序传递的遗留信息进行过滤。复位门之后, 新的记忆信息 \tilde{h}_t 被计算出来。

更新门的结构与采用不同权重矩阵的复位门相同。这一点至关重要, 因为它决定了传送到下一个时序的信息量。最后, 根据更新门 z_t 和记忆信息 \tilde{h}_t 计算出当前时序的隐藏状态, 并将其传送到下一个时序。鉴于神经网络的输入是复杂的 m 阶 QAM 信号, 输入信号 x_t 的分离分量 I 路和 Q 路信号在图 15 中显示。

总的来说, GRU 的复杂结构保留了有效的信息, 放弃了无用的信息, 避免了梯度的爆炸和消失。

图 16 显示了使用双 GRU 和传统 CMMA 算法的 16QAM 信号的误码率 (BER) 与光输入功率的关系^[103]。当光功率为 -1 dB 时, 图 16(a)~(b) 分别描述了使用传统 CMMA 算法和双 GRU 的 16QAM 信号的星座图。可以看出, 随着输入光功率的增加, 误码率明显增加, 当光功率为 -1 dBm 时性能最佳。当光功率超过 -4 dBm 时, 误码率达到硬判决 (HD-FEC) (3.8×10^{-3}), 当光功率等于 -1 dBm 时, 误码率下降到 1.26×10^{-4} 。图 16 表明, 与传统的 CMMA 算法相比, 双 GRU 技术提高了误码率性能, 在 SD-FEC 的误码率下, 增益为 0.5 dB。

4.2.2 带有 CReLU 函数的 CVNN 均衡器

在许多光载无线传输系统中, 相干检测的基带信号是复数的, 而复数信号的 I 和 Q 部分之间存在着固有的联系。在文献[104]中, Volterra 系列的均衡器被扩展到复数域, 其中正交振幅调制信号的实部和虚部分别被均衡。在文献[105]中, Leaky-ReLU 激活函数被分别应用于复数信号的实部和虚部。然而, 将复数

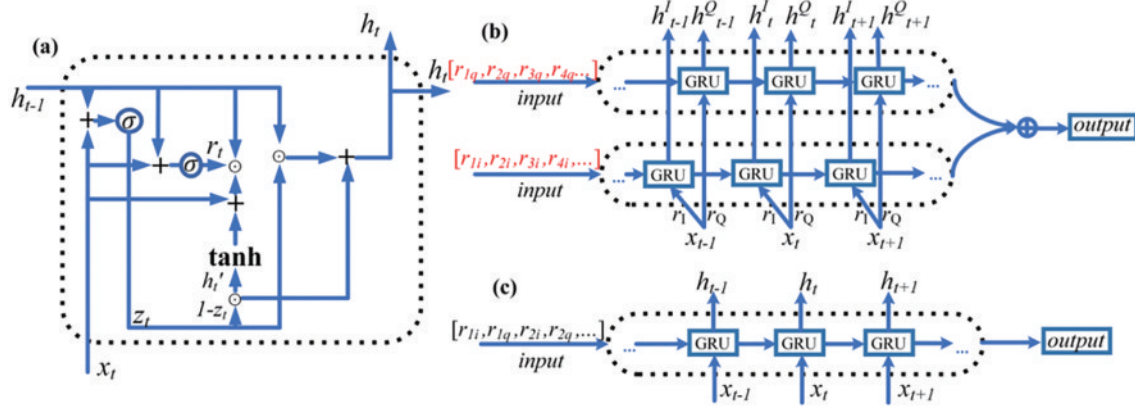


图 15 基于 GRU 的模型结构^[103]。(a) 一个 GRU 单元的详细结构; (b) 一个双 GRU 模型的结构; (c) 一个 GRU 模型的结构
Fig. 15 GRU based model structure^[103]. (a) Detailed structure of a GRU unit; (b) structure of a dual-GRU model; (c) structure of a GRU model

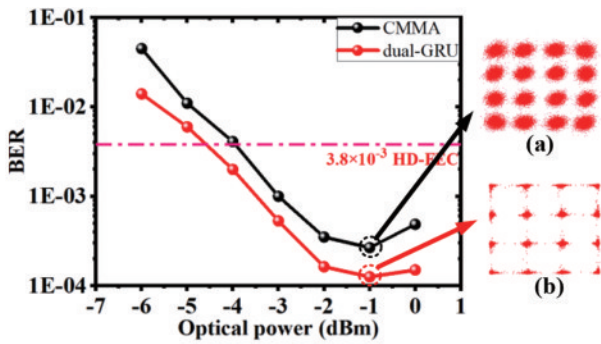


图 16 16QAM 信号的误码率与输入光功率的关系^[103]。(a) 采用传统 CMMA 算法的星座图; (b) 采用双 GRU 的星座图
Fig. 16 BER of 16QAM signal versus the input optical power^[103]. (a) Constellation diagram employing the traditional CMMA algorithm; (b) constellation diagram with dual-GRU

信号转换为独立的实部和虚部时, 会忽略它们的相关性, 导致相位信息的丢失。基于以上考虑, 包括 modReLU、CReLU 和 zReLU 在内的复数神经网络激活函数、先进的复数批归一化以及复数权重初始化技术已经在文献[49]中提出, 这对于建立一个成熟复值神经网络至关重要。

因此, 如图 17 所示, 将传统的实值神经网络




图 17 全复数 DNN 均衡器的神经框架^[101]
Fig. 17 Neural framework of our proposed fully complex valued DNN equalizer^[101]

扩展为完全复数的深度神经网络, 所谓的“完全复数”体现在三个方面: 1) 复值激活函数; 2) 复值权重初始化; 3) 复值误差后向传播。在未来的工作中, 我们将利用批归一化和权重初始化算法对毫米波信号非线性均衡的复值网络进行进一步研究。

在对输入与权重的卷积值进行映射时, $f(\cdot)$ 是隐藏层之间的激活函数, 在实数神经网络中, 比较常见的函数是 sigmoid、tanh 和 ReLU 等, 它们都是非线性的。从梯度爆发、梯度消失和收敛速度方面考虑, 被描述为非线性最大函数的 ReLU, 比其他激活函数更有竞争力。因此, 本文在复数 DNN 中选用复数的 ReLU (CReLU) 作为激活函数

$$C_{\text{ReLU}} = \text{ReLU}(x_{\text{real}}) + i \cdot \text{ReLU}(x_{\text{imaginary}}) = \max(0, x_{\text{real}}) + i \cdot \max(0, x_{\text{imaginary}}) \quad (16)$$

偏移函数表示为

$$C_{\text{ReLU}}' = \begin{cases} 1, & x_{\text{real}} > 0, x_{\text{imaginary}} \leq 0 \\ 1, & x_{\text{real}} \leq 0, x_{\text{imaginary}} > 0 \\ 0, & x_{\text{real}} < 0, x_{\text{imaginary}} \leq 0 \\ 2, & x_{\text{real}} > 0, x_{\text{imaginary}} > 0 \end{cases} \quad (17)$$

所提 CReLU 均衡器框架中设置的误差函数是 L1 损失, 表示为

$$e_n = T_n - O_n, \quad (18)$$

式中: T_n 是目标复数信号; O_n 是复数神经网络均衡器的输出复值。

通过采用线性和非线性均衡方案比较了 45 Gbaud PAM-4 信号的误码率性能, 包括 45 抽头 CMMA 均衡器与 301 抽头 DD-LMS 相结合、RVNN 均衡器如 151 抽头 2 阶 Volterra 与 253 抽头 DD-LMS、含有 Softmax 输出层的 DNN[171-60-4], 两步联合 DNN 均衡器[171-60-1]和隐藏层有 128 个神经元的 LSTM, 以及结构如[571-200-1]的 CVNN 均衡器[101]。为了进一步比较具有相同复杂度的 RVNN 和 CVNN 的误码率性能, 设置了这两类具有相同结构的均衡器[371-

260-1]。根据图 18 所示的曲线,很显然,CMMA 或 DD-LMS 等线性均衡算法在减少非线性损伤方面几乎贡献为 0。相反,得益于使用 NN 均衡器的非线性均衡算法,误码率性能明显提高。与传统的 DNN 均衡器相比,J-DNN 均衡器在误码率性能方面具有优势,因为其误码率相比这些 RVNN 训练结果进一步下降。此外,由于其保持时间序列信息的能力,所应用的 LSTM 均衡器具有更大的接收灵敏度。特别是,当光输入功率为 9.2 dBm 时,在较低的信噪比要求下,误码率急剧下降到 7×10^{-5} 。在比较 RVNN 和 CVNN 时, CVNN 均衡器的性能优于 LSTM,并且在具有较高信噪比的区域表现更好。当进入 PD 的光功率为 9.2 dBm 时,可以实现无误码操作。

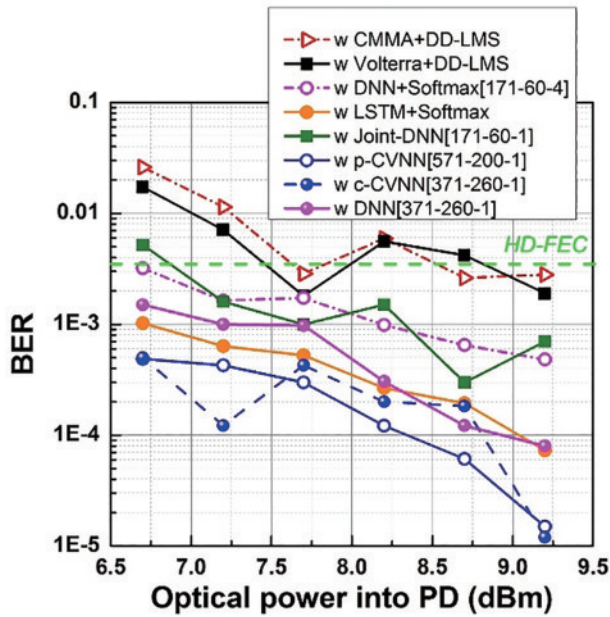


图 18 在 45 Gbaud PAM-4 信号无线传输中,采用 45 抽头 CMMA 均衡器结合 301 抽头 DD-LMS、非线性 RVNN 和 CVNN 均衡器, BER 性能与进入 PD 的光功率的关系^[101]

