

doi:10.13756/j.gtxyj.2021.04.004

光通信系统与网络技术

基于机器学习的相干光通信系统传输性能评估

陈中盛¹, 高冠军¹, 刘鸿飞²

(1. 北京邮电大学 信息光子学与光通信国家重点实验室, 北京 100876;

2. 中国科学院国家天文台 FAST 重点实验室, 北京 100101)

摘要:针对传统相干光通信系统中光纤链路传输性能评估方法理论计算复杂且计算时间较长的问题,文章采用机器学习技术对调制格式和输入光功率等参数各异信道的相干光传输系统传输性能进行关联式建模和精确评估。建模和评估结果表明,该机器学习模型能够代替复杂的理论计算,并且能够较为准确地给出预测值,理论计算值与模型预测 Q 值整体的平均误差为 0.27 dB,理论计算值与模型预测光信噪比(OSNR)值整体的平均误差为 0.33 dB;采用机器学习模型的计算时间稳定在 4.4 s 左右,而采用理论计算的时间随着干扰信道个数的增加计算时间逐渐增加。

关键词:机器学习;相干光通信;传输性能评估

中图分类号: TN914 **文献标志码:** A **文章编号:** 1005-8788(2021)04-0015-06

Transmission Performance Evaluation of Coherent Optical Communication System based on Machine Learning

CHEN Zhong-sheng¹, GAO Guan-jun¹, LIU Hong-fei²

(1. State Key Laboratory of Information Photonics and Optical Communication, Beijing University of Posts and Telecommunications, Beijing 100876, China; 2. Key Laboratory of FAST, National Astronomical Observatories, CAS, Beijing 100101, China)

Abstract: In view of the complexity of theoretical calculation and long calculation time of traditional evaluation method of optical fiber link transmission performance in coherent optical communication system, this paper uses machine learning technology to build correlation model and accurately evaluate the transmission performance of coherent optical transmission system with different modulation format and input optical power parameters. Through the training model, the results show that the machine learning model can replace the complex theoretical calculation, and can more accurately predict the predicted value, The overall average error between the theoretical value and the predicted Q value is 0.27 dB. The overall average error between the theoretical value and the predicted Optical Signal to Noise Ratio (OSNR) value is 0.33 dB. The calculation time of machine learning model is about 4.4 s, while the theoretical calculation time increases with the increase of the number of interference channels.

Key words: machine learning; coherent optical communication; transmission performance evaluation

0 引言

当前,云计算、大数据和大视频等业务快速发展,光纤通信系统已成为移动通信网络和互联网的主干核心,并承载了绝大部分互联网数据流量,对光纤大容量和低时延提出了更高要求。因此,对相干光通信系统中光纤链路的传输性能进行评估在系统设计阶段显得特别重要。在目前已有的许多研究中^[1-5],应用最为广泛的非线性干扰(Nonlinear Interference, NLI)评估模型为高斯噪声(Gaussian Noise, GN)模型,该模型假设系统传输的波分复用(Wavelength Division Multiplexing, WDM)信号服从联合高斯分布,所有 WDM 子信道均可认为服从高斯分布,且通过 GN 模型能够对传输性能进行较

为准确的评估。

本文采用机器学习技术对相干光系统合作式传输性能进行了更准确和更快速的评估,其中,训练和测试数据集根据 GN 模型运用 Matlab 软件进行理论计算获取,通过该机器学习模型能够优化传输系统设计,从而降低使用者的成本,满足高速相干光系统飞速增长的应用需求^[6-8]。

1 GN 传输性能评估模型

相干光通信系统中的传输性能评估模型通常采用 GN 模型的假设,用以描述无色散补偿的相干接收系统中所受到的非线性损伤^[9]。该模型假设光纤系统传输的 WDM 信号服从联合高斯分布,并且系统内所有 WDM 子信道均可认为服从高斯分布。

收稿日期:2020-12-28

基金项目:国家自然科学基金资助项目(U1831110);北京邮电大学行动计划资助项目(2019XD-A15);信息光子学与光通信国家重点实验室自主研究课题资助项目(IPOC2020ZZ02)

