



专题：智算光互联

超高速短距离光互连信号均衡及编码技术

秦昊¹, 杨川川¹, 蓝天祥¹, 秦忻², 赵玉萍¹, 陈章渊¹

(1. 北京大学光子传输与通信全国重点实验室, 北京 100871;

2. 中国电信股份有限公司研究院光纤光缆先进制造与应用技术全国重点实验室, 北京 100032)

摘要: 在人工智能 (artificial intelligence, AI) 大模型蓬勃发展的背景下, 数据中心光模块速率需求持续攀升。为满足超高速短距离光互连高速率、低能耗、低时延、高集成度的要求, 介绍了光模块产业发展趋势, 并着重探讨相关均衡和编码技术。在均衡技术方面, 介绍了基于最小角回归策略的低复杂度沃特均衡方法 LaNLE 和基于隐藏特征提取 (hidden feature extraction, HFE) 的神经网络均衡方法。LaNLE 在 120 Gbit/s PAM-8 信号 100 m 传输下, 相同误码率时, 复杂度相比传统方法降低了 70.1%; HFE 可提升神经网络训练效率, 实现了 288 Gbit/s PAM-8 信号传输。在编码技术方面, 介绍了光互连系统中 QC-LDPC 码优化方法和基于深度学习的 LDPC 联合均衡译码方法, 经实验验证, 所提方法能有效优化误码率, 提升系统性能。同时, 对未来研究方向进行了展望。

关键词: 光互连; 信号处理; 均衡; 编码

中图分类号: TP393

文献标志码: A

doi: 10.11959/j.issn.1000-0801.2025103

Signal equalization and coding techniques in ultra-high-speed short-reach optical interconnect

QIN Hao¹, YANG Chuanchuan¹, LAN Tianxiang¹, QIN Xin², ZHAO Yuping¹, CHEN Zhangyuan¹

1. State Key Laboratory of Photonics and Communications, Peking University, Beijing 100871, China

2. State Key Laboratory of Optical Fiber and Cable Manufacture Technology, Research Institute of China Telecom Co., Ltd., Beijing 100032, China

Abstract: Against the backdrop of the vigorous development of artificial intelligence (AI) large models, the demand for the data center optical module rate continues to rise. To meet the requirements of high rate, low power consumption, low latency, and high integration for ultra-high-speed short-reach optical interconnect, the development trend of the optical module industry was introduced, and relevant equalization and coding technologies were discussed. In terms of equalization technology, a low-complexity Volterra equalization method based on the least angle regression

收稿日期: 2025-02-18; 修回日期: 2025-04-02

通信作者: 杨川川, yangchuanchuan@pku.edu.cn

基金项目: 国家重点研发计划项目 (No.2023YFB2905501)

Foundation Item: The National Key Research and Development Program of China (No.2023YFB2905501)

strategy (LaNLE) and a deep neural network equalization method based on hidden feature extraction (HFE) were proposed. Under the 120 Gbit/s PAM-8 signal transmission, the complexity of LaNLE was reduced by 70.1% compared with traditional methods at the same bit error rate; HFE improved the neural network training efficiency and achieved 288 Gbit/s PAM-8 signal transmission. In terms of coding technology, the optimization method of QC-LDPC codes in the optical interconnection system and the LDPC joint equalization and decoding method based on deep learning were introduced. Experimental results show that the proposed methods can effectively optimize the bit error rate and improve the system performance. At the same time, the future research directions were prospected.

Key words: optical interconnect, signal processing, equalization, coding

0 引言

随着移动互联网、云计算和大数据技术的迅猛发展,全球IP流量呈现爆炸式增长。根据思科(Cisco)的报告^[1],2023年全球连接到IP网络的设备数量为全球人口数的3倍以上,IP流量的年均复合增长率高达26%。与此同时,全球大规模数据中心的数量已超过600个,其中超过70%的数据流量发生在数据中心内部。近年来,数据中心互连网络逐渐向扁平化、无阻塞趋势发展,显著提升了连接密集度与交换容量。一方面,由于资源池化,叶交换节点短距离链路连接端口数量和集成度显著提高,增加了数据中心传输容量的需求。另一方面,由于数据中心网络部署规模剧增,所部署器件的成本和功耗较为敏感。数据中心的扁平化网络架构不仅优化了数据传输路径,减少了网络层级,还大幅提升了数据传输效率,有利于更好地应对人工智能(artificial intelligence, AI)、云计算和大数据等应用场景对网络性能的高要求。这一趋势不仅推动了数据中心内部网络架构的变革,也对光互连技术提出了更高的要求。光互连器件及其通信系统具有大带宽、高密度、低功耗等特点,作为一种高效的数据传输方式,正逐渐成为数据中心和超算系统等网络信息基础设施中的核心部件。数据中心光模块作为数据中心内部和数据中心间互连的核心组件,其速率要求随着数据流量的爆发式增长和技术的不断进步而持续提升。

随着AI时代的到来,尤其是大模型(如生成式预训练模型)的飞速发展,训练和推理任务对高性能算力的需求呈现指数级增长。大模型的训练过程通常需要处理海量数据,并涉及复杂的计算任务,这对计算资源的规模和效率提出了极高的要求。为了满足这一需求,分布式计算架构应运而生,通过并行部署多个图形处理单元(graphics processing unit, GPU)节点来加速训练过程。然而,分布式架构的引入也带来了新的挑战,即各计算节点之间需要频繁交换和同步模型参数,以确保训练过程的一致性和准确性。这种频繁的数据交换对网络通信能力提出了极高的要求,网络带宽、时延和可靠性成为影响整体系统性能的关键因素。在此背景下,AI领域对光互连技术的依赖日益加深,光互连技术也逐渐成为人工智能硬件生态中的重要应用方向。应用于AI训练集群、超大规模数据中心内部互连、数据中心间高速通信的商用光模块速率已增长至800 Gbit/s甚至1.6 Tbit/s。预计至2030年,随着数据中心算力需求的持续增长,光模块速率将进一步向3.2 Tbit/s及以上发展。随着AI模型的规模不断扩大,分布式计算架构的复杂性持续增加,光互连技术需要进一步优化,以满足更高的互连需求,包括更高的传输速率、更低的能耗以及更强的抗干扰能力,从而为大规模AI模型的训练和推理提供强有力的硬件支持。