Fig. 18 BER performance vs the optical power into PD for 45 Gbaud PAM-4 signal wireless transmission by employing 45-tap CMMA equalizer combined with 301-tap DD-LMS, nonlinear RVNN and CVNN equalizers, respectively^[101]

4.3 传统的 DSP 算法与机器学习算法相结合

对于接收到的调制信号的处理,一些学者已经发现,先进的 DSP 算法,如下变频、重采样、FOE 和 CPR 是缓解非线性损伤和提高 D 波段无线通信中再接收灵敏度的有效方法。

然而,非线性是 D 波段 ROF 传输系统的一个重要制约因素,识别和缓解非线性效应始终是 ROF 连接中的一个挑战。在 6G 中,先进的机器学习训练方法已被证明是克服这一挑战的最有效方法。因此,将基于数学模型的神经网络均衡与先进的 DSP 算法相结合,可

以大大降低计算的复杂性,提高接收机的灵敏度和误码率判决的准确性。

本文提出了两种 DSP 方案来恢复发送(Tx)侧的接收信号,如图 19 所示。方案一中采用了重采样后的 CVNN 均衡器。为了在复杂性方面进行比较,设置了方案二,将 FOE 和 CPR 算法与 DVNN 或 CVNN 均衡器相结合。这里, RVNN 和 CVNN 具有相同的结构。

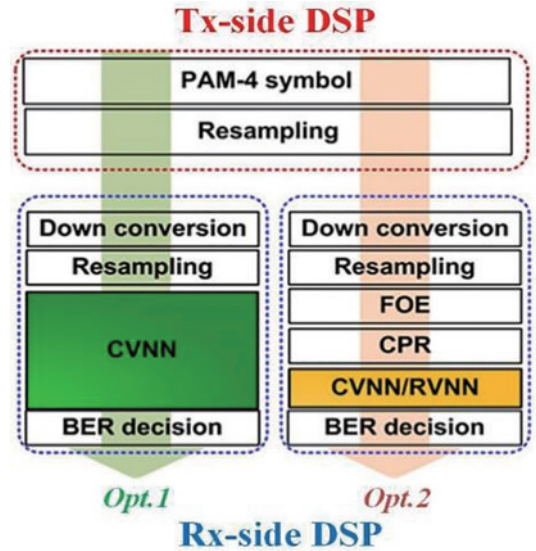


图 19 发送端和接收端的 DSP 模块^[101]

Fig. 19 Detailed DSP blocks at the Tx- and Rx-side^[101]

图 20 描述了经过 DSP 算法后的方案二的 PAM4 信号的星座图^[101]。在下变频后,虚部和实部信号无法区分。使用 FOE 解决了频率偏移噪声的问题,并在 CPR 后缓解了相位偏移。然而,在上述成功的传统 DSP 步骤之后,星座图大部分是沿着虚轴分散的。通过采用 RVNN 均衡器,最终找回 PAM-4 信号的实部。

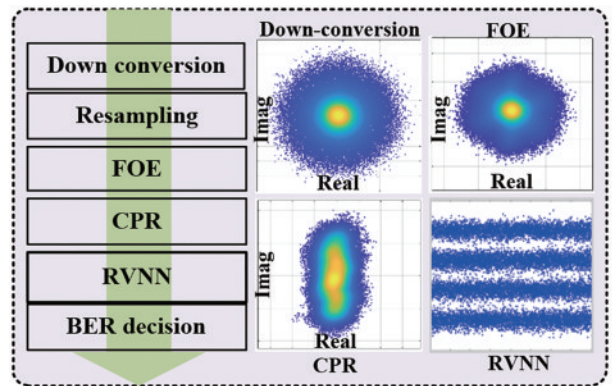


图 20 DSP 步骤以及信号星座图(插图:下变频、FOE、CPR 和 RVNN 均衡后的星座图)^[101]

Fig. 20 DSP steps and signal constellation diagram (insets: constellation diagrams after down-conversion, FOE, CPR, and RVNN equalization)^[101]

4.4 现有机器学习算法对比

通过上述分析,表 6~8 总结了现有机器学习算法。

表 6 不同驱动方式机器学习算法对比

Table 6 Comparison of machine learning algorithms with different driving methods

Model driven approach	Dependence on mathematical models	Network interpretability	Complexity	Generalization ability	Ref.
Model-driven	Higher	Better	Lower	Better	[95]
Pure data driven	Lower	Worse	Higher	Worse	[87-89]

表 7 不同输入类型机器学习算法对比

Table 7 Comparison of machine learning algorithms with different input types

Model input type	Complexity	Information contained	Generalization ability	Ref.
RVNN	Lower	Simply separate real and imaginary parts	Worse	[98]
CVNN	Higher	Effectively mining the coupling relationship between amplitude and phase	Better	[49]

表 8 不同机器学习算法对比

Table 8 Comparison of different machine learning algorithms

Algorithms	Structural characteristics	Complexity	Usage scenario	Ref.
DNN	Unable to capture sequence relationships	Lower	A relatively basic structure	[98]
LSTM	Special case of RNN proficient in capturing long sequences	Higher	Processing complex sequence high demand for accuracy	[100]
GRU	Compared to LSTM, the structure is relatively simple	Compared to LSTM, it is lower	Processing simple sequence data limited computing resources	[103]

5 基于平衡机器学习的复数神经网络非线性均衡技术

THz 光纤无线融合技术可以突破传统电气设备的带宽限制,在不同的应用场景中得到了推广。此外,概率整形技术可以优化传输容量和距离,在光纤通信领域得到了广泛的应用。然而, m -QAM 星座点的概率分布随幅值的变化而变化,这导致了类不平衡(m -QAM 信号被视为一个 m 分类问题),使得 PS- m -QAM 信号中的少数类在后续神经网络的非线性均衡处理过程中得不到充分训练,神经网络算法的性能大大降低。针对类别不平衡的问题,本文提出了两种不同的解决方案。第一种是复旦大学团队提出的一种结合平衡随机过采样(ROS)的 CVNN 分类器^[106],该分类器可以通过训练同时恢复相位信息,解决 PS 导致的类不平衡的问题。基于该分类器的方案,复数的过采样特征融合增加了少数类的有效信息量,从而有效地提高了识别精度。与基于神经网络的分类器相比,它对样本大小的要求更低,并且大大简化了神经网络的结构。随机欠采样(RUS)会删除多数类的训练数据集的长度,因此可能会导致有用信息的丢失,从而进一步导致神经网络优化能力下降。相比之下,ROS 容易增加少数类的训练数据集,这已被证明是克服机器学习不平衡的有效方法。利用其提出的 ROS-CVNN 分类方法,实验实现了 200 m 自由空间距离上单通道 10 Gbaud 335 GHz PS-64QAM 光纤无线传输。因此,可以认为 ROS 与 NN 监督算法的结合在未来 6G 移动通信中具

有应用前景。第二种方案,本课题组提出了一种带有加权损失函数的新型复数分类器^[107],通过 Logit 校准进行机器学习,从而解决分类不平衡的问题。该算法可以提高约 0.5 dBm 的接收灵敏度。它可以减少 4%~7% 训练序列长度,计算复杂度能降低 10.53%~16.89%,并且减少 23.08% 的训练迭代次数。下面将对这两种方法分别进行介绍。

5.1 结合平衡随机过采样的复数神经网络非线性均衡技术

5.1.1 随机重采样

引入 PS 算法会导致生成的 PS- m -QAM 数据出现严重不平衡,即 QAM 星座图的内圈点数明显多于外圈点数。该 PS- m -QAM 训练数据集的严重偏差会导致机器学习的不平衡,从而导致对少数类的训练不充分。一些研究表明,可以通过对训练数据集进行随机重采样来解决这一问题,随机重采样包括欠采样和过采样^[106],已被证明是克服机器学习不平衡的有效方法。

对于 ROF 系统中传输的 m -QAM 信号,如 PS-16QAM 和 PS-64QAM,基于所提神经网络结构优化算法,通过使用不同的深度学习均衡器和分类器来进行恢复解调。在 PS- m -QAM 训练方案中,主要的 DSP 处理涉及图 21 中的 2 个步骤:1)通过随机过采样或者随机降采样来对接收到的 PS- m -QAM 数据进行预处理,该步骤旨在减少数据的不平衡性,避免后续深度学习对少数类训练得不充分。2)通过复数的神经网络均衡器,或是基于交叉熵损失函数的复数神经网络分类




图 21 在进入 NN 分类器前进行预处理的方案^[106]

Fig. 21 Scheme of pre-processing before entering NN classifier^[106]

器对信号进行均衡。

下面分别对随机欠采样和随机过采样两种方案进行介绍。

1) 随机欠采样

如图 22 所示,随机降采样的核心思想在于减少样本中多数类的数量,从而取得训练集的平衡。一个相对来说非常简单的方案是随机去除部分多数类样本,去除样本的数量是根据事先设置的最终生成的多数类与少数类数据集的数量比例(ratio)决定的,在原始的少数类样本数量保持不变的情况下,根据 ratio 随机地去除多数类样本。该欠采样方法的优点在于操作简单,只依赖于样本分布,不依赖于任何距离信息,属于非启发式方法。其缺点在于删除训练数据集中多数类的长度可能会导致有用信息的丢失,从而进一步导致信道容量下降。




