

SHANGHAI JIAO TONG UNIVERSITY



THESIS OF BACHELOR



论文题目: 下一代智慧光网络的建模、监测及 优化问题的研究

学生姓名	刘晓敏
学生学号	516021910542
专业	信息工程
指导教师	诸葛群碧
学院(系)	: 电子信息与电气工程学院

上海交通大学

毕业设计(论文)版权使用授权书

本毕业设计(论文)作者完全了解学校有关保留、使用毕业设计 (论文)的规定,同意学校保留并向国家有关部门或机构送交论文的 复印件和电子版,允许论文被查阅和借阅。本人授权上海交通大学可 以将本毕业设计(论文)的全部或部分内容编入有关数据库进行检 索,可以采用影印、缩印或扫描等复制手段保存和汇编本毕业设计 (论文)。

保 密, 在 年解密后适用本授权书。

本学位论文属于

不保密	0	

(请在以上方框内打"✔")

学位论文作者签名:

指导教师签名:

日期: 年月日日期: 年月日



下一代智慧光网络的建模、监测及优化问题的研究

摘要

随着5G、智能物联网及高清视频等应用的发展,光网络传输容量的需求每年日益增长。 在传输层面,在相干通信架构下,数字信号处理技术已经发展成熟,使得点到点链路的传 输性能逐渐逼近香农极限。然而,为了保证光信号传输的可靠性,各信号在设计初期,都留 出了大量的余量,使得该链路信号在运行到寿命结束时依然能有较好的性能。这也会使得, 在信号运行至寿命终结之前,大量未利用的余量造成频谱资源的浪费。因此,构建低余量网 络可以使下一代系统容量显著增加。余量设计中,有一部分余量预留给了在业务构建初期 的性能估计工具。由于在业务建立前,其传输性能是未知的,且性能估计使用的参数主要来 自于器件的出厂测试值,因此在输入参数与使用的估计模型上都存在一定的误差。而在余 量预留中,设计余量(design margin)就是为这一部分的误差预留。同时,余量预留一般基 于保守估计,因此会有大部分余量在实际系统中被浪费。因此,提高信号的性能估计精度可 以有效降低余量。同时,对已建立的信号,传输性能的监测也非常重要。监测的信息可以辅 助修正估计模型,同时对链路中可能发生的故障进行预判预警。因此,光网络的建模与监测 是构建下一代智能低余量网络的关键技术之一。由于传统理论建模与监测模型在灵活光网 络中存在一系列精度、速度的缺陷,而光网络中大量的数据为使用机器学习为基础的算法 提供了机会。本文对基于机器学习的建模监测算法进行了总结,同时在新架构下,以部署为 目标,对光网络建模监测算法进行了优化。

关键词:智能光网络、性能估计、性能监测、机器学习



THE MODELING AND MONITORING TECHNIQUES FOR THE NEXT GENERATION OPTICAL NETWORKS

ABSTRACT

With the development of 5G, intelligent Internet of Things and high-definition video, the demand for optical network transmission capacity is increasing every year. At the transmission level, under the coherent communication architecture, digital signal processing technology has made the transmission performance of each link gradually approach Shannon limits. However, in order to guarantee the reliability of optical signal transmission, a large amount of margin is mandatory in the design of each signal. In this way, signals can still have better performances at the end of the life. However, the margin can also cause an under-utilization of spectrum resources. Therefore, building a low-margin network can significantly increase the capacity of next-generation optical systems. A part of the margin is designed for the planning tool. Before the lightpath is established, the specific transmission performance is unknown. Moreover, the parameters used for estimation may be uncertain and there are deviations between the input parameters and the estimated model used in the control plane. Therefore, the design margin is reserved for this part of the uncertainty. However, margin design is generally based on conservative estimations so that most of the margin could be wasted. Therefore, improving the accuracy of signal performance estimation can effectively reduce the margin. At the same time, performance monitoring of established signals is also very important. The monitored information can assist in revising the estimation model, and at the same time early warning of possible failures. Therefore, modeling and monitoring of optical networks is one of the key technologies for building next-generation intelligent low-margin networks. Since traditional theoretical modeling and monitoring models have a series of defects in accuracy and complexity in flexible optical networks, a large amount of data provides opportunities for using machine learningbased algorithms. This paper summarizes the modeling and monitoring algorithm based on machine learning. At the same time, under the new architecture, with the goal of deployment, the modeling and monitoring algorithm based on machine learning is optimized.

Key words: intelligent optical networks, quality of transmission estimation, quality of transmission monitoring, machine learning



第一章	绪论	1
1.1	光通信系统与光网络	1
1.2	光网络传输性能建模研究现状	3
	1.2.1 光网络 QoT 估计模型	3
	1.2.2 光网络损伤估计模型	5
1.3	光网络传输性能监测研究现状	6
1.4	本文主要结构与思路	8
太一 立.		0
弗→早	兀 传制非线性效应怕计力杀	9
2.1	非线性噪声建快昇法	9
	2.1.1 非线性噪声介绍 · · · · · · · · · · · · · · · · · · ·	9
	2.1.2 分步傳业叶昇法	9 10
2.2	2.1.3 尚斯噪戸模型	10
2.2	理比快望性能对几次问题採问	11
2.5	非线性监测昇法	12
2.4	平早小	14
第三章	基于理论模型与机器学习的 QoT 建模方法	15
3.1	现有 QoT 与损伤建模算法分析	15
3.2	针对链路的定制化神经网络训练机制	15
3.3	在线定制阶段的主动获取机制	17
3.4	模型定制化框架的仿真验证	18
3.5	本章小结	21
第四章	非线性噪声监测在新架构下的算法设计	22
4.1	非线性噪声监测算法在新架构下的挑战与机遇	22
4.2	多载波系统下非线性噪声监测算法	22
4.3	多载波系统下非线性噪声监测算法性能验证	24
4.4	理想多载波系统下非线性噪声监测算法性能验证	25
4.5	实际多载波系统下非线性噪声监测算法性能验证	26
4.6	多载波系统下非线性噪声监测算法性能评估	29
4.7	本章小结	30
第五音	光网络建模监测技术总结与展望	31
5.1	光网络性能估计技术总结	31
5.2	基于机器学习的光网络性能估计技术的局限与发展	31
全文总约	昔	33
参考文南	秋	34



下一代智慧光网络的建模、监测及优化问题的研究

致 谢	39
攻读学士学位期间已发表或录用的论文	40
攻读学士学位期间参与的项目	41



插图索引

图 1-1	智能光网络系统架构	1
图 1-2	光通信系统架构	2
图 1-3	光通信建模监测应用架构	2
图 2-1	分步傅立叶计算过程	10
图 22	分步傅立叶模型与高斯噪声模型的精度对比	12
图 23	非线性噪声监测算法神经网络框架	14
图 24	非线性噪声监测算法神经网络预测结果	14
图 3-1	基于神经网络的建模算法的局限性分析	15
图 3-2	针对链路的定制化性能估计模型训练机制 ^[63]	16
图 3-3	第一阶段模型初始化训练框图	16
图 34	第二阶段模型离线定制化训练框图	16
图 3-5	第三阶段模型在线定制化训练框图	17
图 36	仿真系统结构	18
图 37	定制化训练前后模型误差直方图对比	20
图 38	拟合过程	21
图 39	定制化训练前后均方差对比	21
图 3-10	定制化前后误差累积直方图对比	21
图 41	多载波系统(subcarrier multiplexing)架构	22
图 42	子载波间互相关特征计算方式	23
图 43	子载波间相关性特征融合机制	23
图 44	多载波系统下非线性监测神经网络结构	24
图 45	多载波系统下非线性监测性能验证仿真框架	24
图 46	8-子载波系统噪声互相关计算结果示意图	25
图 4–7	无随机波动场景下非线性监测结果	26
图 48	不同噪声分布数据训练神经网络的监测结果	27
图 49	不同噪声分布数据训练与监测结果	28
图 410	不同训练方案的监测误差分布直方图	28
图 4-11	不同场景的监测误差分布直方图	29



表格索引

表 1-1	基于机器学习的 QoT 建模工作总结	•	•			 •	•	 •	•			•	•		•	•	•		5
表 12	基于机器学习的 QoT 监测工作总结		•			 •	•		•			•	•		•	•	•	•	7
表 13	基于机器学习的故障处理工作总结			•	•	 •	•	 •	•	• •	•	•	•	•	•	•	•	•	8
表 21	仿真数据配置表			•	•	 •	•		•		•	•	•	•	•	•	•	•	12
表 31	仿真数据配置表					 •	•												18
表 32	各类光纤参数表					 •	•								•	•	•	•	19
表 33	输入特征表			•	•	 •	•	 •	•	• •	•	•	•	•	•	•	•	•	19
表 41	仿真数据配置表					 •	•								•	•	•	•	24
表 42	噪声相关性特征计算拖尾参数					 •	•		•			•	•		•		•	•	25
表 43	噪声相关性特征计算拖尾参数					 •	•		•			•	•		•		•	•	27
表 44	噪声相关性特征计算求和拖尾长度		•			 •	•		•				•		•	•	•	•	29
表 45	噪声相关性特征计算求和拖尾长度		•		•	 •	•		•						•	•	•	•	30



第一章 绪论

5G 移动网络、物联网和云服务的发展对光网络的容量和可靠性提出了更高、更新的要求。为了满足数量迅速增长的互联网用户的需求,光网络技术也在持续不断地发展。弹性光 网络(Elastic optical networks, EON)的发展^[1]使网络控制层可以按照需求对频谱资源进行 精确的分配,以便提高频谱利用率^[2]。然而,由于链路和信号的配置也逐渐多样化,EON结 构增加了网络复杂性,这使得维持高质量的光传输业务从寿命(Beginning of life, BoL)到寿 命终止(End of life, EoL)更具挑战性。每个光传输链路中都存在大量数据传输,即使是短 暂的流量中断也会导致灾难性的服务降级^[2]。因此,提高光网络的可靠性也是未来光网络发 展的一个重要课题。

为了提高光网络容量,下一代光网络应能够更好地利用网络、频谱资源。在大部分情况下,由于光网络规划平台无法准确预估未部署的光信号的传输质量(Quality of transmission, QoT),为确保网络正常运行,较高的设计余量被预留以适应规划的性能指标与实际结果之间的差异^[3]。然而,高余量的设计也会导致频谱资源利用不足,从而浪费了一部分传输容量。因此,为了构建一个低余量的光网络来增加网络容量,控制层需要更准确的光网络规划工具在光路部署前来评估传输性能^[4]。在这种情况下,准确的QoT模型至关重要^[4]。另一方面,为了提高光网络的可靠性,控制层需要获取网络的实时状态以防止故障发生。因此,光传输性能监控(Optical performance monitoring, OPM)技术对于监控QoT和损伤至关重要。如果故障在光网络中发生,监测机制需应能检测、识别并定位这些故障。总的来说,建模和监测技术是识别和定位故障的关键步骤,高性能的光网络建模和监测技术是下一代 EON 中不可缺少的重要模块。



图 1-1 智能光网络系统架构

1.1 光通信系统与光网络

光通信系统在目前的通信网络中承担了大量的通信流量。在目前核心网系统中,光通信 系统使用相干通信架构。在收发机中内置大量数字信号处理(Digital signal processing, DSP) 模块,在波分复用(Wavelength division multiplexing, WDM)中对传输过程中的损伤与噪声



进行补偿,从而获得最佳传输性能。对于单条链路,光通信系统架构如下图1-2所示:



图 1-2 光通信系统架构

如图所示,其中,DAC 为数模转换器 (Digital to analog converter),ADC 为模数转换器 (Analog to digital converter), IQ Mod.为 IQ 调制器 (IQ modulator),Laser 为激光器,LO Laser 为本征激光器 (Local oscillator laser),PBS 为偏振分束镜 (Polarization beam splitter),PBC 为偏振合波器 (Polarization beam combiner),EDFA 为掺铒光纤放大器 (Erbium doped fiber amplifier)。数字信号通过脉冲成型,在调制后成为光信号在光纤链路传输,在收端接 收后转化为数字信号,再进行一系列数字信号处理,最终判决获得真实的符号与比特。在 光信号传输过程中,光信号会受到一系列损伤、噪声的影响,因此,在收端,接收的信号不 可避免地存在噪声与误码。为了保证传输性能的可靠性,光通信系统需要为信号业务预留 余量以防止系统崩溃。然而,在业务部署前,其传输性能只能通过建模估计来获得,因此, 光网络系统也需要为建模估计的不准确预留一系列余量。然而,系统的预留余量是以牺牲 了光系统传输的容量为代价的,为了尽可能地减少余量的预留,传输性能估计模块精度需 要进一步提升,这要求模型对传输过程中各个损伤都有较为准确的估计,并可以考虑到控 制层参数不准确带来的估计影响。同时,为了防止低余量条件下光通信系统崩溃,光网络控 制系统需要有精确的光网络监测机制,在系统崩溃前对故障进行预警,从而调整系统配置,其结构如图1-3。下面将总结目前已有光网络传输性能建模与监测方案的研究现状。



Network Topology





1.2 光网络传输性能建模研究现状

尚未建立的光路的 QoT 建模可以辅助光网络控制层制定最佳的路由、波长分配和信号 配置策略^[5-10]。在 EON 的网络规划阶段,QoT 和损伤模型的准确性受光网络中各种可配置 参数 (如调制格式、符号率和物理路径)的影响。如果这些参数不准确,与实际值相比,QoT 的估计值可能会存在偏差^[11-13]。在这种情况下,由于规划工具的不准确性,控制层在设计 光信号时需要预留很大的设计余量^[3]以避免在 EoL 之前网络性能下降至无法维持传输业务 正常运行的水平。因此,传输层需要具有更高准确性的 QoT 模型,并且其中的各个损伤模 型可以深入了解不同损伤的具体影响,以辅助 QoT 估计模型获得更好的性能。

对于 QoT 建模,一些传统方法^[14] 可以输出信噪比 (Signal to noise ratio, SNR)、前向纠 错 (Forward error correction, FEC)误码率 (Bit error rate, BER)、光信噪比 (Optical signal to noise ratio, OSNR)等指标来评估光链路的性能。对于损伤建模,传统方法可以估计一些重要 的物理层效应,例如光纤非线性,光滤波效应和放大器的自发辐射 (Amplifier spontaneous emission, ASE)噪声。然而,对于高速动态变化的 EON,传统的方法可能无法快速适应链 路的动态变化。因此,基于机器学习对光网络性能与损伤进行建模也成为了受到大量关注 的课题。