在这一背景下,行业对低能耗、低时延、高集成度光模块的需求日益迫切,这成为推动技术



革新的重要动力。传统的重定时（clock data recovery, CDR）光模块虽然能够满足高速率传输的需求，但其功耗和时延较高，难以适应AI数据中心对能效和实时性的严格要求。为此，线性驱动可插拔光（linear-drive pluggable optics, LPO）模块和线性接收光（linear receive optics, LRO）模块应运而生。LPO不需要CDR和数字信号处理（digital signal processing, DSP）模块，依赖高性能交换机的串行器/解串器（serializer/deserializer, SerDes）和高线性度的驱动器与跨阻放大器（trans-impedance amplifier, TIA）实现相关功能，从而大幅降低了功耗和时延，满足了AI大模型预训练的低时延互连需求。LRO则提供了一种介于标准CDR光模块与LPO的折中方案，即在发射端使用重定时器，线性接收器直接驱动到主机侧的专用集成电路（application specific integrated circuit, ASIC）。LRO的功耗、时延、成本降低能力虽较LPO差，但与完全重定时的模块相比，仍然起到了降低模块功耗和一定成本的作用，同时由于保留了发射端的重定时器，还能够提供一定的链路诊断能力。

在超高速短距离光互连场景下，基于垂直腔面发射激光器（vertical-cavity surface emitting laser, VCSEL）和多模光纤（multimode fiber, MMF）的强度调制/直接检测（intensity modulation/direct detection, IM/DD）系统面临信号损伤的挑战，这易导致传输错误的发生。为了补偿信号损伤并提升传输性能，通常使用均衡和编码两项关键技术。现有的均衡与编码技术研究往往以提高性能、降低误码率为目标，忽略了对复杂度的限制，导致其难以应用于未来以降低复杂度为趋势的光模块设计。为应对AI时代短距离光互连的高速率、低能耗、低时延、高集成度要求，新场景下研究的均衡和编码技术必须高效，设计为可以与驱动器集成或部署在交换机主机侧使用。针对以上需求，本文介绍了几种前沿的低复杂度高性能

均衡技术与自适应光互连信道的编码技术，并对未来的研究方向进行展望，旨在提供新场景下均衡与编码技术的研究思路与方法，以推动光互连技术在数据中心和高性能计算领域的广泛应用。

1 超高速短距离光互连均衡技术

传统的均衡算法，如前馈均衡器（feed forward equalizer, FFE）、判决反馈均衡器（decision feedback equalizer, DFE）和沃特非线性均衡器（Volterra nonlinear equalizer, VNLE）等，已在短距离光互连系统中得到广泛应用^[2-4]。为进一步补偿激光器和光链路中的非线性效应，诸多文献研究了神经网络均衡器，通过直接从原始数据拟合到最终目标来实现全局最优^[5-7]。然而，基于神经网络的均衡算法往往复杂度较高，平均每符号的处理需要几千甚至上万次乘法，不利于硬件的低时延高效实现。此外，为保证神经网络训练结果的准确性，需要大量的训练数据，同样限制了这些方法的实时应用。因此，需要研究低复杂度的非线性均衡方法，从而满足超高速短距离光互连系统高速率、低能耗、低时延、高集成度的要求。

1.1 基于最小角回归策略的低复杂度沃特均衡方法

为降低VNLE的实现复杂度，提高均衡器在光互连系统中的硬件实现效率，并降低其对信道环境的敏感性，提高稳定程度，本文研究了基于最小角回归策略的非线性均衡（least angle regression-based nonlinear equalization, LaNLE）方法^[8]。基于最小角回归策略的非线性均衡方法流程如图1所示。在训练阶段，首先进行训练初始化，包括选中特征、权重及训练输出，而后基于评价函数识别显著特征项进行特征选择，并更新所有选中特征项的权重，即均衡器抽头系数；在均衡阶段，使用训练得到的特征项抽头及相应权重对接收数据信号进行均衡，并输出补偿后的信号。

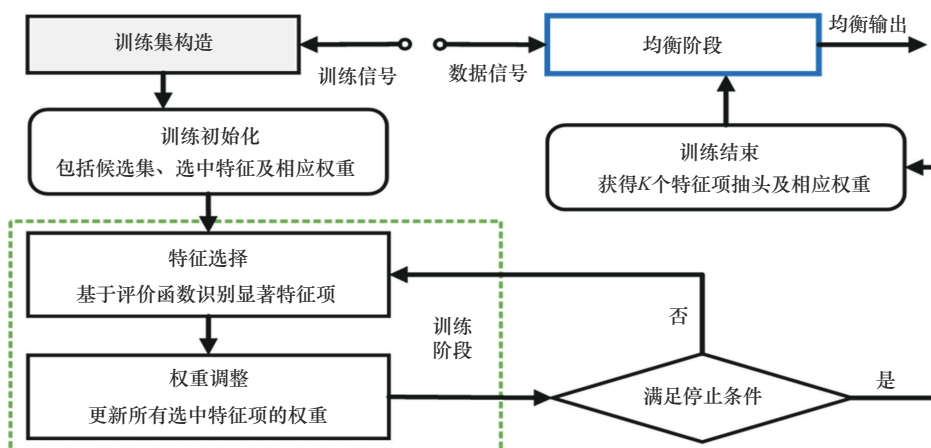


图1 基于最小角回归策略的非线性均衡方法流程

与每次剪枝后都需要重新训练的后向选择方法不同，LaNLE 采用的前向选择方法在每次迭代中只在沃特级数展开的所有特征项（候选集）中选择一个特征，通过评价函数对其重要性进行判别，直到识别出所有需要的特征项，生成显著特征集，并更新相应权重为止。使用当前残差相关性作为评价函数，其表达式为：