图 22 随机欠采样原理

Fig. 22 Principle of random under-sampling

经典的 RUS 算法生成训练集 $\{S'\}$ 的过程描述如下。

步骤 1: 对于一个原始的训练数据集 $\{S\}$, 少数类的数据长度为 N^- 。同时,最大的多数类中的数据长度

为 N^+ , 采样率为 R_s 。此处的 $N^+ + N^- = N$, 且 $N - N^+ \times R_s$ 是每次分类的最终训练数据集的长度。不平衡率为 $\lambda = \frac{N^+}{N^-}$ 。

步骤 2: 对于一个特定的少数类和数量最多的多数类, 其所有的原始样点分别构建了原始的少数类训练集 $\{S^-\}$ 和多数类训练集 $\{S^+\}$ 。

步骤 3: 对于 $i=1:N^+ \times \frac{R_s}{R_s+1}$, 从 $\left[1, N^+ \times \frac{R_s}{R_s+1}\right]$ 中随机选择数字, 并从 $\{S^+\}$ 中找到相应的样本集 $\{x^i\}$ 。

步骤 4: 将所选随机样本从多数类样本中移除, 得到多数类样本集 $\{S^+\} = \{S^+\} - \{x^i\}$ 。

步骤 5: 最终得到生成的训练集 $\{S'\} = \{S^+\} \cup \{S^-\}$ 。

步骤 6: 对于所有的多数类, 重复上面的操作, 得到大量的需剔除的样本集。同时, 对于少数类, 只从原始不平衡数据集中抽取一小部分样本进行剔除。最后, 得到平衡数据集的生成。

2) 随机过采样

对于 NN 分类算法来说, 当某些类别的样本数量多于其他类别时, 就会出现类别不平衡。本文将较大的数据集定义为多数类, 较小的数据集定义为少数类。对于受非线性、相位噪声和高损耗影响的长距离高速无线信道, 在存在严重的类重叠的情况下, 很难从少数类的样本中学习。ROS 算法的主要功能是通过重新分配训练数据集来解决不平衡问题。首先在接收端对接收到的 PS-16QAM 数据采用 ROS 技术。ROS 的基本原理如图 23 所示。众所周知, N 阶调制信号的处理是一个 N 分类问题。PS 技术会在基带 PS-16QAM 数据的类别分布中引入严重的倾斜, 造成内环中产生多数类别, 外环中产生少数类别, 这样就会造成原始的不平衡数据集。ROS 算法的核心思想是随机抽取少数类的样本并进行多次复制, 以平衡训练集的分类

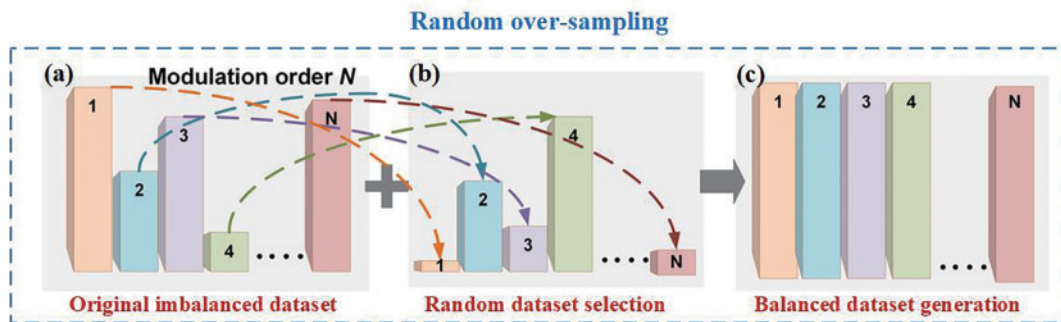


图 23 随机过采样的原理以及不同数据集的目标输出^[106]。(a)原始不平衡数据集;(b)随机过采样数据集;(c)平衡数据集

Fig. 23 Principle of random oversampling and target labels of different datasets^[106]. (a) Original dataset; (b) random oversampling dataset; (c) balance dataset

布^[108-110]。经典的 ROS 算法生成训练集 $\{S^l\}$ 的过程描述如下。

步骤 1: 对于一个原始的训练数据集 $\{S\}$, 最小的少数类中的数据长度为 N^- 。同时, 最大的多数类中的数据量为 N^+ , 采样率为 R_s 。此处的 $N^+ + N^- = N$, 且 $N + N^- \times R_s$ 是每次分类的最终训练数据集的长度。

不平衡率为 $\lambda = \frac{N^+}{N^-}$ 。

步骤 2: 对于一个特定的少数类和数量最多的多数类, 他们所有的原始样点分别构建了原始的少数类训练集 $\{S^-\}$ 和多数类训练集 $\{S^+\}$ 。

步骤 3: 对于 $i = 1: N^- \times R_s$, 从 $[1, N^-]$ 中随机选择数字, 并从 $\{S^-\}$ 中找到相应的样本集 $\{x^l\}$ 。

步骤 4: 将所选样本加入到少数类集中, 得到 $\{S^-\} = \{S^-\} + \{x^l\}$ 。

步骤 5: 最终得到生成的训练集 $\{S^l\} = \{S^+\} \cup \{S^-\}$ 。

步骤 6: 对于所有的少数类, 重复上面的操作, 得到大量的采样样本集。同时, 对于多数类, 只从原始不平衡数据集中抽取一小部分样本。最后, 得到平衡数据集的生成。

5.1.2 运用交叉熵损失函数的复数神经网络分类器

在深度神经网络中, 有许多常见的损失函数, 如 MSE 损失^[111]、交叉熵损失^[112]、L1 损失^[113]、合页损失函数^[114]等。与其他损失函数相比, CE 在收敛速度方面具有优势, 经常被用作分类任务的合理损失函数^[115-116]。在文献^[101]提出的 CVNN 均衡器框架中设置的损失函数是 MSE, 其表达式为 $e_n = T_n - O_n$, 其中 $T_n \in \mathbb{C}^N$ 为目标复数信号, $O_n \in \mathbb{C}^N$ 为 CVNN 均衡器的复数输出值。在复杂度方面, MSE 优于 CE, 因为 CVNN 均衡器的输出层只有一个神经元单元, 而 CVNN CE 的输出 softmax 层有 M 个单元, 其中 M 代表分类的数量。在精度方面, 一方面, CE 的损失权重更新比 MSE 快。另一方面, MSE 是一个非凸式优化, 而交叉熵是一个凸式优化。因此, CE 可以避免陷入局部最优解, 特别是对于多分类优化来说, CE 更方便。因此, 所提长距离太赫兹传输系统中, 采用 CE 损失函数来实现更好的训练精度。图 24(a) 还展示了实数 DNN 分类方案。这里给出的 RVNN 分类器被表示为 $RVNN_{1/Q}$ 。将复数的 m -QAM 信号的实部和虚部分成两路信号, 分别通过两个实数 NN 分类器训练。因此, 输出 softmax 层的数量为 \sqrt{m} 。但值得注意的是, m -QAM 信号本身的复数特性不容忽视, 尤其是其对噪声的敏感性。为了解决这个问题, 文献^[116]提出了一个具有交叉熵损失函数的复数神经网络分类器, 它的输入数据是复数的。首先, 复数的训练集 X 被送入全连接的 CVNN, 如图 24(b) 所示。

为了解决 m -QAM 分类问题, softmax 函数是

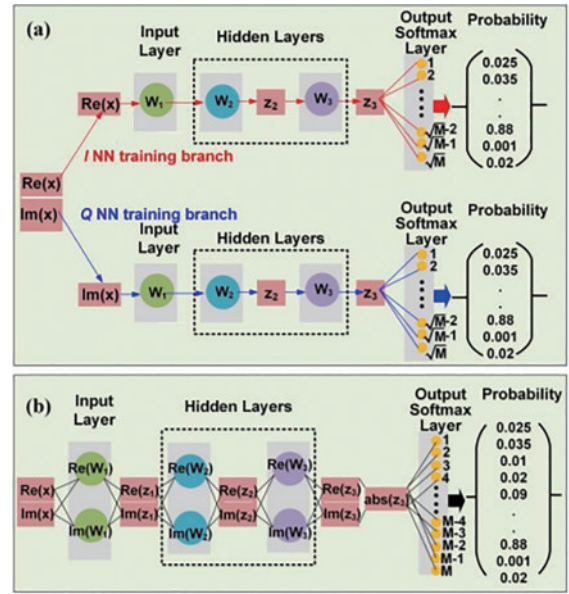


图 24 实数 NN 分类器^[106]。(a) 结构示意图; (b) 具有交叉熵损失函数的复数 NN 分类器

Fig. 24 Real-valued NN classifier^[106]. (a) Schematic structure; (b) complex-valued NN classifier with a cross entropy loss function

logistic 函数的泛化, 以 64QAM 信号为例, 它将一个长度为 T 的实值信号序列映射到一个长度为 64 的概率向量。通过这种方式, 输出向量 $[p_0^t, p_1^t, p_2^t, p_3^t, \dots, p_{63}^t]^T$ ($t = 1, 2, \dots, P$) 的总和等于 1, 即 $\sum p_0^t, p_1^t, p_2^t, p_3^t, \dots, p_{63}^t = 1$ 。第 t 个符号的概率表示为

$$p_v^t = \text{softmax}(z_v^t) = \frac{\exp(z_v^t)}{\sum_{v'=0}^{63} \exp(z_{v'}^t)}, v \in 0, 1, 2, 3, \dots, 63, \quad (19)$$

式中: $z^t = [z_0^t, z_1^t, z_2^t, z_3^t, \dots, z_{63}^t]^T$ 是复数信号的在最后一个隐藏层输出的绝对值, 也是在时刻 t 进入输出层的输入值。在多分类应用中, 常使用交叉熵作为式(19)中的损失函数,

$$L_{\text{loss}} = - \sum_v s_v^t \ln p_v^t = - s_u^t \ln p_u^t = - \ln p_u^t, \begin{cases} s_v^t = 0 (v \neq u) \\ s_v^t = 1 (v = u) \end{cases} \quad (20)$$