作者简介:陈中盛(1996—),男,福建邵武人。硕士,主要研究方向为基于机器学习的光通信系统传输性能。

通信作者:陈中盛,硕士。E-mail:zhongshengchen520@163.com

基于这种假设,计算系统信噪比(Signal to Noise Ratio, SNR)时,系统噪声可以将 NLI 和放大器自发辐射(Amplifier Spontaneous Emission, ASE)噪声进行叠加,GN 模型下系统 SNR 可表示为

$$\text{SNR} = \frac{P_{\text{in}}}{P_{\text{ASE}} + P_{\text{NLI}}}, \quad (1)$$

式中: P_{in} 为输入信号光功率; P_{ASE} 为 ASE 噪声功率; P_{NLI} 为 NLI 功率。

$$P_{\text{ASE}} = (G - 1) \times NF \times R_s \times h\nu, \quad (2)$$

$$P_{\text{NLI}} \approx \int_{-R_s/2}^{R_s/2} G_{\text{NLI}}(f) df, \quad (3)$$

式中: G 为光纤链路中掺铒光纤放大器(Erbium

$$G_{\text{NLI}}(f) = \frac{16}{27} \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} G_{\text{WDM}}(f_1) G_{\text{WDM}}(f_2) G_{\text{WDM}}(f_1 + f_2 - f) |\mu(f_1, f_2, f)|^2 df_1 df_2, \quad (4)$$

式中: $G_{\text{WDM}}(f)$ 为 WDM 信号功率谱密度; f_1 和 f_2 分别为中间信道和干扰信道的频域自变量; $|\mu|^2$ 为输入端至输出端整个传输链路的四波混频(Four Wave Mixing, FWM)效率,此项取决于系统链路的

$$|\mu(f_1, f_2, f)|^2 = \gamma^2 L_{\text{eff}}^2 \left| \frac{1 - e^{-2\alpha L_s} e^{j4\pi^2 \beta_2 L_s (f_1 - f)(f_2 - f)}}{1 - j2\pi^2 \beta_2 \alpha^{-1} (f_1 - f)(f_2 - f)} \right|^2 \frac{\sin^2[2N_s \pi^2 (f_1 - f)(f_2 - f) \beta_2 L_s]}{\sin^2[2\pi^2 (f_1 - f)(f_2 - f) \beta_2 L_s]}, \quad (5)$$

式中: γ 为非线性系数; L_{eff} 为光纤有效长度; α 为光纤衰减系数; L_s 为单个光纤跨段的长度; β_2 为光纤二阶色散系数; j 为虚数单位; N_s 为光纤跨段数。式中,右侧最后一个因子为两个正弦函数平方比率的形式,代表不同跨段在接收端处产生的非线性相干干扰。最后一个因子可用链路中的光纤跨段数

$$G_{\text{NLI}}(f) = N_s \gamma^2 L_{\text{eff}}^2 \frac{16}{27} \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} G_{\text{WDM}}(f_1) G_{\text{WDM}}(f_2) G_{\text{WDM}}(f_1 + f_2 - f) \times \left| \frac{1 - e^{-2\alpha L_s} e^{j4\pi^2 \beta_2 L_s (f_1 - f)(f_2 - f)}}{1 - j2\pi^2 \beta_2 \alpha^{-1} (f_1 - f)(f_2 - f)} \right|^2 df_1 df_2. \quad (6)$$

2 机器学习传输性能评估模型

2.1 相干光通信系统合作式传输模型


相干光通信系统合作式传输模型如图 1 所示。其中包括多个数据中心、多条光缆、光分插复用器(Optical Add-drop Multiplexer, OADM)和放大器等,其最大特点就是各数据中心和光缆连接的网络互联互通,具体的物理层模型已知,这是属于比较理想的情况。本文针对几种不同场景,通过 GN 模型进行理论计算,如调制格式改变、掉波、各跨段光纤类型不同、信道间隔不同和使用不同的光(信号光或 ASE 噪声)进行补光时等,对不同情况的场景进行理论性能评估并获取相应的数据。WDM 系统中,光纤传输链路中产生的 NLI 可分为信道内和信道间 NLI 两种。本文分别对只考虑信道内干扰的