1.2.1 光网络 QoT 估计模型

目前光网络 QoT 估计模型主要分为传统分析模型与基于机器学习的模型。本节将从这两方面分别予以介绍。

1.2.1.1 传统 QoT 模型

大部分传统的 QoT 模型主要考虑传输过程中非线性噪声与掺铒光纤放大器中的 ASE 射噪声,考虑光信号的光纤传输效应可表示为非线性薛定谔方程 (Non-linear Schrodinger equation, NLSE):

$$\frac{\partial E_x}{\partial z} = j\frac{8}{9}\gamma \left| E_x^2 + E_y^2 \right| E_x - \frac{j\beta_2}{2}\frac{\partial^2 E_x}{\partial t^2} - \alpha E_X \tag{1-1}$$

$$\frac{\partial E_y}{\partial z} = j\frac{8}{9}\gamma \left| E_x^2 + E_y^2 \right| E_y - \frac{j\beta_2}{2}\frac{\partial^2 E_y}{\partial t^2} - \alpha E_y \tag{1-2}$$

由于非线性薛定谔方程没有解析解,则理论模型一般基于一些假设对非线性薛定谔方程进行 简化,从而求出近似结果。其中,分步傅立叶模型 (Split-step Fourier transform method, SSFM) 与高斯噪声模型 (Gaussian noise model, GN model) 是最为重要的两个模型。下面将分别介绍 这两个模型。

• 分步傅立叶模型

分步傅立叶模型^[15] 是基于数据样点对传输性能进行仿真的模型。其假设为:在光纤传 输过程中,信号受到的色散与非线性效应在短距离内相互独立。因此,在模拟光传输的过程 中,对于极短传输距离内,可以将色散效应与非线性效应分离考虑,从而快速处理数据获得 传输结果。以 80km 的传输距离为例,20m 左右分段该光纤,可以较为准确模拟信号传输性 能。虽然分步傅立叶模型可以较为准确地仿真链路传输的性能,然而其计算速度较慢,对计 算资源要求也较高。这是由于传输过程中色散效应要求在频域对信号进行处理,非线性要 求在时域对信号数据进行处理,考虑到约每20m 左右需要交替处理一次,因此,传输信号

第3页共41页



需要进行多次傅立叶变换,这延缓了运算速度并要求较大内存的计算机对数据进行变换计 算。因此,该方法适用于对估计时间没有限制而对估计精度有较高要求的应用场景。

• 高斯噪声模型

高斯噪声模型^[16] 根据一系列假设简化了非线性薛定谔方程,从而快速求解简化后非线性薛定谔方程的解析解。高斯噪声模型的假设如下:

1. 信号噪声功率相对于信号功率是很弱的;

2. 传输信号在统计上表现为平稳高斯信号;

3. 非线性产生的干扰,即非线性噪声,表现为加性高斯噪声。

基于以上假设后,高斯噪声模型可以求出非线性薛定谔方程的近似解。其中,当不考虑 各个光纤之间的相互影响时,可以得到非相干高斯噪声模型 (Incoherent GN model, IGN),当 考虑各个光纤之间在传输过程中的相互影响时,可以得到相干高斯噪声模型 (Coherent GN model, CGN)。

由于高斯噪声模型中,非线性噪声求解过程为数值运算,不需要产生符号进行仿真,因 此计算速度较快。同时,当非线性效应较高时,其噪声分布会逐渐偏离高斯信号的特征,无 法满足该模型的假设。因此,高斯噪声模型的估计精度较低,在非线性效应较强的场景下, 误差较大。同时,由于高斯噪声模型可以提供保守的噪声估计,即对于噪声的估计值会大于 实际值,因此适用于对噪声估计速度要求较高、精度要求较低的快速建模场景。

以上两组传统的建模方法可满足不同场景、不同精度的建模需求,为光网络的设计提供准确的指导。同时,随着光网络的逐渐发展,异质的网络、器件会对模型的准确性与可扩展性提出更高的要求。随着 EON 技术的不断发展,传统建模方法需要在精度、速度及可扩展度上进一步提升。由于近年计算机技术的快速发展,人工智能技术成为提升算法效解决场景复杂的问题的有效武器。在光网络 QoT 建模场景中,机器学习也具有非常大的潜能以提高建模算法的性能。

1.2.1.2 基于机器学习的 QoT 模型

机器学习 (Machine learning, ML) 驱动的 QoT 模型可以提高模型的可扩展性,加快运算 速度,并对建模参数的不准确有较高的鲁棒性。首先,机器学习方法主要为数据驱动^[17],这 意味着即使没有任何理论知识,机器学习模型也能学习到数据集的内在特征^[4, 18-21]。如果 能够获得仿真、实验或实际系统数据,利用数据进行自适应学习的特定能力可以使基于机 器学习的模型轻松地扩展到任何情况^[8, 22, 23]。同时,对于大多数光网络而言,用于链路配 置的可调参数的数量是有限的,这使得用于 QoT 或损伤建模的参数数量相对较少^[11, 18, 24], 则 ML 模型能够利用简单的结构(例如具有少量节点和隐藏层的神经网络)达到良好的性 能^[8]。在这种情况下,与某些传统模型相比,这些低复杂度的机器学习模型可以更快地进行 计算。目前,许多仅使用单隐藏层神经网络或线性回归完成光网络性能估计的工作已经取 得了良好的效果^[11]。最后,新兴的机器学习算法(如集成学习^[25]和泰尔森回归^[26]等)可 以解决最小二乘算法的缺点,并使模型对数据的异常值和波动的敏感度降低。此外,数据增 强^[27, 28]技术也可以提高模型对参数不确定性的鲁棒性,并通过人工添加干扰来避免过拟合 发生。在本节中,将回顾基于机器学习的 QoT 建模的工作,如下表1–1所示。



建模输出	算法	输入特征
	K-临近,随机森林 ^[4]	信号流量,调制格式,链路总长度,最
BER		长链路的长度,光链路的数量
	随机梯度下降多项式	广义OSNR,波特率,调制格式,FEC,
	回归 ^[6]	频谱网格尺寸
	深度图卷积网络 ^[29]	光路总长度,跨度长度,中心频率,每
		条光路中的频谱所占网格数目,调制
		格式,EDFA 数,链路数目,BER
O factor	案例推理(Case-based	光路路径,信号波长,路径的总长度,
Q-lactor	reasoning, CBR) ^[30, 31]	每条链路的相关共同传播光路, 总共
		传播光路数的标准差
	迁移学习[18]	通道负载,每通道输出功率
OSNP	网络 Kriging 法, L2 正	每个链路的平均偏振模色散, 总色散
OSINK	则化回归[32]	的累加值, 通过信号的非线性噪声的
		自相位调制
	高斯过程回归[33]	波长,已经建立信号的 OSNR
CNID	机器学习与物理层模	光路长度,链路负载, EDFA 数量
SINK	型结合[34]	
	梯度下降[35]	信号功率, EDFA 的噪声系数
Margin	K-临近,线性回归,支持	跳数,跨度数,总链路长度,平均链
	向量机,神经网络 ^[24]	路长度,最大链路长度,平均跨度衰
		减,平均色散

表 1-1 基于机器学习的 QoT 建模工作总结

1.2.2 光网络损伤估计模型

由于光网络性能损伤由多种损伤共同造成,因此,对各个损伤进行准确建模可以获得 更多信息,以辅助提高 QoT 模型的准确性。此外,对特定损伤的估计可以辅助控制层设计 光路的最佳配置。由于目前的相干接收机可补偿色散(Chromatic dispersion, CD)和偏振模 色散(Polarization mode dispersion, PMD)等损伤,本节将分析目前光传输系统中可能导致 性能下降的损伤。本节分析了基于传统算法及机器学习算法估计光纤的非线性,滤波效应 和 ASE 噪声的建模方法。

对于非线性效应建模,复杂的分析模型(例如 SSFM^[36])可以提供准确的估计。然而,这 些方法需要较长的计算时间。尽管近似模型(例如高斯噪声模型)可以更快地进行计算^[37], 但是不能保证近似计算结果在所有场景下都具有较高的准确度,从而需要预留较高的设计 余量,导致对网络资源的使用效率较低^[3]。为了同时提高运算速度与运算精度,^[11]中提出了 理论分析模型和机器学习组合以达到更高的非线性噪声估计精度的建模方案。

在未来的 EON 中,可重构光分插复用器 (Reconfigurable optical add-drop multiplexer, ROADM)可以使光网络支持灵活的复用和解复用上下波,这对于构建具有更大容量和动态性的智能光网络非常重要。但是,在这种情况下,由于通道之间的间隔减小,由级联 ROADM 引起的滤波效应也会对传输信号的 QoT 产生更大的影响。在^[38]中,引入了一种神经网络辅



助的方法来估计滤波效应。神经网络的输入特征是 ROADM 个数, OSNR, 噪声分布和带宽 分布。单隐藏层的人工神经网络 (Artificial neural networks, ANN) 可以估计由滤波效应作用 后的光路的 SNR, 其误差通常小于 1dB。在实际系统中, 当多个损伤(例如非线性损伤) 共 存时,滤波效应会更显着。此外,实际场景中滤波效应不是一种加性噪声, SNR 可能不是 评估的最佳指标。因此,应该进一步研究诸如如何将滤波效应与其他损伤一起建模以及如 何使用适当的度量来量化滤波效应等问题。

在实际系统中,为了准确地建模由 EDFA 产生的 ASE 噪声,应该精确知道每个 EDFA 在每个波长的噪声系数 (Noise figure, NF)。根据^[21], EDFA 的 NF 与每个波长的增益有关。因此,借助精确的 EDFA 增益模型,可以更准确地估计 ASE 噪声。然而,频谱空穴燃烧^[39] (Spectral hole burning, SHB)效应使 EDFA 的频谱增益曲线在通道重新配置下动态变化,从而导致功率偏移。由于传统模型很难有效地建模每个通道中具有不同功率负载的 EDFA 的增益频谱,因此可以采用数据驱动的 ML 方法。在^[19]中,深度学习被用于分别估计每个通道的具体增益值。为了简化 ML 算法的结构,此处也引入了多层感知器神经网络来同时估计所有通道的增益^[20]。

1.3 光网络传输性能监测研究现状

OPM 是确保光网络可靠性的关键模块^[40]。根据^[2],监测技术可以辅助许多基本和高级的光网络优化功能。首先,对 QoT 和损伤的精确监控^[41,42]可以使控制层准确评估信号质量。因此,监测信息不仅可以指导网络的自我重配置,还可以使接收机优化某些损伤的补偿算法。其次,实时监控可以连续获取物理层的状况。如果 QoT 恶化,则故障监测模块可以检测到故障。然后,控制器可以重新配置网络以避免信号质量进一步降级。最后,来自真实场景的监控数据可用于重新训练规划模型。这种再训练方案可以提高规划工具的准确性,并降低设计余量。同时,在 EON 中部署 OPM 还存在一些具有挑战,例如,如何在较短的响应时间内准确跟踪光网络的实时变化以及如何同时监视多个损伤。这些挑战已在上一节中进行了详细说明。其中,ML 展示了其应对这些挑战的潜力。在本节中,我们回顾了使用ML 进行监测传输性能的各种工作。根据其功能不同,这些方法分为两类。本节首先介绍一些监测 QoT 和光路损伤的算法。然后,回顾了用于监测,识别和定位网络中的软故障的监视技术。这两个方面讨论如下。

对于传输性能监测,传统 OPM 基于收端信号采样评估链路损伤的大小,从而估计 QoT 的结果。然而,传统的 OPM 方法在精度、速度上都受到一定的限制,对于损伤检测的灵敏 度不高,在日益复杂化的 EON 系统中难以部署实现。目前,随着 AI 芯片逐渐部署在实际 控制器与收发机中,基于机器学习的监测算法获得了较多关注,本节总结了目前已有的基于 ML 的监测算法,如下表1-2所示:



算法	特征	监测目标					
神经网络[43]	异步采样信号幅度	OSNR, CD, PMD					
深度神经网络 ^[44]	异步采样的原始数据	OSNR					
卷积神经网络 ^[45]	星座图	OSNR, Modulation Format					
卷 积 神 经 网 络 ^[22, 46]	光信号的水平和垂直偏振分量	OSNR, Modulation Format					
神经网络[23]	发射功率, EDFA 的输入功率, EDFA	OSNR					
	的输出功率, EDFA 的增益, EDFA 的 NF						
主成分分析,神经	异步延迟抽头	OSNR, CD, 差分群时延、联					
网络 ^[47]		合比特率和调制格式识别					
主成分分析,神经 网络 ^[48]	异步单通道采样数据	OSNR, 调制格式					
深度神经网络 ^[49]	信号幅度分布直方图	OSNR, 调制格式					
基于核函数的岭 回归 ^[50]	异步延迟抽头采样数据	CD, 差分群时延					
长短时记忆神经 网络 ^[51]	接收机四路数字输出	OSNR					
长短时记忆神经 网络 ^[52]	频域信号	OSNR,非线性噪声功率					
支持向量机[53]	信号眼图	CD, PMD					
神经网络 ^[54]	信号幅度、相位相关性函数,总色散, 通道数						
神经网络[55]	累积对数幅度噪声相关性、信道数、	非线性 SNR					
	总色散、噪声切向分量和法向分量						
支持向量回归[56]	幅度噪声相关性,累积色散	-					
神经网络[11]	GN模型的非线性信噪比、跨段数、最						
	大跨段长度、平均跨段长度、发射功						
	率、链路长度、总色散、光纤平均非						
	线性系数、光纤跨距平均衰减、波分						
	复用信道数、幅度与相位噪声相关性						

表 1-2 基于机器学习的 QoT 监测工作总结

在故障处理方面,链路故障可以分为硬故障和软故障。链路中的硬故障会立即造成传输中断,可以很容易地监测到并恢复。然而,软故障通常逐渐降低链路传输的的性能,不会 直接中断信号传输,因此难以识别。此外,其导致故障的原因也难以确定。因此,监测和识 别软故障对于下一代灵活的低余量链路非常重要。在本节中,我们回顾了一些基于 AI 技术 的故障处理的最新工作,这些工作在表1-3中列出。



故障处理内容	算法	输入特征				
监测,识别	有限状态机 ^[57]	BER,接收机接收功率				
监测,识别	随机森林,支持向量机 ^[58]	BER 变化趋势				
识别	卷积神经网络 ^[59]	光谱				
监测	决策树,支持向量机 ^[60]	光谱				
监测	支持向量机 ^[61]	自适应滤波器抽头系数				

