



研究与开发

基于数据增强技术的光传送网健康度模型测评研究

王郁, 唐都, 李芳, 徐云斌
(中国信息通信研究院, 北京 100091)

摘要: 随着光传送网 (optical transport network, OTN) 网络向高阶自智生态演进, OTN 健康度模型的预测准确度直接关系到网络优化决策的可靠性。为突破传统通用时间序列增强方法缺乏物理约束的局限, 提出一种基于数据增强技术与 OTN 物理传输特征相结合的健康度模型准确度测评方法。该方法基于 OTN 关键性能参数的物理变化规律设计基底函数, 结合函数发生器与光网络仿真器, 构建“物理引导—数学变换—光域验证”的数据增强机制, 生成高保真合成数据集, 模拟渐变、突变等多种性能变化场景, 形成用于模型训练与验证的基准数据集。此外, 详细设计了包含数据加载、增强、处理、模型训练与测评的完整流程, 并通过实验验证了该方法的有效性。

关键词: 光传送网; 数据增强技术; 健康度模型; 性能预测; 长短期记忆网络

中图分类号: TN929.11

文献标志码: A

doi: 10.11959/j.issn.1000-0801.DXKX250673

Research on evaluation of optical transport network health model based on data augmentation technology

Wang Yu, Tang Du, Li Fang, Xu Yunbin
China Academy of Information and Communications Technology, Beijing 100091, China

Abstract: As optical transport network (OTN) evolve toward a higher-level autonomous and intelligent ecosystem, the prediction accuracy of OTN health models was directly related to the reliability of network optimization decisions. To overcome the limitation of conventional general time-series augmentation methods lacking physical constraints, an evaluation method for health model accuracy was proposed by integrating data augmentation technology with OTN physical transmission characteristics. In this method, basis functions were designed based on the physical variation patterns of key OTN performance parameters, and a data augmentation mechanism of “physics-guided mathematical transformation followed by optical-domain verification” was constructed by combining a function generator with an optical network simulator. High-fidelity synthetic datasets were generated to simulate various performance variation scenarios such as gradual changes and abrupt changes, thereby forming benchmark datasets for model training and validation. Furthermore, a complete workflow encompassing data loading, augmentation, processing, model training,

收稿日期: 2025-11-20; 修回日期: 2026-02-10

基金项目: 工业和信息化部制造业专项“2024年光网络新技术验证项目”(No.20240248)

Foundation Item: MIIT Manufacturing Industry Special Program-2024 Optical Network New Technology Verification Project (No. 20240248)

and evaluation was detailed, and the effectiveness of the method was validated through experiments.

Key words: optical transport network, data augmentation technology, healthy model, performance prediction, long short-term memory network

0 引言

光传送网 (optical transport network, OTN) 凭借大容量、高带宽、低时延等技术优势, 已成为支撑 5G-Advanced/6G、算网融合、空天地一体化等新一代信息技术应用场景的关键基础设施。随着 OTN 规模持续扩大、业务承载日益复杂, 传统依赖人工巡检和经验判断的网络运维模式, 已难以满足实时性、精准性的运维需求, 亟须引入智能化技术提升网络运维水平, 推动网络运维由被动响应向主动预测与智能决策转型。

OTN 健康度模型作为智能运维体系中的重要工具, 借助人工智能 (artificial intelligence, AI) 对网络业务性能数据进行分析与建模, 实现对网络和业务运行性能的预测、评估与预警, 为 OTN 业务的优化决策提供依据和数据支撑。健康度模型的应用价值很大程度上取决于其预测准确度, 只有具备高准确度的健康度模型, 才能有效识别潜在故障风险、优化网络资源的配置, 从而保障网络持续稳定运行。然而, 在实际应用中, OTN 健康度模型的测评仍面临数据资源有限、检测手段不足等挑战, 制约了模型准确度测评的客观性和有效性。

数据增强技术作为 AI 领域的重要技术手段, 通过对现有数据进行合理扩充与优化, 能够有效改善数据样本不足、有效信息缺失等问题, 进而为模型训练与性能提升提供有力支持。将数据增强技术引入 OTN 健康度模型测评体系, 有望突破当前数据资源瓶颈, 提升模型测评的科学性与可靠性。然而, 现有的通用时间序列数据增强方法通常忽略了 OTN 系统特有的物理传输特性。这类方法生成的数据虽在统计层面具有多样性, 却未

必符合光信号在光纤中传播的基本规律, 可能导致模型在真实场景中泛化能力下降。针对这一问题, 本文提出“物理特征与数据增强”协同框架: 一方面, 基于 OTN 链路中光功率、光信噪比 (optical signal-to-noise ratio, OSNR) 等关键指标构建具有物理意义的趋势变化模式; 另一方面, 结合专业光网络仿真器生成合成数据, 确保其符合实际设备与传输特性。该方法不仅扩充了数据规模, 更保障了合成数据的物理真实性与工程可用性, 与通用增强策略形成显著区别。基于此, 本文围绕基于数据增强技术的 OTN 健康度模型测评展开研究, 深入分析 OTN 健康度模型测评的需求与挑战, 探讨数据增强技术在其中的应用价值与实施路径, 旨在为 OTN 网络业务的智能运维提供理论参考与实践指导。

1 AI 赋能 OTN 健康度模型测评需求

OTN 健康度模型的核心能力在于对网络传输和业务运行的性能进行预测、评估与预警, 从而为网络业务的优化决策提供重要依据, 因此可归属于网络全生命周期中的网络维护与优化阶段。AI 赋能下的 OTN 健康度模型测评需求贯穿于网络运维与优化的全流程, 是保障网络高质量运行的关键环节。本文所提及的“OTN 健康度模型测评”特指对 OTN 传输性能预测模型的准确度进行测评, 即通过科学的测评方法, 检验模型基于 OTN 历史传输性能数据预测未来性能的精准程度, 为模型的迭代与优化提供依据。

随着电信管理论坛 (Tele Management Forum, TMF) 等国际组织提出“自智网络” (Autonomous Networks) 理念^[1], 光网络正逐步向“自感知、自决策、自执行、自优化”的高阶自



