

## 光路传输质量智能预测技术

谷志群, 周宇航, 张佳玮, 纪越峰

(北京邮电大学 信息光子学与光通信全国重点实验室, 北京 100876)

**摘要:** 针对传统基于数理模型的光路传输质量(QoT)预测方法难以同时满足高精度和低计算复杂度需求的问题, 介绍了单光路、多光路、跨拓扑光路 3 种光路 QoT 智能预测技术。这些技术依托于机器学习模型, 力求实现端到端光路 QoT 的精确预测, 并可有效应对以下挑战: 其一, 面对物理层参数的多样性, 如何选择适合的机器学习模型和输入特征; 其二, 如何有效捕捉光路间错综复杂的关系; 其三, 如何在少样本情况下实现网络模型的训练和持续优化。最后, 对未来的光路 QoT 预测技术发展方向进行了展望。

**关键词:** 光网络; 光路传输质量; 机器学习

**中图分类号:** TN256 **文献标志码:** A **文章编号:** 1002-5561(2024)03-0001-06

**DOI:** 10.13921/j.cnki.issn1002-5561.2024.03.0001

开放科学(资源服务)标识码(OSID):



## Intelligent prediction technology for optical path quality of transmission

GU Zhiqun, ZHOU Yuhang, ZHANG Jiawei, JI Yuefeng

(State Key Laboratory of Information Photonics and Optical Communications,  
Beijing University of Posts and Telecommunications, Beijing 100876, China)

**Abstract:** Addressing the challenge of traditional mathematical model-based quality of transmission (QoT) prediction methods struggling to simultaneously meet the demands of high precision and low computational complexity, this paper introduces three intelligent QoT prediction techniques for single optical paths, multiple optical paths, and cross-topology optical paths. These techniques rely on machine learning models to achieve accurate end-to-end optical path QoT predictions and effectively tackle the following challenges: firstly, how to select appropriate machine learning models and input features amidst the diversity of physical layer parameters. Secondly, how to effectively capture the intricate relationships among optical paths. Thirdly, how to train and continuously optimize network models with limited samples. Finally, the article offers a glimpse into the future development directions of optical path QoT prediction technologies.

**Key words:** optical networks, optical path quality of transmission, machine learning

## 0 引言

传统光网络主要依赖于强度调制/直接检测(IMDD)技术, 尽管它结构简单、易于集成且成本低, 但由于其采用简单的开关键控(OOK)调制格式和直接

检测方式, 导致频谱效率较低, 难以满足未来流量激增的需求。因此, 为了提高光网络的频谱效率和单波速率, 基于相干光通信的第五代光纤通信系统受到了研究者的广泛关注。

信号在相干光通信系统传输过程中会受到多种物理损伤并不断累积, 如光纤的损耗、色散和非线性效应, 掺铒光纤放大器(EDFA)的放大自发辐射噪声, 以及可重构光分插复用器(ROADM)的滤波损耗等。这些因素会导致光路传输质量(QoT)恶化。因此, 为了保障光路传输的可靠性, 需要在部署前预测物理层的光路 QoT, 并据此优化发射机的配置(如发射功率、调制格式等), 以确保信号能够被正确接收。

收稿日期: 2024-02-29。

基金项目: 国家自然科学基金项目(62101058、U21B2005)资助; 河北省省级科技计划项目(22567624H)资助。

作者简介: 谷志群(1986—), 女, 博士, 北京邮电大学信息与通信工程学院副教授, 中国通信学会高级会员, 主要研究方向是智能光网络、自由空间光网络, 主持和参与了多项国家自然科学基金、国家重点研发计划项目。