表 1-3 基于机器学习的故障处理工作总结

对于软故障监测,光网络中的当前监测方法通常依赖于预定义的阈值。然而,由于目前光网络的高度复杂性,在实际系统中,难以设置准确的阈值。如果设置得太松,可能会忽略一些软故障;如果设置得太紧,可能会误判一些故障。对于软故障识别,通常很难使用传统分析方法来完成准确的识别。为了解决传统方法面临的挑战,目前已提出了许多利用 ML 技术进行故障监测和识别的工作。在^[57]中,有限状态机(Finite state machine, FSM)被用于监测和识别由激光器和波长选择开关(Wavelength selective swtich, WSS)引起的软故障。 在^[58]中,作者对 BER 的变化趋势进行了监测和分析。BER 的统计特征被输入到随机森林和支持向量机以监测软故障,并使用具有单隐藏层的 ANN 来分辨软故障的原因。在^[60]中,使用光谱分析仪(Optical spectrum analyzer, OSA)监测光谱,提取并分析特征,以检测由WSS 引起的软故障。此后,控制器可以识别出滤波器偏移(Filter shift, FS)和滤波器带宽变窄(Filter tightening, FT)等异常。在^[61]中,作者使用支持向量机分析自适应滤波器的抽头值,以检测由激光器,WSS和光纤非线性引起的软故障。综上所述,机器学习技术为解决故障检测和识别问题开拓了新道路。借助 ML 强大的学习功能,可以了解所监测数据的隐藏特征,以实现各种故障管理功能。随着光网络变得更加动态化,用于软故障监测和识别的传统技术可能无法很好地适应复杂的情况。因此,ML 技术有望在该领域获得更多应用。

1.4 本文主要结构与思路

本文主要按以下顺序展开。本章介绍了已有传输性能估计算法,第二章简述了光通信 传输过程中最重要的损伤之一,非线性噪声的经典建模与监测方案,并在搭建的仿真器中 进行了性能对比。第三章总结了基于机器学习的建模方案的问题,提出了定制化的模型训 练框架,并在非线性噪声建模的场景下进行了仿真性能验证。第四章总结了传输性能监测 算法的性能与局限,并在下一代传输系统架构下提出了新额度非线性噪声监测方案,并对 其性能与鲁棒性进行了探究。第五章对全文进行了总结,并对下一代系统中数据驱动的建 模与监测算法进行了展望。



第二章 光传输非线性效应估计方案

2.1 非线性噪声建模算法

2.1.1 非线性噪声介绍

光信号在光纤中传输的过程会受到各种损伤、噪声的影响。其中,ASE 噪声、滤波噪声、非线性噪声、收发机噪声是传输过程中主要的噪声,他们之间可以看作独立的相加关系,如下:

$$NSR_{total} = NSR_{ASE} + NSR_{NL} + NSR_{Transceiver} + NSR_{FL}$$
(2-1)

其中, NSR_{total}, NSR_{ASE}, NSR_{NL}, NSR_{Transceiver}, NSR_{FL}分别为总的、ASE 噪声的、非 线性噪声的、收发机的、滤波效应的噪声信号比(Noise-to-signal ratio, NSR)。由于 ASE 噪 声为线性高斯噪声,滤波噪声在目前系统里影响较小,收发机在生产后可以通过实测获得 其噪声具体值,因此,非线性噪声的准确建模对系统性能的评估至关重要。考虑到非线性效 应与光纤色散效应在光纤中共同作用,光信号在光纤中传播过程遵循非线性薛定谔方程:

$$\frac{\partial E_x}{\partial z} = j\frac{8}{9}\gamma \left| E_x^2 + E_y^2 \right| E_x - \frac{j\beta_2}{2}\frac{\partial^2 E_x}{\partial t^2} - \alpha E_X$$
(2-2)

$$\frac{\partial E_y}{\partial z} = j\frac{8}{9}\gamma \left| E_x^2 + E_y^2 \right| E_y - \frac{j\beta_2}{2}\frac{\partial^2 E_y}{\partial t^2} - \alpha E_y$$
(2-3)

其中, $\mathbf{E} = \begin{bmatrix} E_x \\ E_y \end{bmatrix}$ 为为信号在两个方向的偏振态, γ , α , β_2 分别表示光纤的非线性参数, 光纤的功率衰减参数和光纤的二阶色散系数。由于该方程为高阶方程,无法直接求出解析 解,因此,基于部分假设对该方程进行简化的理论模型得到了较高的关注。其中,分步傅立 叶模型和高斯噪声模型是最为常用的两个模型。在本文的后续部分中,讲针对下一代系统 的非线性监测机制提出新的改进机制以提高非线性建模效果。

2.1.2 分步傅立叶算法

信号在光纤传输过程中,受到色散效应与非线性效应的共同作用。色散效应在时域上 使信号脉冲展宽,造成信号之前的相互影响;非线性效应改变信号的频谱,在新频率位置 出现信号。由于两种效应同时存在,在传输过程中互相作用且同时作用于信号时域与频域, 因此,在仿真环境内准确模拟传输过程较为困难。SSFM 假设了该两种效应在较短的距离内 独立作用,不存在相互影响,因此,在仿真环境内,可以通过将信号在时域与频域间切换计 算获得近似的传输效应,将传输过程简化为:

$$A(z+h,T) \approx \exp(h\hat{D}) \exp(h\hat{N}) A(z,T)$$
(2-4)

其中, A(z + h, T) 和 A(z, T) 分别代表了在 z 处与 z+h 处的信号, 而 $exp(h\hat{D})exp(h\hat{N})$ 是色 散与非线性对信号的作用。SSFM 的仿真模式如下图2–1所示。对于每一段极短的传输距离, SSFM 在时域上先为传输信号模拟色散效应,再将信号转化至频域表达形式,为其模拟极短 距离内的非线性效应。完成时域和频域的仿真后,再于下一段极短距离的传输光纤重复该步

第9页共41页



骤,直到传输完成。SSFM的仿真过程中,色散效应与非线性效应的添加顺序可以改变,每 一次仿真的距离也可以依照仿真场景与准确度的要求进行调整。结果显示,该方法可以较 好地对光纤传输性能进行仿真,然而,由于需要将信号在时域与频域间转换,需要多次对传 输信号进行傅立叶变换与傅立叶反变换。当仿真信号长度较长时,该变换过程复杂度较高, 速度较慢,导致 SSFM 耗时较长。



图 2-1 分步傅立叶计算过程

由于 SSFM 精度较高且运算时间较长,在实际场景中,多用于在链路部署初期对整体 链路的配置进行规划。同时,也有一系列的研究围绕提升 SSFM 算法的速度展开。考虑到 SSFM 算法精度与仿真步长、传输功率、系统色散、信号带宽等因素都有一定关系^[62],变步 长实现精确的传输过程仿真也是受到重点关注的研究方向。

2.1.3 高斯噪声模型

为了更快速地估计光纤传输性能,直接获得特定传输条件下 NLSE 方程的近似解析解, 高斯噪声模型被提出在不产生仿真信号的条件下计算传输过程中的非线性噪声。高斯噪声 基于的三个基本假设在第一章中已经解释过,这里不再赘述。由于不需要产生仿真信号,高 斯噪声模型可以快速计算出光信号经过某一段链路后产生的非线性噪声。GN model^[16] 得到 的接收端非线性噪声的功率谱密度如下所示:

$$G_{\rm NLI}(f) = \frac{16}{27} \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} G_{\rm WDM}(f_1) G_{\rm WDM}(f_2) G_{\rm WDM}(f_1 + f_2 - f) + \sum_{n=1}^{N_s} \gamma_n \left[\prod_{k=1}^{n-1} \exp\left(\int_{k=n}^{L_{s,k}} 3g_k(\zeta) d\zeta \right) \exp\left(-3\alpha_k L_{s,k} \right) \Gamma_k^{3/2} \right] \exp\left(j4\pi^2 \left(f_1 - f \right) \left(f_2 - f \right) \right) + \sum_{k=1}^{n-1} \left[\beta_{2,k} L_{s,k} + \pi \left(f_1 + f_2 \right) \beta_{3,k} L_{s,k} + \beta_{\rm DCU,k} \right] \right) + \int_{0}^{L_{s,n}} \left[\exp\left(\int_{0}^{x_s} \exp\left(\int_{0}^{L_{s,k}} g_k(\zeta) d\zeta \right) \exp\left(-\alpha_k L_{s,k} \right) \Gamma_k^{1/2} \right] + \left[\beta_{2,n} + \pi \beta_{3,n} \left(f_1 + f_2 \right) \right] z \right] dz |^2 df_1 df_2$$

$$(2-5)$$

其中, γ , L_{eff} , $G_{WDM}(f_2)$, $\rho(f_1, f_2, f)$, $\chi(f_1, f_2, f)$ 分别为非线性系数, span 的有效 长度,信号的功率谱,放大器的噪声影响,计算接收端的相干非线性噪声。其余参数为计算



非线性噪声功率谱过程中涉及到的计算参数,见^[16]

$$P_{NLI} \approx \int_{R_S/2}^{R_S/2} G_{NLI}(f) df \qquad (2-6)$$

通过对所得功率谱求积分,可以得到非线性噪声功率。其中, **R**_S 为信号波特率,积分范围 为信号频谱所在范围内。

高斯噪声模型可以分为相干高斯噪声模型(IGN)与非相干高斯噪声模型(CGN),其中 CGN 考虑了信号传输在光纤跨段之间的效应。在实际使用过程中,在大多数情况下,仅使用 IGN 模型就可以获得较好的性能估计结果。IGN 模型认为,光纤传输过程中不同跨段的非线性噪声可以叠加,对于第 n 个 span 的非线性噪声功率谱,其表达式为^[16]:

$$G_{\rm NLI}^{n}(f) = \frac{16}{27} \gamma_{n}^{2} L_{\rm eff,n}^{2} \prod_{k=1}^{n-1} e^{6 \int_{0}^{L_{s,k}} g_{k}(\zeta) d\zeta} e^{-6\alpha_{k} L_{s,k}} \Gamma_{k}^{3} \prod_{k=n}^{N_{s}} e^{2 \int_{0}^{L_{s,k}} g_{k}(\zeta) d\zeta} e^{-2\alpha_{k} L_{s,k}} \Gamma_{k} \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} G_{\rm WDM}(f_{1}) G_{\rm WDM}(f_{2}) G_{\rm WDM}(f_{1}+f_{2}-f) \rho_{n_{s}}(f_{1},f_{2},f) df_{1} df_{2}$$
(2-7)

计算结束后,对各个 span 传输过程的非线性噪声功率进行相加即可得到整条链路的非 线性噪声^[16]:

$$G_{\text{NLI}}^{\text{inc}}(f) = \sum_{n=1}^{N_s} G_{\text{NLI}}^n(f)$$
(2-8)

由于积分会为估计过程带来较大的计算量,在信号功率谱基本为矩形,即非线性噪声保持 正常大小,符合高斯模型假设时,可以简化计算非线性噪声功率谱为^[16]:

$$G_{\text{NLI}}(f_{\text{ch},i}) = \frac{16}{27} \sum_{n_s=1}^{N_s} \gamma_{n_s}^2 L_{\text{eff},n_s}^2 \prod_{k=1}^{n_s-1} \Gamma_k^3 e^{-6\alpha_k L_{s,k}} \cdot \prod_{k=n_s}^{N_s} \Gamma_k e^{-2\alpha_k L_{s,k}}$$
$$\sum_{n=1}^{N_{ch}} G_{\text{ch},n} G_{\text{ch},n} G_{\text{ch},i} \cdot (2 - \delta_{n,i}) \cdot \psi_{n,i,n_s}$$
(2-9)

最终通过计算得到在信道内的非线性噪声,即对信号功率谱在信号范围内进行积分,获得[16]:

$$P_{NLI} = G_{NLI} \left(f_{ch} \right) \cdot R_s \tag{2-10}$$

2.2 理论模型性能对比及问题探讨

在实际场景中,新业务部署至光网络前,需要对该光路的损伤进行估计,在部署后也需 要对链路上的业务进行微调。这要求在部署前期,网络规划工具有较高的准确度,在部署可 以快速进行调整。因此,在部署前期,可以使用 SSFM 为工具对非线性损伤进行准确估计, 在光路部署后期,需要使用 GN 模型对光路进行微调。为了检验两算法的性能差异,此处使 用相同的信号、链路配置的样本对比两个建模算法的性能。此处一共随机产生 500 条数据, 每一条数据的配置随机设置如表2-1所示。

第11页共41页

配置	描述
span 个数	5~30
span 种类	SSMF, ELEAF, PSCF
span 长度	80km
WDM 通道个数	5 ~ 17
调制格式	QPSK/16QAM
发射功率	-4 ~ 4dBm
波特率/通道间隔	35Gbaud/50GHz, 70Gbaud/75GHz, 90Gbaud/100GHz

表 2-1 仿真数据配置表

针对每个不同配置的仿真条件进行仿真,对比 SSFM 输出结果与 GN 模型结果的差异, 其误差分布直方图见图2-2。



图 2-2 分步傅立叶模型与高斯噪声模型的精度对比

可以看出,在某些场景下,GN模型的误差较大,最大可以达到5dB,而大部分样本误差集中在1dB左右。因此,在非线性估计的场景,GN模型的准确度需要进一步提高,否则会对建模带来较大误差,影响网络的传输性能。

总的来说,对于非线性建模,现有理论模型的精度和计算速度都需要提升,同时,目前 的模型没有考虑到参数不准确对性能估计的影响。控制层所获的建模参数都是基于器件出 场标定值记录的,然而,随着时间推移,各种器件会逐渐老化,导致参数变化,使用控制层 存储的结果进行性能估计会造成较大的误差,影响最终的信号设计,降低频谱利用率。因 此,提高模型对不准确参数的鲁棒性和适应性也是光网络性能建模的一个重要问题。

2.3 非线性监测算法

由于受到建模参数不准确、模型不准确的影响,在光路部署之前利用理论模型进行的 性能估计存在较大的不准确。因此,在实际场景下,在光路部署到链路后,也需要实时对链 路中的非线性效应进行监测。非线性效应的监测可以为链路功率优化提供更多的信息,也 可以为非线性补偿算法提供反馈参考,同时,还可以为链路故障的监测提供有效信息,降低



光路设计余量。

由于非线性效应在信号上体现为时域符号间的相互作用以及频域间的相互作用,因此,利用信号在时域上的相关性监测非线性是一个较好的思路。根据^[54],非线性效应会造成信号在幅度和相位上的相关特征 ANC(Amplitude noise correlations, ANC)与 PNC (Phase noise correlations, PNC),因此,可以先利用收端符号计算幅度噪声、相位噪声在符号间的相关性,此处利用卷积式进行计算,对于幅度噪声相关性^[11]:

$$ANC_{ij}(m) = \operatorname{cov}\left(\Delta A_{i}(k), \Delta A_{j}(k-m)\right) \quad i, j \in \{x, y\}$$
$$= \frac{1}{N-1} \sum_{k=1}^{N} \left(\Delta A_{i}(k) - \frac{1}{N} \sum_{k=1}^{N} \Delta A_{i}(k)\right)^{*} \cdot \left(\Delta A_{j}(k-m) - \frac{1}{N} \sum_{n=1}^{N} \Delta A_{j}(k-m)\right)$$
(2-11)

