

doi:10.13756/j.gtxyj.2023.01.004

光通信系统与网络技术

刘军,李伯中,陈芳,等.基于深度神经网络的 IMDD 系统光性能监测技术[J].光通信研究,2023(1):42-46

LIU J, LI B Z, CHENG F, et al. Optical Performance Monitoring Technology of IMDD System Based on Deep Neural Network [J]. Study on Optical Communications, 2023(1):42-46

基于深度神经网络的 IMDD 系统光性能监测技术

刘 军,李伯中,陈 芳,李子凡,郭 莹,孙雨潇,邓春雪,张儒依,王英旭

(国家电网有限公司信息通信分公司,北京 100761)

摘要:在先进高速光纤通信系统中,密集波分复用技术的引入使得信号频谱间隔越来越窄,传统的带外光信噪比(OSNR)监测技术不再准确,需要进一步研究低成本的带内 OSNR 监测方案。文章提出了一种基于深度神经网络(DNN)的直调直检(IMDD)系统链路 OSNR 监测方案,采用 550 000 组数据集训练的 5 层 DNN 结构,在 5~15 dB 范围内,成功估计出了 2 GBaud 开关键控(OOK)信号的 OSNR,平均绝对误差(MAE)小于 0.8 dB。文章所提方案有望作为一种高效低成本方案,助力光网络智能运维。

关键词:深度神经网络;光信噪比;光性能监测;直调直检

中图分类号:TN929.11

文献标志码:A

文章编号:1005-8788(2023)01-0042-05

Optical Performance Monitoring Technology of IMDD System based on Deep Neural Network

LIU Jun, LI Bo-zhong, CHENG Fang, LI Zi-fan, GUO Ying, SUN Yu-xiao, DENG Cun-xue, ZHANG Ru-yi, WANG Ying-xu

(State Grid Information and Telecommunication Branch, Beijing 100761, China)

Abstract: In advanced high-speed fiber optic communication systems, due to the introduction of dense wavelength division multiplexing technology, the signal spectral interval is getting narrower and narrower, and the traditional out-of-band Optical Signal-to-Noise Ratio (OSNR) monitoring technology is no longer accurate. Therefore, further study is required in the low-cost in-band OSNR monitoring scheme. A Deep Neural Network (DNN) link OSNR monitoring scheme for Intensity-Modulation and Direct Detection (IMDD) system is proposed. We used a 5-layer DNN trained from 550 000 datasets to successfully estimate the OSNR of the 2 GBaud On-Off Key (OOK) signal in the range of 5 to 15 dB, and the Mean Absolute Error (MAE) is less than 0.8 dB.

Key words: DNN; OSNR; optical performance monitoring; IMDD

0 引言

深度神经网络(Deep Neural Network, DNN)作为机器深度学习的基础网络之一,被应用于链路光信噪比(Optical Signal-to-noise Ratio, OSNR)的监测之中^[1-2]。利用经过模/数转换器(Analog-to-Digital Converter, ADC)后的电信号数据作为训练数据,输入到 5 层 DNN 中。卷积神经网络(Convolutional Neural Network, CNN)在图像处理领域取得了巨大的突破与进展,不同的 OSNR 水平下,信号的眼图与星座图表现不尽相同,因此,信号的眼图与星座图被用作 CNN 的输入数据^[3-5],将 OSNR 监测由回归问题转变成分类问题,实现了 OSNR 的监测。另一方面,由于 OSNR 数据是时间连续的,所以很适合利用循环神经网络(Recurrent Neural Network, RNN)与长短期记忆(Long Short-Term

Memory, LSTM)网络回归拟合。相干接收机的 4 路信号作为输入数据直接训练 LSTM 网络对 OSNR 进行拟合^[6-7],能够获得不错的效果。

以上基于机器学习的链路 OSNR 监测方案在相干光通信系统中都取得了一定的成果,但在直调直检(Intensity-Modulation and Direct Detection, IMDD)系统中还有待进一步研究。针对 IMDD 系统高效低成本 OSNR 监测需要,本文提出了基于 DNN 链路的监测方案。将通信数据作为沟通物理层和网络层的桥梁,通过大批量样本训练挖掘链路信息。本文采用 5 层 DNN 的网络结构,在 5~15 dB 范围内,成功估计出了 2 GBaud 开关键控(On-Off Key, OOK)信号的 OSNR 值,平均绝对误差(Mean Absolute Error, MAE)小于 0.8 dB。该 OSNR 监测方案具有准确率高、成本低、运行速度快和复杂度低的特点,有助于实现精准和动态地链

收稿日期:2022-05-09

基金项目:国家重点研发计划资助项目(2021YFB2401000)