式中: s_v^t 是时间 t 的目标 64QAM 信号, 将式(19)代入式(20)的偏导函数计算为

$$\frac{\partial L_{\text{loss}}}{\partial u} = \frac{\partial \ln p_u^t}{\partial u} = \frac{\partial \left[- \ln \frac{\exp(z_u^t)}{\sum_{v'=0}^{63} \exp(z_{v'}^t)} \right]}{\partial u} = p_u^t - 1. \quad (21)$$

式(21)给出了根据反向传播算法进行的梯度更新结果, 因此连接的权重向量可以迭代更新, 直到达到预期的历时或误差值。

图 25^[106]比较了在不同输入光功率下, 不同 DSP

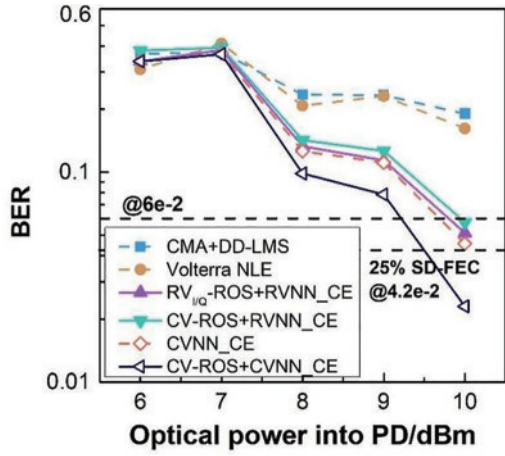


图 25 10 Gbaud THz PS-64QAM 信号的 BER 性能与进入 PD 的光功率的关系,分别采用 21 抽头的 CMMA 均衡器结合 223 抽头 DD-LMS、201 抽头 2 阶 Volterra 均衡器、非线性 RVNN 和 CVNN 分类器^[106]

Fig. 25 BER performance vs the optical power into PD for 10 Gbaud THz PS-64QAM signal wireless transmission by employing 21-tap CMMA equalizer combined with 223-tap DD-LMS, 201-2nd tap Volterra equalizer, nonlinear RVNN, and CVNN classifiers, respectively^[106]

算法和非线性均衡算法的误码性能。线性 CMMA 或 DD-LMS 均衡器对非线性问题不是很有效,二阶 Volterra 系列对误码率性能的改善只能提供较小的帮助。由于分类中交叉熵损失函数的帮助,实数网络表现优异。一方面,对于缓解类别不平衡这一问题,在 ROS 的帮助下,误码率性能得到了很大的改善。另一方面,所利用的 CVNN 分类器能够提高接收灵敏度,因为它可以保留相位信息。综上,当采用 CV-ROS 和 CVNN 分类器的组合时,在光功率为 10 dBm 的情况下,误码率明显下降到 2.29×10^{-2} 。因此,有效比特率达到了 $44 \text{ Gbit/s} / [5.6 - 6 \times (1 - 4/5)] \times 10 = 44 \text{ Gbit/s}$ 。在接收灵敏度方面,在 ROS 的帮助下,在误码率为 4.2×10^{-2} 时,带有 CV-ROS 的 CVNN 分类器比

CVNN 高出 0.5 dB,在误码率为 6×10^{-2} 时,比 $RVNN_{i0}$ 分类器高出约 1 dB。

5.2 带有加权损失函数的复数神经网络非线性均衡技术

2023 年,复旦大学团队提出了一种带有加权损失函数的新型复数分类器^[107],可取代 PS-16QAM 信号在 W 波段长距离传输的传统算法。所提算法可以提供约 0.5 dBm 的接收灵敏度改进。它可以减少 4%~7% 训练序列长度,计算复杂度能降低 10.53%~16.89%,并且减少 23.08% 的训练迭代次数。

前面提到,在利用神经网络均衡 PS- m -QAM 信号时,面临着星座分布概率不平衡的问题。在对出现概率较小的星座点进行判决时,样本的不平衡将导致训练好的模型表现不佳。这种现象在机器学习中也称为“长尾”问题^[117],即训练集中的只有一小分类有很多样本点,而其他类只有少数样本点^[118-119]。训练好的模型则很容易偏向有大量训练数据的头部类,而对数据有限的尾部类的训练表现不佳。近年来关于这类问题的研究发展很快^[120-122],可以实现在不增加复杂度的情况下,利用 Logit 调整来改善“长尾”情况下的机器学习状况。在文献^[107]中,复旦大学团队将 Logit 调整与复数神经网络相结合,用于实现 PS-16QAM 信号类不平衡补偿,最终实现了 4.6 km 的长距离无线传输,传输速率达到 35.6 Gbit/s。此外,我们还讨论了三种 Logit 调整方法的性能,包括 FL (focal loss)^[120]、WSL (weighted softmax loss)^[121] 和 CBL (class-balanced loss)^[122]。结果表明,Logit 调整可以提高 CVNN 对 PS-QAM 信号的均衡性能。此外,与其他方法相比,采用 WSL 的 CVNN 取得了较低的 PS-16QAM 信号的误码率和较低的复杂度。

5.2.1 带有 Logit 校准的复数神经网络分类器

图 26 是一个带有 Logit 校准的 CVNN^[107]的框架,不同 Logit 校准方法的输出结果是不同的,下面将对三种 Logit 校准方法分别进行介绍。




图 26 带有 Logit 校准的 CVNN^[107]

Fig. 26 CVNN with Logit adjustments^[107]

1) FL^[120]

$$L_{\text{loss FL}} = -(1 - p_u)^\gamma \ln(p_u). \quad (22)$$

可以看出,式(22)对比交叉熵函数式(20)增加了

一个校准系数 $(1 - p_u)^\gamma$,其中, γ 为人工校准参数, p_u 反映了分类的置信度。置信度越高,说明样本容易判定,置信度越低,说明分类的难度越大。因此,损失函

数 FL 解决了长尾问题,相对增加了样本较少的类的权重,而减少了主要类的权重。

2) CBL^[122]

$$L_{\text{loss cb}} = -\frac{(1-\mu)}{(1-\mu^{n_u})} \ln(p_u), \quad (23)$$

式中: μ 是一个人为可调的参数; n_u 代表样本 μ 的数量。校准系数 $\frac{1-\mu}{1-\mu^{n_u}}$ 降低了损失函数中高概率样本的权重,增加了损失函数中低概率样本的权重。损失函数偏向于数字较少的样本,从而提高了低概率样本的分类精度。其缺陷是,当 n_u 很大时,分母将退化为 1,使得区分高概率和低概率样本变得很困难。

3) WSL^[121]

$$L_{\text{loss wsl}} = -\frac{1}{\pi_u^\tau} \ln(p_u). \quad (24)$$

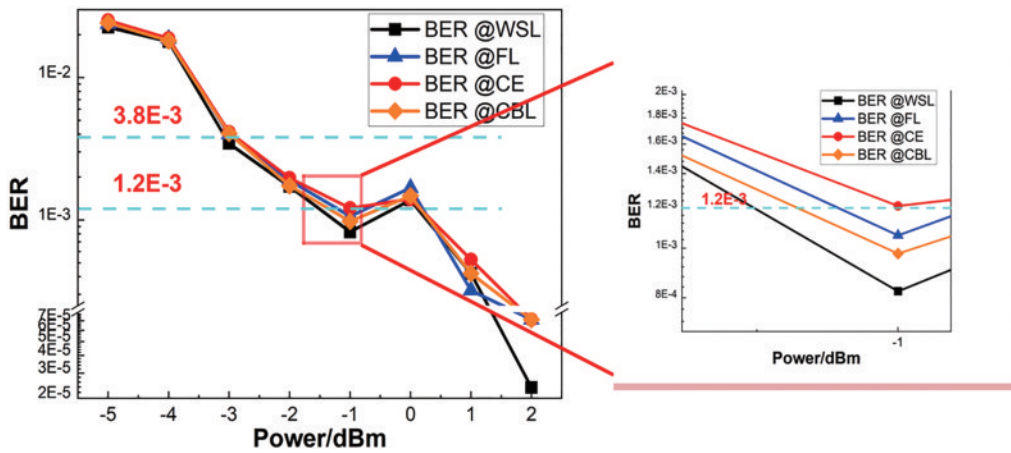


图 27 当接收功率从-5 dBm~1 dBm变化时,PS-16QAM的误码率^[107]

Fig. 27 BER of PS-16QAM when receiving power changes from -5 dBm to 1 dBm^[107]

当光功率为-3 dBm时,WSL首先达到了 3.45×10^{-3} 的误码率,低于 3.8×10^{-3} (7%的硬判决 FEC 阈值)。其他 Logit 校准方法和交叉熵均需要光功率为-2 dBm才能达到硬判决门限。在接收光功率为 2 dBm 时,带 WSL 的 CVNN 实现了 2.35×10^{-5} 的误码率,低于其他方案。通过 BER 曲线分析可以得到,相同误码率下不同损失函数所需的接收功率,如表 9 所示。由表 9 可知,WSL 可以提供 0.3 dBm 的接收灵敏度增益。在误码率为 1.2×10^{-3} 时,与交叉熵损失函数 CE 相比,FL、CBL 和 WSL 可以分别提供 0.2 dBm~0.5 dBm 的接收灵敏度增益。值得注意的是,带 WSL 的 CVNN(0.5 dBm

表 9 达到相同 BER 时不同损失函数所需的接收光功率

Table 9 Receiving power required for different loss functions at the same BER

BER	Receiving power /dBm			
	CE	FL	CBL	WSL
3.8×10^{-3}	-2.9	-2.9	-2.9	-3.2
1.2×10^{-3}	-1	-1.2	-1.3	-1.5