其中, $\Delta A_{i/i}(k)$ 表示在 i 或 j 偏振上信号第 k 个符号的幅度噪声^[11]。

$$\Delta A_{i/j}(k) = \left| A_{i/j}^{R}(k) \right| - \left| A_{i/j}(k) \right| \quad i, j \in \{x, y\}$$
(2-12)

同理,信号的相位噪声可以计算为[11]:

$$PNC_{ij}(n) = \operatorname{corr}\left(\theta_i(k), \theta_j(k-n)\right)$$
$$= \frac{\sum_{k=1}^N \theta_i(k) \cdot \theta_j(k-n)}{N \cdot (N-n)} \quad i, j \in \{x, y\}$$
(2-13)

其中, $\theta_{ili}(k)$ 表示在 i 或 j 偏振上信号第 k 个符号的相位噪声^[11]。

$$\theta_{i/j}(k) = \arg\left(\frac{A_{i/j}^{*}(k) \cdot A_{i/j}^{R}(k)}{\left|A_{i/j}^{*}(k) \cdot A_{i/j}^{R}(k)\right|}\right) \quad i, j \in \{x, y\}$$
(2-14)

由于非线性噪声对于信号的幅度以及相位的影响并不统一,因此,在此处,幅度、相位噪声的相关性长度并不一致,对其相关长度内的卷积结果进行求和处理,可得^[11]:

$$R_{ij} = 10 \cdot \log_{10} \left(1/\sum_{m=1}^{x} ANC_{ij}(m) \right)$$
(2-15)

$$P_{ij} = 10 \cdot \log_{10} \left(1 / \sum_{n=1}^{x} PNC_{ij}(n) \right)$$
(2-16)

R_{ij} 与 *P_{ij}* 为对相关性计算结果求和获得的噪声相关性特征。其中,相关性计算的拖尾长度 与符号噪声之间的相关性大小有关,而符号间噪声的相关性大小与具体的链路、信号设置 相关,因此 x 值在不同的情况下要根据观察取不同的结果。在对幅度噪声、相位噪声进行 了相关性处理后,幅度、相位噪声的相关性呈现出与非线性噪声大小正相关的关系。虽然 该数值关系无法利用明确的理论公式进行表示,但是神经网络可以很好地根据已有的仿真、 实验、现网数据,对两者的关系进行拟合。最终神经网络的结构呈现如图2-3所示。

第13页共41页





图 2-3 非线性噪声监测算法神经网络框架

最终,使用单隐层的神经网络,在利用上一节产生的 500 个仿真数据进行训练与预测, 其中 30% 数据用于测试,图2-4展示了训练好的神经网络在测试集上的结果。



图 2--4 非线性噪声监测算法神经网络预测结果

可以看出,该基于监测的方案在仿真场景内可以对非线性噪声进行较为准确的估计。然 而,该方案的准确度受到相关性计算时符号的数目的影响。同时,对于下一代系统,将呈现 super channel 结合多载波的结构,在多载波系统下的非线性监测也会面临更多的挑战。

2.4 本章小结

本章详细介绍了非线性效应的原理,并对光传输过程中非线性效应的建模与监测算法 进行了介绍。对于非线性建模算法,精度较高的 SSFM 模型与速度较快的 GN 模型都是不 同场景下较常用的算法。本章对这两种算法都进行了介绍,并利用仿真数据对这两种算法 进行了性能对比。同时,在非线性噪声监测方案上,本章也介绍了基于神经网络,利用幅度 与相位噪声相关性作为监测特征,最后对非线性信噪比进行估计的监测算法。本章也利用 仿真数据对基于幅度与相位噪声相关性的神经网络进行了训练与验证。下一步将以非线性 噪声估计作为重要关注点,对链路性能估计的算法的部署进行优化设计,同时考虑在下一 代新架构的系统中,对性能监测算法进行优化。



第三章 基于理论模型与机器学习的 QoT 建模方法

3.1 现有 QoT 与损伤建模算法分析

传输质量(QoT)估计和监测是构建低余量光网络以提高传输容量和效率的关键功能。 在各种光链路条件下,对链路性能进行建模的方法通常会受到精度不足和计算复杂性高的 困扰。近年来,机器学习(ML)受到越来越多的关注,因为它为构建更为智能的光网络提供 了新的机会^[15,16]。尽管在这种情况下,可以使用通过仿真获得的大型数据集来训练 ML 模 型,但是训练数据集可能无法涵盖所有实际部署情况,在某些情况下可能导致较大的偏差。 在^[12]中,作者提出了一种学习策略,使用从已建立或探测的光路中测得的数据来增强训练 数据集。但是,对于网络的所有链路都采用单一模型以实现整体最佳性能会损害实际模型在 每个特定链路上的准确性。此外,部署模型要求基于实际测量为特定的信道损伤重新训练 ML 模型,但提取目标损伤的真实值在实际系统内非常困难。另外,链路参数的不确定性将 使真实场景中的测量不那么准确,这可能会进一步使再训练后的模型性能恶化。综上所述, 如下图所示,目前较多的机器学习为基础的建模模型都受到模型不准确与输入参数不准确 的困扰,从而无法在实际场景中部署使用。



图 3-1 基于神经网络的建模算法的局限性分析

3.2 针对链路的定制化神经网络训练机制

针对光网络性能估计场景,本部分提出了一个三阶段的训练框架来为每个链接构建定制化的模型,如下图3-2所示,同时以自学习的方式进一步提高建模准确性。此外,本节展示了一种主动采集数据的方法来采集线性或非线性减损的实际值。

在这项工作中提出的模型定制的概念旨在通过避免模型在不同链路上的性能的折衷来 最大化模型在每个特定链路的准确性。在我们的框架中,统一的 ML 算法(例如具有固定结 构的神经网络)可以用于所有链路,并且针对每个链接分别训练 ML 模型参数集。在这种情 况下,模型定制仅需要在不同链路使用时更换模型参数,不会导致控制器复杂度的显着增 加。在提出的定制化框架中,首先通过模拟生成的大型数据集训练初始模型。接下来,使用 来自目标链路配置的模拟中的小数据集对模型进行重新训练。最后,将所提出的主动获取 方法应用于使用探针光路来获取实际值,以便进一步重新训练模型。在本节中,我们将细致 描述三阶段训练框架和内嵌的主动获取方法,并以光纤非线性建模为例来说明该框架的有 效性。

第15页共41页





图 3-2 针对链路的定制化性能估计模型训练机制^[63]

如下图所示,本节提出的模型定制化训练框架分为三个阶段。

第一阶段:模型初始化 (model initialization)。首先,大型数据集被用于训练模型,该 数据集的样本由异构链路和通道配置组成。此阶段将为以下定制化训练过程提供一个初始 化的模型。由于所有链接的初始模型都相同,因此此阶段只需执行一次,所获得的模型可以 为所有的模型提供粗略的建模结果。然而,该模型在某些链接中的估计结果,尤其是对于那 些未包含在训练数据集中的链路,可能会有较大的偏差。如果链接参数存在不确定性,则初 始模型的建模效果将进一步降级。



图 3-3 第一阶段模型初始化训练框图

第二阶段:离线定制 (offline customization)。在此阶段,规模更小的来自仿真的数据集 将被用于对初始模型进行重新训练。其中,所有训练数据样本的链路配置与目标链路相同, 仅考虑不同的信道配置。在此过程中,初始化模型会针对不同链路进行进一步训练,从而显 著提高预测精度。由于该模型是根据预先训练的模型进行再训练的,因此该阶段训练时间 会很短。



图 3-4 第二阶段模型离线定制化训练框图



第三阶段:在线定制 (online customization)。为了进一步定制化模型,第三阶段在链路建立开始时采用主动获取方法来获取目标减损的真实值,这些来自真实场景的数据将用于进一步重新训练前一阶段获得的定制模型。此阶段可有效减少链路参数不确定性的影响。链接参数不确定性可以分为两种类型:系统偏差和随机波动。系统偏差是系统中参数的固定的偏移差异,随机波动来自于系统的随机的浮动偏差。通过进行更多测量,系统中的随机波动可以被消除,而系统偏差会体现在获得的真实值的固定偏移中。在此阶段的再训练过程中,主动获取是此阶段的关键,将在下面部分详细介绍。



图 3-5 第三阶段模型在线定制化训练框图

3.3 在线定制阶段的主动获取机制

主动获取机制,即在链路建立之前主动更改探测通道的某些配置,以便获得某些损伤 的真实值。此方法可以应用于各种方案。例如,可以分别通过改变探测信号的发射功率和带 宽来测量实际的非线性噪声和滤波效应。由于对于噪声建模,非线性噪声建模是非常重要 的一个方面,因此我们此处以非线性信噪比的建模为例,展示主动获取非线性噪声的方法。

在长距离传输中,非线性(NLI)噪声与放大器自发辐射(ASE)噪声和背对背(B2B) 收发机噪声混合在一起。总噪声信号比(NSR)可以计算为:

$$NSR_{total} = NSR_{ASE} + NSR_{NLI} + NSR_{B2B}$$
(3-1)

假设在制造过程中已对每个收发机测量了 B2B 噪声,则根据高斯噪声(GN)模型,可以计 算出非线性噪声和 ASE 噪声的总功率。通过:

$$P_{\text{total}} = P_{NLI} + P_{ASE} = P_{SPM} + P_{XPM} + P_{ASE} = \eta_1 P_{CUT}^3 + \eta_2 P_{INT1} P_{INT2} P_{CUT} + P_{ASE}$$
(3-2)

其中 η_1 和 η_2 是与链路配置有关的衡量非线性大小的参数。一系列具有不同输入功率 (P_{CUT})的信号会在探测通道中多次发射,以减少当其他已建立通道的发射功率保持不变时 的随机波动的影响。利用第 n 个干扰信道 (P_{INTn})和被测信道 (P_{CUT})的发射功率,可以 通过拟合 P_{total} 和 P_{CUT} 的曲线来获得真实的 P_{NLI} 。最终,第三阶段定制训练后的模型可以 估计出更为精确的特定链路的非线性噪声 SNR。



3.4 模型定制化框架的仿真验证

为了验证本章提出的模型定制化训练框架的效果,本节进行了一系列的仿真来验证其 性能。结合上节所详细描述的非线性噪声主动获取机制,本节利用非线性噪声的建模定制 化训练为例子,对三阶段的定制化训练模型的方案进行验证。本节仿真样本的配置如下表 所示,仿真架构如图所示。



图 3-6 仿真系统结构

本节仿真使用固定速率 (fixed rate) 系统,其符号速率为 35Gbaud,信道间隔为 50GHz。符号长度为 2¹⁶。在发送机 (Transmitter, Tx)一侧,信号滚降系数为 0.02 的升余弦 (Root raised cosine, RRC) 脉冲整形。对于光纤链路,采用掺铒光纤放大器 (EDFA) 对衰减后的 信号进行放大,噪声系数为 5dB。在传输过程中,光纤非线性是通过分步傅里叶方法模拟,分步步长为 20 米。接收机 (Rx) 过滤出中心信道,以进行后续信号处理,包括色散补偿 (Chromatic dispersion compensation, CDC),匹配滤波,下采样和相位旋转。由于本仿真中忽略了激光相位噪声,因此没有使用相位恢复算法,仅消除了由光纤非线性引起的整体相位 旋转。最后,非线性 SNR 被计算获得。

配置	描述
span 个数	5~30
span 种类	SSMF, ELEAF, PSCF, TWC
span 长度	80km
WDM 通道个数	3 ~ 17
调制格式	QPSK/16QAM
发射功率	-3 ~ 3dBm
波特率/通道间隔	35Gbaud/50GHz

表 3-1 仿真数据配置表

我们选择三条特定链路作为示例来评估该定制化训练框架的效果。第一条和第二条链路分别由六个和十二个标准单模光纤(SSMF)组成。第三条链路有11个跨段,每个跨段由表3-1中的三种类型的光纤随机生成。对于上文中所使用的光纤,其名称与参数如下表3-2所示。



衰减 (dB/km)	色散系数 (ps/nm/km)	非线性系数 (1/w/km)
0.2	16.7	1.3
0.21	4.3	1.47
0.18	20.1	0.9
0.21	2.8	2
	衰减 (dB/km) 0.2 0.21 0.18 0.21	衰減 (dB/km)色散系数 (ps/nm/km)0.216.70.214.30.1820.10.212.8

表 3-2 各类光纤参数表

对第一阶段的初始化训练,我们在前文描述的仿真条件中随机生成了 500 个样本,这些 样本的配置由表3-1中随机选择,以构建训练数据集。其中,随机选择的概率分布遵循均匀 分布。在第二阶段的离线定制化过程中,对于每个不同的链路,我们在此链路配置条件下随 机生成 100 个通道配置以构建离线定制化训练的训练集。在第三阶段的在线定制化过程中, 使用主动采集机制,中心通道的发射功率被不断调整从-5dBm 至 5dBm,以通过前文介绍的 拟合方法获得链路非线性 SNR 的真实值。由于真实场景中,系统功率存在不准确性,此处 假设该功率误差分布遵循正态分布,其中误差均值(即系统误差)为0.5dB,方差(即随机误 差)为0.3dB。为了消除随机误差,每个输入功率下获得的 SNR 被测量十次来抑制随机波 动对系统的影响。为构建测试数据,对于每条链路,将随机生成 100 份在该链路下具有不同 通道配置和功率不确定性的样本以进行测试。

对于机器学习模型,本节构造了一个双隐层的神经网络。其中,Sigmoid 函数和 Linear 函数分别用作第一层和第二层神经元的激活函数。训练过程中,优化函数为 Rmsprop,评估 训练效果的指标为平均根绝对误差 (Mean absolute error, MAE)。对于每个训练阶段,将使 用 20%的样本进行验证 (validation)。最终,我们将定制化训练的模型的性能与^[11] 中提出 的普通训练方法进行比较 (即初始模型),输入特征见表3–3。

表 3-3 输入特征表

序号	特征名
1	GN model 计算获得非线性 SNR
2	跨段数
3	最大跨段长度
4	平均跨段长度
5	发射功率
6	链路总长度
7	链路总色散
8	链路平均非线性系数
9	链路平均衰减
10	WDM 通道数