作者简介:刘军(1970-),男,河北保定人。高级工程师,学士,主要研究方向为电力通信网络和系统设计。

通信作者:李伯中,高级工程师。E-mail:1813697612@qq.com

路监测,辅助光网络高效运维。

1 基本原理

神经网络由大量神经元(Neuron)构成。每个神经元的示意图如图 1 所示,图中, $\mathbf{X} = \{x_1, x_2, x_3, \dots, x_n\}$ 为神经元的输入向量, $\mathbf{W} = \{w_1, w_2, w_3, \dots, w_n\}$ 为神经元的权重向量。




图 1 神经元示意图

Figure 1 Schematic diagram of neuron


设该神经元的阈值为 φ , 则该神经元的输出值 y 为

$$y = f\left(\sum_{i=1}^n w_i x_i - \varphi\right), \quad (1)$$

式中, $f(x)$ 为激活函数。激活函数一般选取 Sigmoid 函数:

$$\text{sigmoid}(x) = \frac{1}{1 + e^{-x}}. \quad (2)$$

假设训练集 $\mathbf{T} = \{(\mathbf{X}_1, \mathbf{Y}_1), (\mathbf{X}_2, \mathbf{Y}_2), \dots, (\mathbf{X}_n, \mathbf{Y}_n)\}$, $\mathbf{X}_n = \{x_1, x_2, x_3, \dots, x_a\}$ 为神经网络的输入向量, a 为输入层神经元个数, $\mathbf{Y}_n = \{y_1, y_2, y_3, \dots, y_c\}$ 为网络的输出向量, c 为输出层神经元个数, 搭建含有输入层、输出层和隐藏层的 3 层全连接神经网络, 如图 2 所示。



注: b 为隐藏层神经元个数。

图 2 神经网络示意图

Figure 2 Schematic diagram of neuron network

如图所示, 输入层神经元为 a 个, 隐藏层神经元为 b 个, 输出层神经元为 c 个。输入层接收并激活信号, 通过隐藏层提取数据特征, 不同的隐藏层单元有

着不同的输入层神经单元权重以及不同的自身偏置。信号从输入层传递至隐藏层, 最后在输出层结合各个隐藏层权重以及自身的偏置输出最后的结果。由此可知, 输入层的神经元个数和输入数据的长度是相同的, 输出层的神经元个数和所需要提取的信息维度也是相同的。神经网络通过前向传播对已有数据进行预测, 接下来通过后向传播算法对每个神经元的阈值以及神经元间的连接权重进行训练, 预测值与目标值之间的误差被用作训练的依据。以图 2 所示神经网络为例, 设第 r ($r=1, 2, 3$) 层神经元的阈值为 φ^r , 第 r 层第 i 个神经元的激活值(输出值)为 O_i^r , 第 r 层第 i 个神经元与第 $r+1$ 层第 j 个神经元之间的连接权重为 w_{ij} , 则正向传播预测公式为

$$O_j^{r+1} = f\left(\sum_i w_{ij} O_i^r - \varphi^r\right). \quad (3)$$

反向梯度下降的权值更新公式为

$$w_{ij}^{r(t+1)} = w_{ij}^{r(t)} - \eta \nabla E(w_{ij}^{r(t)}), \quad (4)$$

反向梯度下阈值更新公式为

$$\varphi^{r(t+1)} = \varphi^{r(t)} - \eta \nabla E(\varphi^{r(t)}), \quad (5)$$

式中: $\eta \in (0, 1)$ 为学习率 (Learning rate), 是神经网络最重要的超参数, 决定目标函数收敛到全局最小值的概率以及收敛到全局最小值的速度; ∇ 为梯度下降算法, 其不断地调整权重至使误差不断减小; E 为输出层的输出误差, 又被称作损失函数; t 为迭代次数。

DNN 是一种含有多个隐藏层的人工神经网络 (Artificial Neural Network, ANN), 在机器视觉、语音识别和航天航空等领域得到了广泛的应用。DNN 的多层隐藏层可以自动提取输入数据的深层次特征, 增加模型的表达能力, 帮助 DNN 对更复杂的数据进行建模。本文提出了一种利用 DNN 预测光链路中 OSNR 的方法。光/电探测器 (Photoelectric Detector, PD) 将信号从光域转换到电域后, 直接输入至 DNN 中。本文将长度为 512 的信号序列送入 DNN 中进行训练, 所以 DNN 的输入层神经元数量也为 512, 最后输出的 OSNR 值是单个数据, 故将输出层的神经元数量设置为 1。训练好的 DNN 将不需要预知系统的结构参数, 可通过接收的数字信号预测得到链路当前的 OSNR 值。