谷志群,周宇航,张佳玮,等:光路传输质量智能预测技术

传统光路 QoT 预测方案依赖于对光信号传输过程的数理建模,例如,求解非线性薛定谔方程<sup>[1]</sup>或采用简化的分析模型<sup>[2-7]</sup>,用以预测接收端的光路 QoT。然而,由于传输过程的复杂性和网络环境的非平稳性,准确预测光网络物理层的光路 QoT 成为一项挑战。一方面,求解非线性薛定谔方程通常采用分步傅里叶法,这种方法计算复杂度高,难以实现实时光路 QoT 预测;另一方面,简化的分析模型虽然降低了计算复杂度,但预测精度较低,可能导致设计余量过大,降低了网络容量和增加了网络部署成本。因此,传统基于数理模型的光路 QoT 预测方案在平衡计算复杂度和预测精度方面存在困难。

相比之下,机器学习(ML)模型因其强大的数据拟合能力和快速计算的特点,为预测光路 QoT 提供了新的解决方案。ML 模型能够克服传统数理模型在预测精度和计算复杂度方面的不足。然而,将 ML 应用于预测光路 QoT 却面临如下挑战:1)由于物理层参数的多样性,如何选择恰当的 ML 模型和输入特征以实现精准的端到端光路 QoT 预测;2)如何捕获复杂的光路间关系;3)如何在网络环境中获取充足的训练样本。

鉴于此,本文针对基于 ML 模型的光路 QoT 预测方案的三大挑战,介绍 3 种光路 QoT 智能预测技术。

## 1 光路 QoT 智能预测技术

针对上述基于 ML 模型的光路 QoT 预测方案所面临的三大挑战,本文将对当前基于 ML 的光路 QoT 智能预测技术进行深入分析与研究,具体包括:1)单光路 QoT 智能预测;2)多光路 QoT 智能预测;3)跨拓扑光路 QoT 智能预测。

### 1.1 单光路 QoT 智能预测

单光路是指在单一网络下端到端的光路传输。在单光路场景中,QoT 智能预测的实现依赖于充足的训练样本,以确保进行准确的端到端光路 QoT 预测。此过程的核心在于利用本网络中采集的光路特征进行高效的模型训练。在文献[8]中,研究者提出了利用随机森林(RF)、支持向量机(SVM)以及 K 近邻(KNN)这 3 种分类器来预测光路 QoT 是否达到既定阈值的方法。仿真结果显示,这些分类器均展现出了较高的预测准确率,其中 SVM 分类器的分类准确率更是高达 99.15%。然而,文献[9]的研究却指出,这些分类器无法给出具体的光路 QoT 数值,这在一定程度上限制了它们在网络优化场景中的应用,尤其是在路由选择和调制格式分配等方面。因此,研究者们开始更多地关注

光路 QoT 回归器的研究。文献[10]通过调整物理层模型(PLM)参数,实现了光路 QoT 值的预测,并将半解析模型和扩展高斯(EGN)模型的预测误差分别降低到 0.1 dB 和 0.02 dB。文献[11]提出了一种光网络闭环控制器架构,该架构能够利用网络测量反馈来减少参数不确定性,从而提高基于 ML 模型的光路 QoT 预测精度。文献[12]则提出了一种嵌入主动采集方法的三阶段训练框架,用于定制光网络中特定链路的 QoT 回归模型。文献[13]研究了一种基于卷积循环神经网络(CRNN)的方案,该方案使用解调过程中不同阶段捕获的原始波形来预测光信噪比(OSNR)和发射功率,得到 OSNR、发射功率的预测误差分别小于 1 dB 和 1 dBm。文献[14]针对 ROADM 节点处的 EDFA 增益波动以及滤波器光谱形状的不确定性进行了建模分析。相较于无感知的 QoT 回归器,采用该模型后,新连接请求的设计余量从 1.68 dB 减少到了 0.37 dB。

然而,上述研究主要集中在对单个信道的光路 QoT 预测上。预测多个信道的光路 QoT 能够为网络控制器提供更全面的网络状态信息,从而有助于实现更精准的网络优化。基于上述思想,本文作者<sup>[15-16]</sup>提出了 2 种针对端到端多信道光路 QoT 预测方法。

