

doi:10.13756/j.gtxyj.2024.230046.

光通信系统与网络技术

李鸿,刘武,罗鸣. 基于机器学习的光网络监测与优化方法[J]. 光通信研究,2024(3):230046.

Li H, Liu W, Luo M. Optical Network Monitoring and Optimization Methods based on Machine Learning[J]. Study on Optical Communications, 2024(3): 230046.

基于机器学习的光网络监测与优化方法

李鸿^a,刘武^b,罗鸣^b

(中国信息通信科技集团有限公司 a. 武汉邮电科学研究院有限公司;b. 光通信技术和网络全国重点实验室,武汉 430074)

摘要:近年来,许多新型调制和复用技术以及动态网络概念被提出,以适应不断提高的网络带宽和质量需求。网络控制平台向系统化、智能化趋势发展,要求网络管理者不断监测网络各项参数,时刻优化网络状态。然而,大范围部署额外的监测设备获取参数信息从成本控制的角度缺乏可行性,利用已知数据与特殊算法进行网络性能监测和优化是更优的选择。机器学习方法因为其足够准确和高效逐渐被学术界采纳用于完成上述任务。文章梳理了在光网络监测与优化任务中使用机器学习算法的不同应用场景,综述了该领域的研究成果,并提出了现存的基于机器学习的光网络监测与优化方法存在的问题及可能的进一步研究的方向。基于机器学习的光学性能监测包括光学损伤辨别、信道质量评估以及通道功率预测,基于机器学习的网络配置优化方法包括强化学习优化通道功率。进一步研究方向可以考虑加强与运营商的合作,使用真实的现场数据,不断获取数据动态训练模型,并使用迁移学习和数据增强等技术,以保证算法的鲁棒性与泛化能力。

关键词:机器学习;光学性能监测;光网络优化;神经网络;强化学习

中图分类号:TN929

文献标志码:A

Optical Network Monitoring and Optimization Methods based on Machine Learning

LI Hong^a, LIU Wu^b, LUO Min^b

(a. Wuhan Research Institute of Posts and Telecommunications Co., Ltd.; b. National Key Laboratory of Optical Communication Technologies and Networks, China Information and Communication Technologies Group Corporation, Wuhan 430074, China)

Abstract: In recent years, many new modulation and multiplexing technologies and dynamic network concepts have been proposed to adapt to the ever-increasing network bandwidth and quality requirements. Network control platform has a systematic and intelligent development trend, which requires network managers to constantly monitor the parameters of the network and optimize the network state. However, it is not feasible to arrange additional monitoring equipment in a large range to obtain parameter information from the perspective of cost control. It is better to use known data and special algorithms to monitor and optimize network performance. Machine learning methods are increasingly adopted by the academic community because they are accurate and efficient enough to accomplish these tasks. This paper first reviews the different application scenarios of machine learning algorithms in optical network monitoring and optimization tasks. Then it reviews the research achievements in this field, and puts forward the existing problems of machine learning-based optical network monitoring and optimization methods as well as the possible direction of future research. The optical performance monitoring based on machine learning includes failure identification, quality of transmission estimation and channel power prediction. The network configuration optimization method based on machine learning includes reinforcement learning to optimize channel power. For future research direction, we believe that it is possible for researchers to use real data from network operators, newly collected data to dynamically train the model, and transfer learning and data enhancement techniques to ensure the robustness and generalization ability of the algorithm.

Key words: machine learning; optical performance monitoring; optical network optimization; neural network; reinforcement learning

0 引言

信息技术的快速发展和大量数据的使用在带宽、延迟和可靠性方面给光网络带来了新的挑战。

为了应对这些挑战,网络传输系统和架构已经发生了革命性的进化,先进的调制格式、新的复用技术、柔性网络和可重构光分插复用器(Reconfigurable Optical Add-Drop Multiplexer, ROADM)等新型技

收稿日期:2023-08-08; 修回日期:2023-10-20; 纸质出版日期:2024-06-10

基金项目:国家重点研发计划资助项目(2022YFB2903303)

作者简介:李鸿(1996—),男,湖南平江人。硕士,主要研究方向为机器学习与光纤通信技术。

通信作者:刘武,正高级工程师。E-mail:liuwu@wri.com.cn

© Editorial Office of *Study on Optical Communications*. This is an open access article under the CC BY-NC-ND license.

23004601

术和概念逐渐被应用到现实中。这些进步增加了网络的复杂性,并给光网络的运营和管理带来了更多困难^[1]。一方面,新型技术引入了大量可调整的参数(如调制格式、符号率、自适应的编码率以及灵活的信道间隔),建模变得更加困难;另一方面,需要某种先进的数学工具从大量网络数据中提取有意义的信息,并依据其做出与网络运行相关的决策——即对光网络进行监测与优化。机器学习(Machine Learning, ML)作为一项人工智能技术,可以从各类监测设备获得的数据(例如,信号质量、数据流样本等)中推断出难以直接测量得到的有用特征或信息,因此被认为是执行网络数据分析并实现网络自我配置和故障管理自动化最有前途的方法之一^[2]。

