



XXXX

光电解耦架构下自治光网络 OSNR 精准评估技术研究与应用展望

韩雨晴¹, 胡骞², 吕浙青¹, 朱显坤², 秦忻¹, 苏广楠², 龚雅栋¹

(1. 中国电信股份有限公司研究院, 北京 102209;

2. 中电信智能网络科技有限公司, 北京 102209)

摘要: 在光电解耦架构下, 光信噪比 (optical signal-to-noise ratio, OSNR) 评估面临精度不足、跨厂商场景适配困难和维护过度依赖人工等问题。本文围绕自治光网络中的 OSNR 精准评估技术开展研究, 并提出配套智能管控方案。基于人工智能 (artificial intelligence, AI) 技术, 对光层与电层参数进行解耦, 结合跨域自适应对齐来缓解多厂商设备间的异构偏移; 构建变换器 (Transformer) 与类别型梯度提升树 (CatBoost) 混合 OSNR 智能评估模型, 实现 OSNR 高精度估计。在此基础上, 将评估模型嵌入自治闭环机制, 形成覆盖“数据获取—OSNR 预测—异常判定—配置优化—迭代收敛—报告输出”的全流程自治体系。基于现网环境的实验结果显示, 该模型 OSNR 评估的平均绝对误差 (mean absolute error, MAE) 为 0.381 dB, 相比传统耦合模型精度提升 78.99%, 验证了该方法在光电解耦架构下支撑自治光网络智能管控的可行性。

关键词: 自治光网络; 光电解耦; OSNR 评估; 智能管控

中图分类号: TN915; TP302

文献标志码: A

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

Research on accurate OSNR estimation and application prospects for autonomous optical networks under decoupled optical-electrical framework

HAN Yuqing¹, HU Qian², LV Zheqing¹, ZHU Xiankun², QIN Xin¹, SU Guangnan², GONG Yadong¹

1. China Telecom Research Institute, Beijing 102209, China

2. China Telecom Intelligent Network Technology Co., Ltd., Beijing 102209, China

Abstract: In optical-electrical decoupled architectures, OSNR estimation methods suffer from inadequate accuracy, poor cross-vendor scenario adaptability, and heavy reliance on manual maintenance. This paper investigates precise OSNR assessment techniques for autonomous optical networks and proposes a corresponding intelligent management and control scheme. Drawing on AI technologies, we first decouple the optical-layer and electrical-layer parameters,

收稿日期: 2026-05-13; 修回日期: 2026-07-22

通信作者: 秦忻, qinx2@chinatelecom.cn

基金项目: 国家重点研发计划项目 (No.2023YFB2905400)

Foundation Items: The National Key Research and Development Program of China (No.2023YFB2905400)



and introduce cross-domain adaptive alignment to mitigate heterogeneous shifts across equipment from different vendors. A hybrid OSNR estimation model combining Transformer and CatBoost is then constructed to achieve high-accuracy estimation. By embedding this model into an autonomous closed-loop mechanism, we establish a full-process autonomous system, covering data acquisition, OSNR prediction, anomaly identification, configuration optimization, iterative convergence, and report generation. Experimental results from a live network environment show that the model achieves an MAE of 0.381 dB in OSNR estimation, corresponding to a 78.99% improvement in estimation accuracy over the conventional coupled model, thus verifying the feasibility of this approach for supporting intelligent management and control of autonomous optical networks under an optical-electrical decoupled architecture.

Key words: autonomous optical networks, optical-electrical decoupling, OSNR estimation, intelligent control

1 引言

随着算力网络、东数西算工程和大规模模型训练业务的部署,光网络正向超大容量、广域覆盖及多厂商互通的方向演进^[1-2]。其中,光电解耦架构将光传输层与电交换层在部署、运维和选型上独立开来,有助于摆脱单一厂商绑定,提升网络构建的灵活性,因此被视作下一代自治光网络的关键使能技术^[3]。

然而解耦也带来了新的问题:跨厂商设备的异构性突出,光层与电层各自的参数定义不统一,导致传统 OSNR 监测方法会引入较大的误差^[4];光纤色散、非线性效应、通道间串扰和器件噪声等物理损伤相互耦合,难以通过传统解析模型精准表现;运维流程依赖人工经验,配置调优、故障定位和性能优化等环节自动化水平不足;系统缺少端到端的闭环自治流程,难以实现全自动运维。

当前 OSNR 评估方法,如光谱分析法、带内监测法和解析模型法等大多数针对紧耦合传输系统,在光电解耦场景下的适用性下降^[5]。基于机器学习的 OSNR 估计算法虽在近年得到广泛关注^[6],但现有方案普遍未能有效处理多厂商场景下的光电特征分离和自动化运维等关键问题^[7-8],难以彻底满足自治光网络的管控需求。

基于上述背景,需建立一套标准化、可迭代闭环的业务数据处理机制,实现自动拆分光电配

置信息、性能分级预测,并对参数实施智能调优与迭代收敛,最终输出可追溯的维护记录。该思路可以形成 AI 驱动的性能评估与自治迭代闭环维护一体化框架。

本文主要贡献如下:

(1) 设计了配置参数获取与标准化表征处理方法,实现多源设备光/电层参数的标准化解析,为后续模型提供高质量输入。

(2) 提出了一种明显提升多厂商场景下 OSNR 估计精度的层级式 Transformer-CatBoost 混合 OSNR 智能评估模型。其中,Transformer 用于捕获参数间的长程依赖关系,最大均值差异(maximum mean discrepancy, MMD)实现跨厂商域的自适应对齐,CatBoost 则完成精细化回归预测。

(3) 构建了端到端自治迭代闭环运维体系,覆盖“数据获取—OSNR 预测—异常判定—配置优化—迭代收敛—报告输出”的完整流程。

基于上述思路开展了现网光电解耦环境验证,采集了涵盖三家主流设备厂商、多种配置组合的真实数据。本文所提模型的 OSNR 评估 MAE 为 0.381 dB,较传统方法精度提升 78.99%,同时可实现异常判定与配置迭代收敛的端到端自治。

2 总体架构

光传送网正向开放解耦方向演进,该架构下光电层管控面相互独立,参数属性与管控权限边

界明确。按管控属性可将链路参数分为两类：一类为光层可控参数，包括WSS端口衰减、光放大器增益及增益倾斜等，可通过标准化开放接口下发配置；另一类为电层可观测辅助参数，如FEC纠错统计、OTUk/ODUk端口误码计数等，仅支持读取运行数据，无法直接调控光层状态，但可间接反映光层传输质量，是OSNR评估的重要特征依据。