1)基于人工神经网络(ANN)的多信道光路 QoT 预测方案。在动态光网络重构的过程中,为了保证网络的性能,需要实时地抽象网络状态。在这一过程中,不仅需要预测可用光路的 QoT 以选择最佳光路,还要评估已有光路的 QoT 以确保系统的稳定性。因此,本文作者曾提出了建立一个归一化的多光路 QoT 预测模型。此外,文献[17]详细介绍了一种基于 ANN 的多信道 Q 因子预测方案,并在 563.4 km 的现场试验台上进行了数据采集和实验验证。实验结果表明,基于 ANN 的光路 QoT 回归模型能够准确预测新部署通道和现有通道的 Q 因子。

2)基于注意力机制的多信道光路 QoT 预测方案。在多信道光网络中,由于光纤的非线性效应,部署在同一光纤的不同光路会相互干扰,影响各自的光路 QoT。这意味着,对于任一条测试光路,除了其自身的特性外,还需要考虑其它所有光路(包括测试光路本身)对其产生的非线性干扰。这种干扰的强度与干扰光路的信号强度及其与测试光路在频谱上的距离密切相关。因此,如何有效地利用 ML 算法来揭示不同干扰光路对测试光路的具体影响,成为了这一领域的关键问题。

在前期的研究工作中<sup>[20-21]</sup>,本文作者针对多信道

网络中复杂非线性干扰建模的难题,引入了自注意力机制。这种机制能够从数据中自动提取并学习干扰信道与测试信道之间的复杂关系,从而构建出基于自注意力机制的多信道光路 QoT 预测模型。该模型能够有效地捕捉光路之间的相互作用,并实现对光路 QoT 的准确预测。实验结果表明:该模型不仅具有较高的预测精度,而且具备良好的可扩展性;更重要的是,该模型无需重新训练即可直接应用于网络波长的拓展场景,并维持较高的预测精度。这为网络重构提供了准确的预测信息,从而保证了网络重配置的高效性。目前,针对端到端光路 QoT 智能预测相关工作所使用的智能算法/ML 模型、输入、输出和性能情况如表 1 所示。

## 1.2 多光路 QoT 智能预测

多光路 QoT 智能预测是指在单一网络拓扑中,考虑到光路间的相互影响,可以采用光路级别的预测方案,从而精确预测新部署光路的 QoT 值。然而,由于光纤存在的非线性效应,新部署的光路可能引发已部署光路的 QoT 值下降,这种下降一旦低于预设的阈值,将不可避免地导致光路传输的中断。目前,已有工作专注于研究多光路下的光路 QoT 预测。

文献[18-19]提出了一种基于深度图形卷积神经

网络(DGCNN)的光路 QoT 分类器,其目的是对网络中所有光路的可用性进行准确分类。为了简化文献[18-19]中复杂的数据预处理过程,文献[20]提出了一种基于深度卷积神经网络(DCNN)的光路 QoT 分类器,用于全网络光路 QoT 预测。然而,光路 QoT 分类器仅提供光路可用性信息,无法提供具体的光路 QoT 值,这限制了其在需要精确光路 QoT 值的网络优化决策中的应用(如选择一条具有最优 QoT 的光路进行路由)。针对这一问题,本文作者<sup>[21]</sup>设计了全网范围的光路 QoT 回归器,并提出了数字孪生辅助的余量感知路由、波长及调制格式分配(RWMA)方案。

RWMA 方案中的物理层包含网络物理设施,并在每个节点处装配光性能监测仪(OPM)。该方案的预测原理如下:首先,物理层中收集到的数据以图数据的形式上传至镜像模型层;然后,镜像模型层基于图注意力网络构建网络传输的数字孪生体,从而预测全网范围的光路 QoT;最后,优化层根据镜像模型层生成的数字孪生体进行余量感知的 RWMA 优化,并将该分配方案下发至物理层进行配置。仿真结果表明,基于图注意力网络的数字孪生体能够使 99.84% 的测试数据误差保持在 0.5 dB 以内,并且相较于传统基于光路