Doped Fiber Amplifier, EDFA) 增益; NF 为 EDFA 噪声系数; R_s 为信号带宽; h 为普朗克常量; ν 为输入光信号的频率; f 为频域自变量; G_{NLI} 为 NLI 功率谱密度。预估非线性功率需知 NLI 的功率谱密度,对接收端匹配滤波器的实际形状进行分析^[10],当中间信道(即被干扰信道)所传输信号脉冲的傅里叶变换形式为根号升余弦形式且滚降系数较小时,式(3)中对 P_{NLI} 的估计比较准确。假设 NLI 服从高斯分布,GN 模型下 NLI 功率谱密度 $G_{\text{NLI}}(f)$ 的表达式为^[10]

设计。假设系统链路为相同跨段,采用泵浦放大方式,每个放大器增益恰好与前一光纤跨段的衰减相等,此时^[10]:

N_s 近似替代。假设不同跨段产生的 NLI 在接收端的影响能够叠加,则由上述公式可得,对于一个均匀且每个放大器增益恰好与前一光纤跨段衰减相等的光纤链路,GN 模型中的 NLI 功率谱密度可表示为^[10]

NLI 以及同时包含信道间和信道内 NLI 两种情况采用机器学习的方法进行性能评估。



注: TX 为发送端; RX 为接收端; L_n 为第 n 段光纤跨段; G_n 为第 n 个放大器; λ_n 为第 n 个波长。

图 1 相干光通信系统合作式传输模型

2.2 相干光通信系统合作式传输神经网络模型的设计

在实验中,利用 TensorFlow 框架搭建了一个神经网络模型用于相干光通信系统合作式传输性能

评估的训练和预测。神经网络模型结构如图 2 所示,主要包含输入层、两个连接层(隐藏层)和输出层。连接层 1 的输出结果通过 relu 函数进行激活,然后输入到连接层 2;连接层 2 将输入与适当的权重和偏移量一起计算,最终输出最佳预测结果,并传递给输出层输出^[11-12]。




图 2 神经网络模型设计结构图

3 结果与分析

3.1 模型的训练

图 3 所示为模型训练的损失折线图,图中,浅蓝色和橘黄色分别为同时包含信道间和信道内 NLI 和只考虑信道间 NLI 的模型训练损失折线图。生成机器学习模型需要经过多次重复训练,采用梯度下降法最小化损失,设置学习率为 0.000 01,最初设置循环 1 000 次,当循环开始并运行后,绘制得到的损失折线图如图 3 所示,随着迭代次数的增加,训练出的模型损失曲线呈收敛趋势。经过反复测试得出,设置训练次数为 600 次时,既不耗费过多时间,也可以获得较好的训练效果。




图 3 损失折线图

3.2 传输性能评估

本节假设链路中传输信号的中间信道调制格式为偏分复用-正交相移键控(Partial Division Multiplexing- Quadrature Phase Shift Keying, PDM-QPSK),系统传输速率为 68 Gbaud,信道间隔为 75 GHz,且设干扰信道个数均为总的干扰信道个数。图 4 所示为不同干扰信道下调制格式各异的理论计算与预测 Q 值对比图,图中,浅蓝色和红色分

别代表调制格式为 QPSK 和 16 阶正交幅度调制(16 Quadrature Amplitude Modulation, 16QAM)干扰信道的理论计算变化曲线,橘黄色和黄色分别代表调制格式为 QPSK 和 16QAM 干扰信道的机器学习预测变化曲线。所评估系统的系统参数设置如下:光纤的非线性系数为 $g = 1.3 \text{ [W} \cdot \text{km]}^{-1}$ 、光纤色散系数为 $\beta = 17 \text{ ps/nm/km}$ 、光纤衰减系数为 $\alpha = 0.2 \text{ dB/km}$,系统链路为有 20 个光纤跨段、每个光纤跨段的长度为 50 km,总长度为 1 000 km 的均匀链路。每个光纤跨段对信号产生的衰减可由该跨段后的 EDFA 完全补偿,即 EDFA 增益等于光纤衰减,且 EDFA 噪声系数为 5 dB。