与传统光电耦合的系统相比，光电解耦架构的核心差异体现在参数可调性、控制粒度和跨厂商接口三个方面。一是参数可调性不同，耦合场景下参数大多由厂商私有算法管控，难以从外部调整；解耦场景下光层参数开放可调，电层则保留观测能力。二是控制粒度不同，耦合场景多为端到端链路级粗粒度调优；解耦场景支持逐节点、波长的细粒度调控，对OSNR评估的精度与通用性要求更高。三是跨厂商接口不同，耦合场景基本采用私有接口；解耦场景则基于标准化接口统一管控，但不同厂商硬件特性差异会导致特征分布偏移，产生域偏移问题。

结合光电解耦组网的实际特点以及自治光网络运维的需求，设计了一种三层递进式自治智能管控架构，自下而上贯通数据采集、特征治理、性能预测与运维闭环等核心环节。整体架构如图

1所示。

(1) 特征解耦与对齐层：面向多厂商异构设备并存的场景，首先完成业务数据的多源采集与清洗，为上层模型提供输入基础。针对光电解耦带来的设备类型差异、参数映射关系不统一等问题，建立跨层关联规则库，实现光层与电层数据的拆分。对参数命名和单位进行规范化处理，形成光电两层特征的统一表示，以降低后续模型在异厂商环境下的适配难度。

(2) 分层智能预测层：采用层级式Transformer-CatBoost混合OSNR智能评估模型，输入数据先由Transformer编码器进行序列建模，再通过MMD跨域自适应分布对齐，使不同厂商域的特征分布趋于一致。对齐后的特征与原始归一化特征进行融合后最终由CatBoost回归器完成OSNR高精度预测。

(3) 自治闭环与维护输出层：在获得OSNR预测结果后，通过迭代流程依次进行指标异常判定与配置参数调优，并在每轮迭代后重新评估，直至各项运行指标收敛至预设的可接受范围。达标后自动汇总操作日志形成可追溯的维护报告，从而减少运维过程中的人工参与度。




图1 面向开放解耦的自治光网络智能管控与自动维护架构



3 核心方法

3.1 概述

基于光电解耦架构的实际需求，构建了覆盖数据采集、特征处理、高精度预测和自治迭代闭环维护的全流程方法体系。将 Transformer 的长程特征捕获能力、MMD 的跨域自适应机制与 CatBoost 的梯度提升回归优势相结合，形成层级式 Transformer-CatBoost 混合 OSNR 智能评估模型。重点解决多厂商设备间弱标签与高噪声数据条件下的稳定估计，以及光层参数的长程耦合效应，从而在开放解耦光网络场景下实现较为准确的 OSNR 预测，为光网络自治运维提供核心技术方法。

3.2 特征解耦与对齐层

3.2.1 业务数据多源采集

结合光网络运维的实际场景，采用网络配置协议（NETCONF）等多协议协同方式完成核心数据采集，在保证时效的同时兼顾覆盖范围。采集对象分为以下三类：

（1）静态配置参数：包括设备型号、端口编号、调制格式、波长规划等。此类参数变动较少，按 24 小时周期轮询更新，维持与设备实际配置的同步即可。

（2）动态状态参数：涵盖发射功率、波长选择开关（wavelength selective switch, WSS）功率、光放大器增益、链路衰减等光层核心运行指标。这些参数直接反映光层状态变化，对 OSNR 波动敏感，因此采用 1 分钟/次的高频采集，以捕获其实时变化特征。

（3）历史性能数据：包括 OSNR 时序曲线、前向纠错（forward error correction, FEC）纠错计数、误码率（bit error rate, BER）等，用于模型训练、参数调优与性能验证。为保证时序对齐，其采集周期与动态状态参数保持一致。

3.2.2 光电分层数据拆分

光电解耦架构使得光层与电层参数天然分布在不同设备与接口中，需要按规则进行拆分，以便后续 OSNR 评估时能精准提取所需的光电层参数。拆分主要遵循以下规则：

（1）设备类型规则：光层设备负责光信号的放大、传输与波长调度；电层设备负责光电转换、编码调制、FEC 处理及业务调度。拆分时先根据设备角色确定参数归属于光层还是电层。

（2）参数映射规则：建立分类映射关系，将参数明确划入两个集合。光层参数以光层直接参数为主体，同时纳入部分可间接表征光层传输性能的电层可观测统计量用于 OSNR 的计算与评估，其中光层直接参数包括发射功率、WSS 功率、光放大器增益、链路衰减等；间接表征指标包括 FEC 纠错字节数（FEC 功能本身属于电层范畴，但其运行统计量可实时反映光层信号损伤程度）等。电层参数包括波特率、调制格式、传输时延等辅助特征参与模型训练，帮助提升跨场景的适配能力。

（3）跨层关联规则：构建光层与电层参数的关联索引，重点记录光层发射功率与电层调制格式、光层增益与电层 BER 等跨层映射关系。这些关联为后续特征工程中的派生特征构造提供物理层面的依据，也有助于增强模型预测结果的可解释性。

3.2.3 特征表征处理

由于不同厂商设备的参数命名和计量单位存在差异，拆分后的光电层数据还需要进行统一标准化处理，以消除量纲影响并弥合厂商间的表示鸿沟，保证模型输入的一致性。具体处理从以下三个方面展开：

（1）参数命名标准化：参照行业标准对光层和电层参数名称进行整理，例如将发射功率统一记为 Tx_Power，将 WSS 功率统一记为 WSS_Power，避免同一物理量因命名不一致而在后续

解析或对齐时错位。

(2) 单位标准化：对各类光电层参数采用统一计量单位，例如光功率统一使用分贝毫瓦 (decibel milliwatt, dBm)、增益统一使用分贝 (decibel, dB)、时延统一使用微秒 (microsecond, μs)，确保不同来源的参数值具有直接可比性，消除单位差异引入的数值偏差。