表 1 针对端到端光路 QoT 智能预测相关工作所使用的智能算法/ML 模型、输入、输出和性能情况

| 文献      | 智能算法/<br>ML 模型 | 输入                                                   | 输出                           | 性能                                             |
|---------|----------------|------------------------------------------------------|------------------------------|------------------------------------------------|
| [8]     | RF、SVM 和 KNN   | 链路总长度、光纤段长度、信道发射功率、调制格式                              | 光路可用性                        | RF、SVM 和 KNN 预测精度分别为 96.32%、99.15% 和 81.75%    |
| [9]     | KNN、RF         | 光路长度、最长链路长度、链路数、流量大小、调制格式、邻近信道保护带宽、邻近信道流量大小、邻近信道调制格式 | 光路可用性                        | 预测精度可达 96%                                     |
| [10]    | 梯度下降           | 真实信噪比(SNR)值、测量噪声系数、测量发射功率                            | 真实噪声系数,真实发射功率                | 误差下降量高达 4.18 dB                                |
| [11]    | 非线性回归          | 真实 SNR 值、测量光纤衰减系数、测量光纤色散系数以及测量光纤非线性系数                | 真实光纤衰减系数,真实光纤色散系数以及真实光纤非线性系数 | 设计余量下降量高达 1.95 dB                              |
| [12]    | ANN            | 光纤段长度、光纤段数量、发射功率、调制格式、信道数量                           | 真实 SNR 值                     | 误差下降量高达 2.3 dB                                 |
| [13]    | CRNN           | 信号数字化后的原始波形、色散(CD)和偏振模色散(PMD)校正后原始波形以及均衡后的原始波形       | OSNR 值和发射功率                  | 在 CD 和 PMD 校正后原始波形的输入下,OSNR 和发射功率的预测误差都小于 1 dB |
| [14]    | SVM            | 每个信道的发射功率、光频谱、前向纠错前误码率                               | SNR 值                        | 平均误差小于 0.2 dB                                  |
| [15-16] | 自注意力机制+ANN     | 信道发射功率、信道频谱占用、光路长度                                   | 每个信道的广义信噪比(GSNR)值            | 在 2 个仿真网络下,误差分别下降 0.147、0.127 dB               |
| [17]    | ANN            | 发射功率、EDFA 输入功率、EDFA 输出功率、EDFA 激光器偏置以及信道状态            | 每个信道的 Q 值                    | 最大误差大约为 0.05 dB                                |

谷志群,周宇航,张佳玮,等:光路传输质量智能预测技术

QoT 预测器的 RWMA 方案,所提方案可以有效地减少不可靠光路的产生。目前,针对多光路 QoT 智能预测相关工作所使用的智能算法/ML 模型、输入、输出和性能情况如表 2 所示。

### 1.3 跨拓扑光路 QoT 智能预测

跨拓扑光路 QoT 预测是一种采用迁移思想的预测方法,通过将其它网络拓扑中的样本、数据或参数等信息迁移到本地拓扑中,以提升本地拓扑的预测性能为目标。只要网络能够收集到足够的训练样本,基于 ML 的光路 QoT 预测器就能实现高精度的预测。然而,在光网络部署初期,由于光路的不可监测性和某些光网络节点缺乏 OPM,导致网络控制器无法收集足够的训练样本,进而影响了训练模型的准确性。因此,跨拓扑光路 QoT 预测受到了广泛关注。文献[22]针对候选光路提出了一种基于域适应(DA)的光路 QoT 预测框架,该框架特别关注大型训练样本不可用或其获取成本较高的特殊场景。仿真结果表明,基于 DA 的光路 QoT 预测器在精度上优于简单混合源域和目标域样本集进行训练的模型。

