

引用格式: LIU Caoyang, SUN Lin, XIAO Jiawang, et al. Hidden-layers Extended Recurrent Neural Network Equalizer for Short Reach Optical Interconnects[J]. Acta Photonica Sinica, 2022, 51(12):1206001

刘曹洋,孙林,肖家旺,等. 面向短距光互连的隐藏层拓展循环神经网络均衡器[J]. 光子学报, 2022, 51(12):1206001

面向短距光互连的隐藏层拓展循环神经网络均衡器

刘曹洋¹, 孙林¹, 肖家旺¹, 毛邦宁², 刘宁¹

(1 苏州大学 电子信息学院, 江苏省新型光纤技术与通信网络工程研究中心, 江苏 苏州 215006)

(2 中国计量大学 光学与电子科技学院, 杭州 310018)

摘 要:为探究光强度调制/直接检测系统中神经网络非线性均衡器的最优结构,实现更优的光通信性能,通过搭建 20 km 的 112 Gbps 四电平脉冲振幅调制无色散补偿的光传输系统,分析了多隐藏层循环神经网络均衡器在该系统中的误码率及算法复杂度性能。结果表明,在同一误码率阈值下,增加隐藏层层数可有效降低单个隐藏层中神经元的数目,从而降低均衡器的算法复杂度。但随着隐藏层数目的进一步增加,均衡器的收敛性能下降,导致误码率及复杂度性能的恶化。通过量化研究隐藏层数目对循环神经网络均衡器性能的影响,发现在 112 Gbps 容量和 20 km 传输距离下,2 层隐藏层 RNNE 具有最优的误码率及算法复杂度性能。与单隐藏层均衡器相比,2 层隐藏层均衡器在 1×10^{-3} 误码率阈值下算法复杂度降低 23.3 %。

关键词:光纤通信;循环神经网络;非线性均衡;强度调制/直接检测;色散补偿

中图分类号: TN913.7

文献标识码: A

doi: 10.3788/gzxb20225112.1206001

0 引言

随着大数据、物联网和人工智能的蓬勃发展,基于云的互联网流量出现了爆炸式增长,这对数据中心的容量及其光互连系统的速率提出了更高的要求。同时 5G/物联网等业务推动了边缘计算和云-边协同需求的发展,催生出更多边缘数据中心间的通信流量,从而将数据中心光互连系统的互连长度需求从百米延伸至 10~20 km。对于高速短距离的数据中心光互连系统,光强度调制/直接检测(Intensity Modulation/Direct Detection, IM/DD)系统因其结构简单、成本低廉而被认为是最有前途的解决方案之一^[1]。同时为了降低光学和电子元件的波特率和带宽要求,先进调制格式引起了人们的关注和研究,如脉冲振幅调制^[2-3]、离散多音调制^[4]和无载波振幅相位调制^[5]。考虑到系统实现和功耗,四电平脉冲振幅调制(Four-level Pulse Amplitude Modulation, PAM-4)是一种针对 100 Gb/s、200 Gb/s 和 400 Gb/s 短距离光纤传输的理想调制格式^[6]。与光相干检测系统不同的是,IM/DD 系统中的平方律检测会丢失信号的相位信息使得色散带来非线性的损伤难以进行补偿^[7],同时低成本激光器的啁啾以及带宽受限器件的非理想响应也会带来严重的非线性,从而限制 IM/DD 系统的传输容量和距离。因此,迫切需要强大的均衡器来补偿 IM/DD 系统的非线性失真。

非线性机器学习模型,特别是神经网络(Neural Network, NN)模型,由于具备高度的非线性特性被广泛用于光通信中相干系统^[8-9]和 IM/DD 系统^[10-15]的非线性补偿。YI Lilin 等^[10]提出一种前馈神经网络均衡器(Feedforward Neural Network Equalizer, FNNE)用于补偿 IM/DD 系统中的强非线性损伤,其与前馈均衡

基金项目:国家自然科学基金(No.62105273)

第一作者:刘曹洋(1998-),男,硕士研究生,主要研究方向为光互连系统和神经网络在光通信应用。Email:20205228009@stu.suda.edu.cn

导师:孙林(1992-),男,讲师,博士,主要研究方向为光通信与传感融合。Email:linsun@suda.edu.cn

通讯作者:刘宁(1976-),男,教授,博士,主要研究方向为短距光通信、自由空间光通信、光交换系统及其相关算法和器件。Email:gordonliu@suda.edu.cn