2006~2011 年,用于光学性能监测(Optical Performance Monitoring, OPM)的 ML 算法相继被提出,用于监测光网络物理层以确定光域中信号的健康状况,使用了包括支持向量机(Support Vector Machines, SVM)^[3]、岭回归(Ridge Regression, RR)^[4]、人工神经网络(Artificial Neural Network, ANN)^[5-7]及其他各种 ML 方法^[8-11]实现对信号损伤的判别。实验证明,利用 ML 实现的分类器具有比传统方法更高的准确率,能够针对性地进行光网络故障排除。2013 年后,研究转向了对于不同信道传输质量(Quality of Transmission, QoT)的分类和预测,基于案例推理(Case-Based Reasoning, CBR)^[12]、随机森林(Random Forest, RF)^[13]和高斯过程非线性回归(Gaussian Processes Nonlinear Re-

gression, GPR)^[14]等的算法被用于评价光传输质量是否达标,以及光信号传输规划和波分复用信道的波长设计。这项工作中参数不确定性的影响是一个关键问题^[15-20],2016 年,研究人员利用 ML 完成了对光放大器这样的光网络非线性器件在功率上的精确建模^[21-23],对于实现光网络功率配置优化^[24-25]有重要意义。随着技术和框架的进步,研究者逐渐倾向于使用神经网络解决光网络上的复杂问题。

本文首先归纳了使用 ML 进行 OPM 的相关工作,包括损伤故障识别、信道质量评估以及通道功率预测;然后介绍了利用 ML 技术进行光网络配置优化的最新成果;最后对基于 ML 的光网络监测与优化方法进行了总结与展望。

1 使用 ML 进行 OPM

1.1 基于 ML 的损伤故障识别

施行物理层监控并识别随时出现的光学损伤或故障是保证光网络服务质量(Quality of Service, QoS)的基础。2006 年,Ronald A. Skoog 等人^[3]在不同的单一光学损伤以及无损伤情形下获取了眼图,并使用 SVM 对其数学特征加以区分。考虑具有单一损伤的光信号,共有 4 种损伤情况,分别为色散(Chromatic Dispersion, CD)、一阶偏振模色散(Polarization Mode Dispersion, PMD)、非相干串扰(Xtalk)和无损伤(Normal),待分类的 4 种眼图及其特征位置如图 1 所示。

该方法将眼图映射成特征向量,利用低阶




图 1 待分类的 4 种眼图及其特征位置^[3]

Figure 1 Example simulated eye diagrams for different cases of a single optical impairment^[3]

Zernike 矩, 每一个眼图都用一个 23 维特征向量来表征。训练时对每种损伤都生成子分类器, 最后对所有子分类器的结果进行投票, 将得票最高的损伤作为判别结果。实验将训练好的 SVM 分类器应用于 17 个测试眼图, 结果中 15 个高置信度(60%)分类正确, 2 个低置信度(50%)分类错误。

以上工作仅限于对单个损伤进行分类。2007 年, Trevor B. Anderson 等人^[4]首次提出了对混合损伤的分类方法, 考虑了包括光信噪比(Optical Signal to Noise Ratio, OSNR)、CD、PMD 和串扰等光学损伤对 10 Gbit/s 非归零信号的影响。实验中使用了改进的 RR 方法对不同种类的相位图和眼图进行判别(包含带有多种损伤的样本)。结果显示, 基于相位图判别 CD、OSNR 和 PMD 的均方根(Root Mean Square, RMS)误差分别为 6.5、0.7 和 3.2, 显著低于使用眼图进行训练的结果, 如图 2 所示。该模式识别技术即使在 OSNR 较差和高色散情况下也具有显著测量损伤的能力。

2008~2011 年间, Xiaoxia Wu 以及 Jeffrey A. Jargon 等人^[5-7]提出了一系列使用 ANN 对高性能光网络进行 OPM 的工作。文献[5]使用 ANN 对从眼图和幅度直方图中得到的参数进行训练, 区分不同情形下数据信道眼图的形状, 使用不同损伤组合进行了 125 次模拟, 神经网络由 4 个输入、3 个输出和 12 个隐藏神经元组成, 并使用共轭梯度技术进行训练。软件报告测试数据的相关系数为 0.96。在 3 通道 40 Gbit/s 差分相移键控(Differential Phase Shift Keying, DPSK)波分复用(Wavelength Division Multiplexing, WDM)系统中, 该技术被扩展为从眼图和眼图参数中同时识别累积的信道非线性效应以及 CD、PMD 和 OSNR, 测试数据的相关系数为 0.97。文献[6-7]通过使用异步图中的参数进行训练, 同时识别 DPSK 与正交相移键控(Quadrature Phase Shift Keying, QPSK)信号的包括 OSNR、CD 和 PMD 在内的多种损伤。文献[7]中, 实验者改变了 100 Gbit/s QPSK 的 OSNR、CD 和差分群时延(Differential Group Delay, DGD), 以获得用于 ANN 训练和测试的两组异步图和数据, 相关系数为 0.997。

在网络运行过程中, 除了光学损伤导致的故障外, 一些软故障也会影响信号质量, 使得接收端的误码率(Bit Error Rate, BER)异常, 最终导致信号丢包甚至业务中断, 因此, 软故障的检测、定位和识别也十分重要。2016 年, Marc Ruiz 等人^[8]提出了一