智阶段演进, L5 等级将实现面向动态网络自主调优的自愈生态演进^[2]。该生态体系构建了一套完整的闭环运行流程, 而健康度评估在其中承担着分析决策的关键作用。

具体而言, 在性能预测与优化场景中, OTN 高阶自智生态借助 AI 智能体、大模型和数字孪生等智能化技术, 实现用户意图转译、优化任务的规划和拆解、数据采集与感知、健康度评估与预测分析、网络优化决策生成、优化方案仿真验证、优化决策执行等重要环节, 打通网络动态优化场景的完整控制闭环。光网络高阶自智生态体系如图 1 所示。

动态调优过程中的关键环节如下。

(1) 数据采集与感知: 通过部署在网络节点、传输链路中的传感器与监测设备, 实时采集光功率、信噪比、误码率、时延、流量等性能数据, 构建反映网络实际运行状态的数据集。

(2) 健康度评估与预测: 基于 AI 健康度模型对采集的性能数据进行分析, 评估当前网络健康等级, 并预测未来一段时间内网络性能的变化趋势,

识别潜在的性能劣化、故障风险或性能变化规律。

(3) 网络优化决策生成: 集合健康度评估与预测结果, 并考虑业务承载需求、资源配置约束等因素, 生成针对性的优化决策方案, 如调整光信号发射功率、切换备用传输链路、优化业务路由等影响现网资源配置的方案建议。

(4) 优化方案仿真验证: 在验证空间预定优化目标, 通过数字孪生体对优化方案进行仿真、推演与寻优, 模拟优化决策执行后的光网络运行状态, 验证方案的可行性与有效性。若仿真结果达到预期目标, 则完成一次闭环流程; 若未达到预期, 则反馈至“健康度评估”环节, 重新调整模型参数或优化决策, 直至形成最优方案, 保障光网络的可靠运行。

(5) 最优决策的执行: 将最终生成的优化决策反向部署于实际物理网络, 执行相应的资源配置变更。

这一过程可实现完全自主调优, 而无须人工干预。由此可见, 健康度模型的预测准确度直接决定了优化决策的合理性与可靠性, 只有当健康




图1 光网络高阶自智生态体系

度模型能够精准预测网络性能变化趋势时,生成的优化决策才能真正解决网络潜在问题,避免决策失误导致资源浪费或网络故障。因此,对健康度模型的准确度进行科学测评,是保障OTN高阶自智生态闭环高效运转的核心前提。与此同时,未来在L5高阶自智阶段,基于健康度模型预测结果生成优化策略反向控制物理设备,其操作将对现网业务产生直接影响。此类涉及现网调整的动作通常难以直接实施,运营商在执行时也会高度谨慎,对可靠性的要求更为严苛。这进一步凸显了对模型预测准确度进行严格测评的重要意义。

2 OTN健康度模型测评面临的问题和挑战

随着OTN复杂度的提升与智能化运维需求的日益增强,健康度模型测评的重要性越发凸显。然而,在实际测评过程中,仍面临着时间序列模型测评方法受限、核心问题突出等多重挑战,这些问题严重制约了测评工作的科学性与有效性,亟须深入剖析并寻求可行的解决方案。

OTN健康度预测模型本质上属于时间序列建模,常见的实现方式包括长短期记忆(long short-term memory, LSTM)网络、卷积神经网络(convolutional neural network, CNN)等。模型的测评过程高度依赖数据支持,测评数据的质量、数量与多样性直接影响模型预测结果的准确性与客观性。目前,用于OTN健康度模型测评的时间序列数据主要来源为现网数据与实验室构造数据,二者均存在明显局限性,具体表现如下。

(1) 现网数据

现网数据是从实际运行的OTN中采集的性能数据,包括光功率、信噪比、误码率等历史时序数据,以及对应的网络故障记录、运维日志等辅助数据。现网数据的最大优势在于真实性强,能够直接反映OTN的运行状态,包含各类网络故障、负载波动、环境影响(如温度变化、电磁干扰等)、设备老化等实际因素。基于现网数据的

测评结果,可直接反映模型在实际应用中的表现。然而,现网数据也存在显著的局限性:OTN现网中网络故障或性能异常的发生概率较低,尤其是严重故障的样本数量极少,导致模型在各种“异常场景”下的有效数据严重不足,难以全面评估模型对各类故障影响的预测能力。此外,出于现网数据安全和隐私考虑,现网数据往往难以对外获取。

(2) 实验室构造数据

实验室构造数据是在实验室环境中利用OTN物理设备搭建实验网络,通过人工配置网络参数、利用仪表加载各种业务,并制造故障或性能劣化场景,采集得到的物理设备实际生成的性能数据。实验室构造数据的优势在于可控性强,研究人员可根据测评需求,灵活设置网络拓扑、业务负载与故障类型(如光纤中断、性能劣化、设备故障等),采集实验室特定配置环境下的性能数据,以用于验证健康度模型在特定环境下的预测准确度。然而,实验室构造数据的缺陷在于物理资源配置有限。实验室环境相对简单,无法完全复现现网的复杂场景,如长期环境变化对设备性能的影响等,基于这种有限变化趋势的性能数据,测评结果可能与模型在现网中的实际应用存在偏差,模型泛化性不足。

综合来看,OTN健康度模型测评主要面临以下问题与挑战。

(1) 缺乏用于模型准确度判定的基准数据集。基准数据是开展模型测评的“标尺”,通过在同一数据集上对比不同模型的测评结果,可以客观判断模型优劣,为模型选择与优化提供依据。目前尚缺乏公认的、覆盖多场景的OTN性能基准数据集。

(2) 数据样本不足,尤其缺乏异常场景下的性能变化趋势。从以上现网数据和实验室数据存在的局限性可以说明异常情况下的样本数据稀缺的问题。



(3) 模型性能测评手段较为单一, 缺乏系统性检测工具。现有测评以功能验证为主, 缺乏对“模型鲁棒性”(如抗噪声、抗干扰能力)的系统检测方法, 也缺乏辅助测评的专业工具支持。