文献[23]则对基于主动学习(AL)和基于 DA 的光路 QoT 预测方案在小规模训练数据集上的性能进行了比较。相较于传统的光路 QoT 预测器训练方法,AL 和 DA 方案均能有效提升光路 QoT 预测的准确性。AL 方案通过选择特定的探测光路来获取额外的几十个样本,显著提高了模型的精度。然而,由于 OPM 的短缺,这些所需的特定样本通常难以获取。另一方面,DA 方案对源域和目标域的要求较为严格,需要来自外部网络拓扑的数百个样本,因此可扩展性较差。

由于 ANN 模型具有高度的灵活性和易于实现的优点,使得基于 ANN 模型的微调方法成为迁移学习(TL)的常用方案。这种方案能够有效地克服 AL 和 DA 方案的限制。在文献[24]中,研究者们建立了一种基于 ANN 的 TL 模型,该模型旨在支持不同调制格式的光网络中进行光路 QoT 预测。通过应用 TL 技术,所需的

训练样本数量从 1 000 个显著减少到 20 个。文献[25]则提出了一种 TL 辅助的深度神经网络(DNN)方法,专门用于预测 OSNR。该方法能够实现快速重构以响应各种系统参数的变化。实验结果表明,在不同的目标发射功率、残余色散和比特率下,所提出的模型大大减少了所需的训练样本数量和训练时间。在文献[26]中,研究者们进一步提出了一种多域弹性光网络中基于进化 TL 的光路 QoT 预测模型,相较于传统训练方式,该模型所需训练样本量最多减少到原来的 1/13,同时预测精度达到 95%以上。

然而,跨拓扑光路 QoT 预测方案的研究仍存在以下不足:首先,迁移模型的粒度较粗;其次,对于网络中的无标签样本,其利用率相对较低;最后,源域样本与目标域样本之间的差异较大。针对上述问题,本文作者针对小样本场景下光路 QoT 预测任务从以下 3 个方面进行了深入研究<sup>[27-31]</sup>。

1) 基于进化神经元级别 TL 的光路 QoT 预测方案。该方案的核心思想是将神经元作为 TL 的最小单位,通过搜索基于神经元重要性的迁移模型结构来确定哪些神经元需要冻结,哪些需要微调<sup>[27]</sup>。这种策略旨在高效利用目标域中的有限训练样本进行知识迁移,从而提升光路 QoT 预测模型的准确度。通过这种方式,网络设计的余量得以减小,网络资源利用率得到显著提高。文献[28]在上述基础上进行了进一步改进,提出了一种基于粒子群优化算法的神经元搜索算法。该算法通过粒子群优化算法来优化可训练的神经元和冻结神经元的选择。与传统的基于层级 TL 的光路 QoT 预测方案相比,基于进化神经元级别 TL 的光路 QoT 预测方案在有限的训练样本下能够实现更高的预测准确度,从而进一步提升了网络资源利用率。该方案特别适用于光网络部署初期,当网络参数数据样本相对较少时,它能够有效克服预测准确度低的问题。因此,该方案是一种适应未来光网络部署需求、提升网络资源利用率的优秀光路 QoT 预测机制。

表 2 针对多光路 QoT 智能预测相关工作所使用的智能算法/ML 模型、输入、输出和性能情况

| 文献      | 智能算法/ML 模型   | 输入                                                                            | 输出              | 性能                              |
|---------|--------------|-------------------------------------------------------------------------------|-----------------|---------------------------------|
| [18-19] | DGCNN        | 光路长度、最长链路长度、起始子波长 ID、占用子波长数目、调制格式、经过 EDFA 数量、链路数量、与其它光路共用的链路数量、邻居子波长占用数、QoT 值 | 网络所有光路的可用性      | 预测精度为 92%~100%                  |
| [20]    | DCNN         | 链路长度、每条光纤段数、每条每个信道 BER 值、每条每个信道调制格式                                           | 网络所有光路的可用性      | 在 2 个仿真拓扑下精度分别可达 98.79%和 99.52% |
| [21]    | 图注意力网络 (GAT) | 每条链路上每个信道的发射功率、每条链路的波长占用情况、每条链路长度                                             | 每条链路上光路的 GSNR 值 | 99.84%的测试数据的误差在 0.5 dB 以内       |