2 实验与仿真

实验室对 2 GBaud OOK 信号传输进行了建模仿真, 仿真系统设置如图 3 所示。激光光源输出光

入射至马赫-曾德尔调制器(Mach-Zehnder Modulator, MZM)中接受调制编码,信号码元由任意波形发生器(Arbitrary Waveform Generator, AWG)生成。而后,光信号经由光耦合器(Optical Coupler, OC)与掺铒光纤放大器(Erbium Doped Fiber Application Amplifier, EDFA)连接,引入自发辐射(Amplifier Spontaneous Emission, ASE)噪声,可变光衰减器(Variable Optical Attenuator, VOA)用于控制 ASE 噪声的大小,测量不同噪声水平下的信号序列。PD 将光信号转换成电信号,并将信号送入带通滤波器(Band-Pass Filter, BPF)进行带通滤波,示波器(Digital Storage Oscilloscope, DSO)可以读取电信号信号序列。最后将电信号序列送入训练好的 DNN 中,即可计算出系统的 OSNR 值。由于仿真的特殊性,我们可以轻松地记录加入噪声前后光信号的功率变化,将光信号功率代入下面的公式(6)计算可以求得链路的 OSNR 值。在实际的测量过程中,我们只能读取到电信号的幅值,所以需要利用 DNN 去学习电信号与链路 OSNR 之间潜在的关联。




图 3 监测 OSNR 的仿真系统示意图
Figure 3 Simulation setup of OSNR monitoring system

链路的 OSNR 变化范围设置为 5~15 dB,步长为 1 dB。为了探究训练网络所需要的数据集以及学习深度,我们选取的数据集分别为 22 000、110 000和 550 000 组,网络的隐藏层数目为 1、3 和 5 层,一共 9 种配置^[3],并分别观察了神经网络的学习性能。特别地,数据集由训练集、测试集和验证集 3 部分组成,其数量的比值为 8 : 1 : 1,每组数据是一个长度为 512 的信号序列。OSNR 的计算公式为

$$OSNR = \frac{P_{sig}}{P_{noise}} = \frac{\sum |E_{w/o\ noise}|^2}{\sum |E_{w\ noise} - E_{w/o\ noise}|^2}, \quad (6)$$

式中: P_{sig} 为光信号的能量; P_{noise} 为噪声的能量; $E_{w/o\ noise}$ 为不含噪声的信号幅值; $E_{w\ noise}$ 为包含噪声的信号幅值, $|\cdot|$ 为绝对值函数。

DNN 的结构如图 4 所示,输入层用于接收并处理信号,随后与 1/3/5 层隐藏层连接,提取信号的特

征,最终将数据送入输出层,输出由信号序列预测出的 OSNR 值。其中,输入层包含 512 个神经元,隐藏层每层包含 500 个神经元,由于输出的 OSNR 值只有 1 个,所以输出层的神经元数量也为 1。输入和输出层均采用线性函数(Linear Function)作为激活函数(Activation Function),隐藏层的激活函数选用线性整流函数(Rectified Linear Unit, ReLU)。网络搭建完成后,选取 Rmsprop 优化器针对训练数据的 MAE 进行优化处理,训练批次(Epoch)设置为 300,批次大小(Batch size)设置为 1 024。




图 4 DNN 结构示意图
Figure 4 Schematic diagram of proposed DNNs

3 数据分析

图 5 所示为 DNN 在不同数据集数量和网络层数下的预测结果。通过对比图 5(c)、5(f)和 5(i)可知,隐藏层数目为 1,即网络总层数为 3 时,相较于其他两种网络,网络的学习深度不够,无法识别出电信号幅值与链路中 OSNR 的内在联系。进一步对比图 5(d)与 5(g)、5(e)与 5(h)和 5(f)与 5(i)可知,3 层和 5 层隐藏层对于网络的学习性能差异并不明显,而 5 层隐藏层需要训练的参量要多于 3 层隐藏层,训练速度更慢,更容易出现过拟合情况,所以 3 层隐藏层相较下是更好的网络结构。从数据集的角度来看,数据集为 22 000 组时,3 种隐藏层结构的网络表现均不佳;数据集为 110 000 组时,3 种隐藏层结构的网络都已初步学习到了信号幅值与 OSNR 的内在联系,但仍处于欠拟合状态;当数据集增加至 550 000 组时,3 层和 5 层隐藏层结构的网络预估的 OSNR 值与实际 OSNR 值误差已经在 1 dB 以内,具备了快速、动态和精准地估计链路 OSNR 的能力。图 6 所示为不同训练集数量下 MAE 随网络总层数的变化图。总的来说,数据集的量太小,神经网络

络无法从训练中学习信号序列与 OSNR 值之间的联系,网络深度不够,神经网络没有能力提取信号的特征。

综合 9 种情况下网络的表现,数据集的量应选

为 550 000 组,隐藏层数应设置为 3 层,即网络总层数为 5 层,此时 DNN 的训练速度和学习表现都为较佳状态。




图 5 不同 DNN 结构与训练集数量下的 OSNR 网络预测图

Figure 5 Test results of OSNR estimation by DNNs




图 6 不同训练集数量下 MAE 随网络总层数的变化图

Figure 6 Averaged error of estimated OSNR versus number of DNN layers under different amount of training dataset