为应对上述问题, 在 OTN 健康度模型测评中引入数据增强技术, 形成第三种数据来源——合成数据, 可应用于模型的开发、验证过程。数据增强技术基于少量真实数据, 借助数学算法或统计方法扩展生成时序性能数据, 可用于传输性能时序模型的测评, 作为准确度评估的参考基准。合成数据的优势在于可扩展性强, 仅需少量真实数据作为参考, 即可模拟各种性能变化趋势, 并灵活高效地生成符合数据特征分布的样本, 而不受光网络配置的限制, 能够有效弥补现有数据样本不足的问题。同时, 合成数据还可根据测评需求, 生成现网中罕见、实验室难于制造的场景数据, 从而丰富测评场景的多样性, 提高模型的泛化能力。

3 AI 数据增强技术应用与发展现状

数据增强技术作为机器学习中的关键预处理手段, 通过扩展训练数据集规模和增加数据多样性, 能够有效提升模型的泛化能力和鲁棒性。近年来, 随着人工智能在多个领域的广泛应用, 数据增强技术已从传统的图像、语音、文本等非结构化数据处理逐步延伸至结构化数据处理中, 例如, 信号处理、时间序列分析等领域。其核心价值在于解决数据稀缺、分布不平衡等问题, 尤其在小样本学习、跨域适应和实时系统等场景中发挥着重要作用。

数据增强技术目前已广泛应用于众多前沿领域。在自动驾驶领域, 通过亲和传播聚类 and 生成对抗网络 (generative adversarial network, GAN) 对驾驶数据进行增强, 可模拟多样化的驾驶行为, 交通流仿真更贴近真实场景^[3]。在医疗健康方面, 基于高斯混合模型的脑电图信号增强技术能够分解时空特征, 并生成合成数据, 以辅助脑

机接口诊断, 避免数据量不足导致的过拟合问题^[4]。在工业检测中, 通过对旋转机械的健康样本进行增强, 可以实现在零故障数据下的故障精准检测与定位^[5]。在通信工程中, 针对电磁信号的小样本识别问题, 研究人员开发了基于时间序列的增强方法, 如对同相/正交时间序列添加噪声扰动、幅度变换和频率偏移, 以模拟真实信道变化, 从而提升通信设备的识别精度^[6]。此外, 在网络安全领域, 利用数据增强技术平衡入侵检测数据集, 能够显著提升对少数类攻击的识别率^[7]。

目前主要的数据增强方法包括基于数学变换方法和生成模型方法两类。其中, 数学变换方法包括几何变换 (如时域翻转、频移) 和噪声注入等。生成模型方法如 GAN 和变分自编码器 (variational autoencoder, VAE), 通过学习数据生成高度逼真的合成数据。例如, 在自由空间光通信中, 研究人员采用 GAN 结合小波变换, 将图像分解为高频和低频成分, 有效增强了斑点图像的多样性^[8]。

当前, 数据增强技术正朝向自动化、自适应、可视化方向发展。自动化增强逐步取代手动设计, 显著提升了增强效率。同时, 面向小样本学习的增强方法成为研究热点, 通过虚拟对抗训练和元学习等技术扩充有限数据, 显著降低了对大规模标注的依赖。此外, 可视化增强技术的引入有助于验证生成数据的合理性, 增强可信度。然而, 数据增强技术仍面临诸多挑战: 生成数据的真实性与多样性难以保证, 可能引入模型偏差; 计算成本较高, 尤其在生成模型训练中; 对领域知识的依赖限制了其通用性。

未来研究需重点关注以下 3 个方面: 一是提升生成数据的质量, 通过物理约束 (如基于信号特性的增强) 确保数据的真实性; 二是降低计算复杂度, 开发轻量级、高效的增强算法; 三是推动标准化, 建立领域的评估基准。

综上所述, 数据增强技术已成为突破数据瓶

颈的关键工具，其角色正从辅助手段演变为数据预处理的核心环节。随着多学科交叉融合的不断深化，数据增强技术未来有望在自动化、高可信和标准化方向取得突破，从而有效提高数据驱动模型的泛化性和鲁棒性。

4 基于数据增强技术的 OTN 健康度模型准确度测评方法与实践

4.1 模型准确度测评设计与实现

结合当前数据增强技术的应用现状，并立足于光传送网的技术特征，本文提出一种基于数学变换的数据增强方法，旨在提升 OTN 健康度模型的准确度测评能力。该方法致力于解决当前 OTN 健康度模型测评中存在的有效数据不足、测评手段效率低等问题，同时推动模型测评向智能化和自动化方向发展。基于数据增强技术构建的数据集可以根据模型训练与验证的特定需求，灵活生成多样化的数据。该方法可模拟多种场景下光传输性能的变化趋势和分布特征，从而为模型提供更为丰富的性能变化场景。通过按需进行数据扩展和增量生成，能够满足模型训练和测评对数据规模和多样性的要求。在 OTN 健康度模型的横向对比时，在相同物理网络配置下，基于增强生成的数据集可以作为模型准确度评估的标称基准。该数据集具有可重复使用的特点，无须反复进行实际数据采集或重复生成，能够提高数据的使用效率。

基于数据增强技术的 OTN 健康度模型测评设计与实现如图2所示。各模块实现的功能如下。

(1) 原始数据集加载和评估模块：采集和导入 OTN 现网数据或实验室数据，完成原始数据的有效性分析评估。原始数据的主要来源是 OTN 系统的历史性能数据，如光功率、误码率等。分析评估环节主要是对原始数据集的数据分布、性能变化趋势等进行评估，判断是否需要数据增强，为后续数据处理提供依据。

(2) 数据增强模块：通过合成数据集扩充样本空间，并融入有效的数据变化趋势，以满足模型准确度测评对数据的要求。其中，函数发生器借助 Python 或 MATLAB 工具，通过平移、缩放、变换、噪声注入等数学方法生成新样本。光网络仿真器则利用专业光网络仿真工具（如 VPI），仿真不同系统配置下的 OTN 传输性能数据。