$$\hat{c}^{(n)}(\mathbf{v}_j) = \mathbf{v}_j^T (D - Y^{(n-1)}) \quad (1)$$

其中， \mathbf{v}_j 为候选特征向量， $\hat{c}^{(n)}(\mathbf{v}_j)$ 表示特征向量 \mathbf{v}_j 与当前残差的相关性， n 表示第 n 次迭代， D 和 Y 分别为输出向量的基准值与当前训练的输出值。训练过程中的每次迭代分为特征选择和权重调整两个阶段。在特征选择阶段，根据式 (1) 所示的评价函数，选择候选集中与当前残差相关性最大的特征项加入显著特征集，随后执行权重调整，即对显著特征集中所有特征项的权重进行更新。在权重调整阶段，首先需要确定最小角方向，即权重向量调整的步进方向。定义等角向量 $\mathbf{u}^{(n)}$ 为显著特征集中特征向量的加权和，表达式为：

$$\mathbf{u}^{(n)} = \mathbf{V}^{(n)} \boldsymbol{\rho}^{(n)} \quad (2)$$

其中， $\mathbf{V}^{(n)}$ 为显著特征集中特征向量组成的矩阵， $\boldsymbol{\rho}^{(n)}$ 为权重向量。根据等角向量 $\mathbf{u}^{(n)}$ 与显著特征集中所有特征向量的夹角相等的性质，在对特

征向量归一化处理后可以得到：

$$(\mathbf{V}^{(n)})^T \mathbf{u}^{(n)} = z^{(n)} \mathbf{1} \quad (3)$$

其中， $z^{(n)}$ 为内积值， $\mathbf{1}$ 为维度等于显著特征集大小的全 1 向量。根据式 (2) 和式 (3)，可以得到权重向量 $\boldsymbol{\rho}^{(n)}$ 和内积值 $z^{(n)}$ 分别为：

$$\boldsymbol{\rho}^{(n)} = z^{(n)} \left((\mathbf{V}^{(n)})^T \mathbf{V}^{(n)} \right)^{-1} \mathbf{1} \quad (4)$$

$$z^{(n)} = \left[\mathbf{1}^T \left((\mathbf{V}^{(n)})^T \mathbf{V}^{(n)} \right)^{-1} \mathbf{1} \right]^{-1/2} \quad (5)$$

在确定权重调整的方向 $\mathbf{u}^{(n)}$ 后，需要确定权重调整的步长 γ 。当 γ 逐渐增大时，显著特征集中特征向量与当前残差的相关性逐渐减小，直到这一相关性减小到与候选集中某个未加入显著特征集的特征向量与当前残差的相关性相等时，步长 γ 的选择就确定了，该条件可表示为：

$$\left| \hat{C}_{\max}^{(n)} - \gamma z^{(n)} \right| = \left| \hat{c}^{(n)}(\mathbf{v}_j) - \gamma \mathbf{v}_j^T \mathbf{u}^{(n)} \right| \quad (6)$$

此时确定的权重调整步长为：

$$\gamma = \min^+ \left\{ \frac{\hat{C}_{\max}^{(n)} - \hat{c}^{(n)}(\mathbf{v}_j)}{z^{(n)} - \mathbf{v}_j^T \mathbf{u}^{(n)}}, \frac{\hat{C}_{\max}^{(n)} + \hat{c}^{(n)}(\mathbf{v}_j)}{z^{(n)} + \mathbf{v}_j^T \mathbf{u}^{(n)}} \right\} \quad (7)$$

其中， \min^+ 表示取最小正值。根据得到的权重调整方向 $\mathbf{u}^{(n)}$ 与步长 γ ，即可获得更新后的输出：

$$\mathbf{Y}^{(n)} = \mathbf{Y}^{(n-1)} + \gamma \mathbf{u}^{(n)} \quad (8)$$



更新完成后，算法进入下一次迭代。当达到收敛条件要求时，使用得到的显著特征集与权重矩阵作为均衡器的最终训练结果。

根据VNLE的结构，得到其均衡复杂度表达式为：

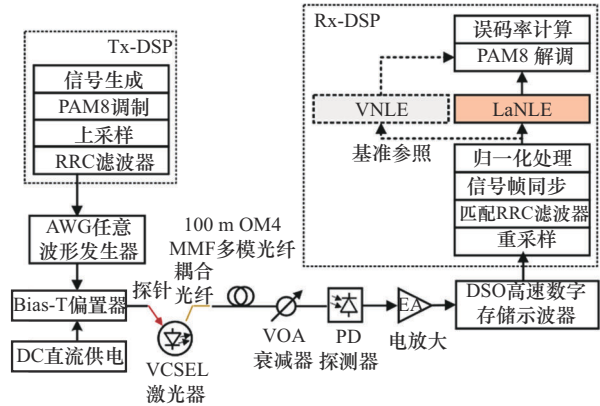
$$CC_{VNLE} = \sum_{r=1}^P r C_{M+r-1}^r = \sum_{r=1}^P \frac{(M+r-1)!}{(r-1)!(M-1)!} \quad (9)$$

其中， P 为均衡器阶数， M 为抽头数量。对于提出的LaNLE方法，由于其结构中只保留重要的特征项而丢弃冗余的抽头，均衡复杂度将大幅降低。随着显著特征项数 K 从初值零逐步增大，LaNLE的性能会快速收敛达到稳定状态，其计算复杂度呈线性增长 $O(PK)$ ，其中 P 为LaNLE结构中特征项的最高阶数。由于LaNLE的 K 个特征项具体形式由训练过程所决定，因此这里只给出其计算复杂度范围：