图 2 基于相位图或眼图的损伤估计

(含 RMS 误差)^[4]

Figure 2 Estimates of impairments with RMS error shown in the subplot titles^[4]

种基于贝叶斯网络(Bayesian Networks, BN)的算法, 该算法能够分析监测时间序列, 利用收集到的

QoT 监测参数——包括接收端功率 P_{Rx} 和前向纠错 (Forward Error Correction, FEC) 前的 BER, 定位并识别最可能影响服务的软故障, 包括滤波过密 (Tight Filtering) 以及信道间干扰 (Inter-channel Interference, ICI)。仿真实验生成了正常信号和故障信号的监测时间序列用于训练与测试, 实验结果在判断两种故障时完全正确, 仅在对正常序列进行辨别时出现了 0.8% 的误差。2017 年, 该团队^[9]提出了误码率异常检测 (BER Anomaly Detection, BANDO) 算法, 减少了监测故障算法所需要的输入数据量, 将算法向实用化推进。BANDO 算法更关注对 FEC 前的 BER (Pre-FEC BER) 进行提前监测, 并且可以放置在网络节点内部, 离监控点更近, 以减少需要传送到控制平台的数据量。实验结果表明, 该算法在连续获取数据流时, 能够在 Pre-FEC BER 到达不可接受的阈值之前 40 个小时以上进行预警。2018 年, 米兰理工学院的 Shahin Shahkarami 等人^[10]也完成了类似的工作, 提出了一种基于 ML 的方法来区分不同的软故障来源, 包括滤波故障和放大器故障。

然而上述算法的主要不足是需要大量标记的软故障样本来训练 ML 模型。由于光链路的设计倾向于保守, 软故障样本在实际系统中相当罕见。为了解决上述问题, 2021 年, 上海交通大学诸葛群碧的团队^[11]提出了一种基于生成对抗网络 (Generative Adversarial Network, GAN) 的软故障检测和识别算法, 使用接收机的电信号作为输入特征。对于软故障检测, 只需要正常样本进行训练, 对于软故障识别, 只需要很少的标记样本进行训练, 就可以达到较高的准确性。结果表明, 只需 67 个标记样本, 该算法对波长选择开关 (Wavelength Selective Switch, WSS) 中心频移 (Frequency Shift, FS) 和滤波器带宽过窄 (Filter Bandwidth Tightening, FT) 两种故障判别的准确率可达 96.7%。虽然文中只演示了 FS 和 FT 的识别, 但所提算法可以扩展到其他类型的软故障。随着时间的推移, 科研人员对光网络损伤故障识别的研究从追求算法的准确率转换成了实用性和准确性兼顾, 同时也考虑了泛用性。这种研究思路更加现实合理, 且更容易走向市场应用。

1.2 基于 ML 的信道质量评估

使用 ML 进行信道质量评估包含两类方法, 一类是利用分类器将待评估信道分为优劣不同的类别, 另一类则是使用回归方法进行信道质量参数的定量估计。

第 1 类方法在 2013 年 OFC 上由 Tamara Jiménez 与 Marianna Angelou 等人^[12]首先提出, 使用了一种 CBR 的认知 QoT 估计器, 将损伤感知波长路由光网络中的光路分为高或低质量类别。其一共提出了两个版本的估计器, 常规 CBR (Regular-CBR, R-CBR) 和固定误差 CBR (Fixed Error CBR, FixE-CBR)。R-CBR 使用不更新的静态知识库, 而 FixE-CBR 使用周期性维护的方式来优化知识库。每次分类后 FixE-CBR 依条件将部分案例存放在辅库中, 并在一定次数后, 将辅库并入原库中, 并删除不在类边界附近的冗余。与 R-CBR 相比, FixE-CBR 正确率略好, 且复杂度更低, 约比 R-CBR 快了一个数量级, 比用作对比的两种传统 Q-Tool 分别快约 4 个和两个数量级。

2017 年 OFC 上, Luca Barletta 以及 Alessandro Giusti 等人^[13,26]将 RF 算法应用于光网络线路的 QoT 估计, 基于交通量、期望的时延和调制格式来预测未建立光路的 BER 是否满足所需的阈值。RF 分类器考虑光路的链接数量、总长度、最长跨的长度、交通量以及调制格式, 目标则是一个二进制变量, 当且仅当 BER 低于设定的阈值时, 该值为 True。文中提出了一种基于加性高斯白噪声信道假设的 BER 估计工具, 用于计算提供 RF 学习所需的仿真数据。在对比了 5 种 RF 算法和 3 种 k 最近邻 (k -Nearest-Neighbors, KNN) 算法后, 该实验选择了由 100 个分类器组成的 RF 以平衡性能和复杂度。所得的受试者工作特征 (Receiver Operating Characteristic, ROC) 曲线如图 3 所示, 使用 ROC 计算得到的曲线下面积 (Area Under the ROC Curve, AUC) 可以用来衡量分类器的优劣。基于 RF 的分类器对未建立光路的预测 AUC 在每个子分类器的训练集为 1 000 时达到了 0.99, 接近完美分类器 (AUC=1)。




图 3 不同训练集大小 (training set size) 下的 ROC 曲线以及 AUC^[13]

Figure 3 ROC curve and AUC for different training set sizes^[13]