(3) 数值范围标准化^[9]：采用 Min-Max 归一化方法^[10]将各类参数值映射至[0, 1]区间，为后续模型训练提供数值稳定的输入。归一化公式如下：

$$x_{\text{norm}} = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (1)$$

其中， x 代表某参数的原始取值， $x_{\min}$ 与 $x_{\max}$ 分别对应该参数在全部样本中的最小观测值和最大观测值， x_{norm} 为标准化后的参数值。Min-Max 归一化主要用于数据预处理阶段的初步标准化，在后续模型训练与推理阶段，为进一步增强对异常值的鲁棒性，将改用鲁棒归一化 (RobustScaler) 方法对输入特征进行二次归一化处理，具体公式见式 (2)。标准化处理完成后，输出光层设备标准化配置数据集 $O = \{o_1, o_2, \dots, o_m\}$ 与电层设备标准化配置数据集 $E = \{e_1, e_2, \dots, e_n\}$ ，其中 m 为光层参数数量， n 为电层参数数量，便于后续模型读取与处理。

3.3 分层智能预测层

3.3.1 层级式 Transformer-CatBoost 混合 OSNR 智能评估模型整体架构

构建了一种层级式 Transformer-CatBoost 混合 OSNR 智能评估模型来解决光电解耦组网中跨厂商数据分布差异、参数间的强关联依赖等影响 OSNR 评估性能的主要问题。模型整体架构如图 2 所示，分为特征编码层、Transformer 编码层、CatBoost 回归层三大功能层级。原始特征在特征编码层完成特征分类、特征归一化、特征增强后，输出归一化特征。一路归一化特征输入

Transformer 编码层，实现时序序列建模与长程依赖捕获，并结合引入的 MMD 有域自适应机制对齐不同厂商设备的特征分布，输出深层特征；另一路归一化特征通过旁路接入 CatBoost 回归层，与深层特征拼接后输入 CatBoost 梯度提升回归器完成精细化拟合，最终输出 OSNR 预测值。




图2 层级式 Transformer-CatBoost 混合 OSNR 智能评估模型架构

3.3.2 特征编码层

光电解耦场景下，多厂商设备的特征分布存在显著差异（域偏移），且原始特征中包含数值、类别、序列等类型，直接输入模型会损害模型的适配稳定性和预测精度。因此，在模型训练前需要对标准化配置数据做进一步的特征归一化与增强处理。

(1) 特征分类：将光层和电层的标准化数据按属性分为三类：

1. 数值特征：如光功率、增益、衰减、光纤长度、波特率等，这类特征具有明确的数值含义，需进行归一化处理以消除量纲影响。

2. 类别特征：如设备厂商、调制格式、FEC 类型、光层设备型号等，这类特征无数值含义，



需进行编码处理以转换为模型可识别的形式。

3. 序列特征：如过去 1 小时的光功率变化、BER 变化曲线等，这类特征包含时间维度信息，需进行时序特征提取以捕捉动态变化规律。

(2) 异构特征归一化：针对上述三类特征分别采用不同的处理策略：

1. 数值特征：采用 RobustScaler 方法进行归一化^[11]，该方法对异常值具有较强的鲁棒性，避免异常值对归一化结果的影响，计算公式如下：

$$x_{\text{robust}} = \frac{x - Q_2}{Q_3 - Q_1} \quad (2)$$

其中， Q_1 、 Q_2 、 Q_3 分别表示参数的 25% 分位数、中位数与 75% 分位数， $Q_3 - Q_1$ 为四分位距 IQR。该归一化方式能够有效保留光层参数的原始分布特征，抑制异常值对归一化过程的干扰，为模型训练提供稳定性更强的输入数据。

2. 类别特征：采用目标编码方法进行编码，该方法将类别特征与目标变量（如 OSNR、BER）相关联，编码值为该类别下目标变量的均值，既避免了独热编码带来的维度爆炸问题，又能保留类别特征与目标变量的关联信息。

3. 序列特征：采用滑窗统计方法进行特征提取，设置滑窗大小为 10（对应 10 分钟的时序数据），提取每个滑窗内的最大值、最小值、均值、方差、峰峰值 5 类统计特征，将时序特征转换为静态特征，便于模型处理。

(3) 特征增强：除归一化与编码外，进一步从两个方向对特征做增强处理：

1. 特征交叉：将光层、电层的关联特征进行交叉组合，生成新的特征，例如光层接收功率与电层调制格式编码、光层增益与光纤损耗等，以显式引入跨层交互信息。

2. 随机噪声添加：对数值特征添加微量高斯噪声，增强模型对微小扰动的鲁棒性，避免模型过拟合。

完成上述处理后，形成光层增强特征集

O_{enhanced} 与电层增强特征集 E_{enhanced} ，作为后续预测模型的输入。

3.3.3 Transformer 编码层

参数间存在显著的长程耦合关系，例如发射功率的变化会经由链路衰减和各段放大器增益的联动对接收端 OSNR 产生协同影响，传统网络难以捕捉此类长程依赖。模型的特征编码部分采用堆叠式 Transformer 编码器，并引入可学习位置编码、残差连接与层归一化，以此缓解梯度消失和网络退化问题，具体结构如图 3 所示。

归一化特征序列首先通过可学习位置编码注入时序位置信息，保留数据的时序依赖关系；随后进入 N 层堆叠的 Transformer 编码块，逐层完成深层特征提取。单个 Transformer 块由多头注意力机制、残差连接与层归一化、前馈网络、残差连接与层归一化依次串联构成：

(1) 多头注意力机制：采用多头自注意力机制^[12]，并行捕捉参数间的不同维度关联特征，提升特征提取的全面性，注意力计算公式如下：

$$\text{Attention}(Q, K, V) = \text{softmax}\left(\frac{QK^T}{\sqrt{d_k}}\right)V \quad (3)$$

其中，Q（查询向量）、K（键向量）、V（值向量）均由投影后的特征序列通过独立的线性变换得到，映射至同一维度空间，以便进行后续的点积注意力计算； d_k 为每个注意力头的特征维度，通过除以 $\sqrt{d_k}$ 对点积结果进行缩放，可有效避免因值域过大导致的梯度消失或梯度爆炸问题。

(2) 残差与层归一化：为解决深层 Transformer 网络的退化问题，在多头自注意力层与前馈网络层均引入残差连接与层归一化机制，确保梯度稳定流动，提升模型的训练效果，计算公式如下：

$$x_{\text{out}} = \text{LayerNorm}(x_{\text{residual}} + \text{Transformer}(x)) \quad (4)$$

其中， x_{residual} 为残差分支通过线性投影将输入特征 x 映射至与 Transformer 输出相同的维度空间，




图3 Transformer编码层详细架构

以解决潜在维度不匹配问题；Transformer(x)为经过多头自注意力与前馈网络处理后的特征输出。将两者逐元素相加后，通过层归一化消除特征分布偏移，加速模型收敛，同时缓解深层网络中的退化问题，提升适配能力。