可以看出,校准系数 π_u^τ 被添加到损失函数 WSL 中,其中, τ 是一个人为的可调参数, π_u^τ 代表样本的发生频率,表示为

$$\pi_u = n_u/n, \quad (25)$$

式中: n 代表训练集的总样本数。校准因子降低了损失函数中高频出现的类别的权重,同时增加了损失函数中低频率出现的类别的权重。损失函数偏向于低频率的类别,从而提高其分类精度。

5.2.2 结果与讨论

当三种损失函数 FL、CE 和 CBL 的最佳参数固定($\gamma=2.5, \mu=0.958, \tau=0.2$)后,为了验证结合 Logit 校准的 CVNN 方案补偿 PS-16QAM 信号的性能,进一步使用带有 CE、CBL、WSL 和 FL 这几种不同损失函数的 CVNN,测试不同接收光功率下的 PS-16QAM 信号的误码性能^[107]。

灵敏度增益)在这三种 Logit 校准方法中表现更好。

5.3 均衡技术小结

传统的 DSP 均衡器如 CMA(CMMA)、DDLMS 以及 Volterra 均衡器都是用于给定任务的、基于领域知识或物理机制的方法。CMA 以及 DDLMS 适用于均衡线性损伤,而二阶 Volterra 均衡器常用于均衡非线性损伤。传统均衡器的性能远不如深度学习算法。当信号发射端采用概率整形技术时,会导致神经网络中出现类不平衡问题,性能大幅度下降。此时可以在传统 DSP 和 ML 算法的基础上,使用复数随机过采样,即 ROS-CVNN 分类器;也可以使用一种带有加权损伤函数的复数分类器,即先进的 Logit 校准技术结合 CVNN 分类器,去取代传统算法。

6 结束语

本文介绍了目前应用光子技术办法产生超高速 THz 波无线信号的国内外主要进展及两种技术路线,接着通过对宽带太赫兹无线通信的非线性效应的理论模型的分析,总结了光子太赫兹系统中强非线性效应

的主要来源,包括激光器、光纤、EA、MZM、PD等。为了对太赫兹无线行为进行精确建模,本文展示了一些经典的 ML 技术,包括深度学习、LSTM、dual-GRU 等。然而,这些算法是纯数据驱动的方法,需要大量的训练数据。本文从三个方面来处理这个问题:1)成功地使用了模型驱动的深度学习方法,实现了更准确的误码率判决和更快的训练速度,实现了传统的 CMA 模型与纯数据驱动的深度学习方法相连接。2)由于相干检测的中频信号是复数的,强调使用 CReLU 的复数激活函数进行信道均衡,实现了利用端到端神经网络模型从原始输入数据中直接恢复,其性能优于 DNN、LSTM 和其他实数网络。3)将神经网络均衡与先进的 DSP 算法相结合,这种方法可以显著降低计算复杂度,提高接收机灵敏度和误码率判决精度。此外,本文调研了一种基于类别平衡机器学习的复数神经网络非线性均衡技术,主要分为两种方案,一种是在 DSP 算法和 ML 算法基础上,通过使用复数分类器加上复数随机过采样,成功实现了 335 GHz 下 44 Gbit/s THz PS-64QAM 光纤无线传输,超过 200 m 无线链路。根据提出的方案,首先对接收的信号进行处理,然后进行下变频、下采样、CMA、FOE、CPR 和 DD-LMS。然后,通过 CVNN 分类器对恢复的复数 PS-64QAM 信号进行分类。本文还比较了传统 DSP 算法、RVNN_{I/Q} 和结合 ROS 的 CVNN 分类器判决精度方面的表现。从比较结果可以得出结论,在训练精度方面,ROS-CVNN 分类器比其他分类器和均衡器在误码率为 6×10^{-2} 量级时的接收灵敏度平均高出 0.5 dB~1 dB。在第二种方案中,本文介绍了一种利用 Logit 校准应对机器学习中长尾效应的方法,提出了一种带有加权损失函数的新型复数分类器,可取代 PS-16QAM 信号在 W 波段长距离传输的传统算法。本文采用先进的 Logit 校准技术结合 CVNN 分类器,实现了 W 波段 4.6 km PS-16QAM 信号的传输,传输比特率达到 35.6 Gbit/s。

对未来大速度、高容量的太赫兹通信技术发展的设想将集中在以下 5 个方面。

1) 实现端到端 AI 智能均衡

针对光子辅助太赫兹通信系统中所遇到的复杂线性和非线性干扰问题,继续发展端到端的 AI 算法智能化均衡补偿光子辅助太赫兹信号的方法。该方法主要使用端到端的神经网络统一结构,替代传统的多网络模块级联结构。通过利用大量的实际通信系统中的发射和接收数据,该方法能够学习端到端的信道状况,并完成网络参数的优化,从而实现最优的信号均衡性能。在该方法中,使用了端到端的神经网络统一结构,能够避免传统方法中各个模块之间传递导致的误差积累。此外,该方法通过使用大量的实际通信数据,能够更加真实地反映通信系统的特性,并且能够对信道状况进行更加准确的学习和预测。最终,该方法可以实现更高效、更准确的信号均衡处理,提高光子辅助太赫兹通

信系统的整体性能和可靠性。总之,采用 AI 算法智能化均衡补偿光子辅助太赫兹信号的方法,能够有效地解决光子辅助太赫兹通信系统中复杂的线性和非线性干扰问题,同时通过端到端的神经网络统一结构和大量实际通信数据的使用,可以获得更好的信道状况学习和预测能力,从而实现更高效、更准确的信号均衡处理,提高通信系统的性能和可靠性。

2) 研究高频谱利用率光子预整形、多天线 THz 信号产生技术

相比于传统电路信号产生方式,光子 THz 波技术可以有效克服电子器件带宽瓶颈,大幅度简化系统结构,具有灵敏度高、功耗低的优势。将光子辅助 THz 技术和概率整形、高阶调制码、多维复用等高频谱效率的技术相结合,可充分发挥光纤带宽大的优势。未来我们将继续研究各种高频谱利用率技术,例如高阶调制技术、Nyquist 整形技术与 MIMO 空分复用、天线极化复用等各种多维复用技术,使之在 THz 波段协调融合,降低信号波特率并提高系统容量。光子辅助 THz 波产生、传输和相应的数字信号处理技术正处于发展的重要阶段,为了进一步降低计算复杂度、提高判决精度,需要加大科研力量,研究面向 6G 高速光载太赫兹无线的空/时/频多域非线性智能均衡技术,这对于未来 6G 大容量 THz 波段无线空间通信的理论和关键技术研究,具有重要的科学和实践意义。目前主要研究方向包括:研究基于高阶调制、概率整形、Nyquist 整形等高频谱利用率技术和空分复用技术的大容量光载太赫兹无线传输系统架构;研究数据驱动的神经网络端到端信道建模方法,在不同的传输场景下实现空-时-频信息的联合估计;研究匹配相干探测和概率整形技术的平衡数据预处理和交叉熵权重优化算法,进一步简化计算复杂度,使光子 THz 波无线通信融合系统朝着高速、大容量、低成本、灵活和稳定的方向发展。

3) 研究基于深度神经网络的空/时/频多维非线性自适应均衡技术

为了实现光载太赫兹波大容量传输,多通道太赫兹通信在单天线单入单出的基础上实现了频率维度上的传输容量提升,多天线 MIMO 空分复用机制可以进一步有效提升空间维度的太赫兹通信传输容量。除了光纤传输信道和光电转换中的线性和非线性损伤,还需要考虑多路空分信道之间的串扰。传统的智能均衡技术能够独立分析时域、频域或空域上的干扰约束,目前先进的均衡技术仍局限在时频或空频双维度上,没有完全建立空、时、频上的信息连接。未来将继续研究包含 MIMO 蝶形空域均衡、时间延迟时域均衡和单载波频域均衡等子网络的智能网络均衡总体结构,根据下变频太赫兹信号提取时频特征,输入 MIMO 空域蝶形子网络,可同时实现空-时-频的非线性自适应均衡。为了解决传统人工智能算法复杂度高与处理延时长

问题,可以根据子网络类型合理分配网络结构类型,例如循环神经网络、卷积神经网络和 BP 反馈神经网络,使得网络训练变得简单高效。

4) 研究联合物理层和网络应用层的 AI 设计

在 THz 波段,实现联合物理层和网络应用层的 AI 设计将成为未来一个重要的研究方向。考虑到实际的无线物理层有其自身的要求,联合使用复杂的深度学习和传统的先进 DSP 技术会有很多收获。该领域的研究可以利用物理层的信息来优化网络应用层的决策,利用网络应用层的信息来优化物理层的设计,以及利用联合的物理层和网络应用层的信息来实现端到端的优化。这需要设计高效的算法和模型,利用基于深度学习的神经网络进行信道建模以实现快速、准确的决策和设计。通过训练神经网络,将物理层的信道状态信息作为输入,将网络应用层的数据传输速率作为输出,建立信道状态和数据传输速率之间的映射关系,从而实现对接口的建模。通过信道建模,可以更准确地评估信道质量,优化调度算法,提高网络性能。其次,可以利用神经网络进行自适应调制。通过训练神经网络,将网络应用层的数据分布特征作为输入,将物理层的信号调制方式作为输出,建立数据分布和信号调制方式之间的映射关系,从而自适应地选择最优的信号调制方式,提高信号传输效率。未来的研究将集中于探索更加高效和可靠的 AI 设计方法,以实现 THz 波段无线通信的高速、大容量、低成本、灵活和稳定的发展。