我们使用 Keras 对神经网络进行定义与训练,在多次训练中,第一阶段的模型初始化需要 6000 个 epoch 以上才会收敛,然而训练完成后,在第二阶段模型离线定制阶段,只需要 约 1000 个 epoch 模型会修正完成。在第三阶段模型在线定制阶段,由于数据量较小,为了 防止过拟合,只进行了少量的训练,约 10 个 epoch 则可以获得最终的修正后定制化完成的 模型。



图3-7展示了链路1、2和3的初始模型和定制模型的误差分布直方图。结果表明,初始 模型在每个链接上的表现不相同,且在某些链路配置与误差场景下具有较大误差。经过定 制化训练框架的重新训练后,在测试集上,模型最大误差从4.3dB降至2dB,这说明三阶段 的定制化模型训练框架有效地减小了功率偏差和波动对建模模型的影响。由于第一阶段只 需要在建立初始模型时进行,在定制化训练过程中,只需要进行第二和第三阶段的训练,由 于这两个阶段的迭代次数较少,因此也一定程度上节省了模型定制的时间。



图 3-7 定制化训练前后模型误差直方图对比

为了描述定制化训练过程的细节,图3-8显示了链路3在主动获取过程中拟合获得真实 非线性噪声值的过程。在主动获取过程中,对每一个功率值都进行5次测量来防止随机波 动对拟合过程的影响,最终获得非线性噪声的真实值。可以看出,虽然每一次功率不一致使 得测量点出现偏差,在多次测量后,随机波动可以被基本消除,而系统偏差会被保留,在拟 合中,系统会拟合含有偏差的非线性效应关系,最终获得非线性噪声的量。





图 3-8 拟合过程

图3-9显示了在定制化训练前后平均绝对误差和均方差的比较,可以看出,当进行定制 化训练后,模型误差显著降低。图3-10显示,对于每个链路,95%样本的误差边界降低了 2dB。在模型定制化训练后,三个链路的大约90%误差均小于1dB。



图 3-9 定制化训练前后均方差对比



图 3-10 定制化前后误差累积直方图对比

可以看出,在进行模型针对不同链路定制化训练后,模型在不同链路配置上的泛化性 以及对于不同误差分布的鲁棒性都有了显著的提高,使得真实场景下建模模型的结果可以 更为准确。

3.5 本章小结

本章对目前已有的基于机器学习算法的传输性能估计算法进行了分析,由于实际数据 与仿真数据的不一致,导致目前的基于机器学习的算法难以落地。因此,本章提出了解决 控制层输入参数不准确,在不同链路上进行定制化模型训练的方法。该方法分为三个阶段, 并且通过主动获取机制在第三阶段获得少量真实链路的性能数据,从而进一步对模型进行 微调。为了验证提出机制的性能,本章进行了仿真验证,并在三条链路配置上对功率参数不 准确的情况进行了定制化的模型训练,均取得了较好的效果。



第四章 非线性噪声监测在新架构下的算法设计

4.1 非线性噪声监测算法在新架构下的挑战与机遇

利用神经网络结合信号幅度噪声相关性与相位噪声相关性进行非线性监测的算法在现 有的 fix-grid 场景下有了较好的验证。然而,对于下一代的系统,整体通信系统将呈现更新 的架构,如下图所示:



图 4-1 多载波系统(subcarrier multiplexing)架构

在该架构下进行非线性噪声监测,相比于曾经的系统,将存在更多的机遇与挑战。首先, 对于多载波 subcarrier multiplexing (SCM)系统,相比于单载波系统,在一个通道内,会有 多个载波信号,它们的信号波特率相对较低,因此色散效应较小。当色散效应较小的时候, 符号间的相关影响减弱,因此在计算 ANC、PNC 时,符号间的相关性较弱,ANC、PNC 值 的随机波动较大,从而导致非线性效应估计不准确。其次,由于多载波系统中信号的波特率 较低,在固定时间内的监测符号变少,可以用于计算相关性的符号长度变短,从而导致计算 结果相关性降低,随机波动增大。并且,实际系统会受到其他的损伤的影响,例如 ASE 噪 声,ASE 等随机噪声会进一步掩盖非线性噪声导致的符号间的噪声相关性,并且更多地增 大相关性计算过程中的抖动,导致估计不准确。

虽然神经网络可以在单载波系统下对非线性噪声进行较好的估计,然而,在下一代系统内,目前的监测方法的性能会受到一定的影响。因此,为了实时获得更准确的非线性噪声监测结果,基于神经网络的监测算法需要进一步提升性能。同时,下一代新架构的系统也为监测提供了更多的机遇。首先,在多载波系统内,单个通道内会有多个子载波,因此,多个子载波的传输性能可以在一个收发机内进行监测,多源信息的融合利用可以提升已有算法的性能,进一步缩短监测时间,提升监测精度。

4.2 多载波系统下非线性噪声监测算法

多载波系统下非线性噪声的监测可以利用更多的载波间互相关信息以及数据融合的技术,进而提升监测算法的性能。在单载波系统中,系统仅能对单个通道内的单载波信号计算 其自身的各偏振内或偏振间的噪声相关性。按照同样的方式,在多载波系统内,在单个通道 内,各个载波的噪声自相关可以被计算,各个子载波的噪声自相关函数可以按照原有方案



进行计算。在获得各个子载波信号的自相关特征后,子载波之间的互相关特征也可以通过 计算不同子载波之间噪声的互相关函数获得,同时,各个子载波的噪声相关性结果可以进 行数据融合,最终得到多载波系统下更准确、监测频率更高的非线性噪声监测算法。

在多载波系统下,基于神经网络的非线性噪声监测算法的特征^[64]如下:

• 子载波内自相关特征 Inter subcarrier correlation features (Inter-SCF):

该特征内包括了所有某目标子载波的自相关特征。这与单载波系统内提取的监测特征 一致,即在监测过程中,使用目标子载波的幅度、相位噪声在偏振内及偏振间自相关特征 来进行非线性噪声监测。该组特征包含如下: $R_{xx}^{aa}(n)$ 、 $R_{yy}^{aa}(n)$ 、 $P_{yy}^{aa}(n)$ 、 $R_{xy}^{aa}(0)$ 以及 $P_{xy}^{aa}(0)$ 。其中, n 为该相关函数输出的第 n 个值, a 代表第 a 个子载波。对于以上特征的计 算方式,在第二章中已经详细阐述。

• 子载波间互相关特征 Intra subcarrier correlation features (Inter-SCF):

该组特征代表了子载波之间噪声的相关关系。其中, *a* 子载波与 *b* 子载波之间的特征为 $R_{xx}^{ab}(n), R_{yy}^{ab}(n), P_{xx}^{ab}(n)$ 和 $P_{yy}^{ab}(n)$ 。通过求解子载波之间的互相关特征,可以衡量子载波之间的 互相影响,从而辅助非线性噪声的监测。该组特征求解方法如下图4-2所示:



图 4-2 子载波间互相关特征计算方式

• 多载波平均相关特征 average intra-subcarrier-correlation features (AISCF):

AISCF 是一个 WDM 信道中所有子载波的 Intra-SCF 特征平均值。由于在某些应用中噪 声监测周期应该较短,因此系统中的噪声(例如 ASE 噪声)将导致相关性计算出现波动,从 而可能影响监视性能。在 SCM 系统中,可以使用数据融合方法来完善来自所有子载波的测 量。由于一个 WDM 信道中的子载波往往具有相似的非线性噪声量,因此在这里我们使用平 均值函数来减少单个子载波内相关性计算中的波动。这种方法可以扩展到跨多个 WDM 通道 或 super channel 场景用于设计联合监测算法。该组特征在多载波系统内的求解如下图4-3所 示:





最终,所有的监测特征会与其余辅助特征一同送入神经网络用于估计非线性噪声,如下图4-4所示。为了验证方案的有效,我们进行了一系列仿真,以分别在符号数量充足和符号数量有限的情况下验证新特征用于非线性监测的有效性,下面将对仿真验证过程进行详细讨论。

第23页共41页





图 4-4 多载波系统下非线性监测神经网络结构

4.3 多载波系统下非线性噪声监测算法性能验证

在多载波系统下,一系列仿真被用于验证该监测算法的性能,其仿真条件如下:



图 4-5 多载波系统下非线性监测性能验证仿真框架

如4-5所示, 仿真是在符号速率为 35Gbaud, 信道间隔为 50GHz 的固定速率系统中进行 的。对于 SCM 系统,此处设置子载波的数量为 4 或 8。在发射机(Tx)端,我们应用滚降 系数为 0.02 的根升余弦(RRC)脉冲整形。其中,总传输符号长度设置为 2¹⁷,对于 4 子载 波系统和 8 子载波系统,符号长度分别为 2¹⁵和 2¹⁴。对于每条链路,均采用掺铒光纤放大 器(EDFA)放大信号,且噪声系数(NF)为 5dB。在接收器(Rx)侧,中心通道被滤出以 进行后续处理,经过色散补偿(CDC)和匹配滤波器,然后进行下采样和相位旋转。最终, 将获得的收端符号用于计算 SNR, Intra-SCF, Inter-SCF 和 AISCF。

在以上条件下,在不同的子载波系统内分别生成700个样本,其中,每个样本的配置随 机生成,生成配置参考表4-1,如下所示。

配置	描述
span 个数	3~30
span 种类	SSMF, ELEAF, PSCF, TWC
span 长度	20:10:90 km
WDM 通道个数	1 ~ 15
调制格式	QPSK/16QAM
发射功率	-4 ~ 4dBm
波特率/通道间隔	35Gbaud/50GHz

表 4-1 仿	复数据配置表
---------	--------

由于随机生成样本配置, 配置选择遵循均匀分布。为了使仿真接近实际情况, 基于4-1中



的相同配置,每个样本会随机将链路上的某些信道随机设置为空闲,并且所有占用信道的 信号功率增加遵循正态分布的随机波动 *ε*,其中 *ε* ~ *N*(0.5, 0.3)*d B*。

4.4 理想多载波系统下非线性噪声监测算法性能验证

本部分首先研究了相关性计算结果。为了减少 ASE 噪声引起的随机波动,本次仿真数据集忽略了 EDFA 中的所有 ASE 噪声。同时,仿真中,所有接收到的符号都用于计算相关值,以避免由于接收到的符号长度有限而引起的不确定性和波动。通过观察相关值,相关性函数输出拖尾的长度如表4-2所示。

	Intra-SCF		Inter-SCF	
系统	幅度噪声	相位噪声	幅度噪声	相位噪声
4-子载波系统	5	30	1	30
8-子载波系统	3	20	1	20

表 4-2 噪声相关性特征计算拖尾参数

为了更好地表示每个子载波之间的相关性关系,此处以 8-子载波系统中幅度和相位噪声的互相关值为例进行了研究。其中,仿真中求解的互相关输出拖尾长度按照上文中表4-2设置。如图4-6所示,由于用于自相关的计算过程中,对相关性计算结果的求和方法与计算互相关的输出求和方法不同,因此代表自相关的区域被忽略并且表示成黑色。其他互相关值的大小在图中标出,当相关值较高,则颜色较深,当相关值较低,则颜色较浅。



图 4-6 8-子载波系统噪声互相关计算结果示意图

图4-6的结果表明,如果两个子载波彼此靠近,则互相关值较高。当两个子载波之间的间隔变大时,互相关结果与相位噪声相关性相比,幅度噪声的互相关值降低得更快。如图4-6a所示,在仿真环境中的8子载波系统内,当两个子载波之间的间隔大于两个子载波时,它们之间的幅度噪声相关性非常小。然而,如图4-6b所示,即使两个子载波相互距离较远,相位噪声的相关性仍然保持在较高水平,随着子载波的距离变远,噪声相关性的减弱较慢。因此,我们可以推断,每个子载波之间的相关性可以表现出每个子载波之间非线性干扰的大小。当两个子载波彼此靠近时,它们之间的非线性交叉相位调制噪声较大,当两个子载波彼此远离,它们之间的非线性交叉相位调制噪声较大,当两个子载波彼



相关,具有为非线性噪声估计提供更多信息的潜力。

为了验证基于噪声相关性特征结合神经网络的非线性噪声监测算法的准确性,此处将 以 Intra-SCF 和 Inter-SCF 作为特征输入神经网络验证监测准确性。其中,此处使用了两种不 同的特征输入方法,第一种仅使用 Intra-SCF 和通道配置特征(即总色散、通道数)进行监测, 该方法保持与原有监测算法一致。第二次在第一次使用的特征的基础上尝试添加 Inter-SCF 作为新监测特征。所有的仿真中,神经网络的结构保持不变,其结构在仿真设置中已经详细 说明。为了避免随机波动对结果产生影响,本次仿真中并未添加 ASE 噪声,并使用了足够 长的符号求得的互相关结果进行训练。在训练阶段,每一次训练结果的监测效果会略有波 动。如4-7所示,此处展示了两次仿真使用不同特征监测的结果。



a) 4-子载波系统非线性监测结果

b) 8-子载波系统非线性监测结果

图 4-7 无随机波动场景下非线性监测结果

如图4-7a所示,在4-子载波系统中,添加 Inter-SCF 特征后,累积误差函数(CDF)显示出约 0.25dB 的增益。此外,在图4-7a中,在8-子载波系统中,使用 Inter-SCF 可以提供约 0.35 dB 的增益。比较两图中的监测结果,我们可以推断,当子载波数量增加时,其噪声特征 与单载波系统差异逐渐增大。因此,若仅仅通过 Intra-SCF 进行监测,当子载波的数量增加时,监测性能逐渐变差。在图4-7a中,仿真环境为4-子载波系统,与传统的单载波系统相似。因此,使用 Intra-SCF 进行监测已经显示出较高的准确性,在添加 Inter-SCF 之后,改进空间较小,增益也相对较小。然而,在图4-7b中,当系统中子载波数量增加,仅使用 Intra-SCF 作为特征进行非线性噪声没有表现出较好的性能。在这种情况下,添加 Inter-SCF 之后,监测结果的精度显示出更多的提高。通过本部分的研究,我们可以推断出,Inter-SCF 可以在多载波系统中提供新的与非线性噪声相关的特征,进而提高监测精度。然而,此处的仿真验证较为理想,在实际系统中,ASE 噪声是无法去除的,并且监测符号长度可能会受到限制,这使得该监测算法在实际场景中达到在相对理想的环境中相同的性能具有了一定挑战。在下一节中,将进行更多仿真来探究将该监测方法部署到实际场景的合适的训练方案。

4.5 实际多载波系统下非线性噪声监测算法性能验证

如上一节所述,当将 Inter-SCF 添加为监测神经网络新的输入特征时,可以提高非线性 噪声监测精度。但是,在实际系统中,由于监测算法需要在合理的时间间隔内做出反馈,所 以用于监测的接收符号的长度是有限的。此外,系统中的 ASE 噪声会使得噪声相关性计算 中出现随机波动,这也可能会影响监测的精度。因此,更合适的神经网络训练方法需要被探