表3 针对不同网络间光路 QoT 智能预测相关工作所使用的智能算法/ML 模型、输入、输出和性能情况

| 文献      | 智能算法/ML 模型                                   | 输入                                         | 输出    | 性能                                   |
|---------|----------------------------------------------|--------------------------------------------|-------|--------------------------------------|
| [22]    | SVM                                          | 总长度、链路数量、最大链路长度、容量需求、调制格式                  | 光路可用性 | 重训练样本数减少 20 倍                        |
| [23]    | 高斯过程,MC 方法(AL),<br>贝叶斯更新,特征增强,<br>关联对齐距离(DA) | 光路长度、最长链路长度、链路数、流量大小、<br>流量大小、调制格式         | SNR   | 主动学习仅需要几十个额外样本即可提升模型精度,而域适应技术需要数百个样本 |
| [24]    | DNN                                          | 输入功率和调制格式                                  | Q 因子  | 所需的训练样本数量从 1 000 个减少到 20 个           |
| [25]    | DNN                                          | 信号增幅直方图                                    | OSNR  | 减少所需训练样本数 5 倍,减少 91.9%的训练时间          |
| [26]    | DNN,基于进化算法的 TL                               | 每个光开关处的功率分布                                | Q 因子  | 只需要 10%的样本大小来进行重训练                   |
| [27-28] | ANN,神经元级别 TL                                 | 每条链路的被测发射功率及邻近信道发射功率、<br>每条链路波长占用情况、每条链路长度 | CSNR  | 在 2 个仿真网络下分别可减少 80%和 70%的训练样本数       |
| [29]    | ANN,集成学习                                     | 光路长度、最长链路长度、发射功率、链路数<br>和光纤段数              | CSNR  | QoT 预测精度预计平均提升 35%                   |
| [30-31] | ANN                                          | 光路长度、最长链路长度、发射功率、链路数<br>和光纤段数、波长占用         | OSNR  | 节省约 30%到 40%的训练样本                    |

2)基于样本扩充学习的 QoT 预测方案。文献[29]提出了一种面向 QoT 回归预测的 AL 方案。该方案通过分析样本预测结果的不确定性来构建信息量预测模型,并据此提出 AL 策略。AL 策略利用预测模型分析特定配置参数下的光路 QoT 预测值的概率分布,并通过计算信息熵筛选出信息量丰富、代表性强的 QoT 实例来扩充数据集,从而提升模型的泛化能力。相较于传统的随机采样方法,该方案的光路 QoT 预测精度提升了 35%。

3)基于样本迁移筛选的光路 QoT 预测方案。文献 [30-31] 提出了一种基于样本分布匹配方法的 TL QoT 方案,该方案考虑了 2 个网络中的光路在长度和相邻信道特征上的差异。在进行模型预训练之前,该方案首先利用目标域的大量无标签数据对源域网络样本进行筛选,以确保筛选后的样本与目标域样本分布更接近。随后,利用这些筛选后的样本完成针对所采用光路 QoT 模型的预训练。通过这种方式,所得到的预训练模型将更适用于目标域网络的光路 QoT 预测。与传统的模型迁移方法相比,采用该方案训练的模型在达到相同精度的情况下,预计能够节省约 30%~40%的训练样本。这一优势使得该方案在少样本条件下的精确光路 QoT 预测方面更具实用性。针对不同网络间光路 QoT 智能预测相关工作所使用的智能算法/ML 模型、输入、输出和性能情况如表 3 所示。

## 2 结束语

本文详细介绍了单光路 QoT 智能预测、多光路 QoT 智能预测和跨拓扑光路 QoT 智能预测这 3 种技术的研究现状。尽管现有研究工作在精度方面取得了不错的成果,但在不同网络场景下的泛化能力仍有待提升。特别是在网络样本稀缺或部署监测设备困难的场景下,模型的预测精度往往会大幅下降。因此,如何在样本量有限的情况下提升光路 QoT 预测模型的精度,仍是一个亟待解决的关键问题。只有当 ML 的光路 QoT 预测技术在泛化性和准确性上取得突破,才能为光网络的智能化和高效传输提供坚实的支撑。