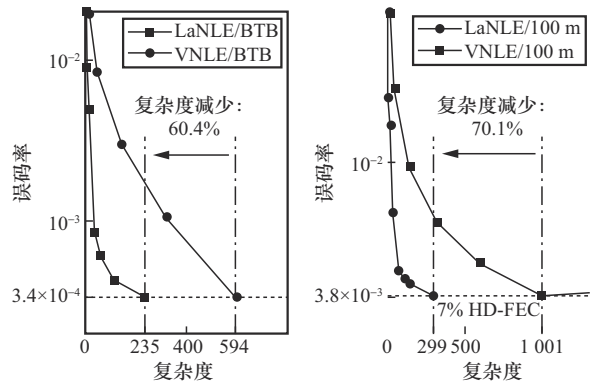
$$CC_{LaNLE} \in [K, PK] \quad (10)$$

由此可以看出，与VNLE方法相比，LaNLE方法的均衡复杂度显著降低。


LaNLE方法实验验证如图2所示。实验选取了全连接的标准VNLE作为基线进行比较。在120 Gbit/s PAM-8信号的传输条件下，当接收光功率为0 dBm时LaNLE方法和VNLE方法的误码率与复杂度关系曲线如图2(b)所示。与全连接的VNLE相比，LaNLE结构的复杂度在相同的误码率水平下，在背对背(back to back, BTB)和100 m链路中分别降低了60.4%和70.1%。基于提出的LaNLE方法，在整体链路带宽受限情况下(10.5 GHz)，实验还实现了100 m VCSEL-MMF系统的225 Gbit/s PAM8信号传输，测试误码率低于软判决前向纠错技术20%冗余度下的阈值门限(20% SD-FEC)。100 m传输场景下225 Gbit/s PAM8接收信号均衡前后眼图对比如图2(c)所示。



(a) 实验链路示意图



(b) 接收光功率为0 dBm时LaNLE方法和VNLE方法的误码率与复杂度关系曲线



(c) 100 m传输场景下225 Gbit/s PAM8接收信号均衡前后眼图对比

图2 LaNLE方法实验验证

1.2 基于隐藏特征提取的神经网络均衡方法

传统的神经网络均衡方法直接使用接收到的数据进行训练，造成了巨大的训练开销。本节提出了一种基于隐藏特征提取(hidden feature extraction, HFE)的神经网络均衡方法^[9]，该方法具有更有效的训练能力，降低了神经网络均衡器在实际系统中应用的复杂度。基于HFE的神经网络均衡方法流程如图3所示。

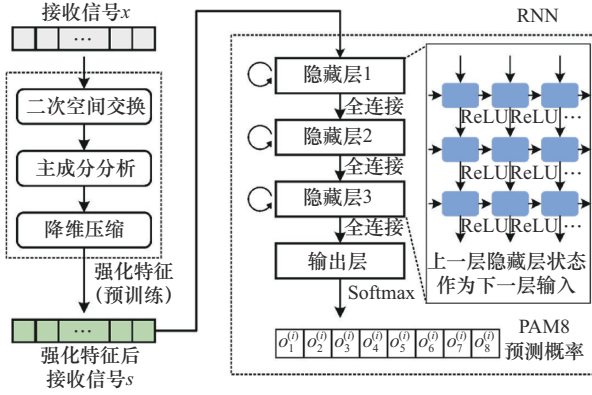


图3 基于HFE的神经网络均衡方法流程

本文在序列训练之前引入HFE作为预训练。需要注意的是，隐藏特征指的是无法从原始数据中直接观察到，但对于提高基于神经网络的信号检测至关重要的特征。这些隐藏特征可以通过如下特征学习过程来提取。基于原始接收信号序列 $\{x(t)\}$ ，二次空间变换通过考虑一定长度接收信号的可重复乘积来表征非线性记忆效应，其表达式为：

$$\begin{aligned} & [c_1^{(t)}, \dots, c_{L+1}^{(t)}, \dots, c_{2L+1}^{(t)}, c_{2L+2}^{(t)}, \dots, c_p^{(t)}, \dots, c_{N_f}^{(t)}] = \\ & [x(t+L), \dots, x(t), \dots, x(t-L), x^2(t+L), \dots, \\ & x(t-r_1)x(t-r_2), \dots, x^2(t-L)] \end{aligned} \quad (11)$$

其中， $-L \leq r_1 \leq r_2 \leq L$ ， L 为变换所需的相邻符号数量。所表征特征的数量记为 N_f ， $N_f = (2L+1)(L+2)$ 。神经网络可以直接将特征分量 $c_p^{(t)}$ ($p=1, \dots, N_f$) 作为输入进行学习，但与原始数据相比，其规模会进一步扩大。因此，需要引入主成分分析进行进一步压缩。

定义预压缩特征矩阵 A 为：

$$\begin{aligned} A &= [C_1, \dots, C_p, \dots, C_{N_f}]_{N_t \times N_f} \\ C_p &= [c_p^{(t)}, \dots, c_p^{(t+N_i-1)}]^T \end{aligned} \quad (12)$$

其中， N_t 表示训练数据的长度。由于 $A^T A$ 是实对称矩阵，且与 A 具有相同的秩，必然存在一个 N_f 阶正交矩阵 $V = (V_{ij})_{N_f \times N_f}$ ，满足：

$$V^T A^T A V = \text{diag}(\lambda_1, \dots, \lambda_m, 0, \dots, 0) = \begin{bmatrix} D & 0 \\ 0 & 0 \end{bmatrix}^2 \quad (13)$$