究以增强其鲁棒性与泛化性。在这一节中,8-子载波系统的数据将用作探究示例。输入神经 网络的特征包括 Intra-SCF, Inter-SCF 和 AISCF。为了使仿真场景更接近真实场景,用于监 测的接收符号的长度仅为 2048 个。用于求和的相关性函数的输出拖尾的长度如表4-3所示。 在此仿真中,由于监测的接收符号的长度比上一节的仿真中使用的符号长度大大缩短,因 此选择在 Inter-SCF 使用的相关性函数求和的拖尾长度更短,可以在一定程度上减小由有限 的符号长度和 ASE 噪声引起的随机波动的影响。

表 4-3 噪声相关性特征计算拖尾参数

Intra-SCF		Inter-SCF		
幅度噪声	相位噪声	幅度噪声	相位噪声	
5	20	1	15	

首先,若使用从没有 ASE 噪声的符号中提取的特征来训练神经网络,这种神经网络可能无法实现在具有 ASE 噪声的系统中准确地监测非线性噪声。因此,此处选择通过从具有 ASE 噪声的符号中获得的特征来训练神经网络。然而,按照某特定量噪声训练出的神经网络在不同的噪声场景下的泛化性需要被探究。此处,针对不同的噪声量,生成了多个数据集,对于每个数据集,链路配置相同,EDFA 的噪声系数不同,分别为 4dB,5dB,6dB,7dB 和 8dB。每种数据集上,原有的训练方案的监测精度和使用具有其本身相同量噪声的数据进行训练的神经网络的监测精度如图4-8所示。



图 4-8 不同噪声分布数据训练神经网络的监测结果

如图4-8所示,当使用从无 ASE 噪声的符号获得的特征进行训练时,测试集特征受到 ASE 噪声的影响,则监测精度会受到较大影响。此外,当 ASE 噪声增加时,监测精度会降 低。这是因为,当系统中存在更多 ASE 噪声时,相关值在相关性函数输出结果的拖尾中中 表现出更多的波动,从而加剧了输入特征的不确定性,导致神经网络无法准确预测非线性 噪声量。在这种情况下,向训练数据集添加合适的噪声是增强神经网络鲁棒性的好方法。如 图4-8所示,利用从具有 ASE 噪声的符号获得的特征进行训练,可以大大提高监测精度。但 是,与此同时,如果训练集中的噪声量增加,神经网络的性能也会将受到一定的影响。因 此,在将该监测算法部署到实际系统中时,最好使用具有合适大小的 ASE 噪声的数据集训 练。由于在实际系统中,每条链接和每个 EDFA 产生的噪声量均不同。因此,为了将基于神



经网络的监测算法部署到实际系统,神经网络的泛化性和鲁棒性非常重要。

为了探究了当训练数据集与测试数据集的噪声量不一致的场景中神经网络的效果,此 处将由具有固定噪声系数的数据集训练的神经网络用于估计具有不同噪声系数的数据样本, 监测结果如图4-9所示。



图 4-9 不同噪声分布数据训练与监测结果

在图4-9中,当使用某个特定噪声系数的数据集训练时,即使测试集数据的噪声系数不同,测试数据集的监测精度都较高,与使用无 ASE 噪声的数据集训练神经网络的情况相比, 在训练阶段引入 ASE 噪声构建数据集可以大大提高检测算法的鲁棒性。在实际使用中,即 使每条链路的噪声含量都是未知的,向训练数据集中添加适量的 ASE 噪声也可以增强监测 神经网络的泛化能力。



图 4-10 不同训练方案的监测误差分布直方图

为了更明确地对比出每种训练方案的精度差异,在图4-10中,展示出了每种训练方案的误差直方图。在这些情况下,系统噪声系数为5dB。当训练数据和测试数据均理想时(没有 ASE 噪声),训练性能最佳。如果仅测试数据具有 ASE 噪声,则理想条件下训练的神经 网络精度会受到很大影响。将 ASE 噪声添加到训练数据集中后,与理想情况相比,总体性能受到了轻微影响,但与未添加 ASE 噪声至训练集的情况相比,其准确性显着提高。



4.6 多载波系统下非线性噪声监测算法性能评估

在分析了非线性监测神经网络的训练方案之后,本节进行了更多的仿真以评估其监测 性能。在 4-子载波系统和 8-子载波系统中,此处令每个样本的噪声系数为 5dB。为了分析 监测符号长度造成的影响,本节中使用了不同长度的符号进行监测以观察效果。在本节中, 探究的接收符号的长度为 1024、2048、4096、8192。结合上节训练方案的探究结果,非线性 监测神经网络使用具有 ASE 噪声的数据集进行训练。对于本部分中的所有仿真样本,相关 性计算求和的拖尾长度设置全部一致。其中,设置详细信息显示在表4-4中。

	Intra-SCF		Inter-SCF	
系统	幅度噪声	相位噪声	幅度噪声	相位噪声
4-子载波系统	5	30	1	30
8-子载波系统	3	20	1	20

在训练过程中,所有的神经网络都经过训练至收敛,用 2048 个符号长度和 4096 个符号 长度的数据集训练的非线性噪声监测性能如图4-11所示。



图 4-11 不同场景的监测误差分布直方图

结果表明, Inter-SCF 和 AISCF 可以在具有 ASE 噪声和有限接收符号的情况下提高系统的非线性噪声监测精度。此外,与4-子载波系统相比,这些新特征在8-子载波系统中显示出更好的性能,提供了更多的增益。这是因为,之前已有的基于单载波的监测方法(即仅使用 Intra-SCF 作为输入特征)的精度在8-子载波系统中劣化,而在该场景下, Inter-SCF 可以提供更多特征,而 AISCF 可以抑制更多的随机性波动,从而带来更大的增益。对于所有



仿真场景,表4-5中汇总了覆盖95%样本的最大监控偏差结果。

至法	收测硅尔	监测符号长度			
<i>示</i> 纪	血侧村怔	1024	2048	4096	8192
4-子载波系统	Intra-SCF	1.6dB	1.6dB	1.55dB	1.6dB
	Intra-SCF+Inter-SCF	1.5dB	1.2dB	1.45dB	1.4dB
	Intra-SCF+AISCF	1.2dB	1.1dB	1.1dB	1.4dB
	Inter-/Intra-SCF+AISCF	1.1dB	1dB	1dB	1.1dB
8-子载波系统	Intra-SCF	2.1dB	1.95dB	2dB	1.3dB
	Intra-SCF+Inter-SCF	1.7dB	1.75dB	1.4dB	0.9dB
	Intra-SCF+AISCF	1.2dB	1.3dB	1.3dB	1dB
	Inter-/Intra-SCF+AISCF	1dB	1.25dB	1.1dB	0.8dB

表 4-5 噪声相关性特征计算求和拖尾长度

可以发现,在4-子载波系统和8-子载波系统中,加入新的监测特征后,监测结果的最大偏差分别减小了约0.5dB和0.9dB,获得了较大增益。因此,在多载波系统内,本章所提出的方案可以提升非线性监测的精度。

4.7 本章小结

本章对非线性噪声监测的应用进行了总结,并对已有非线性监测算法进行了介绍。由于已有的算法多针对单载波系统进行设计,当迁移至多载波系统,受到符号波特率和色散的影响,其性能会受到一定影响。本章在多载波系统框架下,考虑到同一通道内的多个子载波,利用数据融合,设计了新的用于非线性监测的特征,在符号数减少并存在 ASE 噪声的场景下,对训练机制进行了探究,最后设计出了具有较高准确度与鲁棒性的非线性噪声监测算法。



第五章 光网络建模监测技术总结与展望

5.1 光网络性能估计技术总结

为了建立低余量的可靠智能光网络,传统的理论算法的精确度和效率在下一代灵活光 网络中都需要进行提升,其中,机器学习提供了一种有效的方法。通过回顾使用机器学习技 术进行建模和监视的已有工作,我们发现机器学习在可扩展性,效率和鲁棒性方面优于许 多传统方法。

本文中,首先对光网络的建模监测技术进行了回顾,对基于理论模型、机器学习模型进 行光传输性能建模与监测的算法进行了整理与归纳。其后,针对网络中重要的损伤之一,非 线性损伤,回顾了已有的非线性损伤建模与监测的算法,并使用一系列数据对已有非线性 建模、监测算法进行了性能评估,对其计算精度与计算速度进行了分析比较,从而选择在不 同的需求场景使用不同的建模、监测技术。此后,基于机器学习模型,本文在光网络建模场 景下,提出了新的三阶段模型训练方案,以定制化地为不同链路提供定制化训练的模型,并 利用仿真数据在三个不同链路场景下进行了验证。另外,本文还提出了下一代系统新架构 下,非线性监测算法的局限,并在多载波系统架构下提出了新的监测特征以提高监测精度, 并对其训练方式、鲁棒性与泛化性都进行了讨论。

5.2 基于机器学习的光网络性能估计技术的局限与发展

在本文研究中,机器学习在光网络建模与监测中都有较好的性能,从而辅助构建高效, 可靠和自治的光网络。同时,基于机器学习的技术在实际部署中也存在一些挑战。下面将进 行阐述。

1. 高效的适应机制。对于前文提到的大多数工作,在部署之前,都会使用来自仿真或实验室实验的数据对基于 ML 的方法进行离线训练。由于基于 ML 的方法的权重和参数在训练后是固定的,因此在实际系统中使用这些方法时,计算时间很短。对于需要快速响应的场景,对于这种先训练然后部署的方案采用基于 ML 的方法非常有效。然而,来自真实场景的数据可能与仿真数据不同。因此,部署后还需要一个合理的适应机制来让模型迁移至实际的场景。在 EON 中,可使用在线学习方法(例如 re-training)来应对随时间变化的网络场景^[65]。即使在许多工作中都提出了从实用的系统中收集数据的进行再训练方案,但仍需考虑再训练方案的合理性。由于 EON 的变化可能无法预测,因此从真实场景收集的数据可能不会遵循与原始训练数据相同的分布。在这种情况下,收集的数据不能与预训练数据混合来直接重新训练模型。此外,如果仅使用从实际系统中收集的数据进行训练,则还存在其他问题。一方面,如果为了更好的适应性而频繁地进行再训练,则在短时间内收集的数据集相对较小,可能会发生过度拟合。另一方面,如果重新训练不频繁,则当网络状态快速变化时,估计量可能会有较大的偏差。因此,应仔细考虑如何部署有效的适应机制。

2. 机器学习模型结构的合理设计。为了达到更高的精度,目前部分技术方案引入了具有 更复杂结构的 ML 算法,例如图卷积网络、强化学习和生成对抗网络(GAN)。然而,因为 它们需要较大的内存,这些具有复杂结构的 ML 方法可能难以在光网络系统中部署。因此, 对于 EON 来说,需要效率较高的 ML 方法,并且需要适当调整 ML 的结构以适合部署在不 同收发机与控制器当中。

第31页共41页



3. 基于机器学习的方法的可解释性。前文讨论的许多工作都基于神经网络,这是可用 于分类和回归的灵活结构。然而,由于为数据驱动,ML算法通常可解释性较差^[66]。因此, 难以保证机器学习方法的算法的可靠性,这是将机器学习技术应用于实际系统的一大障碍。 未来需要更多的工作来使 ML 方法可解释性增强,以科学地确保这些方法可以按预期执行 其功能。

4. 机器学习算法的部署方案。最近已经提出了许多使用 ML 进行建模和监测的方法,在 哪里部署这些 ML 算法是一个值得讨论的问题。一些 ML 模型可以嵌入到接收器中以构建 低延迟的建模监测系统,而另一些 ML 引擎则需要部署在控制平面中才能从整个光网络中 获取足够的信息^[67]。因此,在部署每一个基于机器学习的算法时,需要设计其部署方案,考 虑是集中式部署还是分布式部署。



全文总结

本文围绕光通信网络的建模、监测及优化的主题,对已有光网络架构下的建模和监测 算法的需求与问题进行了调研,同时总结了目前已有算法的优缺点,构思了未来光网络建 模与监测算法发展的主要方向。由于数字信号处理技术已成为瓶颈,使每个单独链路的容 量接近香农极限,因此弹性光网络和低余量光网络在更高容量的光网络设计中显示出更多 潜力。下一代系统中,更加灵活的网络结构使光网络控制器可以根据每种服务的需求分配 频谱资源。而且,更高级的建模和监测功能可以有效地减少设计余量和系统余量。为了实 现这一点,已经有许多研究在设计和部署建模监视技术,以估计传输整体质量和特定损伤。 然而,许多传统的分析方法无法在准确性和复杂性之间达到良好的平衡。例如,模拟传输过 程并生成符号的估计方法可以达到很高的精度,但不能在短时间内提供结果。相反,无需模 拟即可计算传输性能的分析方法可能基于一些理想的假设,而这些假设在实际情况下并不 满足。因此,为了有效准确地估计传输质量,需要提出更多的方法,而在大数据网络下,机 器学习为解决该问题提供了一种可行的路径。

第一章首先介绍了现有的传输性能估计算法,尤其是基于机器学习的方法,并详细阐述并比较了这些方法的优缺点。其中,介绍了基于理论模型的性能建模方法,但大多数方法都没有较高的准确度或复杂度较高。基于从数据中学习这一思想出发,更多基于人工智能的解决方案被使用。许多模型都使用来自仿真或实验室实验的数据进行离线训练,然后应用于实际系统。对于传输性能监测,该功能要求监测算法具有监控实时网络变化并在网络崩溃之前发出警报的能力。因此,某些监测算法被设计为估计传输质量或特定的损害,而某些监测算法则用于故障管理。即使具有不同的监测任务,也都需要这些监测算法能够跟踪网络的实时变化即使是信号中的微小波动,而这对于监测算法也是一个具有极高挑战性的要求。我们使用表格总结了基于机器学习的建模和监视方法,总结了其监测或建模目标以及所使用的机器学习算法和输入特征。

第二章介绍了非线性损伤的原理以及估计的建模和监测算法。对于非线性噪声建模算法,分步傅立叶方法可以显示出较高的精度,但在更多情况下,使用者更常利用速度更快的高斯噪声模型。我们介绍了这两种算法,并使用仿真数据来比较它们之间的性能。同时,对于非线性噪声监测,本章还介绍了基于神经网络的监测方法,该方法将符号间幅度和相位噪声的相关性作为监测特征。此处,仿真数据用于训练和验证神经网络。由于非线性噪声被视为优化链路或信号配置设计并避免传输过程中出现故障的最重要的监测对象之一,因此改进下一代光网络非线性噪声的监视和建模算法非常重要。同时,基于已有的基于机器学习的监视和建模方法,在后续章节中,我们对其训练方式、训练特征都进行了重新设计。仿真结果表明,这些基于机器学习的方法在改进后,在准确性方面表现出更好的性能。