## 参考文献:

- [1] SHAO J, LIANG X, KUMAR S. Comparison of split-step Fourier schemes for simulating fiber optic communication systems [J]. IEEE Photonics Journal, 2014, 6(4): 1-15.
- [2] PEDDANARAPPAGARI K V, BRANDT-PEARCE M. Volterra series transfer function of single-mode fibers[J]. Journal of lightwave technology, 1997, 15(12): 2232-2241.
- [3] SECONDINI M, FORESTIERI E, MENYUK C R. A combined regular-logarithmic perturbation method for signal-noise interaction in amplified optical systems [J]. Journal of Lightwave Technology, 2009, 27(16): 3358-3369.
- [4] SEVE E, RAMANTANIS P, ANTONA J C, et al. Semi-analytical model for the performance estimation of 100Gb/s PDM-QPSK optical transmission systems without inline dispersion compensation and mixed fiber types

谷志群,周宇航,张佳玮,等:光路传输质量智能预测技术

- [C]/IET. Proceedings of 39th European Conference and Exhibition on Optical Communication (ECOC 2013). London: IET, 2013: Th.1.D.2-1–Th.1.D.2-3.
- [5] POGGIOLINI P. The GN model of non-linear propagation in uncompensated coherent optical systems [J]. Journal of Lightwave Technology, 2012, 30(24): 3857–3879.
- [6] CARENA A, BOSCO G, CURRI V, et al. EGN model of non-linear fiber propagation[J]. Optics Express, 2014, 22(13): 16335–16362.
- [7] SEMRAU D, KILLEY R I, BAYVEL P. The Gaussian noise model in the presence of inter-channel stimulated Raman scattering [J]. Journal of Lightwave Technology, 2018, 36(14): 3046–3055.
- [8] ALADIN S, TREMBLAY C. Cognitive tool for estimating the QoT of new lightpaths [C]/IEEE. Proceedings of 2018 Optical Fiber Communications Conference and Exposition(OFC). San Diego: IEEE, 2018: M3A.3-1–M3A.3-3.
- [9] 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.
- [10] 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.
- [11] BOUDA M, ODA S, VASSILIEVA O, et al. Accurate prediction of quality of transmission based on a dynamically configurable optical impairment model[J]. Journal of Optical Communications and Networking, 2018, 10(1): A102–A109.
- [12] LIU X, LUN H, FU M, et al. A three-stage training framework for customizing link models for optical networks [C]/IEEE. Proceedings of 2020 Optical Fiber Communications Conference and Exhibition (OFC). San Diego: IEEE, 2020: Th3D.6-1–Th3D.6-3.
- [13] CHO H J, VARUGHESE S, LIPPIATT D, et al. Convolutional recurrent machine learning for OSNR and launch power estimation: a critical assessment[C]/IEEE. Proceedings of 2020 Optical Fiber Communications Conference and Exhibition (OFC). San Diego: IEEE, 2020: M2J.5-1–M2J.5-3.
- [14] MAHAJAN A, CHRISTODOULOPOULOS K, MARTNEZ R, et al. Modeling EDFA gain ripple and filter penalties with machine learning for accurate QoT estimation [J]. Journal of Lightwave Technology, 2020, 38(9): 2616–2629.
- [15] ZHOU Y H, GU Z Q, ZHANG J W, et al. Attention mechanism based multi-channel QoT estimation in optical networks[C]/IEEE. Proceedings of 2021 Asia Communications and Photonics Conference (ACP). Shanghai: IEEE, 2021: T4A.131-1–T4A.131-3.
- [16] ZHOU Y H, HUO X Q, GU Z Q, et al. Self-attention mechanism-based multi-channel QoT estimation in optical networks [J]. Photonics, 2023, 10(1): 1–14.
- [17] GAO Z, YAN S, ZHANG J, et al. ANN-based multi-channel QoT-prediction over a 563.4-km field-trial testbed [J]. Journal of Lightwave Technology, 2020, 38(9): 2646–2655.