收稿日期:2022-04-29;录用日期:2022-06-24

<http://www.photon.ac.cn>

器、沃尔泰拉非线性均衡器相比表现出更强的均衡性能,但同时也带来更高的复杂度。除了FNNE之外,径向基函数神经网络均衡器^[12]、卷积神经网络均衡器^[13]和循环神经网络均衡器(Recurrent Neural Network Equalizer, RNNE)^[14]都已在不同的场景中使用和验证。XU Zhaopeng等^[15]在50 Gbps 20 km的IM/DD系统中对比了具有相同输入和隐藏神经元数目的单隐藏层FNNE和基于自回归循环神经网络的RNNE,该RNNE由于添加额外反馈神经元复杂度有所提高,但是得到了更优的性能。然而,上述提到的NN结构中隐藏层只有一层或者两层,隐藏层层数和隐藏层神经元数目的对神经网络均衡器的影响仍是未知的。

本课题组对单层隐藏层RNNE和2层隐藏层RNNE在光IM/DD系统中的性能进行了研究^[16]。在此基础上,为了探究隐藏层数目对RNNE性能的影响,寻求低复杂度高效的均衡方案,本文进一步分析了增加隐藏层数目对均衡器算法复杂度降低的有效性,并制订了隐藏层神经元数目的选择策略。搭建了112 Gbps 20 km的PAM-4光IM/DD传输仿真平台,在不同维度下定量分析了隐藏层数目对RNNE误码率(Bit Error Rate, BER)及算法复杂度的影响,结果表明2层隐藏层RNNE具有更优的性能。另外,通过遍历隐藏层内部神经元的数目、分析其对均衡器性能的影响,统计得出隐藏层神经元数目的优化策略,对多层RNNE实现非线性均衡具有一定的指导意义。

1 基本原理

1.1 RNNE神经网络均衡器结构

单隐藏层FNNE的结构如图1。这是一个两层网络,包括隐藏层和输出层,输入层不计入其中。图1中 x 代表均衡器的输入, l 是输入的数目, h 代表隐藏层神经元, n 是隐藏层神经元的数目, y 是均衡器的输出,代表均衡后的值。RNNE结构中 D 代表四电平判决模块, Z 代表延时模块, d 是判决后反馈的符号, k 是反馈的数量。与FNNE的结构相比,RNNE重用输出判决后的符号的作为输入,在预测当前输出时,过去预测的输出作为输入提供了额外的信息。因此,在强非线性系统中,RNNE具有更优的均衡性能。

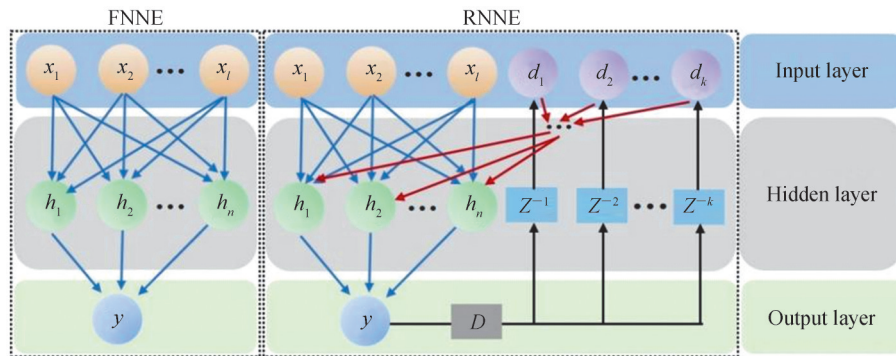


图1 单隐藏层NN均衡器的结构
Fig. 1 Schematic of the single hidden layer NN equalizers

1.2 均衡器算法复杂度衡量

在衡量RNNE的性能时,除了BER还有一个重要的参数指标是算法复杂度。首先考虑单隐藏层FNNE的算法复杂度。因为乘法比加法复杂得多,所以均衡一个符号所需要的执行的乘法次数用来表示FNNE的算法复杂度^[11]。为了恢复一个符号,将 l 个相邻的采样序列作为输入神经元,然后通过 n 个隐藏层神经元的计算,得到一个输出。在图1 FNNE中,每个隐藏层神经元都可以看做是一个计算单元,其内部计算可以表示为

$$y_h = f\left(\sum_{i=1}^l w_i x_i + b\right) \quad (1)$$

式中, y_h 为当前隐藏层神经元的输出, w_i 为对应输入 x_i 的权重, b 是偏置。 w 和 b 需要通过训练来优化。 $f(\cdot)$ 为激活函数,用来引入非线性。ReLU(x)结构简单,同时也能很好地解决IM/DD系统中的非线性,作为激活函数,其表达式为