即使在本文中提出了许多基于数据的方法,并对其进行改进获得了更好的效果。然而, 在部署到实际系统之前也有一些问题需要解决。在最后一部分中,我们讨论了在实际的光网 络中应用人工智能技术的挑战和机遇。这些方法的可解释性和泛化能力应进一步提高,以 确保建模和监测算法可以按预期工作。由于光链路一次传输成千上万个信号,因此即使是 很小的异常也可能导致整个网络的灾难性降级。因此,那些基于离线训练的方法需要提高 可靠性,并且与异构的网络结构兼容。



参考文献

- [1] BERTHOLD J, SALEH A A M, BLAIR L, et al. Optical Networking: Past, Present, and Future[J]. Journal of Lightwave Technology, 2008, 26(9): 1104-1118.
- [2] DONG Z, KHAN F N, SUI Q, et al. Optical Performance Monitoring: A Review of Current and Future Technologies[J]. Journal of Lightwave Technology, 2016, 34(2): 525-543.
- [3] POINTURIER Y. Design of Low-margin Optical Networks[C]//Optical Fiber Communication Conference. [S.l.: s.n.], 2016.
- [4] ROTTONDI C, BARLETTA L, GIUSTI A, et al. Machine-Learning Method for Quality of Transmission Prediction of Unestablished Lightpaths[J]. IEEE/OSA Journal of Optical Communications & Networking, 2018, 10(2): A286.
- [5] FANG W, LU M, LIU X, et al. Joint defragmentation of optical spectrum and IT resources in elastic optical datacenter interconnections[J]. IEEE/OSA Journal of Optical Communications & Networking, 2015, 7(4): 314-324.
- [6] DELEZOIDE C, CHRISTODOULOPOULOS K, KRETSIS A, et al. Marginless Operation of Optical Networks[J]. Journal of Lightwave Technology, 2019, 37(7): 1698-1705.
- [7] CHANNEGOWDA M, NEJABATI R, SIMEONIDOU D. Software-Defined Optical Networks Technology and Infrastructure: Enabling Software-Defined Optical Network Operations [Invited][J]. IEEE/OSA Journal of Optical Communications & Networking, 2013, 5(10): A274.
- [8] ELLINAS G, PANAYIOTOU T, P. C S. Performance Analysis of a Data-Driven Quality-of-Transmission Decision Approach on a Dynamic Multicast-Capable Metro Optical Network[J]. Journal of Optical Communications & Networking, 2017.
- [9] POLITI C, ANAGNOSTOPOULOS V, MATRAKIDIS C, et al. Physical Layer Impairment Aware Routing Algorithms Based on Analytically Calculated Q-Factor[C]//Optical Fiber Communication Conference. [S.l.: s.n.], 2006.
- [10] ELLINAS G, ANTONIADES N, PANAYIOTOU T, et al. Multicast Routing Algorithms Based on *Q*-Factor Physical-Layer Constraints in Metro Networks[J]. IEEE Photonics Technology Letters, 2009, 21(6): 365-367.
- [11] ZHUGE Q, ZENG X, LUN H, et al. Application of Machine Learning in Fiber Nonlinearity Modeling and Monitoring for Elastic Optical Networks[J]. Journal of Lightwave Technology, 2019, 37(13): 3055-3063.
- [12] ELLINAS G, ANTONIADES N, PANAYIOTOU T, et al. Multicast Routing Algorithms Based on *Q*-Factor Physical-Layer Constraints in Metro Networks[J]. IEEE Photonics Technology Letters, 2009, 21(6): 365-367.
- [13] ZHANG F, ZHUGE Q, PLANT D V. Fast analytical evaluation of fiber nonlinear noise variance in mesh optical networks[J]. IEEE/OSA Journal of Optical Communications & Networking, 2017, 9(4): C88.



- [14] PASTORELLI R, BOSCO G, PICIACCIA S, et al. Network planning strategies for nextgeneration flexible optical networks [invited][J]. IEEE/OSA Journal of Optical Communications & Networking, 2015, 7(3): 511-525.
- [15] HARDIN R H, TAPPERT F D. Applications of the Split-Step Fourier Method to the Numerical Solution of Nonlinear and Variable Coefficient Wave Equations[J]. Siam Review, 1973, 15(1): 423.
- [16] POGGIOLINI P. The GN Model of Non-Linear Propagation in Uncompensated Coherent Optical Systems[J]. Journal of Lightwave Technology, 2012, 30(24): 3857-3879.
- [17] MURTY M N, DEVI V S. Introduction to pattern recognition and machine learning[M]. [S.I.]: Co-Published with Indian Institute of Science (IISc), Bangalore, India, 2015.
- [18] MO W, HUANG Y, ZHANG S, et al. ANN-Based Transfer Learning for QoT Prediction in Real-Time Mixed Line-Rate Systems[C]//Optical Fiber Communication Conference. [S.1. : s.n.], 2018.
- [19] ZHU S, GUTTERMAN C L, MO W, et al. Machine Learning Based Prediction of Erbium-Doped Fiber WDM Line Amplifier Gain Spectra[C]//2018 European Conference on Optical Communication (ECOC). [S.l.: s.n.], 2018.
- [20] YOU Y, JIANG Z, JANZ C. Machine Learning-Based EDFA Gain Model[C]//European Conference on Optical Communication. [S.l. : s.n.], 2018.
- [21] MO W, ZHU S, YAO L, et al. EDFA Wavelength Dependent Gain Spectrum Measurement Using Weak Optical Probe Sampling[J]. IEEE Photonics Technology Letters, 2017, PP(99): 1-1.
- [22] TANIMURA T, HOSHIDA T, KATO T, et al. Data-analytics-based Optical Performance Monitoring Technique for Optical Transport Networks[C]//Optical Fiber Communication Conference. [S.l.: s.n.], 2018.
- [23] YAN S, KHAN K N, MAVROMATIS A, et al. Field trial of Machine-Learning-assisted and SDN-based Optical Network Planning with Network-Scale Monitoring Database[C]//Ecoc. [S.l.: s.n.], 2017.
- [24] RUI M M, PEDRO J. Machine learning models for estimating quality of transmission in DWDM networks[J]. IEEE/OSA Journal of Optical Communications & Networking, 2018, 10(10): 84-99.
- [25] WANG J, LUO S W. Exploiting Ensemble Method in Semi-Supervised Learning[C]// International Conference on Machine Learning & Cybernetics. [S.l.: s.n.], 2009.
- [26] WILCOX R. A Note on the Theil-Sen Regression Estimator When the Regressor Is Random and the Error Term Is Heteroscedastic[J]., 1998, 40(3): 261-268.
- [27] WONG S C, GATT A, STAMATESCU V, et al. Understanding data augmentation for classification: when to warp?[J]. CoRR, 2016, abs/1609.08764. arXiv: 1609.08764.
- [28] Van DYK D A, MENG X L. [The Art of Data Augmentation]: Rejoinder[J]. Journal of Computational & Graphical Statistics, 2001, 10(1): 98-111.



- [29] PANAYIOTOU T, SAVVA G, SHARIATI B, et al. Machine Learning for QoT Estimation of Unseen Optical Network States[C]//OFC. [S.l.: s.n.], 2019.
- [30] DE MIGUEL I, DURAN R J, JIMENEZ T, et al. Cognitive dynamic optical networks [invited][J]. IEEE/OSA Journal of Optical Communications & Networking, 2013, 5(10): 107-118.
- [31] JIMÉNEZ T, AGUADO J C, de MIGUEL I, et al. A Cognitive Quality of Transmission Estimator for Core Optical Networks[J]. J. Lightwave Technol., 2013, 31(6): 942-951.
- [32] SAMBO N, POINTURIER Y, CUGINI F, et al. Lightpath Establishment Assisted by Offline QoT Estimation in Transparent Optical Networks[J]. IEEE/OSA Journal of Optical Communications & Networking, 2010, 2(11): 928-.
- [33] VELASCO L, SHARIATI B, BOITIER F, et al. Learning Life Cycle to Speed Up Autonomic Optical Transmission and Networking Adoption[J]. IEEE/OSA Journal of Optical Communications & Networking, ts, 11(5): 226-237. DOI: 10.1364/JOCN.11.000226.
- [34] SARTZETAKIS I, CHRISTODOULOPOULOS K K, VARVARIGOS E M. Accurate quality of transmission estimation with machine learning[J]. IEEE/OSA Journal of Optical Communications and Networking, 2019, 11(3): 140-150.
- [35] SEVE E, PESIC J, DELEZOIDE C, et al. Learning process for reducing uncertainties on network parameters and design margins[C]//2017 Optical Fiber Communications Conference and Exhibition (OFC). [S.l. : s.n.], 2017: 1-3.
- [36] SINKIN O V, HOLZLOHNER R, ZWECK J, et al. Optimization of the split-step Fourier method in modeling optical-fiber communications systems[J]. Journal of Lightwave Technology, 2003, 21(1): 61-68.
- [37] POGGIOLINI P, BOSCO G, CARENA A, et al. A Simple and Effective Closed-Form GN-Model Correction Formula Accounting for Signal Non-Gaussian Distribution[J]., 2014.
- [38] ZHANG B, ZHANG R, ZHANG Q, et al. Optical filtering penalty estimation using artificial neural network in elastic optical networks with cascaded reconfigurable optical add–drop multiplexers[J]. Optical Engineering, 2019, 58(7): 1.
- [39] BOLSHTYANSKY M. Spectral hole burning in erbium-doped fiber amplifiers[J]. Journal of Lightwave Technology, 2003, 21(4): p.32-38.
- [40] 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: 1-1.
- [41] WOODWARD S L, NELSON L E, FEUER M D, et al. Characterization of Real-Time PMD and Chromatic Dispersion Monitoring in a High-PMD 46-Gb/s Transmission System[J]. IEEE Photonics Technology Letters, 2008, 20(24): 2048-2050.
- [42] GEYER J C, FLUDGER C R S, DUTHEL T, et al. Optical Performance Monitoring using a 43Gb/s Realtime Coherent Receiver[J]. Leos Summer Topical Meeting, 2009: 93-94.



- [43] KHAN F N, SHEN T S R, ZHOU Y, et al. Optical Performance Monitoring Using Artificial Neural Networks Trained With Empirical Moments of Asynchronously Sampled Signal Amplitudes[J]. IEEE Photonics Technology Letters, 2012, 24(12): 982-984.
- [44] TANIMURA T, HOSHIDA T, RASMUSSEN J C, et al. OSNR monitoring by deep neural networks trained with asynchronously sampled data[C]//2016 21st OptoElectronics and Communications Conference (OECC) held jointly with 2016 International Conference on Photonics in Switching (PS). [S.l. : s.n.], 2016: 1-3.
- [45] 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.
- [46] TANIMURA T, HOSHIDA T, KATO T, et al. Convolutional Neural Network-Based Optical Performance Monitoring for Optical Transport Networks[J]. Journal of Optical Communications and Networking, 2019, 11(1): A52.
- [47] TAN M C, KHAN F N, AL-ARASHI W H, et al. Simultaneous optical performance monitoring and modulation format/bit-rate identification using principal component analysis[J]. IEEE/OSA Journal of Optical Communications & Networking, 2014, 6(5): 441-448.
- [48] KHAN F N, YI Y, TAN M C, et al. Simultaneous OSNR Monitoring and Modulation Format Identification Using Asynchronous Single Channel Sampling[C]//Asia Communications & Photonics Conference. [S.l.: s.n.], 2015.
- [49] KHAN F N, ZHONG K, ZHOU X, et al. Joint OSNR monitoring and modulation format identification in digital coherent receivers using deep neural networks[J]. Optics Express, 2017, 25(15): 17767.
- [50] ANDERSON T, KOWALCZYK A, CLARKE K, et al. Multi Impairment Monitoring for Optical Networks[J]. Journal of Lightwave Technology, 2009, 27(16): 3729-3736.
- [51] 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.
- [52] WANG Z, YANG A, GUO P, et al. OSNR and nonlinear noise power estimation for optical fiber communication systems using LSTM based deep learning technique[J]. Optics Express, 2018, 26(16): 21346-.
- [53] 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: p.2398-2400.
- [54] KASHI A S, ZHUGE Q, CARTLEDGE J, et al. Artificial Neural Networks for Fiber Nonlinear Noise Estimation[C]//Asia Communications & Photonics Conference. [S.l. : s.n.], 2017.
- [55] CABALLERO F J V, IVES D, ZHUGE Q, et al. Joint Estimation of Linear and Non-linear Signal-to-Noise Ratio based on Neural Networks[C]//Optical Fiber Communication Conference. [S.I.]: Optical Society of America, 2018: M2F.4. DOI: 10.1364/OFC.2018.M2F.4.



- [56] ZHANG K, FAN Y, YE T, et al. Fiber Nonlinear Noise-to-Signal Ratio Estimation by Machine Learning[C]//Optical Fiber Communication Conference (OFC) 2019. [S.l.]: Optical Society of America, 2019: Th2A.45. DOI: 10.1364/OFC.2019.Th2A.45.
- [57] VELA A P, RUIZ M, FRESI F, et al. BER Degradation Detection and Failure Identification in Elastic Optical Networks[J]. Journal of Lightwave Technology, 2017, 35(21): 4595-4604.
- [58] SHAHKARAMI S, MUSUMECI F, CUGINI F, et al. Machine-Learning-Based Soft-Failure Detection and Identification in Optical Networks[C]//Optical Fiber Communication Conference. [S.l.: s.n.], 2018.
- [59] LUN H, FU M, LIU X, et al. Soft Failure Identification for Long-haul Optical Communication Systems Based on One-dimensional Convolutional Neural Network[J]. Journal of Lightwave Technology, 2020, 38(11): 2992-2999.
- [60] SHARIATI B, RUIZ M, COMELLAS J, et al. Learning From the Optical Spectrum: Failure Detection and Identification[J]. Journal of Lightwave Technology, 2019, 37(2): 433-440.
- [61] S. V, D. L, T. R, et al. Identification of Soft Failures in Optical Links Using Low Complexity Anomaly Detection[C]//Optical Fiber Communication Conference. [S.l. : s.n.], 2019.
- [62] MUSETTI S, SERENA P, BONONI A. On the Accuracy of Split-Step Fourier Simulations for Wideband Nonlinear Optical Communications[J]. Journal of Lightwave Technology, 2018, 36(23): 5669-5677.
- [63] LIU X, LUN H, FU M, et al. A Three-stage Training Framework for Customizing Link Models for Optical Networks[C]//Optical Fiber Communication Conference (OFC) 2020. [S.1.]: Optical Society of America, 2020: Th3D.6. DOI: 10.1364/OFC.2020.Th3D.6.
- [64] LIU X, LUN H, FU M, et al. Machine Learning Based Fiber Nonlinear Noise Monitoring for Subcarrier-multiplexing Systems[C]//Optical Fiber Communication Conference (OFC) 2020. [S.1.]: Optical Society of America, 2020: M2J.6. DOI: 10.1364/OFC.2020.M2J.6.
- [65] MUSUMECI F, ROTTONDI C, CORANI G, et al. A Tutorial on Machine Learning for Failure Management in Optical Networks[J]. Journal of Lightwave Technology, 2019, 37(16): 4125-4139.
- [66] VELLIDO A, MARTÍN-GUERRERO J, LISBOA P. Making machine learning models interpretable[J]. Proc ESANN, 2012, 12: 163-172.
- [67] BOITIER F, LAYEC P. Automated Optical Networks with Monitoring and Machine Learning[C]//. [S.l.: s.n.], 2018: 1-4. DOI: 10.1109/ICTON.2018.8473802.