另一种思路是直接将评价 QoT 的参数作为 ML 算法的输出以得到定量的结果。2017 年, Jesper Wass 团队^[14]提出了利用 GPR 预测 WDM 光通信系统的性能。GPR 使用了平方指数核函数来量化训练集中两个数据点的相似程度, 以输入功率、传输长度、符号速率以及 WDM 通道间的间距作为输

入, 系统最终的 BER 作为输出, 利用仿真数据训练模型。最终, 在如图 4 所示的一个 24×28 G-Bd 的 QPSK WDM 光传输系统上实现了以输入功率和通道间间隔为模型输入的系统 BER 精确预测, 预测 BER 作为输入功率的函数, 具有 95% 的置信区间。




图 4 高斯过程用于学习传输参数和输出 BER 之间的映射关系^[14]

Figure 4 The Gaussian process learns the mapping function between transmission parameters and the output BER^[14]

基于对 QoT 的估计结果, 网络设计者还可以通过适当降低网络的安全裕度来实现对成本的控制。前文所述的 QoT 估计器虽然可以达成较高的精度, 但要求模型的输入参数为已知的正确值。然而, 真实条件下现场设备提供的参数通常不够精确, 因此, 网络设计者需要在设计时预留安全裕度以保证实际传输时调制信号 QoT 高于 FEC 的阈值, 使得光路不会中断。2020 年, Matteo Lonardi 等人^[15]比较了基于高斯噪声 (Gaussian Noise, GN) 模型和基于 ML 的 QoT 估计工具受网络参数不确定性的影响情况, 结果显示, 基于 ML 的 QoT 估计器对网络参数不确定性的容忍度更高。他们还研究了这些不确定性如何作用于 WDM 网络中基于 ML 的 QoT 估计^[16]。

华为巴黎研究中心的 Yvan Pointurier 团队^[17,20]近几年一直在关注这项问题, 致力于缓解网络参数不确定性对基于 ML 的 QoT 估计器的影响。2021 年^[17]其提出了一种名为输入细化 (Inputs Refinement, IR) 的 ML 方法, 利用网络监测数据与光传播的物理特性来提高影响 QoT 估计的主要参数的精度, 包括光纤跨段前后由连接器等器件带来的总损耗以及放大器的增益谱。基于实际监测数据估计这些参数后, 通过 QoT 估计计算得到的设计

裕度从超过 2 dB 减少到小于 0.1 dB。文献^[17]中只考虑了满负载的情况, 这使得放大器的增益谱不需要考虑负载情况。2022 年, 在上述工作的基础上他们进一步考虑了部分负载网络^[18], 证明了 IR 方法仍适用于静态部分负载网络, 能够使信噪比 (Signal to Noise Ratio, SNR) 预测误差下降 2 dB。而在一个动态的、部分负载的网络中, 放大器的增益谱是负载相关的, 这使得 QoT 估计更加复杂化。对此, 文献提出将 IR 方法与基于 ML 的掺铒光纤放大器 (Erbium-Doped Fiber Amplifier, EDFA) 功率谱预测方法结合起来, 最终使 SNR 预测误差下降了 1 dB。除了 IR 方法外, 同年, Yvan Pointurier 还与米兰理工学院的团队合作探索了另一条回避不确定性的道路, 即“概率 QoT 建模”^[19]。该方法在多个物理层参数具有不确定性并导致精度有限的情形下, 通过估计和分析 QoT 度量的分布, 来决定实行保守 (高) 或激进 (低) 的裕度设置策略。该项工作特别地考虑了多个物理层不确定性 (文献^[17]中的两种以及标注错误的光纤类型), 数值结果显示, 使用该方法可通过支付非常低的代价 (光路中断概率增加 0.3%~0.4%) 来节省 5%~10% 的网络资源。2023 年^[20], 该团队将实验扩展到 6+6 THz 的 C+L 波段 WDM 系统的 QoT 估计, 信道间隔为 75 GHz, 每个

频段 80 个信道。仿真信道波特率为 68 Gbaud, PDM-QPSK 为 200 Gbit/s。考虑 3 个级联的光复用段 (Optical Multiplex Section, OMS), IR 工具估计 OSNR 的均方根误差 (Root Mean Squared Error, RMSE) 低至 0.2 dB, 估计非线性 SNR 的最大误差为 1.3 dB, 估计广义信噪比 (Generalized SNR, GSNR) 的 RMSE 可降至 0.5 dB 以下, 其中 GSNR 同时考虑了放大自发辐射和非线性噪声。

1.3 基于 ML 的通道功率预测

使用 ML 进行通道功率预测, 可以用于实现对光网络中放大器的增益平衡, 利用预测的功率模型补偿长距离传输中的增益波动。2016 年, Yishen Huang 等人^[21,27]演示了一种被称为核化贝叶斯回归 (Kernelized Bayesian Regression, KBR) 的 ML 方法来描述多跨 EDFA 网络中功率偏移的信道依赖性, 即在动态信道负载条件下, 增益谱波动发生变化的现象。与 GPR 类似, KBR 同样使用了一个平方指数核函数作为径向基函数 (the Radial Basis Function, RBF)。训练的输入是信道开关状态数组, 输出是输出功率的标准差作为评价功率偏移的标准。假设具有相似通道开关状态的网络具有相似的功率偏移, 则实际预测结果是带有 RBF 权重的输出的线性组合, 通道状态越相近, 结果权重越高。