5) 机器学习算法在实时通信中的实现

经典的机器学习算法并不适用于实时通信,较高的复杂度使其难以从新的数据中持续学习。实时机器学习算法需要考虑实时学习和实时推理带来的约束,同时又对计算速度、泛化能力和鲁棒性提出了更高的要求。太赫兹传输系统中数据速率更快,对系统性能要求更高,需要更强大的硬件技术和更完善的机器学习算法。该领域的研究可以从硬件技术和机器学习算法两方面入手。机器学习算法方面,可以通过结合模型驱动的方法,改善经典的机器学习算法结构,降低算法计算复杂度,并保持泛化能力和鲁棒性,此外也可以利用新的机器学习范式,如脉冲神经网络等,有望解决经典机器学习算法存在的问题。另一方面也可以从硬件技术角度出发,研究机器学习的并行实时资源处理优化算法,这需要对数据结构、算法、电路及系统进行大量的研究和开发。

参 考 文 献

- [1] Ahmed F, Furqan M, Heinemann B, et al. 0.3-THz SiGe-based high-efficiency push-push VCOs with > 1 -mW peak output power employing common-mode impedance enhancement[J]. IEEE Transactions on Microwave Theory and Techniques, 2018, 66(3): 1384-1398.
- [2] Wang L, Qiu H S, Jin P, et al. THz generation by optical rectification of femtosecond laser pulses in a liquid crystal[J]. Journal of the Optical Society of America B, 2022, 39(3): A89-A93.
- [3] Nagatsuma T, Takada T, Song H J, et al. Millimeter- and THz-wave photonics towards 100-Gbit/s wireless transmission[C]//2010 23rd Annual Meeting of the IEEE Photonics Society, November 7-11, 2010, Denver, CO, USA. New York: IEEE Press, 2011: 385-386.
- [4] Shams H, Fice M J, Balakier K, et al. Photonic generation for multichannel THz wireless communication [J]. Optics Express, 2014, 22(19): 23465-23472.
- [5] Wang Y Y, Zhao F, Wang K H, et al. Integrated terahertz high-speed data communication and high-resolution radar sensing system based-on photonics[C]//2021 European Conference on Optical Communication (ECOC), September 13-16, 2021, Bordeaux, France. New York: IEEE Press, 2021.
- [6] Tan Y X, Zhao F, He M H, et al. Transmission of high-frequency terahertz band signal beyond 300 GHz over metallic hollow core fiber[J]. Journal of Lightwave Technology, 2022, 40(3): 700-707.
- [7] Li X Y, Yu J J, Wang K H, et al. Photonics-aided 2×2 MIMO wireless terahertz-wave signal transmission system with optical polarization multiplexing[J]. Optics Express, 2017, 25(26): 33236-33242.
- [8] Li X Y, Yu J J, Wang K H, et al. 120 Gb/s wireless terahertz-wave signal delivery by 375 GHz-500 GHz multi-carrier in a 2×2 MIMO system[J]. Journal of Lightwave Technology, 2019, 37(2): 606-611.
- [9] Rodrigues F, Ferreira R, Castro C, et al. Hybrid fiber-optical/THz-wireless link transmission using low-cost IM/DD optics[C]//Optical Fiber Communication Conference (OFC) 2020, March 8-12, 2020, San Diego, California. Washington, DC: Optica Publishing Group, 2020: W2A.40.
- [10] Li W P, Yu J J, Wang F, et al. Photonics millimeter wave bidirectional full-duplex communication based on polarization multiplexing[J]. Optics Letters, 2022, 47(24): 6389-6392.
- [11] Wang C, Yu J J, Li X Y, et al. Fiber-THz-fiber link for THz signal transmission[J]. IEEE Photonics Journal, 2018, 10(2): 7200706.
- [12] Li X Y, Yu J J, Wang K H, et al. 120 Gb/s wireless terahertz-wave signal delivery by 375 GHz-500 GHz multi-carrier in a 2×2 MIMO system[J]. Journal of Lightwave Technology, 2019, 37(2): 606-611.
- [13] Yu J J, Wei Y. Digital signal processing for high-speed THz communications[J]. Chinese Journal of Electronics, 2022, 31(3): 534-546.
- [14] Zhang J, Zhu M, Lei M Z, et al. Real-time demonstration of 103.125-Gbps fiber-THz-fiber 2×2 MIMO transparent transmission at 360-430 GHz based on photonics[J]. Optics Letters, 2022, 47(5): 1214-1217.
- [15] Wang C, Wang K H, Tan Y X, et al. High-speed terahertz band radio-over-fiber system using hybrid time-frequency domain equalization[J]. IEEE Photonics Technology Letters, 2022, 34(11): 559-562.
- [16] Zhu M, Zhang J, Yu J J, et al. Demonstration of record-high 352-Gbps terahertz wired transmission over hollow-

- core fiber at 325 GHz[J]. *Science China Information Sciences*, 2021, 65(2): 1-2.
- [17] Wang Y Y, Li W P, Ding J J, et al. Integrated high-resolution radar and long-distance communication based on photonic in terahertz band[J]. *Journal of Lightwave Technology*, 2022, 40(9): 2731-2738.
- [18] Tan Y X, Zhao F, He M H, et al. Transmission of high-frequency terahertz band signal beyond 300 GHz over metallic hollow core fiber[J]. *Journal of Lightwave Technology*, 2022, 40(3): 700-707.
- [19] Ding J J, Tan Y X, Wang Y Y, et al. 352-Gbit/s single line rate THz wired transmission based on PS-4096QAM employing hollow-core fiber[J]. *Digital Communications and Networks*, 2023, 9(3): 717-722.
- [20] Ding J J, Li W P, Wang Y Y, et al. 124.8-gbit/s PS-256QAM signal wireless delivery over 104 m in a photonics-aided terahertz-wave system[J]. *IEEE Transactions on Terahertz Science and Technology*, 2022, 12(4): 409-414.
- [21] Ding J J, Zhang L, Liu J X, et al. THz-over-fiber transmission with a net rate of 5.12 Tbps in an 80 channel WDM system[J]. *Optics Letters*, 2022, 47(12): 3103-3106.
- [22] Ding J J, Wang M X, Li W P, et al. 200-m PS-64QAM THz-wave signal wireless transmission utilizing likelihood-based selection radius-directed equalizer[J]. *Optics Letters*, 2022, 47(15): 3904-3907.
- [23] Li W P, Yu J J, Ding J J, et al. 104 meters photonics-aided terahertz wireless transmission without terahertz amplifier[J]. *IEEE Photonics Technology Letters*, 2022, 34(16): 858-861.
- [24] Li W P, Yu J J, Zhu B W, et al. Photonics-aided THz-wireless transmission over 400 m at 335 GHz[J]. *Science China Technological Sciences*, 2022, 65(12): 3082-3084.
- [25] Zhu B W, Wang Y Y, Kong M, et al. Photonics-aided terahertz-wave wireless communication employing advanced post-equalizer[J]. *IEEE Photonics Technology Letters*, 2022, 34(23): 1269-1272.
- [26] Zhang J, Zhu M, Hua B C, et al. Real-time demonstration of 100 GbE THz-wireless and fiber seamless integration networks[J]. *Journal of Lightwave Technology*, 2023, 41(4): 1129-1138.
- [27] Zhu M, Zhang J, Hua B C, et al. Ultra-wideband fiber-THz-fiber seamless integration communication system toward 6G: architecture, key techniques, and testbed implementation[J]. *Science China Information Sciences*, 2022, 66(1): 113301.
- [28] Zhao F, Yang X W, Zhao L, et al. Demonstration of 4096QAM THz MIMO wireless delivery employing one-bit delta-sigma modulation[J]. *Optics Letters*, 2022, 47(24): 6361-6364.
- [29] Schneider T. Ultrahigh-bitrate wireless data communications via THz-links; possibilities and challenges[J]. *Journal of Infrared, Millimeter, and Terahertz Waves*, 2015, 36(2): 159-179.
- [30] Ding Q, Wang M G, Mu H Q, et al. Full-duplex broadcast RoF-WDM-PON with self-coherent detection and photonic frequency up/down-conversion using SSB pilot-carrier[J]. *Optics Communications*, 2018, 427: 54-60.
- [31] Zabala-Blanco D, Mora M, Azurdia-Meza C A, et al. Extreme learning machines to combat phase noise in RoF-OFDM schemes[J]. *Electronics*, 2019, 8(9): 921.
- [32] Liu S M, Xu M, Wang J, et al. A multilevel artificial neural network nonlinear equalizer for millimeter-wave mobile fronthaul systems[J]. *Journal of Lightwave Technology*, 2017, 35(20): 4406-4417.
- [33] Cavdar A, Türk K. Artificial neural network based indoor positioning in visible light communication systems [C]//2018 International Conference on Artificial Intelligence and Data Processing (IDAP), September 28-30, 2018, Malatya, Turkey. New York: IEEE Press, 2019.
- [34] Xu T Y, Xu T H, Darwazeh I. Deep learning for interference cancellation in non-orthogonal signal based optical communication systems[C]//2018 Progress in Electromagnetics Research Symposium (PIERS-Toyama), August 1-4, 2018, Toyama, Japan. New York: IEEE Press, 2019: 241-248.
- [35] Shinde P P, Shah S. A review of machine learning and deep learning applications[C]//2018 Fourth International Conference on Computing Communication Control and Automation (ICCUBEA), August 16-18, 2018, Pune, India. New York: IEEE Press, 2019.
- [36] Li L, Hou H J, Meng W X. Convolutional-neural-network-based detection algorithm for uplink multiuser massive MIMO systems[J]. *IEEE Access*, 2020, 8: 64250-64265.
- [37] Tang F X, Fadlullah Z M, Mao B M, et al. An intelligent traffic load prediction-based adaptive channel assignment algorithm in SDN-IoT: a deep learning approach[J]. *IEEE Internet of Things Journal*, 2018, 5(6): 5141-5154.
- [38] Dai X X, Li X, Luo M, et al. LSTM networks enabled nonlinear equalization in 50-Gb/s PAM-4 transmission links[J]. *Applied Optics*, 2019, 58(22): 6079-6084.
- [39] Liu X Y, Wang Y J, Wang X S, et al. Bi-directional gated recurrent unit neural network based nonlinear equalizer for coherent optical communication system[J]. *Optics Express*, 2021, 29(4): 5923-5933.
- [40] Zhang J, Yu J J, Li X Y, et al. 200 Gbit/s/ λ PDM-PAM-4 PON system based on intensity modulation and coherent detection[J]. *Journal of Optical Communications and Networking*, 2019, 12(1): A1-A8.
- [41] Xie C J, Spiga S, Dong P, et al. Generation and transmission of 100-Gb/s PDM 4-PAM using directly modulated VCSELs and coherent detection[C]//Optical Fiber Communication Conference, March 9-13, 2014, San Francisco, California. Washington, DC: OSA, 2014: Th3K. 2.
- [42] Zhou X, Zhong K P, Huo J H, et al. 112 Gb/s transmission over 80 km SSMF using PDM-PAM4 and coherent detection without optical amplifier[J]. *Optics Express*, 2016, 24(15): 17359-17371.
- [43] Kakkar A, Navarro J R, Pang X D, et al. Low complexity timing recovery algorithm for PAM-8 in high