$$\text{ReLU}(x) = \max(0, x) \quad (2)$$

由于 $\text{ReLU}(x)$ 函数只需要做简单判断,其复杂度可以忽略不计。根据式(1)可以计算出一个隐藏层神经元中需要的乘法次数等于输入神经元的数目 l ,输出神经元需要的乘法次数等于上一层的输入数目 n 。FNNE均衡一个符号需要的乘法总数 N_{FNN} 等于所有神经元中乘法的次数总和,可表示为

$$N_{\text{FNN}} = (l + 1)n \quad (3)$$

类似地,单隐藏层RNNE的算法复杂度也使用均衡一个符号需要的乘法次数 N_{RNN} 表示,图1中RNNE与FNNE不同的是:输入神经元除了相邻的采样序列 x_i ,还包括判决反馈符号 d_j ,其中一个隐藏层神经元的计算可以表示为

$$y_h = f\left(\sum_{i=1}^l \omega_i x_i + \sum_{j=1}^k \omega_j d_j + b\right) \quad (4)$$

根据式(4),RNNE每个隐藏层神经元中乘法次数等于输入神经元的数目 $(l+k)$,和输入数目为 $(l+k)$ 的FNNE相等。RNNE均衡一个符号需要的乘法总数 N_{RNN} 同输入数目为 $(l+k)$ 的FNNE相等,可表示为

$$N_{\text{RNN}} = (l + k + 1)n \quad (5)$$

多隐藏层RNNE结构如图2,第 i 层隐藏层的神经元数目为 $n_i (i=1, 2, \dots, m)$,其中第一层隐藏层神经元输出可用式(4)表示,第 i 层($i=2, \dots, m$)隐藏层神经元输出可表示为

$$y_i = f\left(\sum_{j=1}^{n_{i-1}} \omega_j y_{i-1}^{[j]} + b_i\right) \quad (6)$$

式中, $y_{i-1}^{[j]}$ 为第 $i-1$ 层隐藏层第 j 个神经元的输出, ω_j, b_i 为对应的权重和偏置。根据式(4)和式(6)可以推导出多隐藏层RNNE算法复杂度的一般式,可表示为

$$N_{\text{RNN}} = (l + k)n_1 + \sum_{i=1}^{m-1} (n_i \times n_{i+1}) + n_m \quad (7)$$




图2 多隐藏层RNNE的结构

Fig. 2 Schematic of the multiple hidden layers RNNE

特殊地,当每层神经元的数目都相等时,即 $n_1 = n_2 = \dots = n_m = n$,式(7)可简化为

$$N_{\text{RNN}} = (l + k + 1)n + (m - 1)n^2 \quad (8)$$

1.3 RNNE的初始化和训练

对于不同结构的RNNE在均衡信号之前需要通过训练来优化均衡器的参数,这些参数包括所有的权重和偏差。对于一个 m 层隐藏层RNNE一共包括 $m+1$ 组权重和偏置,分别位于输入层和隐藏层、隐藏层和隐藏层、隐藏层和输出层之间。在训练之前,需要对这些参数进行随机初始化,然后通过反向传播和Adam优化器进行小批量梯度下降训练。训练超参数的设置:学习率设置为 10^{-3} ,最大迭代轮次设定为100,小批量梯度下降的批次大小为16。每批数据正向传播后,计算均方误差 L_{MSE} ,其表达式为

$$L_{\text{MSE}} = \frac{1}{s} \sum_i^s (y_i - \hat{y}_i)^2 \quad (9)$$

式中, s 为小批量梯度下降的批次大小, \hat{y}_i 为一批数据中第 i 个原始符号, y_i 为第 i 个符号对应的均衡器输出。得到 L_{MSE} 后进行反向传播, 再更新权重和偏置以最小化均方误差。在每轮迭代完成后, 使用 RNNE 分别均衡训练集和测试集上的数据, 得到均衡后的符号, 并计算 BER。随着迭代轮次的增加, 参数不断优化, L_{MSE} 值逐步减小, 测试集上的 BER 也越来越小。当测试集上的 BER 不再下降时, 网络停止更新, 记录下 BER 最优时的均衡器参数。