其中， m 为 A 的秩， λ_g ($g=1, 2, \dots, m$) 为 A 的非零特征值， D 为特征值 $\sqrt{\lambda_g}$ 组成的对角矩阵。由于可以保证 $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_m$ ，特征可以由前 N_{rd} 维子块 ($1 \leq N_{rd} \leq N_f$) 来表征。降维后的隐藏特征可推导为：

$$S_{N_t \times N_{rd}} = A_{N_t \times N_f} V_{N_f \times N_{rd}} \quad (14)$$

作为预训练过程，HFE方法可应用于训练任何神经网络。此处的序列学习基于循环神经网络 (recurrent neural network, RNN) 实现。通过连接反馈机制和参数共享，RNN允许当前输出在同一节点影响后续的输入，展现出与时间序列相关的动态跟踪能力。通过增加隐藏层的数量，RNN实现了从输入到输出的深度拟合。具有 l 个隐藏层的RNN的前向传播过程可表示为：

$$h_j^{(t)} = \begin{cases} \sigma(W_{r,j} h_j^{(t-1)} + W_{s,j} s^{(t)} + b_j), & j=1 \\ \sigma(W_{r,j} h_j^{(t-1)} + W_{s,j} h_{j-1}^{(t)} + b_j), & j \in (1, l] \end{cases} \quad (15)$$

$$o^{(t)} = \text{softmax}(W_{s,l+1} h_l^{(t)} + b_{l+1}) \quad (16)$$

其中， $\sigma(\cdot)$ 表示激活函数， $W_{s,j}$ 、 $W_{r,j}$ 、 b_j 表示第 j 层神经元的权重， $h_j^{(t)}$ 表示相应的隐藏层状态。所有参数通过反向传播算法进行训练更新。经过上述训练阶段后，权重参数确定的RNN均衡器即可上线运行。对于PAM-K信号，通过softmax函数可得到每个调制幅度 $o_k^{(t)}$ ($k=1, 2, \dots, K$) 的预测概率。基于最大后验概率准则，均衡后的信号检测结果为：

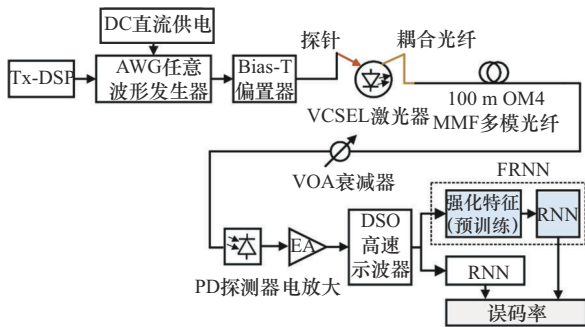
$$\begin{aligned} y^{(t)} &= \arg \max \{o_k^{(t)}\} \\ \sum_{k=1}^K o_k^{(t)} &= 1 \end{aligned} \quad (17)$$

通常情况下， $N_{rd}=1$ 足以满足性能要求。在该算法的整体流程中，HFE过程的复杂度远低于RNN序列学习过程的复杂度。与传统的RNN训

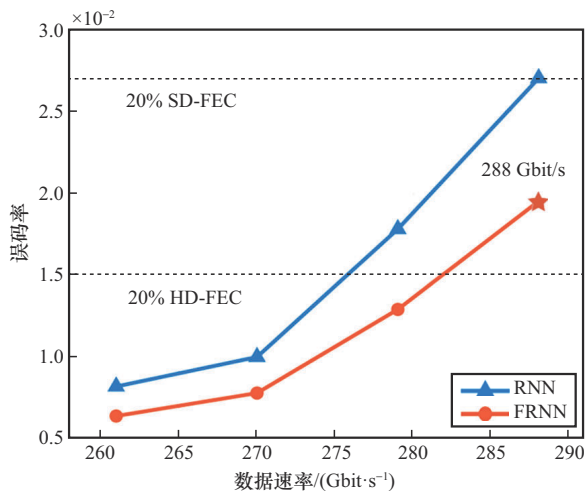


练方法相比，经过HFE之后输入维度保持不变，这意味着在不增加序列学习过程计算负担的情况下，提高了神经网络的训练效率。

在如图4(a)所示的实验链路中对算法进行了测试。实验中使用的二次空间变换相邻符号数量 $L=2$ ，降维后的特征维度 $N_{rd}=1$ 。基于以上算法，本文实现了288 Gbit/s PAM-8信号传输，在100 m OM4 MMF链路下测试误码率达到20% SD-FEC门限以下。不同传输速率下的误码率曲线如图4(b)所示，与传统的RNN相比，随着数据速率的增加，基于HFE训练的RNN获得了更大的误码率增益。



(a) 实验链路示意图



(b) 不同传输速率下的误码率曲线

图4 基于HFE的深度神经网络均衡方法实验验证

1.3 未来研究方向

为满足超高速短距离光互连的低能耗、低时延要求，未来研究的均衡算法应进一步降低复杂度，

同时提高并行化程度，以降低处理时延。此外，为降低接收端均衡算法复杂度，可以研究发送端数字预加重技术，即将部分信号处理任务转移至发送端，在数字域通过对发送数据波形的预处理，在不增加接收端计算开销的同时，降低符号的错误率。近年来，端到端学习架构也被引入光纤通信系统中^[10]，端到端模型由包含发射机、光信道模型和接收机的完整链路构成，可以通过收发端联合优化提高系统的整体性能。以上研究方向有利于在控制计算复杂度的同时，实现系统传输速率的提升。

2 超高速短距离光互连编码技术

为实现无差错传输，前向纠错（forward error correction, FEC）编码技术也是超高速短距离光互连研究的重点领域之一，对满足日益增长的数据传输需求意义重大。FEC编码技术在光互连系统中发挥着关键作用，可部署在交换机主机侧，能够有效提升传输的可靠性，降低误码率，为系统的稳定运行提供有力保障。随着集成电路技术的迅猛发展，软判决FEC（soft-decision FEC, SD-FEC）编码技术的应用逐渐成为现实。在光网络中，极高的传输速率对编码技术提出了严苛的要求。SD-FEC编码技术尽管具备诸多优势，但其计算密集性较高，且高性能模拟/数字（analog/digital, A/D）转换器成本依然很高，这在一定程度上限制了它的广泛普及。然而，随着集成电路技术的持续进步，以及新型数字相干接收机的开发，高性能A/D转换器得以大范围使用，SD-FEC编码技术有望成为下一代光网络的主流技术。