3.3.4 MMD有域自适应

针对光电解耦组网中多厂商设备硬件与配置差异所导致的数据分布偏移，在Transformer特征层后加入MMD最大均值差异机制，通过最小化源域与目标域特征分布的MMD距离来对齐不同厂商域，从而提升模型在多厂商异构场景下的适配能力。

(1) 计算公式：MMD将源域与目标域的特征映射至再生核希尔伯特空间（RKHS）^[13]，以两个分布在RKHS中的嵌入均值距离作为域差异的度量指标，本文采用径向基函数（radial basis function, RBF）高斯核计算MMD，可有效捕捉特征分布的非线性差异，计算公式如下：

$$\text{MMD}^2 = \frac{1}{N^2} \sum_{i,j=1}^N k(x_i, x_j) + \frac{1}{M^2} \sum_{i,j=1}^M k(y_i, y_j) - \frac{2}{NM} \sum_{i=1}^N \sum_{j=1}^M k(x_i, y_j) \quad (5)$$

其中，N、M分别为源域与目标域的样本数量， x_i 为源域样本特征， y_j 为目标域样本特征， $k(\cdot, \cdot)$ 为核函数。为有效捕捉多厂商设备间特征分布的非线性差异，本文采用多尺度RBF高斯核，通过多个不同带宽的高斯核加权组合，全面度量细粒度局部差异与全局分布偏移。多尺度RBF核的具体定义如式（6）所示：

$$k(x, y) = \frac{1}{K} \sum_{i=1}^K \exp\left(-\frac{\|x-y\|^2}{\sigma_i}\right), \sigma_i = \frac{\sigma_0}{2^i} \quad (6)$$

其中，K为核数量， σ_0 为初始带宽，根据源域与目标域特征分布的平均欧氏距离自动计算，以适应不同数据尺度；通过多个不同带宽的高斯核加权组合，可同时捕捉细粒度局部差异与全局分布偏移，提升MMD对多尺度域偏移的度量能力。

(2) 损失联合优化：模型训练采用MSE回归损失与MMD域适应损失联合优化，平衡模型的回归精度与跨域适配能力，联合损失函数如下：



$$\mathcal{L}_{\text{total}} = \text{MSE}(\hat{y}, y) + \alpha \cdot \text{MMD}(f_{\text{src}}, f_{\text{tgt}}) \quad (7)$$

其中, $\text{MSE}(\hat{y}, y)$ 为回归损失, 用于衡量模型 OSNR 预测值与真实值的偏差; $\text{MMD}(f_{\text{src}}, f_{\text{tgt}})$ 为域适应损失, 用于度量源域与目标域经 Transformer 提取后的特征分布差异。 α 为域适应权重, 在训练过程中采用线性预热策略动态调整, $\alpha = 0.3$ 为最终域适应权重, 前 30 轮采用线性预热策略, 从 0 线性增长, 使模型优先专注于回归任务的学习, 避免早期域适应损失干扰梯度更新; 预热结束后, 域适应损失以完整权重介入, 在保证高精度预测的同时, 增强模型对多厂商域偏移的抑制能力。

3.3.5 CatBoost 回归层

Transformer 编码器输出的深层特征主要反映参数间的长程耦合关系, 而经 RobustScaler 归一化的原始特征包含具体的物理参数信息, 两者结合可显著提升模型的预测精度。为此, 将两种特征进行拼接后输入 CatBoost 梯度提升回归器, 由其完成最终的 OSNR 预测, 兼顾预测精度与可解释性。

(1) 拼接输入: 将 Transformer 编码器输出的 128 维深层特征与 24 维归一化原始特征进行拼接, 得到 152 维拼接特征, 作为 CatBoost 回归器的输入^[14], 拼接公式如下:

$$X_{\text{cb}} = \text{Concat}(f_{\text{trans}}, X_{\text{scaled}}) \quad (8)$$

其中, f_{trans} 为 Transformer 提取的深层特征, X_{scaled} 为 RobustScaler 归一化后的原始 24 维特征, 拼接后的特征既包含参数间的长程关联信息, 又

保留原始物理参数的细节, 为高精度 OSNR 预测提供支撑。

(2) CatBoost 参数: CatBoost 采用有序提升机制, 能够原生处理类别特征, 并通过叶节点先验项抑制过拟合, 适合用于光网络场景下含噪声的 OSNR 回归任务。具体参数设置如表 1 所示。

(3) 损失函数: CatBoost 回归器采用均方误差 (MSE) 作为损失函数, 衡量模型预测值与真实 OSNR 值的偏差, 确保模型聚焦于提升预测精度, 损失函数公式如下:

$$\mathcal{L}_{\text{MSE}} = \frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2 \quad (9)$$

其中, N 为样本数量, y_i 为第 i 个样本的真实 OSNR 值, $\hat{y}_i$ 为第 i 个样本的 OSNR 预测值, 该损失函数可有效惩罚预测偏差较大的样本, 推动模型提升预测精度。

3.4 自治闭环与维护输出层

围绕层级式 Transformer-CatBoost 混合 OSNR 智能评估模型, 设计了覆盖“数据获取—OSNR 预测—异常判定—配置优化—迭代收敛—报告输出”的自治维护流程, 具体流程如图 4 所示。

(1) 数据获取: 采集设备的静态配置参数和动态状态参数, 在线构造模型所需的输入特征, 确保数据的实时性与完整性, 实时完成光电分层拆分与特征表征处理, 生成光层设备标准化配置数据集与电层设备标准化配置数据集。

(2) OSNR 预测: 将标准化配置数据集输入离线训练完成的混合模型进行在线推理, 单次推

表 1 CatBoost 回归层最优超参数设置

超参数名称	取值	说明
决策树数量	1000	迭代次数, 确保模型充分收敛
决策树深度	8	平衡模型拟合能力与适配能力
学习率	0.02	采用小学习率逐步更新模型参数, 避免过拟合
早停轮次	80	若连续 80 轮不下降则停止训练, 避免过拟合
L2 叶节点正则化系数	3.0	抑制模型过拟合
贝叶斯 Bootstrap 温度系数	0.5	控制贝叶斯 Bootstrap 采样的随机性, 值越大采样越均匀, 有助于增强模型适配能力