和单隐藏层 RNNE 的训练相比, 多隐藏层均衡器的误差函数的收敛会变缓甚至无法收敛, 使得经过 100 轮迭代更新后的 RNNE 不能在测试集上得到理想的 BER。增加迭代轮次可使误差函数收敛来解决这个问题, 但训练时长也会相应增加, 所以训练时使用迁移学习而不是单纯的增加迭代轮次。在迁移学习的帮助下, 可以显著减少迭代轮次和训练符号数目, 从而保证大大缩短 NN 训练时间。同一个 NN 结构在不同场景下的迁移学习的有效性已经被验证^[17]。本文将其推广到同一场景下的不同 NN 结构, 在训练 2 层隐藏层 RNNE 时, 将已经训练好的单隐藏层 RNNE 的第一组的权重和偏置 (输入层和第一层隐藏层之间) 赋值给 2 层隐藏层 RNNE 对应位置的参数。这样 2 层隐藏层 RNNE 可以在单隐藏层 RNNE 的参数上继续优化, 均方误差可以更快地收敛, 从而大大缩减训练所需要的迭代轮次, 缩短训练所需要的时间。类似地, 对 m 层隐藏层 RNNE 的训练, 可以直接加载对应 $m-1$ 层隐藏层 RNNE 的前 $m-1$ 组的权重和偏置。

1.4 光 IMDD 传输仿真平台搭建

为了衡量多隐藏层 RNNE 的 BER 和复杂度性能, 使用 VPItransmissionMaker 13.1 搭建的仿真平台如图 3。ERIKSSON T A 等^[18]指出: 基于机器学习的均衡器的性能可能被高估了, 因为在使用伪随机二进制比特序列 (Pseudo-random Bit Sequence, PRBS) 训练模型情况下, NN 可以识别 PRBS 数据的模式, 从而获得卓越的性能。因此, 在发射机处 200 000 PAM-4 符号由 MATLAB 随机生成的, 其中 50 000 用于训练, 其余用于测试。PAM-4 信号经过 4 倍上采样和滚降系数为 0.1 的奈奎斯特滤波整形后通过数模转换器 (Digital to Analog Converter, DAC) 变成模拟信号, 再被电吸收调制器 (Electro-absorption Modulator, EAM) 调制到 1 550 nm 波长的激光上。调制好的光信号经过标准单模光纤 (Standard Single-mode Fiber, SSMF) 传输 20 km 到达接收端。在接收端, 可变光衰减器 (Variable Optical Attenuator, VOA) 将接收光功率 (Received Optical Power, ROP) 调整到合适的水平, 光信号被检测响应度为 0.65 A/W 的光电探测器 (Photo-detector, PD) 接收转变为电信号, 然后通过采样率为 224 GSa/s、分辨率为 8 位的模数转换器 (Analog to Digital Converter, ADC) 变为数字信号, 最后进入离线数字信号处理 (Digital Signal Processing, DSP) 模块。该模块包括匹配滤波、重采样、RNNE 均衡和 BER 计算。仿真采用的参数如表 1。




图 3 用于 112 Gbps PAM-4 光链路的多隐藏层 RNNE 的验证设置

Fig. 3 Verification setup of the multiple hidden layers RNNE for a 112-Gbps optical PAM-4 link

表 1 PAM-4 光链路的仿真参数
Table 1 Parameters of optical PAM-4 link

Parameter	Value
Modulation	PAM-4
Signal bit rate	112 Gbps
Wavelength	1 550 nm
Fiber length	20 km
Dispersion coefficient	16 ps/(nm·km)
Fiber attenuation	0.16 dB/km

2 结果与分析

2.1 隐藏层内神经元数目选择策略

为了得到最优的BER及复杂度性能,对于多隐藏层RNNE结构的确定,需要考虑每层隐藏层中神经元数目的选择。图4中散点代表不同结构的2层隐藏层RNNE,数字表示RNNE隐藏层神经元数目,具体地, (u, v) 表示第一隐藏层具有 u 个神经元、第二隐藏层具有 v 个神经元的RNNE。图4中固定第一隐藏层神经元的数目,然后遍历优化第二隐藏层神经元的数目得到了不同结构RNNE的BER及复杂度性能。结果表明,均衡器的BER及复杂度性能最优时,第二隐藏层的神经元数目与第一层相近。然后将最优的均衡器结构用实线拟合,同时将第二和第一隐藏层神经元数目相等的均衡器作为目标结构用点划线拟合。对比两条曲线,发现选择神经元数目相等的均衡器结构可以得到与最优结构相近的性能,同时避免了大量重复的遍历训练。