致 谢

四年的时光过的飞快,转眼就到了毕业的日子。我毕业论文的整体工作其实完成得较 早,但是在框架和内容上,还需要非常多的完善。最终的毕业论文,是汇集了多篇我在大四 期间发表的会议、期刊以及报告,最后总结升华后整理而得。这其中,无数的心血汗水,无 数的日日夜夜,无数的眼泪和笑容,都是深深印在我的心中。曾经的我是无法想到,我最终 的研究方向会是光通信系统,从接触这一行业到进入实验室再到科研成果,时间快得就像 马车,突然就来到了毕业季。

首先要感谢我的父母,本科四年起起落落,没有你们的陪伴,我一定不会是现在的我。 由于离家很远,每年回家的时间屈指可数,你们在无数个夜晚都在视频前等待我,无论是工 作、生活、感情上的问题,你们都给我了无穷无尽的帮助和鼓励!你们是我坚实的后盾,没 有你们我一定不能义无反顾地冲向前方,毫无保留地追求自己的明天。谢谢你们!

其次,我要感谢带我完成毕设,以及我以后的博士导师,诸葛群碧老师!您不辞辛劳地 为我改论文、与我讨论 idea,并给我一系列的机会让我参与到一些科研项目和论文发表里面 来。您的帮助让我在大四期间投出了多篇论文,建立起了良好的科研信心!都说万事开头 难,我相信这样好的开头能让我在进入科研领域的初期拥有良好的心态和储备,才有了后 期更多的可能。在入组的一年时间里,您在各个方面给我了极大的帮助,也让我从一个懵 懂无知的本科生逐渐蜕变成为一个具有一定科研素养的研究生。无数个日夜,无数个任务, 在您的建设下,我们获得了非常多的机会,我也走到了更多的地方,看到了更多我曾经梦 想的景色。在这一年中,我得到了非常多机会去尝试和经历很多从前不敢想不敢做的事情, 也让我对自己的认知和期待和以往完全不同。我想,这一切都是因为我所处的环境在蓬勃 的发展,充满了生命活力,这是与诸葛老师的规划与劳动分不开的。同样,我也要感谢实验 室的各位同学,感谢凡哥与我一直以来的同进退,感谢华志师兄带我入门,让我能顺利完成 实验室的一系列工作,感谢各位对我无微不至的照顾,你们的好我都深深记在心里。

我同样也要感谢在大学四年内陪伴我的同学们。感谢立言同学两年多的陪伴,你的好心 态深深感染着我,让我从一个为一切的未知都焦虑担心的敏感的人逐渐变得乐观积极,能 够充满希望地面对明天!感谢余爽、母姐、芸芸和志云,几位好姐妹都在我最最困难的时候 鼓励我,支持我,帮助我,谢谢你们给我力量去面对生活中的困难!感谢信工专业的几位好 朋友,姚逸凡、朱薇,你们是我在本专业领域最好的朋友,感谢你们在课业期间与我合作, 也感谢你们和我交心,不厌烦我的马虎与粗心,也感谢几位一起做了许多大作业的朋友,李 可,小姐姐,秦师傅,你们身上对于学业精益求精的态度深深感染了我,也让我感觉到在这 个专业里,我不再孤单,我有很多可以一起打拼的朋友。

我还要感谢辩论队的各位学长学姐学弟学妹们。你们是我在交大第一批熟悉的朋友,在 你们身上,我学到了非常多的知识、技能,也看到了非常多种人生的可能。几年辩论的经验 积累,让我学会了如何去思考,去说服,去讨论,这些技能和我们的友谊一样,都是我人生 宝贵的财富。

最后,我想感谢一直以来都在前进的自己。四年前的我是迷茫的,也许现在我也并不非 常清晰。但是,四年中,我都没有停止尝试和寻找自己的热爱,并且在很多地方留下了精彩 的身影与记忆。我相信,满怀对明天的热情,把握住当下,未来一定充满无穷可能!



攻读学士学位期间已发表或录用的论文

- Xiaomin Liu, Huazhi Lun, Mengfan Fu, Lilin Yi, Weisheng Hu, Qunbi Zhuge*, "Machine Learning Based Fiber Nonlinear Noise Monitoring for Subcarrier-multiplexing Systems," in Optical Fiber Communication Conference (OFC) 2020, OSA Technical Digest (Optical Society of America, 2020), paper M2J.6.
- [2] <u>Xiaomin Liu</u>, Huazhi Lun, Mengfan Fu, Yunyun Fan, Lilin Yi, Weisheng Hu, Qunbi Zhuge*, "A Three-stage Training Framework for Customizing Link Models for Optical Networks," in Optical Fiber Communication Conference (OFC) 2020, OSA Technical Digest (Optical Society of America, 2020), paper Th3D.6.
- [3] <u>Xiaomin Liu</u>, Huazhi Lun, Mengfan Fu, Yunyun Fan, Lilin Yi, Weisheng Hu and Qunbi Zhuge*, "AI-Based Modeling and Monitoring Techniques for Future Intelligent Elastic Optical Networks," Appl. Sci. 2020, 10, 363.
- [4] Qunbi Zhuge*, Xiaobo Zeng, Huazhi Lun, Meng Cai, <u>Xiaomin Liu</u>, Lilin Yi and Weisheng Hu, "Application of Machine Learning in Fiber Nonlinearity Modeling and Monitoring for Elastic Optical Networks," in Journal of Lightwave Technology, vol. 37, no. 13, pp. 3055-3063, 1 July1, 2019, doi: 10.1109/JLT.2019.2910143.
- [5] Qunbi Zhuge, Mengfan Fu, Huazhi Lun, <u>Xiaomin Liu</u>, Weisheng Hu. "Fiber Nonlinearity Mitigation and Compensation for Capacity-Approaching Optical Transmission Systems," in Asia Communications and Photonics Conference. 2019, paper T4B.1.
- [6] Huazhi Lun, <u>Xiaomin Liu</u>, Meng Cai, Mengfan Fu, Lilin Yi, Weisheng Hu and Qunbi Zhuge*, "Anomaly Localization in Optical Transmissions Based on Receiver DSP and Artificial Neural Network," in Optical Fiber Communication Conference (OFC) 2020, OSA Technical Digest (Optical Society of America, 2020), paper W1K.4.
- [7] Huazhi Lun, Mengfan Fu ,<u>Xiaomin Liu</u>, Meng Cai, Lilin Yi, Weisheng Hu and Qunbi Zhuge*, "Anomaly Identification for Long-haul Optical Communication Systems Based on One-dimensional Convolutional Neural Network," in Journal of Lightwave Technology, vol. 38, no. 11, pp. 2992-2999, 1 June1, 2020, doi: 10.1109/JLT.2020.2989153.
- [8] Qunbi Zhuge*, <u>Xiaomin Liu</u>, Huazhi Lun, Mengfan Fu, Lilin Yi and Weisheng Hu, "DSPaided Telemetry in Monitoring Linear and Nonlinear Optical Transmission Impairments," 2020 Optical Fiber Communications Conference and Exhibition (OFC), San Diego, CA, USA, 2020, pp. 1-3.
- [9] Yiwen Wu, Huazhi Lun, Mengfan Fu, Xiaobo Zeng, <u>Xiaomin Liu</u>, Qiaoya Liu, Lilin Yi, Weisheng Hu and Qunbi Zhuge*,"Degenerated look-up table–based perturbative fiber nonlinearity compensation algorithm for probabilistically shaped signals," Opt. Express 28, 13401-13413 (2020)



攻读学士学位期间参与的项目

- [1] 华为 AI 使能部: 基于 oDSP 的低余量网络设计 (2019 年 6 月-至今)
- [2] 华为成都接入产品线联合实验室合作项目: OSNR 监测与余量监测方案设计(2020 年 4月-至今)
- [3] 腾讯网络部门光网络估计平台(2019年9月-至今)



THE MODELING AND MONITORING TECHNIQUES FOR THE NEXT GENERATION OPTICAL NETWORKS

With the development of the cloud services, internet applications and the 5G technologies, there are growing demands for the capacity and reliability of the optical networks. Since the digital signal processing technologies have reached a bottleneck, which pushes the capacity of each individual link closer to the Shannon Limit, the elastic optical networks and low-margin optical networks show more potentials in paving a new way for optical networks with higher capacity. The more flexible network structures enable the optical networks controllers to assign the spectrum according to the needs of each services. Moreover, more advanced modeling and monitoring functionalities can reduce the design margin and system margin effectively. To achieve this, many researches have been conducted to design and deploy the modeling and monitoring techniques to estimate the quality of transmission and specific impairments. However, many traditional analytical methods cannot reach a good balance between the accuracy and complexity. For instance, estimating methods which simulate the transmission and generate symbols can reach a high accuracy but cannot provide results in a short time. On the contrary, analytical methods which calculate transmission results without simulation may be based on some ideal assumptions. Therefore, to estimate the transmission quality effectively and precisely, more methods need to be proposed and machine learning provides a promising way to solve this problem.

We first introduce the existing transmission performance estimation algorithms, especially methods based on machine learning. The advantages and drawbacks of these methods are elaborated and compared. The analytical modeling methods are introduced first and most of them lack satisfying accuracy or complexity. Then, more solutions are proposed based on artificial intelligence. Many models are trained offline with data from simulations or lab experiments and then applied to the real system. For the transmission monitoring, the monitors are required to have the ability of monitor the real-time network changes and alarm the failures before the networks break down. Therefore, some monitors are designed to estimate the transmission quality or specific impairments while some monitors are utilized for failure management. Even with different targets, these monitoring engines are all required to track the real time changes of the networks, even a tiny fluctuations in the signals, which is a challenging requirements for the monitoring methods. Then, we use tables to conclude those machine-learning-based modeling and monitoring methods, which summaries the monitoring or modeling targets, machine learning algorithms they used and the input features.

The second chapter introduces the principle of nonlinear impairments and the modeling and monitoring algorithms for estimation. For nonlinear noise modeling algorithms, the Split-step Fourier method can show a high accuracy but the Gaussian noise model with faster speed is more commonly used in different scenarios. We introduce both algorithms, and uses simulation data to compare the performance between them. At the same time, for the nonlinear noise monitoring, this chapter also introduces the neural-network-based monitoring methods which applies the correlations between the amplitude and phase noise as the monitoring features. Simulation data is utilized



to train and verify the neural network. Since nonlinear noise estimation will be considered as one of the most important impairments to optimize the design of the link or signal configurations and avoid the failures during transmissions, the improvement of the monitoring and modeling algorithm for the next generation optical systems is of great importance. At the same time, machine-learning-based methods for monitoring and modeling have been investigated. The simulation results show that these machine-learning-based methods show better performance in accuracy and complexity.

Many works have proved that machine-learning-based modeling and monitoring techniques can reach a better performance. There are many problems existed if these models are to be deployed to the real system. The problems can be divided into two categories, the first part are the uncertainty brought by the model itself. Since the machine learning models are trained to fit the data from simulations or experiments, the models are trained according to the loss function and the result reaches a good performance among most data, which means that they may sacrifice the performance on each specific configurations and reach the statistically optimal. The second uncertainty is from the uncertainty of the input parameters. Due to the difference between the data from the practical systems and the simulated data, the performance of these pre-trained models is limited by the uncertain parameters in the control plane. Therefore, the robustness and generalization ability of these methods should be improved to guarantee the reliability of these data-driven methods. To solve this problem, in the third chapter, a method is proposed to solve the uncertain input parameters of the control layer and provide customized model for different links. This customization framework is divided into three stages. In the first and the second stage, the model is trained by the data from simulations. Afterwards, a small amount of data from the real scenes through the active acquisition mechanism are used to further fine-tune the model. In order to verify the performance of the proposed mechanism, this chapter carried out simulation and customized model on the circumstances with inaccurate power parameters on the three link configurations, all of which achieved good performances.

Then, the applications of nonlinear noise monitoring methods are introduced and discussed. Since existing algorithms are mostly designed for single-carrier systems, when extended to multicarrier systems, the performance may be affected to some extent by the reduced symbol baud rate. In the fourth chapter, considering digital subcarrier multiplexing system (SCM), we propose a new monitoring schemes to estimate the nonlinear noise in the SCM system. Firstly, the correlation calculation within one channel is extended to within and between each subcarrier. The inter-subcarrier correlation features are proposed to monitor the nonlinear interference between each subcarrier so as to provide more information for the nonlinear noise estimation. Moreover, using data fusion, a set of new features for non-linear monitoring is designed. After exploring the training schemes, we designed a nonlinear noise monitoring algorithm with high accuracy and robustness. A series of simulations are conducted to analyze the performance of our proposed monitoring features with different noise distribution and various symbol lengths. The results show that the new features can provide new information and make the neural networks more robust to the random fluctuations caused by the limited symbol length or the amplifier spontaneous emission noise. Therefore, even in a practical system, the monitor can accurately estimate the nonlinear noise in a very short monitoring period.

Even though many machine-learning-based methods have been proposed in this article, there are also problems to be addressed before deployment. In the last section, the challenges and opportunities for applying artificial intelligence techniques in the practical optical networks are discussed.



The interpretability and generalization ability of these methods should be further improve to guarantee that the engine can work as expected. Since the optical link transmit thousands of signals at a time, even a tiny anomaly can cause the disastrous degradation of the whole networks. Therefore, those methods based on offline training should be more reliable and compatible to heterogeneous network structures. We discuss and summaries the requirements and problems for the future deployment when applying these data-driven methods to the practical optical systems.