如图所示,当系统存在外接波长接入的情况时,将外接波长作为已有系统波长的干扰信道来评估其对系统传输性能的影响。由图可知,随着干扰信道个数的增加,系统 Q 值缓慢减小,理论计算和机器学习模型预测曲线较为接近,与预期结果相符。对于 QPSK,理论计算值与机器学习模型预测 Q 值误差最大为 0.210 dB,最小为 0.001 dB,平均误差为 0.140 dB;对于 16QAM,理论计算值与机器学习模型预测 Q 值误差最大为 0.530 dB,最小为 0.330 dB,平均误差为 0.470 dB;总的平均误差为 0.310 dB。




图 4 不同干扰信道下调制格式各异的理论计算与预测 Q 值对比图

图 5 所示为不同干扰信道下调制格式各异的理论计算与预测广义光信噪比 (Generalized Optical Signal to Noise Ratio, GOSNR) 值对比图。GOSNR 为噪声,不仅包含 ASE 噪声,还考虑了 NLI 的光信噪比 (Optical Signal to Noise Ratio, OSNR)。由图可知,随着干扰信道个数的增加,系统 GOSNR 值逐渐降低,对于 QPSK,理论计算值与机器学习模型预测 GOSNR 值误差最大为 0.15 dB,最小为 0.09 dB,平均误差为 0.12 dB;对于 16QAM,理论

计算值与机器学习模型预测 GOSNR 值误差最大为 0.19 dB,最小为 0.04 dB,平均误差为 0.10 dB;总的平均误差为 0.11 dB。由此可知,理论计算值与机器学习模型预测 GOSNR 值误差较小。




图 5 不同干扰信道下调制格式各异的理论计算与预测 GOSNR 值对比图

图 6 所示为不同输入光功率下调制格式各异时,仅考虑信道内 NLI 的理论计算与预测 Q 值对比图。由图可知,随着输入光功率的增加,Q 值逐渐增大,对于 QPSK,理论计算值与机器学习模型预测 Q 值误差最大为 0.72 dB,最小为 0.09 dB,平均误差为 0.32 dB;对于 16QAM,理论计算值与机器学习模型预测 Q 值误差最大为 0.44 dB,最小为 0.01 dB,平均误差为 0.16 dB;总的平均误差为 0.24 dB。




图 6 不同输入光功率下调制格式各异仅考虑信道内 NLI 的理论计算与预测 Q 值对比图

图 7 所示为不同输入光功率下调制格式各异时,仅考虑信道内 NLI 的理论计算与预测 OSNR 值对比图。由图可知,随着输入光功率的增加,OSNR 值逐渐增大,对于 QPSK,理论计算值与机器学习模

型预测 OSNR 值误差最大为 0.74 dB,最小为 0.03 dB,平均误差为 0.27 dB;对于 16QAM,理论计算值与机器学习模型预测 OSNR 值误差最大为 0.92 dB,最小为 0.37 dB,平均误差为 0.69 dB;总的平均误差为 0.48 dB。由此可知,理论计算值与模型预测值较为接近,且整体趋势基本一致。




图 7 不同输入光功率下调制格式各异仅考虑信道内 NLI 的理论计算与预测 OSNR 值对比图

图 8 所示为不同输入光功率下调制格式各异考虑信道内和信道间 NLI 的理论计算与预测 Q 值对比图。由图可知,随着输入光功率的增加,Q 值逐渐增大,对于 QPSK,理论计算值与机器学习模型预测 Q 值误差最大为 0.62 dB,最小为 0.11 dB,平均误差为 0.24 dB;对于 16QAM,理论计算值与机器学习模型预测 Q 值误差最大为 0.67 dB,最小为 0.01 dB,平均误差为 0.30 dB;总的平均误差为 0.27 dB。由此可知,理论计算值与机器学习模型预测值较为接近,且整体趋势基本一致。




图 8 不同输入光功率下调制格式各异考虑信道内和信道间 NLI 的理论计算与预测 Q 值对比图

图 9 所示为不同输入光功率下调制格式各异考虑信道内和信道间 NLI 的理论计算与预测 GOSNR

值对比图。由图可知,随着输入光功率的增加,GOSNR 值逐渐增大,对于 QPSK,理论计算值与机器学习模型预测 GOSNR 值误差最大为 1.00 dB,最小为 0.02 dB,平均误差为 0.37 dB;对于 16QAM,理论计算值与机器学习模型预测 GOSNR 值误差最大为 1.10 dB,最小为 0.03 dB,平均误差为 0.42 dB。总的平均误差为 0.40 dB。由此可知,理论计算值与机器学习模型预测值较为接近,且整体趋势基本一致。