(3) 数据处理模块：对原始数据或合成数据进行标准化适配与预处理，确保输入模型的数据格式统一、特征有效。其中，数据适配是解决多源数据的格式异构问题，通过数据解析、字段映射，将数据转换为模型可识别的数据格式。数据预处理包括数据归一化、特征提取、数据降维、数据集划分等。

(4) 模型训练与推理模块：被测模型的探测过程，基于处理后的数据训练被测模型，并执行推理得到预测结果。

(5) 模型评测模块：通过多种统计指标对模型准确度进行量化评估，如均方误差（mean squared error, MSE）、均方根误差（root mean squared error, RMSE）、平均绝对误差（mean ab-




图2 基于数据增强技术的 OTN 健康度模型测评设计与实现



solute error, MAE) 等。

基于数据增强技术的OTN健康度模型测评设计,能够根据OTN传输性能的变化趋势和物理设备配置,扩展合成适用于健康度性能预测所需的数据集,并通过自动化测评系统完成对测评结果的统计与分析,最终输出被测模型的测评结果和结论。该设计为OTN健康度模型准确度测评提供了科学的测评方法和判定标称基准,并为模型的可靠性与有效性验证提供了系统化的技术手段。

4.2 健康度模型准确度测评方法与数据集构建过程

基于上述健康度模型测评设计与实现,形成了一套完整的模型准确度测评方法,并包含基准数据集的构建过程。健康度模型准确度测评过程如图3所示,具体包括以下步骤。




图3 健康度模型准确度测评过程

(1) 采集并加载原始数据集:采集并加载从现网或实验室实际物理系统获取的原始数据集,如接收光功率、OSNR等性能指标,采集频率可为间隔15 min或更高。分析并评估原始数据集是否包含有效的性能变化趋势(如渐变递减/递增、突变增大/减小、周期性变化等),并评估是否满足模型测评的需求。

(2) 确定数据来源:若原始数据集满足模型测评需求,则直接采用原始数据集。否则,通过数据增强模块(包括函数发生器和光网络仿真器)合成数据集。

(3) 生成变化趋势数据:启动数据集合成。首先,根据原始数据集的数据特征,确定将要构建的传输性能数据集的变化范围与数据样本数量,即合成数据集大小。其次,设计合成数据集的整体数据变化趋势,通过函数发生器选择合适的基底函数和参数,并叠加随机噪声(如白噪声)以引入数据随机性。

(4) 生成合成数据集:将函数发生器生成的数据作为光网络仿真器中传输性能影响参数的变化数据,如线路衰耗。此时引入光网络仿真器的目的是使最终合成的数据更具真实性,确保仿真系统配置与实际物理系统设置保持一致,从而得到目标传输性能的变化数据,如光功率、OSNR、色散等性能变化数据。

(5) 数据处理:通过数据处理模块将初始合成数据集映射至被测模型所需格式,完成数据适配和数据预处理。经过映射后的合成数据集可以满足模型训练、验证和测试的要求。

(6) 数据集划分:将基准数据集按一定比例划分为训练集与测试集。训练集用于被测模型训练;测试集作为模型准确度判定的基准数据集,暂不公开,以确保测试集的安全性。

(7) 模型训练与推理:使用训练集对被测AI模型进行训练,并完成推理过程,输出性能预测数据。

(8) 测评结果与结论：通过模型评测模块收集模型测试全过程的输出数据，与基准数据集进行对比、统计和分析，最终得出模型准确度的测试结果和结论，为后续性能优化提供依据。

与通用时间序列数据增强方法（如时间缩放、噪声注入等）不同，本文所采用的数学变换方法紧密结合OTN系统的物理传输机理，具有以下创新与优势。

(1) 基底函数设计基于OTN关键性能参数的物理变化规律。例如，在光纤弯曲场景中，接收光功率的变化遵循弯曲损耗模型的指数变化规律；OSNR的劣化经传输性能仿真后呈现非线性下降趋势等。因此，本文所选用的基底函数并非任意波形，而是依据光传输性能的实际变化特征，确保合成数据在宏观趋势上符合实际物理系统的真实行为。

(2) 光传输性能仿真的关键器件参数（如衰减、色散斜率、非线性阈值等）直接来源于现网或实验室设备规格，使得生成的数据不仅在变化分布上与真实数据匹配，更在物理机理上具备可解释性和一致性。

综上所述，本文通过物理约束的数学变换生成中间数据，并将其输入光网络仿真器，在与实际部署一致的调制格式、光纤类型、放大器配置等条件下进行端到端传输性能仿真，最终输出具备高保真度的合成OTN性能数据集（如光功率、OSNR、Q因子等）。这一“物理引导的数学变换+光域仿真验证”的双重机制，显著提升了合成数据的真实性与模型测评的可靠性，这是现有通用时间序列增强方法难以实现的。

4.3 典型场景的性能变化趋势建模

基于上述健康度模型准确度测评方法和数据集的构建过程，还需重点突破典型场景下OTN性能变化趋势的建模问题。OTN健康度的

核心观测量包含接收光功率、OSNR、Pre-FEC BER等指标，其中接收光功率能够最为直观地反映OTN的健康度。因此，本节以接收光功率为例，介绍典型场景性能变化趋势的数学建模方法。

根据时间维度上的表现形式，链路健康度劣化可以分为非周期性变化与周期性变化两类。非周期性变化主要对应不可逆或难以恢复的性能退化过程，可进一步分为渐变型（缓慢劣化）与突变型（瞬时异常）。突变场景则对应瞬时发生的显著变化场景，一般对应急剧变化的事件或设备故障。