- [18] PANAYIOTOU T, SAVVA G, SHARIATI B, et al. Machine learning for QoT estimation of unseen optical network states[C]/IEEE. Proceedings of Optical Fiber Communication Conference. San Diego: IEEE, 2019: Tu2E.2-1–Tu2E.2-3.
- [19] SAVVA G, PANAYIOTOU T, TOMKOS I, et al. Deep graph learning for QoT estimation of unseen optical sub-network states: capturing the crosstalk impact on the in-service lightpaths[J]. Journal of Lightwave Technology, 2021, 40(4): 921–934.
- [20] SAFARI P, SHARIATI B, BERGK G, et al. Deep convolutional neural network for network-wide QoT estimation [C]/IEEE. Proceedings of Optical Fiber Communication Conference. San Francisco: IEEE, 2021: Th4J.3-1–Th4J.3-3.
- [21] ZHOU Y H, XU P, LI W, et al. Digital twin-assisted margin-aware RWMA scheme in optical networks [C]/IEEE. Proceedings of 2022 Asia Communications and Photonics Conference (ACP). Shenzhen: IEEE, 2022: 1228–1232.
- [22] ROTTONDI C, DI MARINO R, NAVA M, et al. On the benefits of domain adaptation techniques for quality of transmission estimation in optical networks[J]. Journal of Optical Communications and Networking, 2021, 13(1): A34–A43.
- [23] AZZIMONTI D, ROTTONDI C, GIUSTI A, et al. Comparison of domain adaptation and active learning techniques for quality of transmission estimation with small-sized training datasets[J]. Journal of Optical Communications and Networking, 2021, 13(1): A56–A66.
- [24] YU J, MO W, HUANG Y K, et al. Model transfer of QoT prediction in optical networks based on artificial neural networks [J]. Journal of Optical Communications and Networking, 2019, 11(10): C48–C57.
- [25] XIA L, ZHANG J, HU S, et al. Transfer learning assisted deep neural network for OSNR estimation [J]. Optics Express, 2019, 27 (14): 19398–19406.
- [26] LIU C Y, CHEN X, PROIETTI R, et al. Performance studies of evolutionary transfer learning for end-to-end QoT estimation in multi-domain optical networks [J]. Journal of Optical Communications and Networking, 2021, 13(4): B1–B11.
- [27] ZHOU Y H, GU Z Q, ZHANG J W, et al. Neuron-level transfer learning for ANN-based QoT estimation in optical networks [C]/IEEE. Proceedings of 2023 Asia Communications and Photonics Conference/2023 International Photonics and Optoelectronics Meetings (ACP/POEM). Wuhan: IEEE, 2023: 1–4.
- [28] ZHOU Y H, GU Z Q, ZHANG J W, et al. Evolutionary neuron-level transfer learning for QoT estimation in optical networks[J]. Journal of Optical Communications and Networking, 2024, 16(4): 432–448.
- [29] LI Z, GU Z Q, ZHANG J W, et al. Predictive uncertainty aware active learning for regression-based QoT estimation in optical networks[C]/IEEE Group. Proceedings of Asia Communications and Photonics Conference. Shanghai: IEEE, 2021: T2B.4-1–T2B.4-3.
- [30] QIN T Z, GU Z Q, ZHANG J W, et al. Sample distribution matching based transfer learning for QoT estimation in optical networks[C]/IEEE Group. Proceedings of Asia Communications and Photonics Conference. Shanghai: IEEE, 2021: T1C.4-1–T1C.4-3.
- [31] GU Z Q, QIN T Z, ZHOU Y H, et al. Sample-distribution-matching-based transfer learning for QoT estimation in optical networks[J]. Journal of Optical Communications and Networking, 2023, 15(9): 649–663.