低密度奇偶校验（low-density parity-check, LDPC）码作为第三代光通信FEC中广泛应用的码字，具有诸多显著特性。它灵活性高，能够根据不同的通信需求进行优化配置；误码率平台低，可有效保障数据传输的准确性；编码增益大，有助于提升信号的传输质量；并行迭代译码方式不仅使得吞吐率大，而且在硬件上易于实现。因此，

LDPC码被广泛应用于IEEE 802.3n、IEEE 802.16e、5G、长距离光纤传输、下一代无源光网络等多种通信场景的编码方案中^[11]。在LDPC码的研究与应用过程中，也面临一些技术挑战。为了进一步提升超高速短距离光互连系统的编码性能，需要针对光互连链路的非高斯特性，设计适用于光互连链路的编译码方法。本节介绍两项相关研究，即光互连系统中准循环LDPC（quasi-cyclic LDPC, QC-LDPC）码优化方法以及基于深度学习的LDPC联合均衡译码方法，旨在提高编译码效率，更好地适应光互连链路的复杂环境，推动LDPC码在光互连系统中的应用。

2.1 光互连系统中QC-LDPC码优化方法

QC-LDPC码具有高效率、并行化特点，其硬件实现的复杂度相对较低，同时可以保持较低的误码率平台，已被用作下一代以太网的上行和下行信道码^[12]。码字优化是指从现有码字出发，通过特定算法优化校验矩阵，改善码字的纠错能力和编码复杂度，使其在实际应用中具有更高的可靠性和效率。本文首先建立了新的基于近似环外部信息度（approximated cycle extrinsic message degree, ACE）的ACE数量谱度量，并提出了一种基于围长和全局ACE特性的方法来优化QC-LDPC码^[13]，被称为EEA算法。ACE较低的短环是导致误码率平台的主要原因之一，该优化算法的目标为减少或消除导致误码率平台的低ACE短环，通过调整LDPC码基矩阵中的每一个元素，依次增加围长、ACE谱中的元素值和减少ACE数量谱中的元素。对于QC-LDPC码，只搜索一部分环，便可以快速计算所有的度量。在边交换之后，环的总体连通性变好，Tanner图的总体性能也会提高。通过调整EEA算法中基矩阵的非零元素，可以得到围长更大、Tanner图连通性更好的QC-LDPC码，用该方法优化的QC-LDPC码具有良好的误码性能。EEA算法流程如算法1所示。

算法1 EEA算法

输入: H, Z, d_{\max}

输出: 优化后的 H

$g(H), \eta(H), \tau(H) = \text{metrics}(H, Z, d_{\max})$

$g_{\text{init}} = g(H), \eta_{\text{init}} = \eta(H), \tau_{\text{init}} = \tau(H)$ //初始化

$g^{\text{opt}} = g_{\text{init}}, \eta^{\text{opt}} = \eta_{\text{init}}, \tau^{\text{opt}} = \tau_{\text{init}}$

for $j = 1$ to J do

 for $s = 1$ to S do

 if $w_{j,s} \neq 0$ then

 for $Z = 1$ to Z do // $w_{j,s}$ 在 1 和 Z 之间

$w_{j,s} = w_{j,s} + 1 \pmod{Z+1}$

 if $w_{j,s} = 0$ then

$w_{j,s} = 1$

 end if

$g(H), \eta(H), \tau(H) = \text{metrics}(H, Z, d_{\max})$

$H, g^{\text{opt}}, \eta^{\text{opt}}, \tau^{\text{opt}} = \text{cmp}(j, s, g^{\text{opt}}, \eta^{\text{opt}},$

$\tau^{\text{opt}}, g(H), \eta(H), \tau(H), H, Z, d_{\max})$

 end for

 end if

 end for

end for

 if $g_{\text{init}} = g^{\text{opt}} \&\& \eta_{\text{init}} = \eta^{\text{opt}} \&\& \tau_{\text{init}} = \tau^{\text{opt}}$

then

 return H

else

 Go to line 1

end if

基于IEEE 802.16e和3GPP^[14]，本文选取了3个性能良好的QC-LDPC码作为原始码字进行优化。由于光通信系统对编码的基本要求是码率需要大于80%，且通过编码可以将误码率从 10^{-2} 降低到 10^{-12} ，选取的原始码字并不能直接应用于光通信系统。本文比较了基于并行消息传递的边交换（parallel vector messaging edge exchange, PMPE）算法^[15]和EEA算法对QC-LDPC码性能的改善。原始



的QC-LDPC码、PMPE算法优化后的QC-LDPC码和EEA算法优化后的QC-LDPC码在FEC前后的误码率性能比较如图5所示,由图5可知,利用所提出的EEA算法,3种QC-LDPC码的误码率都被优化至 10^{-12} 以下,优化后的码字可用于光通信系统,而广泛使用的PMPE优化算法无法实现这一目的。

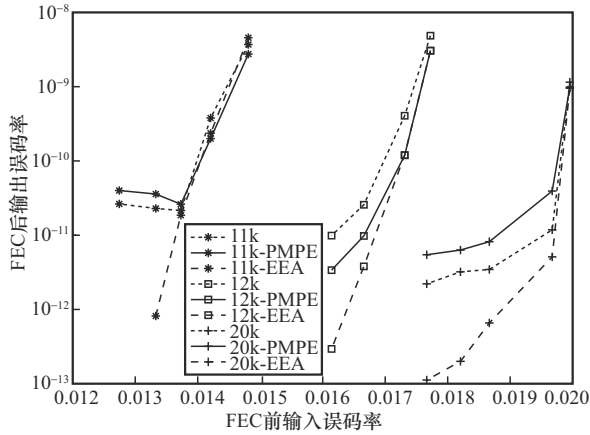


图5 原始的QC-LDPC码、PMPE算法优化后的QC-LDPC码和EEA算法优化后的QC-LDPC码在FEC前后的误码率性能比较

2.2 基于深度学习的LDPC联合均衡译码方法

在传统的DSP架构中,均衡和译码被视为独立的两部分,分别进行算法设计与优化。联合均衡译码方法则是指将均衡和译码两个步骤视为统一的整体,以端到端方式进行联合优化,从而提高系统的整体性能^[16-17]。