图4 自治迭代维护流程

理时延控制在 100 ms 以内，输出链路实时 OSNR 预测值 $\text{pred}_{\text{OSNR}}$ 。

(3) 异常判定：参考光网络运维规范设定链路正常传输阈值 $\text{OSNR}_{\text{th}} = 25 \text{ dB}$ 。若 $\text{pred}_{\text{OSNR}} \geq \text{OSNR}_{\text{th}}$ ，判定链路传输质量正常，直接跳转至报告输出环节；若 $\text{pred}_{\text{OSNR}} < \text{OSNR}_{\text{th}}$ ，判定链路信号劣化，进入光层参数自动调优分支。

(4) 配置优化策略：结合现网运维经验，为有效修正接收光功率并改善链路 OSNR，综合确定调整策略为调整发射功率、光放大器增益、WSS 衰减三类可控参数。参考行标 YD/T 3391-2018《光波分复用（WDM）系统总体技术要求》及中国电信波分设备技术规范设置可调参数范围以避免功率过冲引入光纤非线性损伤，发射功率调整范围为 $[-5, 5] \text{ dBm}$ ，光放大器增益调整范围为 $[10, 25] \text{ dB}$ ，WSS 衰减下限为 0 dB ^[15]。根据 OSNR 预测值与正常传输阈值的差值 $\Delta = \text{OSNR}_{\text{th}} - \text{pred}_{\text{OSNR}}$ 动态配置调整步长，仅当 $\Delta > 0 \text{ dB}$ 时执行调优，劣化差值越大单次调整幅度越高。参考行标 YD/T 1259-2003《波分复用系统（WDM）光安全进程技术要求》，结合现网工程运维操作经验设置两档调节步长：当 $\Delta < 3 \text{ dB}$ 时，采用小步长精细微调，步长设置为发射功率 0.2 dB 、光放大器增益 0.5 dB 、WSS 衰减 0.1 dB ； $\Delta \geq 3 \text{ dB}$ 时，采用较大步长加快收敛，步长设置为发射功率 0.5 dB 、光放大器增益 1.0 dB 、WSS 衰减 0.2 dB ^[16]。

(5) 迭代收敛判定：参数下发后预留 0.2 s 设备配置生效时延，重新采集链路数据并预测 OSNR，设置最大迭代轮次 $\text{Iter}_{\text{max}} = 5$ 。最大迭代次数的设定兼顾场景与现网维护时效要求。依据光网络工程系统性能指标规划，现网链路普遍预

留 $4.5 \sim 6 \text{ dB}$ OSNR 裕量^[17]，结合实际运维中 $3 \sim 5 \text{ dB}$ 的典型 OSNR 劣化幅度与本文调优步长，5 次迭代的累计调节量可覆盖绝大多数 OSNR 异常场景。同时设置迭代上限可避免调优流程陷入死循环，若迭代过程中 OSNR 满足阈值要求则直接终止调优；若达到最大迭代次数仍未达标，标记链路为阈值异常并生成需人工介入告警。

(6) 报告输出：将每轮迭代的 OSNR 预测结果、异常判定记录、配置调整方案及迭代收敛过程等信息整理为维护报告，为后续分析、模型优化提供数据支撑。

完整自治维护流程的标准化定义如算法 1 所示。

4 实验设计与结论

4.1 概述

为评估层级式 Transformer-CatBoost 混合 OSNR 智能评估模型的预测精度、跨厂商场景适配效果及现网部署可行性，同时检验全流程闭环自治体系在实际运维环境中的运行效果，基于中国电信自研盒式波分设备及管控系统，在现网光电解耦环境下采集真实运行数据开展实验。

4.2 数据集

实验数据集来源于多厂商光电解耦现网部署场景，拓扑图如图 5 所示，涵盖 A、B、C 三家主流设备厂商的运行数据。

具体数据集信息如下：

(1) 原始数据：包含 300 种配置组合，覆盖不同波长规划、链路长度以及光/电层设备参数设置，具体数据集核心信息如表 2 所示；

(2) 输入特征：构造 24 维光电特征（17 维

**算法1：自治闭环与维护输出算法**

输入：链路标识LinkID，初始设备参数集合DevParam，OSNR正常阈值 $OSNR_{th} = 25$ dB，最大迭代次数 $Iter_{max} = 5$
输出：迭代报告Report，链路最终OSNR值 $final_{OSNR}$

```

1: IterRecord =  $\emptyset$ , IterCount = 0, ConvergeFlag = False //初始化
2: While IterCount <  $Iter_{max}$  and ConvergeFlag = False do
3:   RawData  $\leftarrow$  CollectDeviceData(LinkID) //采集设备原始数据
4:   EnFeature  $\leftarrow$  FeatureNorm(RawData) //标准化处理
5:    $pred_{OSNR} \leftarrow$  Transformer-CatBoost(EnFeature) //混合模型预测OSNR
6:   IterRecord  $\leftarrow$  IterRecord  $\cup$  {IterCount,  $pred_{OSNR}$ , DevParam} //记录本轮迭代信息
7:   if  $pred_{OSNR} \geq OSNR_{th}$  then
8:     ConvergeFlag  $\leftarrow$  True //链路指标达标，终止迭代循环
9:     break
10:  else
11:     $\Delta \leftarrow OSNR_{th} - pred_{OSNR}$  //计算当前差值
12:    if  $\Delta < 3$  then
13:      TxStep = 0.2, GainStep = 0.5, WSSStep = 0.1 //微调
14:    else
15:      TxStep = 0.5, GainStep = 1.0, WSSStep = 0.2 //快速收敛
16:    end if
17:    DevParam.TxPower  $\leftarrow$  min(DevParam.TxPower+Tx-Step, 5)
18:    DevParam.AmpGain  $\leftarrow$  min(DevParam.AmpGain+Gain-Step, 25)
19:    DevParam.WSSAtt  $\leftarrow$  max(DevParam.WSSAtt-WSSStep, 0)
20:    SendConfig(LinkID, DevParam), 等待设备生效时延0.2 s //下发配置并等待生效
21:    IterCount  $\leftarrow$  IterCount + 1
22:  end if
23: end while
24:  $final_{OSNR} \leftarrow pred_{OSNR}$ 
25: if ConvergeFlag = True then
26:   AlarmLevel  $\leftarrow$  "正常"
27: else
28:   AlarmLevel  $\leftarrow$  "阈值异常，需人工介入"
29: end if
30: Report  $\leftarrow$  GenReport(LinkID, IterRecord,  $final_{OSNR}$ , AlarmLevel) //生成可维护报告
31: return Report,  $final_{OSNR}$ 