4.3.1 非周期性变化

(1) 渐变型场景

光纤本体老化会在数月乃至数年的时间尺度上导致链路损耗的缓慢增加。在工程实践中，通常采用线性漂移模型来近似描述实际网络中光纤段损耗逐月递增的场景。具体而言，某一光纤跨段在时间 t 的总损耗 $L(t)$ （单位为dB）可表示为：

$$L(t) = L_0 + kt \quad (1)$$

其中， L_0 表示初始时刻的光纤跨段损耗（dB）； $k > 0$ 表示损耗增长斜率（dB/月或dB/年），可由线性回归估计。

光纤跨段损耗实验统计结果及数学模型拟合结果如图4所示。图4显示，跨段损耗可在约一年时间尺度内基本呈现线性趋势的渐变型上升^[9]。该变化趋势具有显著的稳定性和可预测性，通常表现为单位时间内损耗的缓慢增加，且未伴随明显的突发异常或短期周期性波动。因此，针对此类场景，可采用Theil-Sen方法对一年时间序列的光纤跨段损耗数据进行趋势拟合（如图4中实线所示），以提前判断光纤老化趋势并规划预防性更换维护措施。

此外，从更长时间尺度来看，损耗并非无限



线性增长,而是逐渐逼近一个饱和值。这种现象可用指数模型描述:

$$L(t) = L_{\infty} - (L_{\infty} - L_0)e^{-t/\tau} \quad (2)$$

其中, L_{∞} 表示损耗饱和上限, $\tau > 0$ 表示衰减变化速率的时间常数。当 $t < \tau$ 时, 式(2)在一阶近似下退化为线性形式, 与前述线性漂移模型一致; 当 $t > \tau$ 时, 损耗逐渐饱和而不再显著上升, 符合先上升后趋于平稳的观测。




图4 光纤跨段损耗实验统计结果及数学模型拟合结果

(2) 突变型场景

突变场景对应瞬时发生的显著性能, 主要包括光纤被急剧弯折/拉伸导致局部附加损耗的瞬时上升; 有源/无源器件故障, 如放大器异常、连接器松动、衰减器失灵等; 光缆受外力损伤甚至中断等场景。这类事件在性能上往往表现为阶跃式的功率突降或损耗突增, 可在数学上建模成一个在事件发生时刻 t_0 产生的阶跃项。设被监测量为接收光功率 $P_{rx}(t)$, 则其表达式可写为:

$$P_{rx}(t) = P_{bg}(t) - \Delta P u(t - t_0) \quad (3)$$

其中, $P_{bg}(t)$ 表示除了突变外原本的背景功率演化, $\Delta P > 0$ 表示突变造成的附加功率下降幅度,

$u(t - t_0)$ 表示 Heaviside 阶跃函数, 其表达式如下:

$$u(t - t_0) = \begin{cases} 0, & t < t_0 \\ 1, & t \geq t_0 \end{cases} \quad (4)$$

为在数据增强中更真实地描述弯折/应变这类局部物理事件本身的损耗幅度, 引入弯曲/应变引起的附加弯曲损耗模型。其中, 光纤宏弯损耗被广泛建模为与弯曲半径呈指数关系递增的形式, 并与弯曲圈数近似线性叠加。单模步进折射率光纤在经验上可写为:

$$L_R(R) = \eta_{R1} e^{-\eta_{R2} R} \quad (5)$$

$$L_N(N) = \eta_N N \quad (6)$$

其中, $L_R(R)$ 表示单位长度的弯曲附加损耗, dB/mm 或 dB/m; R 表示弯曲半径; η_{R1} 和 η_{R2} 表示拟合参数, 在 1 550 nm 波长附近的典型取值分别约为 70 和 0.5; $L_N(N)$ 表示弯曲圈数 N 对损耗的影响; η_N 表示多圈绕纤时弯曲损耗的线性累积, 近似常数 (约 0.01 dB/圈的量级)。

阶跃折射率光纤的弯曲半径与弯曲损耗的关系^[10]如图5所示。该光纤的纤芯和包层折射率分别为 1.48 和 1.46, 当波长为 1 550 nm 的光波传输到该光纤时, 其弯曲损耗与弯曲半径呈现指数变化。因此, 基于指数及阶跃函数的复合模型可用于合成数据中的突变场景数据的生成。




图5 阶跃折射率光纤的弯曲半径与弯曲损耗关系

4.3.2 周期性变化

除长期缓慢退化, 光纤跨段损耗还表现出稳定的周期性波动成分^[9]。这类波动通常与外部环境相关, 如昼夜温度循环、机房和放大段运行状态周期性变化等。在工程观测中, 可通过时间序列分解方法, 如季节-趋势分解等, 将此类波动从跨段损耗测量数据中显式分离, 并被标记为季节性 (seasonal) 分量。光纤跨段损耗时间序列分解结果如图6所示, 其幅值通常为亚 dB 级别并呈现日/周尺度的准周期振荡, 而非不可逆劣化。




图6 光纤跨段损耗时间序列分解结果

为在健康度评估的数据增强中刻画此类可重复扰动, 采用简化的正弦模型进行描述:

$$\Delta L_{\text{per}}(t) = A \sin\left(\frac{2\pi}{T}t + \varphi\right) \quad (7)$$

其中, T 表示典型周期 (如 24 h 的昼夜温度循环), A 为周期波动幅度, φ 为初相位。

该模型能够有效贴近实际跨段损耗监测数据中周期性小幅振荡的观测结果, 并为后续数据增强中周期性变化数据的合成提供参考。

4.3.3 噪声建模

除了单一的非周期与周期变化外, 数据增强过程中还会对所合成的数据叠加噪声, 以模拟系统参数的真实采样特性。此处可以采用经典通信和传感监测领域中的经典噪声模型: 加性高斯白噪声模型和低频漂移型噪声模型。

(1) 加性高斯白噪声模型

常用的假设是测量序列中的噪声为零均值高斯噪声, 满足:

$$n(t) \sim \mathcal{N}(0, \sigma^2) \quad (8)$$

其中, $n(t)$ 表示独立同分布的高斯噪声; σ^2 表示方差, 用于体现噪声的功率。

该模型等价于通信系统中的加性高斯白噪声信道模型, 适用于描述测量误差、量化噪声以及放大器瞬时功率波动等在短时间尺度上的随机扰动。该模型是数字通信中对接收信号噪声的经典近似建模方式, 广泛用于链路质量评估^[11]。