在LDPC码的传统译码算法中,归一化偏置最小和(normalized offset min-sum, NOMS)算法由于引入了比例因子 α 和偏置因子 β ,而得到广泛应用。在第 d 次译码迭代中,由第 m 个校验节点向第 n 个变量节点的软信息传递可表示为:

$$l_{m \rightarrow n}^d = \left(\prod_{n' \in V_m \setminus n} \text{sgn} \left(l_{n' \rightarrow m}^d \right) \right) \cdot \max \left(\alpha \cdot \min_{n' \in V_m \setminus n} \left(\left| l_{n' \rightarrow m}^d \right| \right) - \beta, 0 \right) \quad (18)$$

在AWGN信道下,使用密度演化算法得到 α 和 β 的优化取值分别为0.8和0.15^[18]。然而,短距离光互连链路的信道特性与AWGN信道不同,现有算法

无法确定 α 和 β 的最优取值。根据式(18)不难发现,NOMS算法的译码结构与深度神经网络具有相似之处,即译码算法的每一次迭代可以看作神经网络的一层。将 α 和 β 分别替换为神经网络中可训练的权重 $w_{n,m}^d$ 和偏置 $b_{n,m}^d$,并在每一层后加入非线性激活函数 $f(\cdot)$,可将式(18)用神经网络结构表示为:

$$l_{m \rightarrow n}^d = \left(\prod_{n' \in V_m \setminus n} \text{sgn} \left(l_{n' \rightarrow m}^d \right) \right) \cdot f \left(w_{n,m}^d \cdot \min_{n' \in V_m \setminus n} \left(\left| l_{n' \rightarrow m}^d \right| \right) - b_{n,m}^d \right) \quad (19)$$

本文通过梯度反向传播算法训练得到每一次迭代的最优参数取值。接下来,为实现均衡和译码算法的全局最优,本文使用均衡层级译码层的方法,即在 d 层译码网络前级联 n 层均衡网络,并对 $n+d$ 层深度神经网络进行联合优化,从而实现全局最优。基于深度学习的LDPC联合均衡译码算法示意图如图6所示。

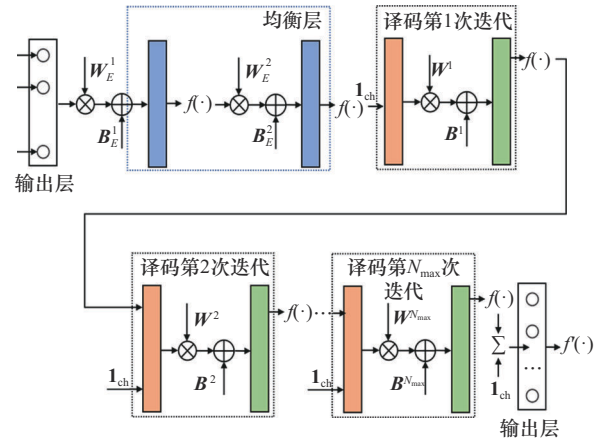


图6 基于深度学习的LDPC联合均衡译码算法示意图

为了解决深度神经网络中的梯度消失问题,本文采用了贪婪逐层训练方法。首先对两层均衡隐藏层进行训练,训练完成后将其权重和阈值参数固定,并逐次在已训练的网络后增加一层译码网络并再次训练,在该训练方式中,每次只有最后一层的权重和阈值参数是可学习的。通过贪婪逐层训练,从 n 层网络逐渐训练为 $n+d$ 的多层网络。由于实际训练的网络始终具有浅层结构,该训练方法避免了

梯度消失问题，并降低了训练复杂度，同时减轻了 Tanner 图中短环导致的消息相关性，通过较早的反向传播过程优化了由短环导致的译码性能下降，并且可灵活配置译码网络的迭代层数，更深层数的译码网络可重复使用已训练的浅译码网络参数，不需要从头训练，节省了训练时间和资源。

本文采用 80 Gbit/s 开关键控 (on-off keying, OOK) 信号对算法进行实验验证，比较沃特非线性均衡器级联传统 NOMS 算法、基于神经网络的 NN-NOMS 算法以及联合均衡译码算法在不同接收光功率下的误码率性能，3 种均衡译码方案误码率与接收光功率关系曲线如图 7 所示。实验结果表明，当误码率为 10^{-4} 时，联合均衡译码算法相比使用了沃特均衡器的 NOMS 算法，在 BTB 和 2 km 场景下分别拥有 1.99 dB 和 1.85 dB 的信噪比增益，而联合均衡译码算法相比使用了沃特均衡器的 NN-NOMS 算法，在 BTB 和 2 km 场景下分别拥有 0.76 dB 和 0.71 dB 的信噪比增益。




图 7 3 种均衡译码方案误码率与接收光功率关系曲线

2.3 未来研究方向

除了进一步提升 LDPC 码的纠错性能和译码效率，选取适用于光互连系统的新型纠错编码也是未来的研究方向之一。相较于其他信道编码方案，极化 (Polar) 码可以针对实际信道的转移概率，采用密度演化等子信道选择算法对编码方案进行优化设计，从而能以较低的成本重新部署在不同场景、不同信道条件下达到较高的系统性能^[19]，同时还能在子信道选择过程中对码率进行灵活调节，从而在保证一定误码率指标的前提下，达到尽可能高的频谱效率，具有很高的灵活性和实用性。在短码情形下，Polar 码相较 LDPC 码，能够以较为接近的编译码复杂度实现更高的系统性能，在追求低成本、低功耗的高速短距离光互连等其他光通信应用场景中具有较高的应用价值。