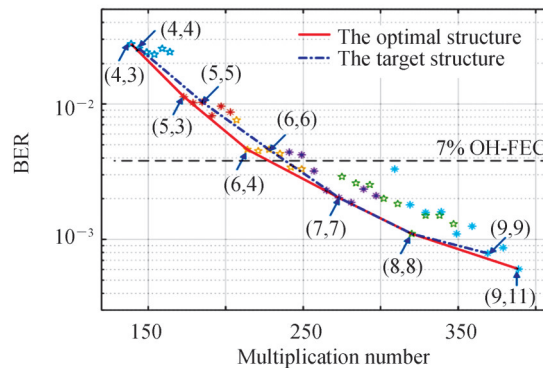


图4 2层隐藏层RNNE BER和乘法次数的关系

Fig. 4 BER vs. multiplication numbers for two hidden layers RNNE

2.2 多层隐藏层网络复杂度和性能对比

图5显示了隐藏层数目不同的RNNE算法复杂度和BER之间的关系。从整体的趋势来看,随着隐藏层神经元数目的增加,RNNE的均衡一个符号的所需乘法次数相应增加,BER结果也越好。对比单层和2层隐藏层RNNE的曲线,发现在同一BER阈值下,2层隐藏层RNNE的复杂度小于单隐藏层RNNE的复杂度,具体复杂度对比如表2。

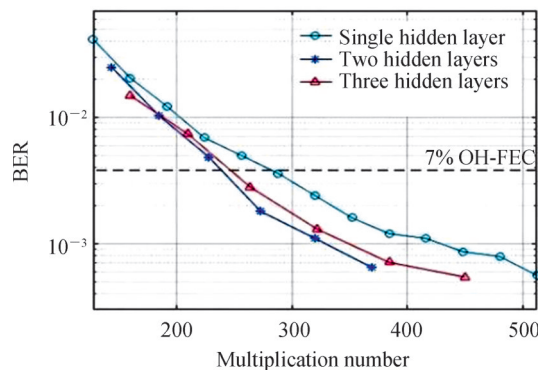


图5 多隐藏层RNNE BER和乘法次数的关系

Fig. 5 BER vs. multiplication numbers for multiple hidden layers RNNE

在BER为 10^{-2} 、 3.8×10^{-3} (7% OH-FEC)和 10^{-3} 三个阈值下,2层隐藏层RNNE相比于单隐藏层RNNE的算法复杂度理论上分别可以降低8.3%、15.6%和23.3%。随着复杂度的增加,降低复杂度的效果也越好。但是在同一BER阈值下,隐藏层数目继续增加,RNNE的算法复杂度反而会增加。为了进一步研究隐藏层数目对RNNE性能的影响,在隐藏层神经元数目相同的条件下,对比多隐藏层RNNE的BER性能,具体如表3。

表2 不同阈值下多隐藏层RNNE的算法复杂度
Table 2 N_{RNN} of multiple hidden layers RNNE at different thresholds

BER threshold	N_{RNN} of one hidden layer	N_{RNN} of two hidden layers	N_{RNN} of three hidden layers
10^{-2}	204	187	189
3.8×10^{-3}	283	239	247
10^{-3}	429	329	349

表3 隐藏层神经元数目相同的多隐藏层RNNE的BER性能
Table 3 BER of multiple hidden layers RNNE with the same hidden neurons number

Number of neurons per layer	BER of one hidden layer	BER of two hidden layers	BER of three hidden layers
6	1.22×10^{-2}	4.85×10^{-3}	2.80×10^{-3}
7	6.90×10^{-3}	1.80×10^{-3}	1.30×10^{-3}
8	5.00×10^{-3}	1.10×10^{-3}	7.11×10^{-4}

观察表3中数据,增加RNNE的隐藏层层数和隐藏层神经元的数目均可以提高均衡器的BER性能。对比隐藏层神经元数目相同的RNNE,发现增加隐藏层数目总是可以降低BER,虽然增加隐藏层数目带来的算法复杂度增加是一样的,但是增加第三层隐藏层带来的BER优化远远小于增加第二层隐藏层带来的BER优化。隐藏层神经元数目相同的多隐藏层RNNE的算法复杂度对比具体如图6。

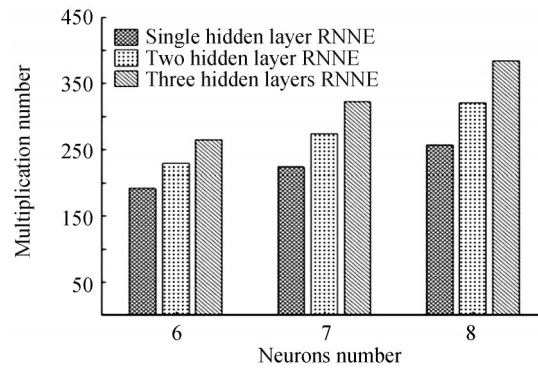


图6 隐藏层神经元数目相同的多隐藏层RNNE的算法复杂度对比

Fig. 6 Comparison of multiplication numbers of multiple hidden layers RNNE with the same hidden neurons number