2017 年, Craig L. Gutterman 等人^[22]进一步开发了一个可扩展的 ANN, 并进行了实验以评估其预测多跨距的 ROADM 网络动态响应的准确性。该 ANN 模型输入和输出与文献^[21,27]中的模型相同, 结构如图 5 所示。实验结果显示, 该 ANN 具有低于 0.15 dB 的 RMSE 和平均绝对误差 (Mean Absolute Error, MAE), 优于文献^[21]中 RR 算法的 Q 因子改善, 在全 C 波段多跨距 ROADM 系统的大数据集上性能表现良好, 波长分配精度达 99%。




图 5 4 层隐含层神经网络结构^[21]

Figure 5 Architecture of neural networks with 4 hidden layers^[21]

上述工作虽然考虑到了 EDFA 网络的功率偏移, 但是模型的输出结果只是用于衡量总体的功率偏移大小, 给出信道的添加删除建议, 而不能用于直接对长距离传输中的增益波动进行补偿。在 2018 年, Shengxiang Zhu 等人^[23]发布了利用 ML 动态缓解 EDFA 功率偏移的研究成果。该工作建立并训练深度神经网络 (Deep Neural Network, DNN) 来确定信道配置和依赖于输入功率的 EDFA 增益频谱。使用的神经网络结构类似于文献^[22], 但为每个通道都建立了一个网络, 如图 6 所示, 输入为所有波长通道的发射功率, 经过神经网络最后获得每个通道的输出功率并形成输出功率谱。





图 6 多通道神经网络结构示意图^[23]

Figure 6 Architecture of neural networks with 90 channels^[23]


作者对比了分析模型^[28]和 ML 模型预测 EDFA 增益谱的误差分布情况: 在输入的发射功率具有 ± 3 dB 动态范围的情况下, ML 模型的误差低于 0.5 dB 的比率为 99.95%, 而分析模型的误差为 94.9%; 在 ± 6 dB 的情况下, 该比率分别为 98.37% 和 85.11%; 在 ± 9 dB 的情况下, 该比率分别为 93.57% 和 81.07%。可见, 在所有情况下的增益谱预测任务中, ML 模型都具有更优秀的性能。

上述工作仅限于将传输波段划分为一些通道、且只对每个通道的平均增益建模, 输出结果并不包含整个波段的增益曲线轮廓的信息。为了获得精确的带内增益波动 (In-band Gain Ripple, IGR) 信息, 一种方法是尽量减小每个通道的带宽以提高分辨率, 这种方法大大增加了建模计算量, 但并不实用。2022 年, 加拿大华为科技的 Zhiping Jiang 等人^[29]提出了一种基于 ML 的 EDFA 信道 IGR 建模方法, 提高了对 EDFA 增益波动预测的精细度。该方法不再直接以每个通道的平均输出功率作为模型输出, 而是通过多项式拟合 IGR 曲线, 然后通过 DNN

训练多项式的各项系数,如图 7 所示, ΔG_0 为某负载条件下通道中心增益与全负载时的差值。实验结果反映了良好的精度,预测一阶 IGR 系数的标准差为 0.022 dB/nm,总增益的标准差为 0.053 dB,二阶系数标准差略大,但对结果影响较小。



(a) 信道增益波动差值
(a) Illustration of differential channel gain ripple



(b) EDFA 中心增益和 IGR 的 ML 模型

(b) ML model for EDFA center gain and IGR

图 7 机器学习与多项式拟合 EDFA 中心增益及 IGR 示意图^[29]

Figure 7 EDFA center gain and IGR fitting based on ML and polynomial^[29]


为了将该技术更实用化,杜克大学的 Zehao Wang 等人^[30]不再在实验中使用光谱分析仪(Optical Spectrum Analyzer, OSA),而是直接通过商业化的 ROADM 网络单元内置的光通道监测(Optical Channel Monitoring, OCM)功能进行数据收集,再使用 DNN 进行建模。实验表明,所训练的基于 DNN 的 EDFA 模型可以准确预测经过 10 个 EDFA 后的功率谱,在城域尺度下,MAE 分别为 0.73 和 0.61 dB。

2 使用 ML 进行网络配置优化

如上节所述,ML 已能够被用于预测任意输入信号功率条件下的 EDFA 输出功率响应,并且相比于分析模型在准确度上更具优势。然而,如何利用


这种优势实现光网络配置的优化,增大光信号传输的效率,仍值得进一步研究。

2020 年, Maria Ionescu 等人^[24-31]提出将强化学习(Reinforcement Learning, RL)用于海底光网络的优化设计。Maria Ionescu 建立 RL 系统模型时用到了上一节中提到的基于神经网络的 EDFA 模型,其 RMSE 低至 0.18 dB。图 8 所示为使用 RL 优化非均匀系统的示意图,图 8(a)中非均匀系统模型将神经网络 EDFA 模型和具有固定跨度的 10 dB 损耗光纤串联,并周期性插入理想增益平坦滤波器(Gain Flattening Filter, GFF)。RL 模型结构如图 8(b)所示,3 层神经网络分别由 89、128 和 128 个节点组成。RL 过程中,系统将不断调整发射机处信道功率以达到全局最大化系统容量的目的。C 波段光谱划分为 7 个子波段,其中的信道被归入一个信道组。动作被定义为在总信号功率固定条件下,特定某个信道组的功率增加 0.5 dBm。系统将根据行为导致的系统容量变化来确定奖励。每一轮训练都以随机频谱作为输入,从 128 种可能性中依次采取多达 300 个动作。