网络总层数为 5 层的 DNN 在 550 000 组数据

集下的训练过程如图 7 所示,随着网络训练轮次的不断增加,训练集和验证集的 MAE 都在不断减小,





图 7 5 层 DNN 在 550 000 组数据集下的训练过程图


Figure 7 MAE versus epoch during the 5-layers DNN training by 550 000 dataset

当网络经历了 50 轮次的训练后,验证集 MAE 变化趋于平缓。最终,神经网络的训练集 MAE 为 0.31 dB,验证集 MAE 为 0.65 dB。将测试集数据输入训练好的 DNN 中,得到 OSNR 的预测 MAE 为 0.67 dB,与验证集的结果相近。虽然网络训练集和验证集的 MAE 相差较大,存在着一定的过拟合,但验证集和测试集的 MAE 相差较小,说明模型具有很强的泛化能力。

网络预测 OSNR 值与真实 OSNR 值之间的关系如图 8(a)所示,预测 OSNR 与真实 OSNR 相差大部分在 1 dB 以内。图 8(b)所示为不同 OSNR 水平下,预测 OSNR 的 MAE。由图可知,所有 OSNR 水平下,预测 MAE 均低于 0.8 dB,且实际 OSNR 为 5 dB 时,预测出 OSNR 的 MAE 只有不到 0.4 dB,说明其预测准确性最高。OSNR 处于较低水平时,信号受噪声影响较大,故而 DNN 更能准确地识别此时的 OSNR 值;当链路的 OSNR 处于较高水平时,噪声对信号的影响较小,网络对于 OSNR 值的识别误差逐渐增加。本文所提方案只需将电信号输入至 1 个 DNN 中,处理时延为 3 ms,就可以实现链路 OSNR 的精准和动态监测。相较于其他神经网络,DNN 结构简单,运算速度更快,并且网络的输入数据为电信号幅值,相较于输入其他统计特征参量的方案,省去了数据处理步骤,进一步降低了系统的复杂度,因此本文所提电域 OSNR 监测方案具



(a) 预测 OSNR 与真实 OSNR 对比图



(b) OSNR 的预测 MAE 图

(b) MAE of the estimated OSNR

图 8 网络预测性能评估

Figure 8 Test results of OSNR estimation by the proposed DNN

有成本低、运行速度快和复杂度低等优点,是未来智能光网络的理想选择。

4 结束语

本文提出了一种基于 DNN 的电域信号处理、精确监测 OSNR 的方案。该方案从 PD 接收到的电信号中提取 OSNR 的特征,不需要提前预知光传输链路的传输特性或人为输入其他参数,就可以准确、灵活地监测光链路的 OSNR 值。由实验结果可知,当 OSNR 在 5~15 dB 时,监测的 MAE < 0.8 dB。本文所提基于 DNN 的电域 OSNR 监测方案,能根据实时信号动态反馈链路中的 OSNR 信息,辅助优化光链路结构,有望助力未来智能光网络更加稳定和可靠。

参考文献:

[1] Pan Z, Yu C, Willner A E. Optical Performance Monitoring for the Next Generation Optical Communication Networks[J]. Optical Fiber Technology, 2010, 16(1):20-45.

[2] Khan F N, Lu C, Lau A. Optical Performance Monitoring in Fiber-optic Networks Enabled by Machine Learning Techniques[C]//Optical Fiber Communications Conference and Exposition. San Diego, CA, USA; IEEE, 2018:M2F. 3.

[3] Wang D, Wang M, Zhang M, et al. Cost-effective and Data Size-adaptive OPM at Intermediated Node Using Convolutional Neural Network-based Image Processor [J]. Optics Express, 2019, 27(7):9403-9419.

[4] Tanimura T, Hoshida T, Rasmussen J, et al. OSNR Monitoring by Deep Neural Networks Trained with Asynchronously Sampled Data[C]//Optoelectronics & Communications Conference. Niigata, Japan; IEEE, 2016:TuB3-5.

[5] Wang D, Zhang M, Li Z, et al. Modulation Format Recognition and OSNR Estimation Using CNN-based Deep Learning[J]. IEEE Photonics Technology Letters, 2017, 29(19):1667-1670.

[6] Wang D, Zhang M, Li J, et al. Intelligent Constellation Diagram Analyzer Using Convolutional Neural Network-based Deep Learning[J]. Optics Express, 2017, 25(15):17150.

[7] Wang C, Fu S, Xiao Z, et al. Long Short-Term Memory Neural Network (LSTM-NN) Enabled Accurate Optical Signal-to-Noise Ratio (OSNR) Monitoring [J]. Journal of Lightwave Technology, 2019, 37(16): 4140-4146.