2.3 不同ROP下网络结构的性能

通过调节VOA,绘制了不同接收光功率下三种RNNE的BER性能,如图7。具有10个隐藏神经元的单隐藏层RNNE的复杂度为320,具有12个隐藏神经元的单隐藏层RNNE的复杂度为384,分别如图7中

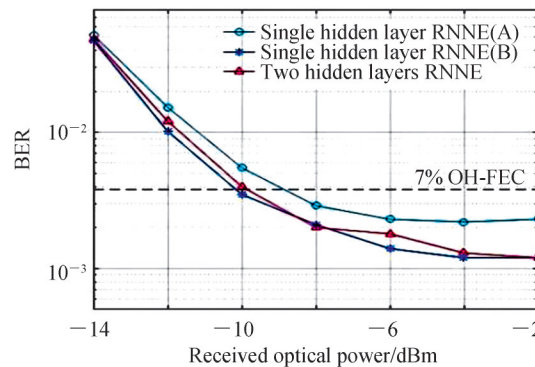


图7 不同结构的RNNE的BER和ROP的关系

Fig. 7 BER vs. received optical power for single and two hidden layers RNNEs

RNNE(A)和(B)。对于图7中2层隐藏层的RNNE,每层神经元数目为8,对应的乘法数是320。图7中2层隐藏层RNNE和单隐藏层RNNE(A)相比,复杂度降低了16.7%,同时得到了相似的性能。另外,在相同的复杂度下,2层隐藏层RNNE比单隐藏层RNNE(B)具有更好的BER性能,在7% OH-FEC阈值下,系统整体功率预算提高约1 dB。图8展示了一8 dBm接收光功率下的单隐藏层RNNE(B)和2层隐藏层的RNNE的眼图。

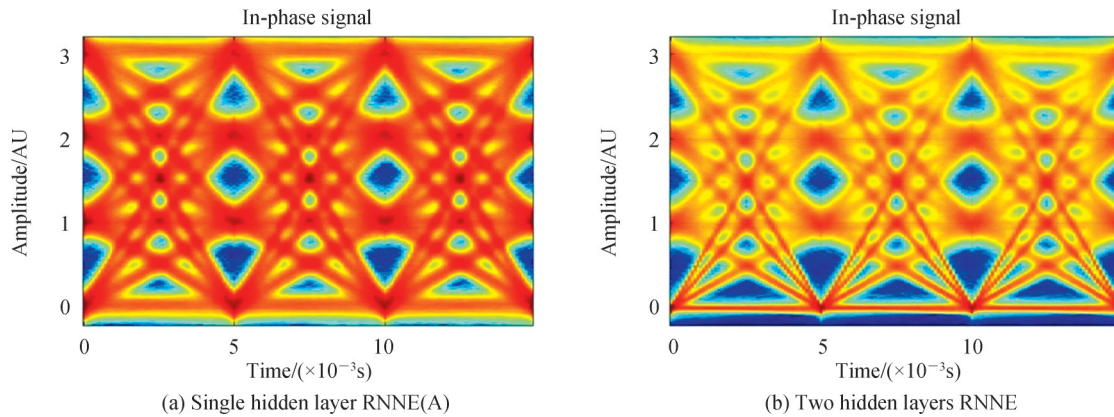


图8 ROP为-8 dBm的眼图
Fig. 8 Eye diagrams at -8 dBm ROP

3 结论

本文研究了IM/DD系统中多隐藏层RNNE隐藏层层数及隐藏层神经元数目对神经网络均衡器性能的影响。针对2层隐藏层RNNE,固定第一隐藏层神经元的数目,比较第二隐藏层神经元数目不同的RNNE的性能,结果表明:对于2层隐藏层的RNNE,隐藏层神经元数目相近时,其BER及复杂度性能最优。对于多隐藏层的RNNE,通过定量研究隐藏层数目对RNNE的BER及算法复杂度的影响,发现最佳隐藏层数目为2。在相同BER性能条件下,2层隐藏层RNNE相较于单隐藏层RNNE最多可以实现23.3%的复杂度降低。在同一算法复杂度条件下,2层隐藏层RNNE比单隐藏层RNNE在7% OH-FEC阈值下功率预算提高1 dB左右。本文以均衡器的最优结构为目标,分别量化研究了隐藏层层数和隐藏层神经元数目对RNNE性能的影响,为神经网络解决IM/DD系统的非线性时隐藏层层数和隐藏层神经元数目的选择提供了参考。