(a) 非均匀系统设计的模型图

(a) Model diagram of heterogeneous system design



(b) RL 网络结构

(b) Representation of neuronal network used for RL

图 8 RL 优化非均匀系统示意图^[31]

Figure 8 Optimizing heterogeneous system using RL^[31]

该策略在给定的基础配置模式(图 8(a)中 $M=1$)中不断学习。一旦 RL 网络找到了最大化容量的优化频谱形状,就延长传输距离,将优化后的信号应

用于整个跨太平洋系统模型($M > 1$)。

同时, Maria Freire-Hermelo 等人^[25,32]提出了一种使用 RL 算法的信道功率预补偿方法,以减少自动增益控制(Automatic Gain Control, AGC)模式下的级联 EDFA 中的累积功率漂移。使用 TensorFlow 开发的“演员-评论家”(Actor-Critic)方法^[33]训练 RL 模型,在 375 km 的光纤链路系统 12、24 和 40 通道的情况下,通道功率偏移的平均减少率分别为 86%、74% 和 62%,相比通道负载从 15% 到 80% 变化的更复杂的场景,平均减少了 28%。

3 光网络监测优化中的 ML 方法

ML 通常被用来解决各种分类和回归问题,但两者常常有共通之处。当一种 ML 算法被用来解决分类问题时,并不意味着它不能被用于回归。损伤故障识别显然是一种分类问题,应用于损伤故障识别的 ML 算法包含了 SVM、RR、ANN、BN 和 GAN 等。SVM 是一种二类分类模型,它的基本模型是定义在特征空间上的使距离最大的线性分类器,通过使用核方法能够解决非线性分类问题;RR 则是最小二乘的一个变体,它在普通最小二乘的目标函数中,增加了一项针对系数大小的惩罚项,通过将二值目标转换成 $\{1, -1\}$, 可以将分类问题视作回归来解决;ANN 是一种多层感知机,它是模拟人类大脑处理信息的生物神经网络所产生出来的一种计算模型,通过隐藏层不同的神经元,以及每个神经元所携带的权重,能够完成对非线性系统的预测;BN 是一种概率图模型,是一种模拟人类推理过程中因果关系的不确定性处理模型,其网络拓扑结构是一个有向无环图(Directed Acyclic Graphical, DAG);GAN 则是一种架构,通过一个生成器和一个判别器互相对抗训练,可以应用上面提到的其他算法。

最简单的信道质量评估可以被视为一个分类问题,只需要将信道划分为可用或不可用两类,CBR 和 RF 等算法被用于此目的。CBR 是一种基于实例的学习方式(Instance-Based Learning, IBL),另一种常见的 IBL 方法是 KNN 算法。在 CBR 中,解决问题需要从知识库中检索过去最相似的案例,重用检索到的案例或调整它们以提供解决方案,并更新知识库。RF 算法则是一种非常成功的通用分类和回归方法,该方法结合了几个随机决策树,并通过平均的方式聚合了它们的预测,在变量数量远远大于观察数量的情况下显示出了出色的性能。相对于之前的算法,RF 显著提高了分类的精度,减小了泛

化误差。随着算法的发展,最近的信道质量评估任务不再限于分类,而是直接估计 QoT 参数,与通道功率预测一样都是一个回归问题。大多数情况下,研究者们更倾向于使用 ANN/DNN 解决这些问题,因为其准确度更好。

网络配置优化主要用到了 RL 算法。RL 是指智能系统在与环境的连续互动中学习最优行为策略的 ML 方法,其本质是学习最优的序贯决策。在每一步,智能系统从环境(Environment)中观察到一个状态(State) s_t 与一个奖励(Reward) r_t ,并采取一个动作(Action) a_t 。环境根据智能系统选择的动作,决定下一步 $t+1$ 的状态 s_{t+1} 与奖励 r_{t+1} 。RL 过程中,系统不断地试错(Trial and Error),以达到学习最优策略的目的。RL 通过从历史数据中提取知识来学习状态和动作之间的潜在映射机制,并具有自进化能力,可以对动态的网络状况做出适当的决策,因此适用于网络配置优化任务。

4 结束语

随着光网络通信的发展以及 ML 技术的进步,基于 ML 的光网络监测和优化方法逐渐发展,以适应其面对的复杂系统。但是,这些方法中仍有一些值得注意的问题,试图解决这些问题的尝试可能包含在未来光通信领域 ML 方法的研究方向中。

(1) 数据集的来源

ML 方法需要使用大量的数据进行训练来对复杂系统进行建模,而数据集的来源就会变得非常重要。前文许多工作都采用了在实验室搭建测试平台收集数据的方法,考虑到高泛化能力的 ML 训练需要的大量数据,即使使用了自动化的程序,数据采集过程仍然十分漫长。此外,通过在光网络测试平台上模拟产生的故障或损伤,并不能完全再现真实网络场景的多样性。