```

1. 基础17维特征：4维核心物理与间接特征参数（发射功率、WSS功率、光放大器功率、FEC纠错字节数）直接表征光信号的传输状态，是评估OSNR的核心依据；其余13维为各段光放大器增益与链路衰减参数，覆盖BA（booster amplifier）、LA1（line amplifier 1）等关键放大段的增益与衰减数据，用以反映信号沿链路的功率演化。

2. 派生7维物理特征：从基础特征经物理关系计算得到，包括各段净增益（如BA段净增益、LA1段净增益）、总净增益、入纤功率估计值、总损耗估计以及FEC压力因子等，这些特征引入了传输过程中的物理约束和先验知识，有助于改善模型的解释性和预测稳定性。

（3）目标变量：OSNR值，取值范围为10~40 dB，覆盖从正常到严重异常的多种链路状态，其真实值由仪表直接测量获取。

（4）数据划分：采用60%训练集、20%验证集、20%测试集的划分比例，对应样本量分别为180条、60条、60条。首先，划分时以不同光电跨厂商组网配置及线路侧速率为分层变量，通过分层抽样随机抽取20%的样本作为测试集，保证测试集中各组网样本占比与原始数据集一致；随后，将剩余80%的样本按3:1比例随机拆分为训练集（60%）和验证集（20%）。所有划分操作均在特征处理与模型训练前完成，可有效避免跨集信息泄露，适配多厂商现网部署的评估需求。

基础特征+7维派生特征）作为模型输入：




图5 现网光电解耦环境数据实验拓扑图

表2 数据集核心信息统计

统计维度	详细参数说明	分布
样本规模	配置组合总样本量 不同厂商样本分布	300 条 光电跨厂商组网配置（光电解耦架构）： 1. 厂商A电层设备+厂商C光层设备：150 条 2. 厂商B电层设备+厂商C光层设备：150 条
链路基础配置	光路跳数 光纤总长度	固定 3 跳 固定 75 km
传输制式	线路侧速率 调制格式	200 Gbps、400 Gbps 各 150 条（两类光电跨厂商组网配置各对应 75 条） QPSK、16QAM
波长覆盖	通道数量与频率范围	频率范围 191.4 THz - 196.1 THz，共 48 波，信道间隔 100 GHz（0.1 THz）
OSNR 实际值获取	测量标准与设备 测量精度	采用高精度光谱分析仪（OSA）直接测量，符合 ITU-T 相关测试标准 OSA 测量误差 $\leq \pm 0.1$ dB
核心参数范围	发射功率范围	-7.29 dBm - 7.00 dBm

4.3 对比方法及评价指标

4.3.1 对比模型

针对层级式 Transformer-CatBoost 混合 OSNR 智能评估模型设置以下对比实验模型：

（1）耦合传统多层感知机（multilayer perceptron, MLP）模型：作为传统机器学习方法的代表，采用 MLP 构建 OSNR 评估模型，加入批量归一化与正则化，优化模型训练稳定性，无域适应机制、无 Transformer 编码器、无 CatBoost 回归器；

（2）解耦有域适应 MLP 模型：为验证 MMD 有域自适应机制的有效性，构建解耦有域自适应的 MLP 模型，采用 MLP 作为特征提取器，加入 MMD 域适应机制与回归头，无 Transformer 编码器、无 CatBoost 回归器；

（3）解耦无域适应 Transformer 模型：为验证 Transformer 编码器的长程特征捕获能力与 MMD 域适应机制的必要性，构建解耦无域适应的 Transformer 模型，采用纯 Transformer 编码器+回归头结构，无 MMD 域适应机制、无 CatBoost 回归器；

（4）解耦有域适应 Transformer 模型：为验证域适应权重的影响及 CatBoost 回归器的作用，构建 Transformer 及 MMD 简化版模型，模型架构与

本文完整模型一致，仅降低域适应强度。

4.3.2 评价指标

结合 OSNR 评估的工程需求与评价规范，采用 MAE 作为核心评价指标，用于衡量模型预测值与真实值的偏差，MAE 越小，模型预测精度越高，单位为 dB，计算公式如下。

$$MAE = \frac{1}{N} \sum_{i=1}^N |y_i - \hat{y}_i| \quad (10)$$

同时以耦合传统 MLP 模型为基准，计算各模型的精度提升率，量化模型的性能优势。

4.4 核心对比实验结果

所有模型在同一数据集、相同随机种子、相同硬件环境下训练，确保实验对比的公平性。

层级式 Transformer-CatBoost 混合 OSNR 智能评估模型及 4 个对比模型在测试集 60 条样本上的预测 OSNR 与真实 OSNR 的散点分布如图 6 所示，各模型 OSNR 预测值的误差分布如图 7 所示，各模型 MAE 对比及精度提升率如图 8 所示。

层级式 Transformer-CatBoost 混合 OSNR 智能评估模型的预测误差集中程度最高，分布峰值紧邻零误差位置且整体覆盖区间最窄，其余对比模型的误差分布更为分散且部分模型存在显著的系统性偏移。各模型具体 MAE 指标及精度提升率结果如表 3 所示：




图6 各模型预测 OSNR 与真实 OSNR 的散点分布图




图7 各模型 OSNR 预测值的误差分布图

核心对比实验结果表明,解耦有域适应MLP模型较耦合传统MLP模型精度提升32.41%,验证了MMD域适应机制在跨厂商数据分布对齐中的有效性;解耦无域适应Transformer模型精度提升65.21%,验证了Transformer编码器对光链路参数长程依赖关系的高效特征捕获能力;解耦有域适应Transformer模型精度提升68.41%,验证了融合方案的协同增益。本文所提层级式Transformer-CatBoost混合OSNR智能评估模型整

体测试MAE为0.381 dB,较耦合传统MLP模型精度提升78.99%,显著优于其他对比模型,充分验证了所提混合架构的先进性与有效性。

4.5 消融实验设计与结果

为明确层级式Transformer-CatBoost混合OSNR智能评估模型中各关键模块的独立贡献,本文开展系统消融实验。在完整模型的基础上,分别移除各核心模块设计四种消融配置,不同消融配置的MAE差异如图9所示。