(2) 低频漂移型噪声模型

某些设备, 尤其是模拟放大器增益和光功率监测 ADC 会出现缓慢的、相关性很强的漂移噪声。工程上可以用一个随机游走过程来描述这类缓慢漂移:

$$d(t) = \rho d(t-1) + \epsilon(t), \quad \epsilon(t) \sim \mathcal{N}(0, \sigma_\epsilon^2), |\rho| < 1 \quad (9)$$

其中, $d(t)$ 表示设备读数本身的缓慢漂移, 如光放大器增益的缓慢抖动、ADC 零点漂移等。

该模型可作为经典加性高斯白噪声的补充建模形式^[12]。

5 实验验证

5.1 实验环境搭建

本文构建的仿真实验系统框架如图7所示, 主要包括3台设备: 设备1负责400 Gbit/s业务信号



的发送与异常注入,设备2和设备3分别实现链路传输与光功率保护功能。在设备1中,400 Gbit/s业务转发卡产生并发送测试业务信号,经可编程可调光衰减器(variable optical attenuator,VOA)实现功率动态调节。通过自研的自动化控制程序,可对VOA施加包括周期型与非周期型变化在内的多种功率扰动,从而模拟光纤链路中可能出现的老化、环境扰动及设备故障等典型性能变化过程。




图7 仿真实验系统框架

实验系统的性能监测通过网管系统实现,以15 min为一个采样周期自动采集全网光功率数据、跨段损耗以及放大器输出功率等关键性能指标。采集到的数据经统一存储后,可用于构成模型训练和验证所需的实验网络功率数据集。

然而,受限于采集频率,实验系统无法在短时间内快速获取大量的关键性能指标数据。为进一步验证模型在更大规模数据下的适用性,本文基于仿真平台构建了与实验系统1:1对应的数字孪生仿真网络。该仿真系统通过优化策略迭代调整系统参数,复刻了物理实验的光链路结构、放大模块参数

与衰减控制逻辑,能够在虚拟环境中快速生成多种功率变化与噪声叠加场景的数据,有效支持数据增强,从而扩充数据集的规模与多样性。

5.2 数据集生成

在实验室环境中,网管系统以15 min为采样周期自动记录各监测点的接收光功率、发射功率及放大器输出功率等关键参数。通过自动化衰减控制程序,各场景可按设定时长与幅度独立加载不同的衰减变化类型,实现实验的可重复性。每个场景均对应一组功率变化序列,并附带时间戳与场景类别标签,形成以时间为索引的多维性能数据集。所采集的数据覆盖超过160 h的连续运行周期,包含多种由自动控制程序注入的功率扰动模式。

非周期与周期场景下所注入的衰减变化及其对应的功率演化曲线如图8所示。由图8可以看出,时间与功率呈现良好的对应关系,充分体现了自动化衰减控制程序在不同功率扰动模式下的可控性与一致性。其中,非周期性场景下的功率曲线随时间呈单调衰减或突变特征,对应光纤老化、弯折或设备故障等不可逆的性能退化过程;而周期性场景下的功率曲线则表现为规律性的周期波动,反映出环境温度与放大器增益漂移等外部因素对链路功率的可重复扰动影响。对比分析可以发现,实验系统能够准确地复现多类型功率变化模式,验证了实验平台在异常场景复现方面的可靠性。

为保证数据适用于健康度模型训练,对原始采样序列进行了统一的数据清洗,包括对各场景下的数据长度进行规整并剔除异常值,从而获得连续的功率演化曲线。随后,按8:2划分训练集和测试集,便于后续模型训练与分类评估。

在数字孪生仿真平台中,基于VOA的扫频模式,分别加载不同类型的衰减变化,自动生成更大规模的功率时序样本。通过功率计等器件采集功率变化序列,并附带时间戳与场景类别标

签, 形成以时间为索引的多维性能数据。仿真数据经格式对齐后, 与实测数据融合构成测试验证数据集。最终形成的数据增强数据集涵盖多类型功率变化与噪声干扰模式, 既能反映真实网络的运行特征, 又能在孪生域内扩充样本数量, 为后续模型训练与准确度评测提供可靠支撑。




图8 非周期性与时周期性场景下所注入的衰减变化及其对应的功率演化曲线

5.3 模型测评结果对比分析

为验证 OTN 健康度模型的有效性, 本节基于数据增强所构建的数据集开展多模型性能测评与对比分析。实验在 PyTorch 1.9.0 深度学习框架下进行, 计算平台配置为 NVIDIA RTX 3080 GPU (CUDA 11.1), 系统环境为 Ubuntu 18.04。在模型训练阶段, 以 LSTM 为基线模型, 输入为时间序列功率数据, 输出为未来若干时间步的功率预测值, 用于表征网络的短期健康度变化趋势。

LSTM 模型的主要参数配置见表 1, 其中包括输入与输出序列长度、LSTM 隐藏层维度、堆叠层数以及优化器参数等。输入序列长度设置为不超过 2 000 步, 输出序列长度设置为不超过 2 000 步, 具体取值根据历史数据长度及所需要的未来时间段长度而定; 隐藏层维度设为 120,

采用两层堆叠的 LSTM 结构以增强时序建模能力。优化器采用 Adam, 学习率设为 0.001, 训练批次大小 (batch size) 为 32, 最大训练轮次为 200, 并在验证集损失函数 (MSE) 连续 100 轮未改善时提前终止训练。

表1 LSTM模型的主要参数配置

参数	数值
输入序列长度 (时间步)	$\leq 2\ 000$
一次性/迭代预测的未来序列长度	$\leq 2\ 000$
每个时间步的特征维度	由数据列数自动推断
每层 LSTM 隐状态维度	120
LSTM 堆叠层数	2
训练批次大小	32
优化器的学习率	0.001
最大训练轮数 (如未提前停止)	200
损失函数 MSE 无改善的容忍轮数	100
使用的参数优化算法	Adam

LSTM 模型在训练过程中的损失函数变化曲线如图 9 所示。从图 9 可见, 训练与验证损失均在前 20 轮内快速下降, 说明模型能够较快收敛; 20 轮之后, 损失值趋于稳定并在约第 130 轮后收敛并少量波动, 表明模型在训练集与验证集上均具有良好的拟合能力与泛化性能。