上文提到的许多工作采用了仿真方式,通过模拟方法,快速生成大量的合成数据用于 ML 模型的训练。这样的方式虽然便捷且高效,却也同样存在着上面提到的问题:模拟环境不同于真实的现场条件,在应用于实际场景时会因为未被仿真的某些现实因素干扰而导致缺乏准确性。并且如果生成合成数据的方法过于简单,将会导致 ML 经过大量训练最终学习到的不是实验设计的目标,而是用于生成数据的算法。考虑到上述问题,仿真训练是否能够很好地移植到实际运营环境还有待进一步的探索。

综合上面所提到的问题,未来研究人员可以考

虑加强与企业的合作,使用网络运营商提供的真实现场数据以解决这部分问题。然而,因为网络的维护和运营通常采用保守的思路,想要获取带有故障或损伤的数据用于算法学习,一种可能是获取较长时间跨度下的数据集,另一种是将场景限制在网络建立或升级的阶段,这对 ML 算法的应用场景限制很大。

(2) 训练的时效性

现有的 ML 算法在现场决策之前使用历史数据进行训练,这在网络建立和升级时并没有大的问题,然而现实中运营的光网络场景一直处于动态变化中,并且这种动态变化既包含了短时间(几小时或数天)内随着流量涨跌产生的波动,又包含了长时间跨度下随着器件老化引发的劣化。考虑到这种情况,目前大多数光网络 ML 研究中所采用的离线监督学习方法并不能很好地适应这种动态变化。

未来的研究可以在利用历史数据训练 ML 模型后,逐渐吸收由网络控制平面提供的新输入数据进行实时训练和快速收敛,以期实现光网络的自学习、自适应和自优化。因此,在未来开发基于 ML 的光网络解决方案时,算法的效率也将愈发重要。

(3) 算法的鲁棒性和泛化能力

实验室条件或者仿真算法下,发射功率、传输距离和色散等参数全部可以以精确的值参与 ML 模型的训练,但是当使用误差较大的现场数据时,将比较考验算法的鲁棒性。此外,这些参与训练的精确参数会导致算法程序的可移植性较差,限制这些 ML 算法在不同的系统中的实际部署。因此,有必要研究 ML 模型的迁移学习和数据增强等技术,以将其适用性扩展到不同的网络系统。

参考文献:

- [1] Musumeci F, Rottondi C, Nag A, et al. An Overview on Application of Machine Learning Techniques in Optical Networks [J]. IEEE Communications Surveys & Tutorials, 2018, 21(2): 1383–1408.
- [2] Saif W S, Esmail M A, Ragheb A M, et al. Machine Learning Techniques for Optical Performance Monitoring and Modulation Format Identification: A Survey [J]. IEEE Communications Surveys & Tutorials, 2020, 23(4): 2839–2882.
- [3] Skoog R A, Banwell T C, Gannett J W, et al. Automatic Identification of Impairments Using Support Vector Machine Pattern Classification on Eye Diagrams[J]. IEEE Photonics Technology Letters, 2006, 18(22): 2398–2400.
- [4] Anderson T B, Dods S D, Clarke K, et al. Multi-Impairment Monitoring for Photonic Networks [C]// ECOC 2007. Berlin, Germany: VDE, 2007:1–4.
- [5] Jargon J A, Wu X, Willner A E. Optical Performance Monitoring Using Artificial Neural Networks Trained with Eye - Diagram Parameters [J]. IEEE Photonics Technology Letters, 2009, 21(1): 54–56.
- [6] Wu X, Jargon J A, Skoog R A, et al. Applications of Artificial Neural Networks in Optical Performance Monitoring [J]. Journal of Lightwave Technology, 2009, 27(16): 3580–3589.
- [7] Wu X, Jargon J A, Paraschis L, et al. ANN - based Optical Performance Monitoring of QPSK Signals Using Parameters Derived from Balanced - Detected Asynchronous Diagrams [J]. IEEE Photonics Technology Letters, 2010, 22(4): 248–250.
- [8] Ruiz M, Fresi F, Vela A P, et al. Service - Triggered Failure Identification/Localization Through Monitoring of Multiple Parameters[C]//ECOC 2016. Dusseldorf, Germany: VDE, 2016: 1136–1138.
- [9] Vela A P, Ruiz M, Fresi F, et al. Early Pre - FEC BER Degradation Detection to Meet Committed QoS [C]//OFC 2017. Los Angeles, CA, USA: IEEE, 2017: W4F. 3.
- [10] Shahkarami S, Musumeci F, Cugini F, et al. Machine - Learning - based Soft - Failure Detection and Identification in Optical Networks[C]//OFC 2018. San Diego, CA, USA: IEEE, 2018: M3A. 5.
- [11] Lun H, Liu X, Cai M, et al. GAN based Soft Failure Detection and Identification for Long - haul Coherent Transmission Systems[C]// OFC 2021. San Francisco, CA, USA: IEEE, 2021: Th4J. 2.
- [12] Jiménez T, Aguado J C, de Miguel I, et al. A Cognitive Quality of Transmission Estimator for Core Optical Networks[J]. Journal of Lightwave Technology, 2013, 31(6): 942–951.
- [13] Barletta L, Giusti A, Rottondi C, et al. QoT Estimation for Unestablished Lighpaths Using Machine Learning[C]//OFC 2017. Los Angeles, CA, USA: IEEE, 2017: Th1J. 1.
- [14] Wass J, Thrane J, Piels M, et al. Gaussian Process Regression for WDM System Performance Prediction [C]// OFC 2017. Los Angeles, CA, USA: IEEE, 2017: Tu3D. 7.
- [15] Lonardi M, Pesic J, Zami T, et al. The Perks of Using Machine Learning for QoT Estimation with Uncertain Network Parameters [C]//Photonic Networks and De-