图9 不同输入光功率下调制格式各异考虑信道内和信道间 NLI 的理论计算与预测 GOSNR 值对比图

通过以上计算可知,理论计算值与机器学习模型预测 Q 值整体的平均误差为 0.27 dB,与机器学习模型预测 OSNR 值整体的平均误差为 0.33 dB。因此,调用基于机器学习的相干光系统合作式传输评估模型,可以较为准确地估计出预测值。

图 10 所示为不同单侧干扰信道下调制格式各异的 Matlab 软件理论计算与机器学习模型预测计算时间对比图。随着单侧干扰信道个数的增加,采用机器学习模型预测计算的时间稳定在 4.4 s 左




图10 不同干扰信道下调制格式各异的理论计算与模型预测计算时间对比图

右,采用 Matlab 软件理论计算的时间逐步增加,其中 Matlab 软件理论计算通过对式(3)和(6)采用蒙特卡洛积分方法进行计算,与解析公式^[5]相比计算更精准,误差较小,但随着干扰个数的增加,计算时间逐渐增加。当干扰个数 <5 时,采用 Matlab 软件理论的计算时间优于机器学习模型预测;当干扰个数 >5 时,机器学习模型预测的速度明显优于 Matlab 软件理论计算时间;当干扰个数 $=5$ 时,Matlab 软件理论计算与机器学习模型预测所用时间一致。

4 结束语

本文提出了一种基于机器学习对相干光通信系统进行合作式传输性能评估的方法。通过模型训练,再调用模型预测,可以较为准确地估计出预测值。实验证明,Matlab 软件理论计算值与机器学习模型预测值较为接近,理论计算值与机器学习模型预测 Q 值整体的平均误差为 0.27 dB,理论计算值与机器学习模型预测 OSNR 值整体的平均误差为 0.33 dB。此外,该模型能够代替复杂的积分理论计算,大大提高了计算速度。

参考文献

- [1] 李炜,陈宝靖,柴京,等. 100 Gb/s PDM-QPSK 系统传输性能评估技术研究[J]. 光通信技术,2015,39(4): 15—17.
- [2] Huang Y, Heritage J P, Mukherjee B. Connection Provisioning with Transmission Impairment Consideration in Optical WDM Networks with High-Speed Channels [J]. Journal of Lightwave Technology, 2005, 23(3): 982—993.
- [3] Ramamurthy B, Datta D, Feng H, et al. Impact of Transmission Impairments on the Teletraffic Performance of Wavelength-routed Optical Networks[J]. Journal of Lightwave Technology, 1999, 17(10): 1713—1723.
- [4] Martins-Filho J F, Bastos-Filho C J A, Arantes E A J. et al. Novel Routing Algorithm for Transparent Optical Networks based on Noise Figure and Amplifier Saturation[C]//Proceedings of the 2003 SBMO/IEEE MTT-S International Microwave and Optoelectronics Conference-IMOC 2003. Foz do Iguacu, Brazil: IEEE, 2003:1242704.
- [5] Poggiolini P, Carena A, Curri V, et al. Analytical Modeling of Nonlinear Propagation in Uncompensated Optical Transmission Links [J]. IEEE Photonics Technology Letters, 2011, 23(11): 742—744.

[6] Rottondi C, Barletta L, Giusti A, et al. Machine-Learning Method for Quality of Transmission Prediction of Unestablished Lightpaths[J]. Journal of Optical Communications and Networking, 2018, 10(2): A286 — A297.

[7] Seve E, Pesic J, Delezoide C, et al. Learning Process for Reducing Uncertainties on Network Parameters and Design Margins[J]. Journal of Optical Communications and Networking, 2018, 10(2): A298 — A306.

[8] Sartzetakis I, Christodouloupoulos K, Varvarigos E. Formulating QoT Estimation with Machine Learning [C]//2018 European Conference on Optical Communication (ECOC). Rome, Italy: IEEE, 2018: 8535429.