图9 LSTM模型在训练过程中的损失函数变化曲线

在模型性能评估中, 采用均方根误差 (root mean square error, RMSE)、平均绝对误差 (mean absolute error, MAE) 与决定系数 (R^2) 进行定量分析。RMSE 用于衡量预测误差的整体方差, MAE 反映平均偏差幅度, 而 R^2 用于评价模型对功率演化趋势的拟合程度, 三者的数学表



达式如下:

$$\text{RMSE} = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2} \quad (10)$$

$$\text{MAE} = \frac{1}{N} \sum_{i=1}^N |y_i - \hat{y}_i| \quad (11)$$

$$R^2 = 1 - \frac{\sum_i (y_i - \hat{y}_i)^2}{\sum_i (y_i - \bar{y})^2} \quad (12)$$

其中, N 表示样本总数, 即测试集中被预测的时间步数量; y_i 表示第 i 个时刻的真实值; $\hat{y}_i$ 表示模型预测的第 i 个时刻功率值; $\bar{y}$ 表示真实值的均值。当 RMSE 与 MAE 值越小、 R^2 越接近 1 时, 表明模型的预测精度越高。

在对比实验中, 以一次周期性场景为例, 选取多层感知机 (multilayer perceptron, MLP)、时序卷积网络 (temporal convolutional network, TCN)、LSTM 与双向 LSTM (BiLSTM) 4 种模型进行性能比较。4 种模型预测性能与参考性能契合程度对比如图 10 所示。从图 10 可以看出, MLP 模型在周期波动段的拟合精度较低, 预测结果存在明显滞后; TCN 模型能够较好地捕捉周期变化趋势, 但在突变点处存在一定延迟; LSTM 模型在整体拟合上更平滑且与真实曲线高度一致; BiLSTM 模型与 LSTM 性能相当。

4 种模型在测试集上的定量评估结果见表 2。

由表 2 可以看出, LSTM 模型在 3 项指标上均表现突出, RMSE 为 0.399 9, R^2 达到 0.918 6, 整体优于其他模型。相比之下, MLP 由于无法有效建模时序依赖, 误差较大; TCN 在捕捉周期变化上略优, 但在突发场景中误差略高; BiLSTM 由于复杂度更高, 在有限的训练轮次内未见性能提升。

表 2 4 种模型在测试集上的定量评估结果

性能评估指标	MLP	TCN	LSTM	BiLSTM
RMSE	1.037 3	0.483 5	0.399 9	0.407 4
MAE	0.805 9	0.377 9	0.317 6	0.323 5
R^2	-0.666	0.768 3	0.841 5	0.835 5

此外, 除了模型间的性能对比外, 本评测方案还支持对同一模型在不同输出模式下的性能差异进行系统性评估。以 LSTM 为例, 分别测试了 2 种典型预测策略: (1) 一次性预测 (direct prediction), 即模型在输入完整时间序列后直接输出整个未来预测窗口; (2) 滚动预测 (rolling prediction), 即模型每次仅预测下一时间步, 并将预测结果反馈至输入端, 循环生成完整预测序列。

两种输出模式在周期性场景与渐变型场景下的预测结果对比如图 11 所示。从图 11 可以看出, 滚动预测模式在短期内具有较强的连续性和局部




图 10 4 种模型预测性能与参考性能契合程度对比

精度,但由于误差在逐步滚动过程中会累积,长期预测部分将产生偏移,在渐变型场景中表现不佳;而一次性预测模式虽然在短期内略有平滑偏差,但整体趋势与真实曲线更加一致,在全区间范围内保持较高的稳定性和抗漂移能力。




图11 两种输出模式在周期性场景与渐变型场景下的预测结果对比

两种场景下LSTM两种输出模式的量化指标分别见表3、表4。在选定的一次周期性场景中,LSTM一次性预测的RMSE为0.678 1, R^2 为0.779 1,整体优于滚动预测模式;而在选定的一次渐变型场景中,一次性预测的RMSE为0.159 9, R^2 为0.682 5,而滚动预测由于误差在逐步滚动过程中累积,模型评估指标表现不佳,其 R^2 甚至为负值。以上结果表明,一次性预测模式在处理连续缓变趋势时具有更好的稳定性和全局一致性。相对而言,滚动预测在捕捉短周期振荡时表现更为敏感,

适用于小窗口高频预测任务,但在长时间尺度上其误差累积效应更明显。需要说明的是,不同的预测模式对模型能力的发挥具有不同影响,滚动预测仅为LSTM模型训练完成后的一种预测模式,在实验中作为一次性预测模式的对比参照,旨在说明在OTN链路功率的预测任务中,使用一次性预测模式能够更充分地发挥模型能力。

表3 周期性场景下LSTM两种输出模式的定量评估结果

性能评估指标	一次性预测	滚动预测
MAE	0.468 1	0.459 5
RMSE	0.678 1	0.711 5
R^2	0.779 1	0.756 8

表4 非周期性(渐变)场景下LSTM两种输出模式的定量评估结果

性能评估指标	一次性预测	滚动预测
MAE	0.126 0	0.617 1
RMSE	0.159 9	0.693 7
R^2	0.682 5	-4.975 2

此外,仿真实验还对模型的鲁棒性进行了量化评估和对比。以非周期性(渐变)场景下LSTM的一次性预测为例,在预测阶段注入不同标准差的高斯白噪声,以对比不同噪声水平下模型的稳定性,结果如图12所示。实验表明,当噪声标准差在0.1以内时,3项性能评估指标基本保持稳定,说明模型在一定的噪声范围内具有较强的鲁棒性。

需要指出的是,本实验均采用了数据增强方案以提升模型准确度。若直接使用原始小样本数




图12 非周期性(渐变)场景下LSTM的一次性预测在不同噪声水平下的评估指标对比



据进行训练,其预测结果将产生明显偏差。以非周期性(渐变)场景下LSTM的一次性预测为例,只采用原始小样本数据(其规模仅为数据增强后数据规模的20%)进行模型训练后得到的预测结果如图13所示。结果表明,受限于数据规模,仅采用原始小样本数据进行模型训练得到的预测结果与参考值差异较大,与图12中采用增强数据训练的结果形成鲜明对比。该结果进一步证明,本文所采用的数据增强方案能够有效提升模型的预测准确度。