图8 各模型MAE对比柱状图

表3 各模型评价指标对比

模型	MAE (dB)	精度提升率
耦合传统MLP模型	1.814	(基线)
解耦有域适应MLP模型	1.226	↑ 32.41%
解耦无域适应Transformer模型	0.631	↑ 65.21%
解耦有域适应Transformer模型	0.573	↑ 68.41%
层级式Transformer-CatBoost混合OSNR智能评估模型 (本文模型)	0.381	↑ 78.99%

各消融配置下的MAE指标及精度下降率如表4所示:

单次消融实验结果表明,去除MMD域适应模块精度下降5.77%,说明域适应机制有效缓解了跨厂商数据分布差异,提升了模型的跨厂商适配效果;去除派生特征时模型精度下降7.34%,验证了基于光链路物理规律构造的派生特征对OSNR评估精度的辅助增益作用;去除CatBoost

顶层回归器仅使用Transformer直接回归时精度下降达49.34%,验证了CatBoost对高层语义特征的非线性拟合能力是提升评估精度的核心环节;同时去除MMD与CatBoost模块时,模型精度进一步下降至57.21%,表明域适应与集成回归模块的协同作用,对模型整体性能具有关键支撑作用。

为排除数据随机划分、参数初始化带来的偶然性结果,共完成10次全样本随机打乱的独立重

表4 四种消融配置评价指标对比

消融配置	描述	MAE (dB)	精度下降率
本文模型	Transformer + MMD + CatBoost + 全特征	0.381	(基线)
无MMD	去除MMD域适应,仅用MSE训练	0.403	↓ 5.77%
无派生特征	去除7维派生特征,保留17维基础特征	0.409	↓ 7.34%
无CatBoost	去除CatBoost,Transformer直接回归	0.569	↓ 49.34%
无MMD+无CatBoost	同时去除MMD域适应和CatBoost	0.599	↓ 57.21%




图9 四种消融配置MAE差异柱状图

复实验，进一步验证模型性能的稳定性与统计严谨性。统计10次实验的MAE均值与95%置信区间，结果如表5所示：

10次独立重复消融实验结果表明，各消融配置下的结果与单次实验一致。移除核心模块均会造成MAE均值升高，其中CatBoost模块对评估精度影响最为显著；95%置信区间验证了模型性能的统计稳定性，能够排除数据随机划分、参数初始化带来的偶然波动。

4.6 闭环自治流程验证

为验证全流程闭环自治体系在现网环境中的实际运行能力，基于现网光电解耦实验环境设计了闭环压测实验。具体验证过程如下：

(1) 从测试集中抽取20组正常样本，通过

网管系统向设备注入发射功率衰减、放大器增益偏移等异常扰动，使真实OSNR降低至15~20 dB区间，以此触发闭环流程。

(2) 系统按照3.4节所述六步机制依次执行特征采集、OSNR预测（层级式Transformer-CatBoost混合OSNR智能评估模型）、阈值比对、参数调整与迭代优化，并通过网管接口将调整指令下发至设备，整个闭环过程在现网模拟环境中完成。

(3) 以人工仪表实测OSNR为基准，主要测试异常判定准确率、配置优化后的OSNR达标率、平均迭代轮次以及单次闭环耗时。

实验结果表明：20组异常注入全部被正确判定为异常；经自动配置优化后，18组样本的

表5 消融实验重复测试统计结果(10次独立重复实验)

消融配置	描述	MAE 均值 (dB)	95% 置信区间 (dB)
本文模型	Transformer + MMD + CatBoost + 全特征	0.379	[0.356,0.402]
无 MMD	去除 MMD 域适应，仅用 MSE 训练	0.407	[0.386,0.428]
无派生特征	去除 7 维派生特征，保留 17 维基础特征	0.429	[0.397,0.461]
无 CatBoost	去除 CatBoost，Transformer 直接回归	0.552	[0.519,0.585]
无 MMD+无 CatBoost	同时去除 MMD 域适应和 CatBoost	0.621	[0.578,0.664]

OSNR 恢复至 25 dB 以上, 达标率 90%; 平均迭代 1.8 轮即可收敛至正常阈值; 单次闭环全流程平均耗时约 1.2 s, 在工程运维可接受的时间范围内。各轮的预测结果、参数调整记录及最终运行状态均按规范自动生成维护报告并存入运维平台, 初步验证了该闭环自治系统在现网环境中的可行性与稳定性。

4.7 实验结论

综合核心对比实验、消融实验及闭环自治流程验证结果, 可得出以下结论:

(1) MMD 域适应机制能有效缓解跨厂商数据分布差异, 与 Transformer 架构协同可进一步放大性能增益, 在多厂商光电解耦架构的应用场景下, 能够降低异构设备带来的重复建模成本。

(2) Transformer 编码器对参数的长程依赖关系具备高效特征捕获能力, 是实现高精度 OSNR 评估的基础支撑。

(3) 基于光链路物理规律构造的派生特征, 能够有效辅助提升模型评估精度。

(4) CatBoost 顶层回归器对高层语义特征的非线性拟合能力, 是决定模型整体性能的核心环节, 其与域适应模块的协同作用对最终效果至关重要。

(5) 依托混合模型构建的自治迭代闭环维护体系, 在异常注入实验中判定准确率达到 100%, 经平均 1.8 轮迭代后 OSNR 达标率 90%, 验证了全流程闭环自治系统在光电解耦现网环境中的工程可行性与稳定性。

以上实验表明, 本文所提出的层级式 Transformer-CatBoost 混合 OSNR 智能评估模型及配套自治闭环机制, 在开放解耦光网络现网条件下能够兼顾预测精度与自动化运维需求, OSNR 评估精度相较耦合传统 MLP 方法提升 78.99%。该方案用于光网络管控系统, 推动运维模式从被动响应向主动自治演进, 为开放解耦场景下的智能管控提供一条可行的技术路径。

5 应用展望

本方案未来可在现有基础上, 向通感算融合^[18]、大小模型协同^[19]、全生命周期自智三大方向持续演进:

(1) 探索 OSNR 评估与光链路感知、网络算力调度的深度结合, 向通感算融合方向延伸, 为通传一体化光网络的动态资源优化提供评估依据。

(2) 研究轻量化模型在边缘节点的快速推理部署, 与云端大模型形成大小模型协同, 以适应不同场景下的算力和时延约束;