参考文献

- [1] CARTLEDGE J C, KARAR A S. 100-Gb/s intensity modulation and direct detection [J]. *Journal of Lightwave Technology*, 2014, 32(16): 2809-2814.
- [2] SHU Liang, LI Jianqiang, WAN Zhiquan, et al. Single-lane 112-Gbit/s SSB-PAM-4 transmission with dual-drive MZM and Kramers-Kronig detection over 80-km SSMF [J]. *IEEE Photonics Journal*, 2017, 9(6): 7204509.
- [3] ZHU Mingyue, ZHANG Jing, YI Xingwen, et al. Hilbert superposition and modified signal-to-signal beating interference cancellation for single side-band optical NPAM-4 direct-detection system [J]. *Optics Express*, 2017, 25(11): 12622-12631.
- [4] ZHANG Liang, ZUO Tianjian, MAO Yuan, et al. Beyond 100-Gb/s transmission over 80-km SMF using direct-detection SSB-DMT at c-band [J]. *Journal of Lightwave Technology*, 2016, 34(2): 723-729.
- [5] OLMEDO M I, ZUO T J, JENSEN J B, et al. Multiband carrierless amplitude phase modulation for high capacity optical data links [J]. *Journal of Lightwave Technology*, 2014, 32(4): 798-804.
- [6] ZHONG Kangping, ZHOU Xian, GUI Tao, et al. Experimental study of PAM-4, CAP-16, and DMT for 100-Gb/s short reach optical transmission systems [J]. *Optics Express*, 2015, 23(2): 1176-1189.
- [7] ZIBAR D, WINTHER O, FRANCESCHI N, et al. Nonlinear impairment compensation using expectation maximization for dispersion managed and unmanaged PDM 16-QAM transmission [J]. *Optics Express*, 2012, 20(26): B181-B196.
- [8] MENG Jianyu, ZHANG Hongbo, ZHANG Min, et al. Fiber nonlinear impairments compensation based on IPCA-DNN algorithm [J]. *Acta Optica Sinica*, 2021, 41(24): 2406002.
- [9] 蒙建宇, 张宏波, 张敏, 等. 基于IPCA-DNN算法的光纤非线性损伤补偿 [J]. *光学学报*, 2021, 41(24): 2406002.
- [9] WU Jinda, LU Jin, REN Hongliang, et al. Nonlinear equalizer based on general regression neural network in coherent

- optical OFDM system [J]. *Acta Optica Sinica*, 2018, 38(9): 0906002.
- 吴金达, 卢瑾, 任宏亮, 等. 基于广义回归神经网络的 CO-OFDM 系统非线性均衡[J]. *光学学报*, 2018, 38(9): 0906002.
- [10] YI Lilin, LIAO Tao, HUANG Luyao, et al. Machine learning for 100-Gb/s/ λ Passive optical network[J]. *Journal of Lightwave Technology*, 2019, 37(6): 1621-1630.
- [11] ZHU Ziyue, ZHAO Mengxin, ZHANG Yichen, et al. MIMO equalization technology based on neural network in high-speed IM-DD mode division multiplexing transmission system[J]. *Acta Optica Sinica*, 2021, 41(14): 1406003.
朱子岳, 赵梦鑫, 张一尘, 等. 高速 IM/DD 模分复用通信系统中基于神经网络的 MIMO 均衡技术[J]. *光学学报*, 2021, 41(14): 1406003.
- [12] ZHENG Yang, GAO Fan, FU Songnian, et al. Radial basis function neural network enabled C-band 4×50 -Gbs PAM-4 transmission over 80 km SSMF[J]. *Optics Letters*, 2018, 43(15): 3542-3545.
- [13] ZHANG Jing, YAN Lianshan, JIANG Lin, et al. Convolutional neural network equalizer for short-reach optical communication systems[C]. 2020 Asia Communications and Photonics Conference (ACP) and International Conference on Information Photonics and Optical Communications (IPOC), 2020.
- [14] YE Chenhui, ZHANG Dongxu, HU Xiaofeng, et al. Recurrent neural network (RNN) based end-to-end nonlinear management for symmetrical 50Gbps NRZ PON with 29dB+loss budget [C]. 2018 European Conference on Optical Communication (ECOC), 2018.
- [15] XU Zhaopeng, SUN Chuan Bowen, JI Tonghui, et al. Computational complexity comparison of feedforward/radial basis function/recurrent neural network-based equalizer for a 50-Gb/s PAM-4 direct-detection optical link[J]. *Optics Express*, 2019, 27(25): 36953-36964.
- [16] LIU Caoyang, SUN Lin, XIAO Jiawang, et al. Low-complexity RNNE with multiple hidden layers for optical PAM-4 signals[C]. 2022 Opto-Electronics and Communications Conference (OECC) and Photonics Global Conference (PGC), 2022.
- [17] XU Zhaopeng, SUN Chuan Bowen, JI Tonghui, et al. Transfer learning aided neural networks for nonlinear equalization in short-reach direct detection systems[C]. 2020 Optical Fiber Communications Conference and Exhibition (OFC), 2020.
- [18] ERIKSSON T A, BÜLOW H, LEVEN A. Applying neural networks in optical communication systems: possible pitfalls [J]. *IEEE Photonics Technology Letters*, 2017, 29(23): 2091-2094.