- speed direct detection short range links[C]//Optical Fiber Communication Conference, March 19-23, 2017, Los Angeles, California. Washington, DC: OSA, 2017: W2A.54.
- [44] Zhang J, Gou P Q, Kong M, et al. PAM-8 IM/DD transmission based on modified lookup table nonlinear predistortion[J]. *IEEE Photonics Journal*, 2018, 10(3): 7903709.
- [45] Liu R, Guo Y X, Zhu S B. Modulation recognition method of complex modulation signal based on convolution neural network[C]//2020 IEEE 9th Joint International Information Technology and Artificial Intelligence Conference (ITAIC), December 11-13, 2020, Chongqing, China. New York: IEEE Press, 2021: 1179-1184.
- [46] Wang C, Du J B, Chen G Y, et al. QAM classification methods by SVM machine learning for improved optical interconnection[J]. *Optics Communications*, 2019, 444: 1-8.
- [47] Al-Nuaimi D H, Akbar M F, Salman L B, et al. AMC2N: automatic modulation classification using feature clustering-based two-lane capsule networks[J]. *Electronics*, 2021, 10(1): 76.
- [48] Hirose A. Applications of complex-valued neural networks to coherent optical computing using phase-sensitive detection scheme[J]. *Information Sciences-Applications*, 1994, 2(2): 103-117.
- [49] Trabelsi C, Bilaniuk O, Zhang Y, et al. Deep complex networks[EB/OL]. (2017-05-27) [2023-03-04]. <https://arxiv.org/abs/1705.09792>.
- [50] An J P, Wu Y B, Liu G M. Delay and Doppler shift joint tracking method for OFDM based aeronautical communication systems[C]//2008 4th International Conference on Wireless Communications, Networking and Mobile Computing, October 12-14, 2008, Dalian, China. New York: IEEE Press, 2008.
- [51] Zhou W, Zhang J, Han X F, et al. PAM-4 delivery based on pre-distortion and CMMA equalization in a ROF system at 40 GHz[J]. *Optics Communications*, 2018, 416: 61-65.
- [52] Li X Y, Yu J J, Xu Y M, et al. 60-Gbps W-band 64QAM RoF system with T-spaced DD-LMS equalization[C]//2017 Optical Fiber Communications Conference and Exhibition (OFC), March 19-23, 2017, Los Angeles, CA, USA. New York: IEEE Press, 2017.
- [53] Yang Y, Sun J, Li H B, et al. ADMM-net: a deep learning approach for compressive sensing MRI[EB/OL]. (2017-05-19) [2023-04-05]. <https://arxiv.org/abs/1705.06869>.
- [54] Ito D, Takabe S, Wadayama T. Trainable ISTA for sparse signal recovery[J]. *IEEE Transactions on Signal Processing*, 2019, 67(12): 3113-3125.
- [55] Chen X H, Liu J L, Wang Z Y, et al. Theoretical linear convergence of unfolded ISTA and its practical weights and thresholds[EB/OL]. (2018-08-29) [2023-05-04]. <https://arxiv.org/abs/1808.10038>.
- [56] Gregor K, LeCun Y. Learning fast approximations of sparse coding[EB/OL]. [2023-05-06]. <https://icml.cc/Conferences/2010/papers/449.pdf>.
- [57] He H T, Wen C K, Jin S, et al. A model-driven deep learning network for MIMO detection[C]//2018 IEEE Global Conference on Signal and Information Processing (GlobalSIP), November 26-29, 2018, Anaheim, CA, USA. New York: IEEE Press, 2019: 584-588.
- [58] He H T, Jin S, Wen C K, et al. Model-driven deep learning for physical layer communications[J]. *IEEE Wireless Communications*, 2019, 26(5): 77-83.
- [59] Glushkov V, Svinarenko A A, Loboda A V. Theory of neural networks on basis of photon echo and its program realization[M]. Odessa: TEC, 2004.
- [60] Gordienko V N. Optical telecommunication systems[M]. Moscow: Hotline-Telecom, 2011.
- [61] Graupe D. Deep Learning neural networks: design and case studies[M]. Hackensack: WORLD SCIENTIFIC, 2016.
- [62] Goodfellow Y, Courville B A. Deep learning[M]. Cambridge: The MIT Press, 2016.
- [63] Aggarwal C C. Neural networks and deep learning: a textbook[M]. Cham: Springer, 2018.
- [64] Sehovac L, Grolinger K. Deep learning for load forecasting: sequence to sequence recurrent neural networks with attention[J]. *IEEE Access*, 2020, 8: 36411-36426.
- [65] Wang W H, Chang B B. Graph-based dependency parsing with bidirectional LSTM[C]//Proceedings of the 54th Annual Meeting of the Association for Computational Linguistics (Volume 1: Long Papers), August 7-12, 2016, Berlin, Germany. Stroudsburg: Association for Computational Linguistics, 2016: 2306-2315.
- [66] Li P X, Yi L L, Xue L, et al. 56 Gbps IM/DD PON based on 10G-class optical devices with 29 dB loss budget enabled by machine learning[C]//2018 Optical Fiber Communication Conference, March 11-15, 2018, San Diego, California. New York: IEEE Press, 2018.
- [67] Deligiannidis S, Bogris A, Mesaritakis C, et al. Compensation of fiber nonlinearities in digital coherent systems leveraging long short-term memory neural networks[J]. *Journal of Lightwave Technology*, 2020, 38(21): 5991-5999.
- [68] Pfau T, Hoffmann S, Noe R. Hardware-efficient coherent digital receiver concept with feedforward carrier recovery for M-QAM constellations[J]. *Journal of Lightwave Technology*, 2009, 27(8): 989-999.
- [69] Fatadin I, Ives D, Savory S J. Laser linewidth tolerance for 16-QAM coherent optical systems using QPSK partitioning[J]. *IEEE Photonics Technology Letters*, 2010, 22(9): 631-633.
- [70] Harter T, Ummethala S, Blaicher M, et al. Wireless THz link with optoelectronic transmitter and receiver[J]. *Optica*, 2019, 6(8): 1063-1070.
- [71] Pang X D, Ozolins O, Jia S, et al. Bridging the terahertz gap: photonics-assisted free-space communications from the submillimeter-wave to the mid-infrared[J]. *Journal of Lightwave Technology*, 2022, 40(10): 3149-3162.
- [72] Li X Y, Yu J J, Zhao L, et al. 1-Tb/s photonics-aided vector millimeter-wave signal wireless delivery at D-band [C]//Optical Fiber Communication Conference Postdeadline