3 结束语

本文介绍了 AI 时代超高速短距离光互连技术的发展趋势，以及在该趋势下对均衡和编码技术研究的新要求。为满足高速率、低能耗、低时延的要求，新时代的均衡和编码技术需要与驱动器集成，满足光模块的高集成度要求，或提高设计灵活性，部署在交换机主机侧使用。基于以上需求，本文介绍了几种前沿的均衡与编码技术，即低复杂度的基于最小角回归策略的沃特均衡方法、基于 HFE 的深度学习均衡方法，以及光互连系统中 QC-LDPC 码优化方法和基于深度学习的 LDPC 联合均衡译码方法，并设计实验验证了算法的可行性与高效性。同时，本文还围绕超高速短距离光互连系统未来的均衡与编码技术研究进行了探讨。

参考文献:

[1] CISCO. Cisco annual internet report (2018-2023) white paper[R]. 2020: 1-35.



- [2] ZHOU H H, LI Y, LIU Y Y, et al. Recent advances in equalization technologies for short-reach optical links based on PAM4 modulation: a review[J]. Applied Sciences, 2019, 9(11): 2342.
- [3] GAO Y F, YANG C C, ZHANG X Y, et al. Augmented space signal detection method for IM/DD optical communication systems[J]. Optics Letters, 2022, 47(16): 4147-4150.
- [4] LAN T X, YANG C C, FANG X S, et al. Generalized Rayleigh quotient optimization method for inter-channel nonlinearity compensation in coherent optical communication systems[J]. Optics Letters, 2024, 49(3): 694-697.
- [5] SCHAEGLER M, BLUEMM C, KUSCHNEROV M, et al. Deep neural network equalization for optical short reach communication[J]. Applied Sciences, 2019, 9(21): 4675.
- [6] ZHOU Q Y, ZHANG F, YANG C C. AdaNN: adaptive neural network-based equalizer via online semi-supervised learning[J]. Journal of Lightwave Technology, 2020, 38(16): 4315-4324.
- [7] GAO Y F, YANG C C, WANG J X, et al. 288 Gb/s 850 nm VCSEL-based interconnect over 100 m MMF based on feature-enhanced recurrent neural network[C]//Proceedings of the 2022 Optical Fiber Communications Conference and Exhibition (OFC). Piscataway: IEEE Press, 2022: 1-3.
- [8] GAO Y F, YANG C C, WANG J X, et al. Least angle regression-based modified Volterra nonlinear equalizer for optical interconnection system[J]. Journal of Lightwave Technology, 2022, 40(12): 3622-3632.
- [9] YANG C C, GAO Y F, WANG J X, et al. Enhanced recurrent neural network equalization based on hidden feature extraction learning for optical interconnect[C]//Proceedings of the 2024 Optical Fiber Communications Conference and Exhibition (OFC). Piscataway: IEEE Press, 2024: 1-3.
- [10] KARANOV B, CHAGNON M, THOUIN F, et al. End-to-end deep learning of optical fiber communications[J]. Journal of Lightwave Technology, 2018, 36(20): 4843-4855.
- [11] TZIMPRAGOS G, KACHRIS C, DJORDJEVIC I B, et al. A survey on FEC codes for 100 G and beyond optical networks[J]. IEEE Communications Surveys & Tutorials, 2016, 18(1): 209-221.
- [12] Institute of Electrical and Electronics Engineers. IEEE standard for Ethernet amendment 9: physical layer specifications and management parameters for 25 Gb/s and 50 Gb/s passive optical networks: IEEE Std 802.3ca-2020[S]. 2020.
- [13] QIN X, YANG C C, ZHENG Z Y, et al. Optimization of QC-LDPC codes by edge exchange method based on ACE[J]. IEEE Photonics Technology Letters, 2019, 31(17): 1401-1404.
- [14] 3GPP. Discussion on rate-compatible quasi-cyclic LDPC codes[R]. 2016.
- [15] LIU X C, XIONG F, WANG Z F, et al. Design of binary LDPC codes with parallel vector message passing[J]. IEEE Transactions on Communications, 2017, 66(4): 1363-1375.
- [16] QIN X, YANG C C, GUO H P, et al. Recurrent neural network based joint equalization and decoding method for trellis coded modulated optical communication system[J]. Journal of Lightwave Technology, 2023, 41(6): 1734-1741.
- [17] YANG C C, QIN H, LAN T X, et al. Hidden feature extraction learning and end-to-end joint equalization with LDPC decoding method for optical interconnect[J]. Journal of Lightwave Technology, 2025, 43(4): 1746-1758.
- [18] CHEN J H, DHOLAKIA A, ELEFTHERIOU E, et al. Reduced-complexity decoding of LDPC codes[J]. IEEE Transactions on Communications, 2005, 53(8): 1288-1299.
- [19] ARIKAN E. Channel polarization: a method for constructing capacity-achieving codes for symmetric binary-input memoryless channels[J]. IEEE Transactions on Information Theory, 2009, 55(7): 3051-3073.

[作者简介]



秦昊 (2001-), 男, 北京大学电子学院博士生, 主要研究方向为高速光通信与光互连。



杨川川 (1982-), 女, 博士, 北京大学电子学院副教授, 主要研究方向为高速光传输、光互连与光传感。



蓝天祥 (1998-), 男, 北京大学电子学院博士生, 主要研究方向为高速光通信与光互连。



赵玉萍 (1961-), 女, 博士, 北京大学电子学院教授, 主要研究方向为无线通信系统。



秦忻 (1995-), 女, 博士, 现就职于中国电信股份有限公司研究院, 主要研究方向为智能光网络与数字孪生光网络。



陈章渊 (1968-), 男, 博士, 北京大学电子学院教授, 区域光纤通信网与新型光通信系统国家重点实验室主任, 主要研究方向为光传输、微波光子学和光子器件。