Hidden-layers Extended Recurrent Neural Network Equalizer for Short Reach Optical Interconnects

LIU Caoyang¹, SUN Lin¹, XIAO Jiawang¹, MAO Bangning², LIU Ning¹

(1 *Jiangsu New Optical Fiber Technology and Communication Network Engineering Research Center, School of Electronic and Information Engineering, Soochow University, Suzhou Jiangsu 215006, China*)

(2 *College of Optical and Electronic Technology, China Jiliang University, Hangzhou 310018, China*)

Abstract: There has been a lot of interest in the installation of high-speed short-reach optical interconnect systems recently because of the growth of 5G and the Internet of Things (IoT), which have caused the data traffic between and within data centres to expand quickly. In data centres, optical transmission systems frequently use optical Intensity Modulation and Direct Detection (IM/DD) to save cost and power consumption. However, loss of optical phase from square law detection and fiber dispersion cause a nonlinear distortion in the optical IM/DD system. Moreover, the nonlinear responses of modulator and driver/amplifier also cause serious nonlinear distortions at the same time, which seriously reduce the optical IM/DD system's transmission range and capacity. Various equalization algorithms have been proposed to eliminate them. A classical equalization scheme is the combination of feedforward and decision feedback equalizer, but the nonlinear distortions can not be effectively equalized. Volterra Nonlinear Equalizer (VNE) can correct for nonlinear distortions, nevertheless, higher-order VNE items in strongly nonlinear settings result in a significant increase in complexity. On the other hand, nonlinear equalizers based on neural networks were also widely investigated in optical communication recently, which includes feedforward neural network, radial basis function neural networks, convolutional neural network and recurrent neural network. In contrast to the feedforward equalizer and VNE, feedforward neural network equalizer exhibits stronger equalization performances, but also brings a higher complexity in order to

compensate for strong nonlinear impairments in optical IM/DD system. Moreover, equalizers based on auto-regressive recurrent neural network have higher complexity, however, better performance thanks to the involvement of additional feedback neurons. These equalisers, however, only employ one or two hidden-layers. In optical IM/DD systems, the influence of the number of hidden-layers as well as the number of neurons in every hidden layer on the performance of the equalizer remains unknown. Also, the optimal structure of neural network equalizer is worth exploring. Thus, we constructed a 112-Gbps 20-km four-level pulse-amplitude modulation optical IM/DD transmission simulation platform to investigate the influence of the number of hidden-layers and the number of neurons in every hidden layer on Recurrent Neural Network Equalizer (RNNE) performance. Also, to seek the most efficient equalization scheme with better complexity and Bit Error Rate (BER) performance. The effects of the number of hidden layers and the number of hidden neurons on the performance of RNNE are studied quantitatively to determine the ideal structure for RNNE. Initially, the performance of the RNNE with different numbers of neuron in the second hidden layer has been compared when the number of neurons in the first hidden layer is fixed. The results show that when RNNE has a comparable number of neurons in each hidden layer, the BER and complexity performance is optimized. Then, as for the RNNE with multiple hidden layers, we quantitatively examined the influence of the number of hidden-layer on the BER and complexity of RNNE. According to the results, the two-hidden-layer RNNE outperform RNNE with three-hidden-layer. The complexity of two-hidden-layer RNNE is 23.3% less complex than a single-hidden-layer RNNE. With similar algorithm complexities, the power budget of the two-hidden-layer RNNE is approximately 1 dB higher as compared to the single-hidden-layer RNNE at 7%-OH FEC threshold. This optimization strategy provides a reference for the selection of the number of hidden-layer number as well as the number of hidden neuron while using RNNE to compensate for nonlinear distortions in the optical IM/DD system.

Key words: Optical fiber communication; Recurrent neural network; Nonlinear equalization; Intensity modulation/direct detection; Dispersion compensation

OCIS Codes: 060.4510; 200.4260; 070.4340