- vices 2020. Washington, DC, USA: Optica Publishing Group, 2020: NeM3B. 2.
- [16] Pesic J, Lonardi M, Rossi N, et al. How Uncertainty on the Fiber Span Lengths Influences QoT Estimation Using Machine Learning in WDM Networks[C]//OFC 2020. San Diego, CA, USA: IEEE, 2020: Th3D. 5.
- [17] Morette N, de Jauregui Ruiz I F, Pointurier Y. Leveraging ML-based QoT Tool Parameter Feeding for Accurate WDM Network Performance Prediction [C]//OFC 2021. San Francisco, CA, USA: IEEE, 2021: Th4J. 4.
- [18] Morette N, de Jauregui Ruiz I F, Hafermann H, et al. On the Robustness of a ML-based Method for QoT Tool Parameter Refinement in Partially Loaded Networks [C]//OFC 2022. San Diego, CA, USA: IEEE, 2022: M3F. 1.
- [19] Karandin O, Ferrari A, Musumeci F, et al. Low-Margin Optical-Network Design with Multiple Physical-Layer Parameter Uncertainties [C]//ECOC 2022. Basel, Switzerland: IEEE, 2022: Mo3B. 2.
- [20] Yang X, Ferrari A, Morette N, et al. QoT Estimation Improvement with Inputs Refinement Tool for C+L Networks [C]//OFC 2023. San Diego, CA, USA: IEEE, 2023: W4G. 6.
- [21] Huang Y S, Samoud W, Gutterman C L, et al. A Machine Learning Approach for Dynamic Optical Channel Add/Drop Strategies that Minimize EDFA Power Excursions [C]// ECOC 2016. Dusseldorf, Germany: VDE, 2016: 268–270.
- [22] Gutterman C L, Mo W, Zhu S, et al. Neural Network based Wavelength Assignment in Optical Switching [C]// Big-DAMA '17. CA, USA: ACM, 2017: 37–42.
- [23] Zhu S X, Gutterman C L, Mo W, et al. Machine Learning based Prediction of Erbium-Doped Fiber WDM Line Amplifier Gain Spectra [C]//ECOC 2018. Rome, Italy: IEEE, 2018: Mo3E.
- [24] Ionescu M, Ghazisaeidi A, Renaudier J, et al. Design Optimisation of Power-Efficient Submarine Line Through Machine Learning [C]//CLEO 2020. San Jose, CA, USA: IEEE, 2020: STh4M. 5.
- [25] Freire-Hermelo M, Sengupta D, Lavignotte A, et al. Dynamic Power Predistortion Implementation with Reinforcement Learning for Excursion-Free Amplified Optical Systems [C]//ONDM 2020. Castelldefels, Barcelona, Spain: IFIP Open Digital Library, 2020: PS.
- [26] 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.
- [27] Huang Y S, Gutterman C L, Samadi P, et al. Dynamic Mitigation of EDFA Power Excursions with Machine Learning [J]. Optics Express, 2017, 25 (3) : 2245–2258.
- [28] Ishii K, Kurumida J, Namiki S. Wavelength Assignment Dependency of AGC EDFA Gain Offset Under Dynamic Optical Circuit Switching [C]//OFC 2014. San Francisco, CA, USA: IEEE, 2014: W3E. 4.
- [29] Jiang Z P, Lin J, Hu H. Machine Learning based EDFA Channel In-band Gain Ripple Modeling [C]//OFC 2022. San Diego, CA, USA: IEEE, 2022: W4I. 2.
- [30] Wang Z H, Akinrintoyo E, Kilper D, et al. Optical Signal Spectrum Prediction Using Machine Learning and In-line Channel Monitors in a Multi-span ROADM System [C]//ECOC 2022. Basel, Switzerland: IEEE, 2022: We3B. 5.
- [31] Ionescu M, Renaudier J, Ghazisaeidi A, et al. Optimization of Power Efficient Spatial Division Multiplexed Submarine Cables Using Adaptive Transponders and Machine Learning [J]. Journal of Lightwave Technology, 2022, 40(6) : 1597–1604.
- [32] Freire-Hermelo M, Sengupta D, Lavignotte A, et al. Reinforcement Learning for Compensating Power Excursions in Amplified WDM Systems [J]. Journal of Lightwave Technology, 2021, 39(21): 6805–6813.
- [33] Abadi M, Barham P, Chen J, et al. Tensorflow: A System for Large-Scale Machine Learning [C]// OSDI 16. Savannah, GA, USA: USENIX, 2016: 265–283.