(3) 引入持续学习与在线微调机制, 使模型能够跟随网络扩容、设备迭代等变化自适应更新, 逐步覆盖从训练、部署到运维的全生命周期。

6 结束语

针对光电解耦架构下跨厂商 OSNR 评估面临的域偏移、参数长程耦合及高噪声等挑战, 本文提出了一种层级式 Transformer-CatBoost 混合 OSNR 智能评估模型, 并配套构建了闭环自治运维流程。现网实验结果显示, 该方案的 OSNR 评估 MAE 为 0.381 dB, 相比耦合传统 MLP 方法精度提升 78.99%, 在跨厂商解耦场景适配能力和运维自动化程度上均表现出优势。未来工作将围绕通感算融合、大小模型协同及模型持续进化等方向展开, 以进一步适配开放解耦光网络的动态管控需求。

参考文献:

- [1] FABREGA J M, et al. Experimental demonstration of a metro area network with terabit-capable sliceable bitrate variable transceiver using direct modulated VCSELs and coherent detection[C]//Proceedings of 2022 Optical Fiber Communications Conference and Exhibition (OFC). Piscataway: IEEE Press, 2022: 1-3.




- [2] JIANG X T, QIN X, et al. Grey-box digital twin model for QoT estimation in field-deployed networks[C]//Proceedings of 2026 Optical Fiber Communication Conference (OFC). Piscataway: IEEE Press, 2026: 1-3.
- [3] BORRACCINI G, et al. Experimental demonstration of partially disaggregated optical network control using the physical layer digital twin[J]. IEEE Transactions on Network and Service Management, 2023, 20(3): 2343-2355.
- [4] D'AMICO A, et al. Enhancing lightpath QoT computation with machine learning in partially disaggregated optical networks[J]. IEEE Open Journal of the Communications Society, 2021, 2: 564-574.
- [5] DONG Z, et al. Optical performance monitoring: A review of current and future technologies[J]. Journal of Lightwave Technology, 2016, 34(2): 525-543.
- [6] MORETTE N, et al. Machine learning enhancement of a digital twin for wavelength division multiplexing network performance prediction leveraging quality of transmission parameter refinement[J]. Journal of Optical Communications and Networking, 2023, 15(6): 333-343.
- [7] PAOLUCCI F, et al. Peer-to-peer disaggregated telemetry for autonomic machine-learning-driven transceiver operation[J]. Journal of Optical Communications and Networking, 2022, 14(8): 606-620.
- [8] LI J J, et al. Reservoir computing for few-mode fiber channel OSNR monitoring in deep learning frameworks[J]. IEEE Photonics Journal, 2025, 17(2): 1-7.
- [9] AHSAN M M, et al. Effect of data scaling methods on machine learning algorithms and model performance[J]. Technologies, 2021, 9(3): 52.
- [10] 杨寒雨, 赵晓永, 王磊. 数据归一化方法综述[J]. 计算机工程与应用, 2023, 59(3).
- YANG H Y, ZHAO X Y, WANG L. Review of data normalization methods [J]. Computer Engineering and Applications, 2023, 59(3).
- [11] ALHADIDI T I, et al. Enhancing pavement crack classification with bidirectional cascaded neural networks[C]//Proceedings of 2025 IEEE International Conference on Advanced Systems and Emergent Technologies (IC_ASET). Piscataway: IEEE Press, 2025: 1-6.
- [12] VASWANI A, et al. Attention is all you need[C]//Proceedings of 2017 Neural Information Processing Systems (NIPS). Long Beach: Curran Associates Inc., 2017.
- [13] GRETTON A, et al. A kernel two-sample test[J]. Journal of Machine Learning Research, 2012, 13: 723-773.
- [14] PROKHORENKOVA L, et al. CatBoost: unbiased boosting with categorical features[C]//Proceedings of the 32nd International Conference on Neural Information Processing Systems (NeurIPS). Piscataway: IEEE Press, 2018: 6639-6649.
- [15] CHINA COMMUNICATIONS STANDARDS ASSOCIATION. General technical requirements for optical wavelength division multiplexing systems: YD/T 3391-2018 [S]. 2018.
- [16] CHINA COMMUNICATIONS STANDARDS ASSOCIATION. Technical specification for optical safe procedure for Wavelength Division Multiplexing (WDM) system: YD/T 1259-2003[S]. 2003.
- [17] 叶胤, 汪令全. 骨干光网络工程系统性能指标分析[J]. 邮电设计技术, 2022 (11): 65-69.
- YE Y, WANG L Q. Analysis of system performance indexes in backbone optical network engineering[J]. Designing Techniques of Posts and Telecommunications, 2022 (11): 65-69.
- [18] WANG Z, et al. Integrated sensing and communication (ISAC) in optical fiber networks: Current research and challenges[C]//Proceedings of 2025 International Conference on Advanced Information and Communication Technology (ICAIT). Piscataway: IEEE Press, 2025: 1-5.
- [19] BAO T, et al. Joint optimization of DNN model partitioning and slice delivery for distributed edge-cloud inference over optical networks[J]. Journal of Optical Communications and Networking, 2025, 17(11): 1047-1058.

[作者简介]



韩雨晴 (1995-), 女, 硕士, 中国电信股份有限公司研究院, 工程师, 科研人员, 主要研究方向为光网络智能运维技术, 光传送网数字孪生模型等。



胡骞 (1988-), 男, 博士, 中电信智能网络科技有限公司, 高级工程师, 传输网产品线副总经理, 主要研究方向为开放光网络、智能光网络、光网络管控系统及相关标准制定等。



吕浙青 (1997-), 女, 硕士, 中国电信股份有限公司研究院, 工程师, 科研人员, 主要研究方向为光网络智能运维技术、光网络智能化算法等。



朱显坤 (1996-), 男, 硕士, 中电信智能网络科技有限公司, 工程师, 科研人员, 主要研究方向为SDN与软件系统架构设计、传输网管控技术等。



秦忻 (1995-), 女, 博士, 中国电信股份有限公司研究院, 工程师, 科研人员, 主要研究方向为光网络智能运维技术、光网络通感一体技术及相关标准制定等。



苏广楠 (1987-), 男, 硕士, 中电信智能网络科技有限公司, 高级工程师, 科研人员, 主要研究方向为 SDN 与软件系统架构



设计、传输网管控技术等。

龚雅栋 (1985-), 男, 硕士, 中国电信股份有限公司研究院, 高级工程师, 传输网络研究中心副总监, 主要研究方向为光传送网 (OTN) 与光业务单元 (OSU)、高速光通信与光模块技术、智能算力网络协同等。