[9] Dar R, Feder M, Mecozzi A, et al. Properties of Non-linear Noise in Long, Dispersion-Uncompensated Fiber Links[J]. Optics Express, 2013, 21(22): 25685 — 25699.

[10] Poggiolini P, Jiang Y. Recent Advances in the Modeling of the Impact of Non-Linear Fiber Propagation Effects on Uncompensated Coherent Transmission Systems [J]. Journal of Lightwave Technology, 2017, 35(3): 458 — 480.

[11] 刘卫华. 基于 TensorFlow 神经网络的数据中心故障预测研究[J]. 电子测试, 2019(16): 64 — 65, 130.

[12] 陈豪, 吴健. 基于神经网络的正弦波函数拟合实现研究[J]. 现代信息科技, 2019, 3(21): 4 — 6.

(上接第 4 页)

MPA。在 SNR = 1 dB 时, IBP-MPA 的计算复杂度可以降低为 MPA 计算复杂度的 75%。随着 SNR 的上升, IBP-MPA 的 CCR 在逐渐下降。这是因为, 不参与迭代的可靠用户节点数会随着 SNR 的增加而增加。在 SNR = 10 dB 时, IBP-MPA 的计算复杂度可以降低为 MPA 的 51%。

4 结束语

本文主要研究了上行异步 SCMA 系统的低复杂度检测算法, 由于 BP-MPA 会对不必要的用户节点进行更新, 增加了计算复杂度。本文根据每个资源对用户发送码字概率的判断, 选择部分高可靠用户节点不参与后续迭代, 提出了 IBP-MPA。仿真结果表明, IBP-MPA 可以在保证检测性能的同时有效降低计算复杂度, 更适用于上行异步 SCMA 系统。

参考文献:

[1] Nikopour H, Baligh H. Sparse Code Multiple Access [C]//IEEE International Symposium on Personal, Indoor, and Mobile Radio Communications. London, UK: IEEE, 2013: 332 — 336.

[2] Liu Y, Qin Z, El Kashlan M, et al. Non-Orthogonal Multiple Access for 5G and Beyond[J]. Proceedings of the IEEE, 2018, 105(12): 2347 — 2381.

[3] Du Y, Dong B, Zhu W, et al. Joint Channel Estimation and Multiuser Detection for Uplink Grant-Free NOMA [J]. IEEE Wireless Communications Letters, 2018, 7(4): 682 — 685.

[4] Wang X, Labeau F, Mei L. Asynchronous Uplink Non-Orthogonal Multiple Access (NOMA) with Cyclic Prefix [C]//IEEE Wireless Communications and Networking Conference. Barcelona, Spain: IEEE, 2018: 1 — 6.

[5] Zou X, He B, Jafarkhani H. On Uplink Asynchronous Non-Orthogonal Multiple Access Systems with Timing Error [C]//IEEE International Conference on Communications. Kansas City, MO: IEEE, 2018: 1 — 6.

[6] Zou X, He B, Jafarkhani H. An Analysis of Two-User Uplink Asynchronous Non-Orthogonal Multiple Access Systems [J]. IEEE Transactions on Wireless Communications, 2019, 18(2): 1404 — 1418.

[7] Yu Q Y, Li H, Meng W, et al. Sparse Code Multiple Access Asynchronous Uplink Multiuser Detection Algorithm[J]. IEEE Transactions on Vehicular Technology, 2019, 68(6): 5557 — 5569.

[8] Dai L, Wang B, Ding Z, et al. A Survey of Non-Orthogonal Multiple Access for 5G[J]. IEEE Communications, Surveys & Tutorial, 2018, 20(3): 2294 — 2323.

[9] Taherzadeh M, Nikopour H, Bayesteh A, et al. SCMA Codebook Design [C]//IEEE 80th Vehicular Technology Conference (VTC2014-Fall). Vancouver, BC: IEEE, 2014: 1 — 5.

[10] Bayesteh A, Nikopour H, Taherzadeh M, et al. Low Complexity Techniques for SCMA Detection [C]//IEEE Globecom Workshops. San Diego, CA, USA: IEEE, 2015: 1 — 6.