- Papers, March 11-15, 2018, San Diego, California. New York: IEEE Press, 2018.
- [73] Jia S, Zhang L, Wang S W, et al. 2×300 Gbit/s line rate PS-64QAM-OFDM THz photonic-wireless transmission[J]. *Journal of Lightwave Technology*, 2020, 38(17): 4715-4721.
- [74] Ding J J, Li W P, Zhang L, et al. Demonstration of 6.4-Tbit/s THz-wave signal transmission over 20-km wired and 54-m wireless distance[C]//2022 European Conference on Optical Communication (ECOC), September 18-22, 2022, Basel, Switzerland. New York: IEEE Press, 2022.
- [75] Hong X, Chen S, Harris C J. B-spline neural network based single-carrier frequency domain equalisation for Hammerstein channels[C]//2014 International Joint Conference on Neural Networks (IJCNN), July 6-11, 2014, Beijing, China. New York: IEEE Press, 2014: 1834-1841.
- [76] Fernandes C. Nonlinear MIMO communication systems: channel estimation and information recovery using Volterra models[EB/OL]. [2023-05-06]. <https://theses.hal.science/tel-00460160/document>.
- [77] Liu S M, Wang X Y, Zhang W H, et al. An adaptive activated ANN equalizer applied in millimeter-wave RoF transmission system[J]. *IEEE Photonics Technology Letters*, 2017, 29(22): 1935-1938.
- [78] Liu S M, Alfidhli Y M, Shen S Y, et al. A novel ANN equalizer to mitigate nonlinear interference in analog-RoF mobile fronthaul[J]. *IEEE Photonics Technology Letters*, 2018, 30(19): 1675-1678.
- [79] Ganesh S, Sayee Sunder V, Thakre A. Performance improvement in Rayleigh faded channel using deep learning[C]//2018 International Conference on Advances in Computing, Communications and Informatics (ICACCI), September 19-22, 2018, Bangalore, India. New York: IEEE Press, 2018: 1307-1312.
- [80] Wang F, Yu J J, Wang Y Y, et al. Delivery of polarization-division-multiplexing wireless millimeter-wave signal over 4.6-km at W-band[J]. *Journal of Lightwave Technology*, 2022, 40(19): 6339-6346.
- [81] 柏果, 程郁凡, 唐万斌. 基于深度学习的单载波频域均衡算法研究[J]. *信号处理*, 2021, 37(6): 922-931.
- Bai G, Cheng Y F, Tang W B. Deep learning-based single-carrier frequency-domain equalization[J]. *Journal of Signal Processing*, 2021, 37(6): 922-931.
- [82] Wang C, Yu J J, Zhang J A, et al. Beyond 300-Gbps/ λ photonics-aided THz-over-fiber transmission employing MIMO single-carrier frequency-domain equalizer[J]. *Optics Letters*, 2023, 48(6): 1363-1366.
- [83] Wen, Zhou. Research on AI techniques in broadband Terahertz communications. *Sensors* 2022, 22.
- [84] Wang W H, Tao Y D, Ma J G, et al. Parametric generation and phase locking of multiple sidebands in the regime of full-back-conversion[J]. *High Power Laser Science and Engineering*, 2023, 11: e21.
- [85] Shi J T, Zhou W, Zhao L. Modeling device nonlinearity in MMW transmitter systems based on photonics-aided technology[C]//2022 Asia Communications and Photonics Conference (ACP), November 5-8, 2022, Shenzhen, China. New York: IEEE Press, 2022: 1836-1839.
- [86] Yu J J, Chi N. Digital Signal Processing in high-speed optical fiber communication principle and application[M]. Singapore: Springer, 2020.
- [87] Wang T, Li C, Ren B, et al. High-power femtosecond laser generation from an all-fiber linearly polarized chirped pulse amplifier[J]. *High Power Laser Science and Engineering*, 2023, 11: e25.
- [88] Gutierrez-Estevez M A, Kasparick M, Stanczak S. Online learning of any-to-any path loss maps[J]. *IEEE Communications Letters*, 2021, 25(5): 1573-1577.
- [89] Rai A, Kannan R J. Evolutionary neurodynamic algorithm based data driven modeling of non-linear systems[J]. *International Journal of Pure and Applied Mathematics*, 2018, 118(24): 1-10.
- [90] Ma X S, Gao Z. Data-driven deep learning to design pilot and channel estimator for massive MIMO[J]. *IEEE Transactions on Vehicular Technology*, 2020, 69(5): 5677-5682.
- [91] Ma Z, Wu W, Gao F F, et al. Model-driven deeplearning for non-coherent massive machine-typecommunications[EB/OL]. (2023-01-02) [2023-08-09]. <https://arxiv.org/abs/2301.00516v1>.
- [92] Xu Z B, Sun J. Model-driven deep-learning[J]. *National Science Review*, 2018, 5(1): 22-24.
- [93] Wu F Y, Yang X H, Ma Y Y, et al. Machine-learning guided optimization of laser pulses for direct-drive implosions-CORRIGENDUM[J]. *High Power Laser Science and Engineering*, 2022, 10: e17.
- [94] He H T, Wen C K, Jin S, et al. Model-driven deep learning for MIMO detection[J]. *IEEE Transactions on Signal Processing*, 2020, 68: 1702-1715.
- [95] Zhou W, Zhao L, Zhang J, et al. 135-GHz D-band 60-Gbps PAM-8 wireless transmission employing a joint DNN equalizer with BP and CMMA[J]. *Journal of Lightwave Technology*, 2020, 38(14): 3592-3601.
- [96] Zhang L Y. Blind equalization in neural networks: theory, algorithms and applications[M]. Berlin: De Gruyter, 2017.
- [97] Giacoumidis E, Le S T, Ghanbarisabagh M, et al. Fiber nonlinearity-induced penalty reduction in CO-OFDM by ANN-based nonlinear equalization[J]. *Optics Letters*, 2015, 40(21): 5113-5116.
- [98] Li Y, Chen M H, Yang Y, et al. Convolutional recurrent neural network-based channel equalization: an experimental study[C]//2017 23rd Asia-Pacific Conference on Communications (APCC), December 11-13, 2017, Perth, WA, Australia. New York: IEEE Press, 2018.
- [99] Chi N, Zhao Y H, Shi M, et al. Gaussian kernel-aided deep neural network equalizer utilized in underwater PAM8 visible light communication system[J]. *Optics Express*, 2018, 26(20): 26700-26712.
- [100] Lu X Y, Lu C, Yu W X, 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.
- [101] Zhou W, Shi J T, Zhao L, et al. Comparison of real- and complex-valued NN equalizers for photonics-aided 90-Gbps D-band PAM-4 coherent detection[J]. *Journal of Lightwave Technology*, 2021, 39(21): 6858-6868.
- [102] Hahnloser R H R, Sarpeshkar R, Mahowald M A, et al. Digital selection and analogue amplification coexist in a cortex-inspired silicon circuit[J]. *Nature*, 2000, 405(6789): 947-951.
- [103] Liu C W, Wang C, Zhou W, et al. 81-GHz W-band 60-Gbps 64-QAM wireless transmission based on a dual-GRU equalizer[J]. *Optics Express*, 2022, 30(2): 2364-2377.
- [104] Zhao L, Wang K H, Zhou W, et al. Demonstration of 73.15 Gbit/s 4096-QAM OFDM D-band wireless transmission employing probabilistic shaping and Volterra nonlinearity compensation[C]//2020 European Conference on Optical Communications (ECOC), December 6-10, 2020, Brussels, Belgium. New York: IEEE Press, 2021.
- [105] Chang Z X, Wang Y S, Li H, et al. Complex CNN-based equalization for communication signal[C]//2019 IEEE 4th International Conference on Signal and Image Processing (ICSIP), July 19-21, 2019, Wuxi, China. New York: IEEE Press, 2019: 513-517.
- [106] Xie T Y, Yu J G, Zhou W. Photonics-aided 335 GHz PS-64QAM wireless transmission over 200 m employing complex-valued NN classification and random sampling techniques[J]. *Optics Express*, 2023, 31(6): 10333-10347.
- [107] Wang Q H, Sang B H, Shi J T, et al. A novel complex-valued classifier with a weighted loss function employed for W-band PS-16QAM transmission over 4.6 km[J]. *Optics & Laser Technology*, 2023, 163: 109369.
- [108] Ghazikhani A, Yazdi H S, Monsefi R. Class imbalance handling using wrapper-based random oversampling[C]//20th Iranian Conference on Electrical Engineering (ICEE2012), May 15-17, 2012, Tehran, Iran. New York: IEEE Press, 2012: 611-616.
- [109] Wang S, Yao X. Multiclass imbalance problems: analysis and potential solutions[J]. *IEEE Transactions on Systems, Man, and Cybernetics, Part B (Cybernetics)*, 2012, 42(4): 1119-1130.
- [110] Choirunnisa S, Lianto J. Hybrid method of undersampling and oversampling for handling imbalanced data[C]//2018 International Seminar on Research of Information Technology and Intelligent Systems (ISRITI), November 21-22, 2018, Yogyakarta, Indonesia. New York: IEEE Press, 2019: 276-280.
- [111] Yang C C, Yang F, Wang Z Y. Iterative minimum mean square error equalization for optical fiber communication systems[J]. *IEEE Photonics Technology Letters*, 2007, 19(19): 1571-1573.
- [112] de Boer P T, Kroese D P, Mannor S, et al. A tutorial on the cross-entropy method[J]. *Annals of Operations Research*, 2005, 134(1): 19-67.
- [113] Zhang N, Xue X M, Xia X, et al. Robust T-S fuzzy model identification approach based on FCRM algorithm and L1-norm loss function[J]. *IEEE Access*, 2020, 8: 33792-33805.
- [114] Duan K B, Keerthi S S. Which is the best multiclass SVM method? an empirical study[M]//Oza N C, Polikar R, Kittler J, et al. Multiple classifier systems. Lecture notes in computer science. Berlin: Springer, 2005, 3541: 278-285.
- [115] Zhang K, Wang X S, Guo Y R, et al. Competing ratio loss for multi-class image classification[C]//2019 IEEE Visual Communications and Image Processing (VCIP), December 1-4, 2019, Sydney, NSW, Australia. New York: IEEE Press, 2020.
- [116] Kurian N C, Meshram P S, Patil A, et al. Sample specific generalized cross entropy for robust histology image classification[C]//2021 IEEE 18th International Symposium on Biomedical Imaging (ISBI), April 13-16, 2021, Nice, France. New York: IEEE Press, 2021: 1934-1938.
- [117] Zhang Y F, Kang B Y, Hooi B, et al. Deep long-tailed learning: a survey[EB/OL]. (2021-10-09) [2023-08-06]. <https://arxiv.org/abs/2110.04596>.
- [118] Hong Y, Han S, Choi K, et al. Disentangling label distribution for long-tailed visual recognition[C]//2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), June 20-25, 2021, Nashville, TN, USA. New York: IEEE Press, 2021: 6622-6632.
- [119] Kang B Y, Xie S N, Rohrbach M, et al. Decoupling representation and classifier for long-tailed recognition [EB/OL]. (2019-10-21)[2023-08-07]. <https://arxiv.org/abs/1910.09217>.
- [120] Lin T Y, Goyal P, Girshick R, et al. Focal loss for dense object detection[C]//2017 IEEE International Conference on Computer Vision (ICCV), October 22-29, 2017, Venice, Italy. New York: IEEE Press, 2017: 2999-3007.
- [121] Park S, Lim J, Jeon Y, et al. Influence-balanced loss for imbalanced visual classification[C]//2021 IEEE/CVF International Conference on Computer Vision (ICCV), October 10-17, 2021, Montreal, QC, Canada. New York: IEEE Press, 2022: 715-724.
- [122] Cui Y, Jia M L, Lin T Y, et al. Class-balanced loss based on effective number of samples[C]//2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), June 15-20, 2019, Long Beach, CA, USA. New York: IEEE Press, 2020: 9260-9269.