图13 非周期性(渐变)场景下LSTM的direct预测只采用原始小样本数据进行模型训练后得到的预测结果

综上所述,本节通过多种典型预测模型的训练与验证,系统评估了健康度建模方法在不同功率变化场景下的适用性。结果表明,LSTM网络表现优异,能够有效捕获OTN链路功率的动态演化特征。同时,本文构建了一套完整的实验流程,包括自动化功率扰动注入、网管数据采集、数据集构建、模型训练与性能评估,均已实现自动化运行与闭环验证,能够在实际环境中稳定复现不同类型的功率变化过程,并可直接用于OTN链路健康度模型的性能验证与算法对比测评中。该系统化验证框架为后续健康度建模算法的快速迭代、泛化能力验证及实际网络部署提供了可复用的技术基础。

6 结束语

本文提出了一种面向OTN健康度模型准确度测评的新方法,旨在解决当前AI模型在OTN应用中面临的“数据墙”难题,同时弥补该领域缺

乏高效测评手段的不足。通过引入OTN物理传输特征与数据增强技术的协同机制,本文构建了可灵活扩展的合成数据集,模拟了OTN传输性能的多种变化趋势,包括渐变、突变等典型场景,既满足了模型训练与验证对大规模数据的需求,又显著提升了模型的泛化能力。仿真实验结果表明,该方法在模拟真实网络环境下能够有效测评健康度模型的预测准确度,为模型的迭代优化提供了可靠依据。

需要指出的是,本文所提方法的适用性存在一定的前提条件,其有效性依赖于对OTN物理传输特性的先验知识,故主要适用于拓扑结构和设备参数已知的OTN组网环境,暂不适用于完全未知或异构的网络场景。此外,虽然本文所提方法聚焦于OTN中的性能预测任务(如光功率、OSNR等健康度建模),但其“物理引导+数据增强”的核心思路亦可为其他专业网或行业领域的性能预测模型提供借鉴。

在应用层面,本测评方法可在实验室或试点网络中构建典型OTN数字孪生环境,利用本文所提方法生成高保真合成数据集,支持健康度模型的训练与验证。在此基础上,可将测评系统与设备厂商的网管平台对接,实现模型上线前的自动化准确度验证与模型微调。长期来看,可联合厂商、运营商等相关方,推动建立面向OTN性能预测模型的统一测评接口规范,为构建高阶自智光网络提供标准化支撑。

随着AI技术与OTN融合的不断深入,未来研究可从以下三方面进一步拓展:一是扩展传输性能数据覆盖的类型,构建更丰富的传输性能数据集,并开展针对性试验验证;二是延伸OTN性能数据集的研究维度,覆盖更多层面的性能特征;三是推动模型测评方法的标准化进程,建立统一的模型准确度测评基准。这些探索与拓展将为AI在OTN领域的深化应用提供技术支撑,推动光网络的智能化升级与可持续发展。

参考文献:

- [1] TMF. Autonomous networks-business requirements & architecture: IG1218[R].2020.
- [2] TMF. Autonomous networks-technical architecture: IG1230[R]. 2021.
- [3] Zhang W Q, Chu P M, Huang K S, et al. Driving data generation using affinity propagation, data augmentation, and convolutional neural network in communication system[J]. International Journal of communication systems, 2021, 34(2): e3982.
- [4] Liao C C, Zhao S Y, Wang X C, et al. EEG data augmentation method based on the Gaussian mixture model[J]. Mathematics, 2025, 13(5): 729.
- [5] Chen Z Y, Huang H Z, Deng Z W, et al. Shrinkage mamba relation network with out-of-distribution data augmentation for rotating machinery fault detection and localization under zero-faulty data[J]. Mechanical Systems and Signal Processing, 2025, 224: 112145.
- [6] Cai Z R, Ma W X, Wang X R, et al. The performance analysis of time series data augmentation technology for small sample communication device recognition[J]. IEEE Transactions on Reliability, 2023, 72(2): 574-585.
- [7] Mohammad R, Saeed F, Almazroi A A, et al. Enhancing intrusion detection systems using a deep learning and data augmentation approach[J]. Systems, 2024, 12(3): 79.
- [8] Liu Y C, Liu Y J, Song S, et al. GAN-based data augmentation for AI-enabled ATP in free space optical communication[J]. IEEE Communications Letters, 2024, 28(5): 1067-1071.
- [9] Yaméogo B L M, Charlton D W, Doucet D, et al. Trends in optical span loss detected using the time series decomposition method[J]. Journal of Lightwave Technology, 2020, 38(18): 5026-5035.
- [10] Amanu A A. Macro bending losses in single mode step index fiber[J]. Advances in Applied Sciences, 2016, 1(1): 1-6.
- [11] McDowell E J, Cui X Q, Yaqoob Z, et al. A generalized noise variance analysis model and its application to the characterization of 1/f noise [J]. Optics Express, 2007, 15(7): 3833-3848.
- [12] Dong J, Huang J C, Li T, et al. Observation of fundamental thermal noise in optical fibers down to infrasonic frequencies[J]. Applied Physics Letters, 2016, 108(2): 021108.

[作者简介]



王郁 (1975-), 女, 中国信息通信研究院正高级工程师, 主要研究方向为光网络智能管控、自智光网络、光网络数字孪生、人工智能与光网络融合。



唐都 (1998-), 男, 博士, 中国信息通信研究院工程师, 主要研究方向为高速光通信、光网络通感一体、卫星光通信、光网络智能化。



李芳 (1974-), 女, 中国信息通信研究院正高级工程师, 主要研究方向为高速光通信、分组传送、4G/5G 移动承载和光网络智能化。



徐云斌 (1978-), 男, 博士, 中国信息通信研究院正高级工程师, 主要从事智能光网络新技术研究、标准研制、测试验证等工作。