

doi:10.13756/j.gtxyj.2025.240047.

光通信系统与网络技术

陈丽萍,廖亮,张鹏,等.基于机器学习的OTN网络性能劣化预测[J].光通信研究,2025(2):240047.

Chen L P, Liao L, Zhang P, et al. Machine Learning based OTN Network Performance Degradation Prediction [J]. Study on Optical Communications, 2025(2): 240047.

基于机器学习的 OTN 网络性能劣化预测

陈丽萍¹,廖亮²,张鹏^{2,3},朱德瀚¹,彭智聪¹,周浩¹

(1.烽火通信科技股份有限公司,武汉 430074;2.中国信息通信科技集团,武汉 430074;

3.华中科技大学电子信息与通信学院,武汉 430074)

摘要:【目的】文章旨在解决光传送网(OTN)网络性能劣化(即误码)预测难题。OTN误码类性能值依赖于OTN帧开销中的比特交叉奇偶校验(BIP)字节检测,并由网络管控系统周期性统计计算得出。在OTN网络正常运行的绝大多数情况下,误码类性能值保持为零,这无疑为传统方法及最新人工智能(AI)技术预测OTN误码相关性能带来了挑战。【方法】文章提出了一种利用OTN光层与电层之间对应关系进行误码概率预测的方法。首先,借助深度学习技术预测光信道误码率(BER)的变化趋势;随后,基于预测的光信道BER,运用文章所提机器学习模型进一步预测OTN误码概率。【结果】通过仿真实验验证,该方法的预测准确性超过90%。【结论】文章所提方案达到了工程化应用的要求,为OTN网络性能劣化预测提供了新的有效方法,并为OTN网络预测性维护提供了有力依据。

关键词:光传送网;帧误码率预测;光信道误码率预测;长短期记忆网络;逻辑回归

中图分类号:TN929

文献标志码:A

Machine Learning based OTN Network Performance Degradation Prediction

CHEN Liping¹, LIAO Liang², ZHANG Peng^{2,3}, ZHU Dehan¹, PENG Zhichong¹, ZHOU Hao¹

(1. FiberHome Telecommunications Co., Ltd., Wuhan 430074, China; 2. China Information and Communications Technology Group Corporation, Wuhan 430074, China; 3. School of Electronic Information and Communications, Huazhong University of Science and Technology, Wuhan 430074, China)

Abstract: 【Objective】This paper aims to address the challenge of predicting performance degradation (frame transmission errors) in Optical Transport Network (OTN). Frame error performance metrics in OTN rely on the detection of Bit Interleaved Parity (BIP) bytes in OTN frame overhead, which are periodically calculated by network management systems. In the vast majority of cases where the OTN network operates normally, the error-related performance values remain zero, which undoubtedly poses a challenge for both traditional methods and the Artificial Intelligence (AI) technologies in predicting OTN error-related performance. 【Methods】This paper proposes a creative approach to predict error probability by leveraging the correspondence between the optical and electrical layers in OTN. Firstly, deep learning techniques are used to predict the trend of Bit Error Rates (BER) in optical channels. Subsequently, based on the predicted BER in optical channels, the proposed machine learning models are employed to further predict the frame error probability in OTN. 【Results】Verified through simulation experiments, the prediction accuracy of this method exceeds 90%. 【Conclusion】The proposed solution meets the requirements for engineering applications, providing a new and effective method for predicting performance degradation in OTN networks. It also provides a strong basis for predictive maintenance of OTN networks.

Key words: OTN; frame error probability prediction; optical channel BER prediction; long short-term memory; logistic regression

0 引言

光纤通信技术^[1]作为信息社会的基石,承载着互联网、第四/五代移动通信技术(4th/5th Generation Mobile Communication Technology, 4G/5G)以及电力和金融等行业网络的数据传输任务。光传送网(Optical Transport Network, OTN)^[2-4]是一种高性能的光纤通信网络技术,特别适用于长距离和大

容量的数据传输,其在现代通信网络中发挥着至关重要的作用,为社会的信息化进程提供了坚实的技术支撑。

OTN网络故障一旦发生,将对最终用户业务产生严重影响。因此,在OTN网络故障发生前,及时预测潜在问题,确保用户对网络故障零感知,一直是电信运维领域面临的重要挑战^[5]。据相关统计数据显示,高达60%的OTN网络故障源于误码类问

收稿日期:2024-04-22; 修回日期:2024-05-09; 纸质出版日期:2025-04-10

基金项目:湖北省重点研发计划资助项目(2024BAB029)

作者简介:陈丽萍(1986-),女,湖北荆州人。高级工程师,硕士,主要研究方向为传送网管控和人工智能应用。

通信作者:张鹏,高级工程师。E-mail:hustzhangpeng@hust.edu.cn

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

题^[6]。在 OTN 中误码类性能值是通过 OTN 帧结构中的比特交叉奇偶校验(Bit Interleaved Parity, BIP)开销字节检测,再根据国际电信联盟-电信标准化部门(International Telecommunication Union-Telecommunication Standardization Sector, ITU-T)所定义的标准和方法在网络管控系统中进行计算,并周期性统计上报^[7]。

然而,在 OTN 正常运行时,大部分误码类性能值为零,这使得传统方法以及最新的人工智能(Artificial Intelligence, AI)技术难以直接对 OTN 误码相关性能进行预测。为解决这一问题,本文提出了一种创新性的方法,利用 OTN 光层与电层的对应关系,通过深度学习预测光信道误码率(Bit Error Rate, BER),并进而利用预测的光信道 BER,通过机器学习模型预测 OTN 误码概率。仿真实验结果表明,该方法的 OTN 误码预测准确性超过 90%,为工程化应用奠定了坚实基础。这一研究成果为 OTN 的预测性维护奠定了基础,对保障用户业务连续性具有重要意义。

1 利用光信道 BER 预测 OTN 帧误码的方案

在网络运维实践中,光传送单元(Optical Transport Unit, OTU)层的误码通常作为 OTN 帧误码或 OTN 误码的表征。为了多维度描述 OTN 误码的相关性能,ITU-T G. 798 标准^[8]基于 OTN 帧的 BIP-8 开销字节定义了一系列与误码相关的性能参数,包括 BIP 误码、误码块(Error Block, EB)、背景块误码(Background Block Error, BBE)、误码秒(Error Seconds, ES)、严重误码秒(Severe Error Seconds, SES)以及不可用时间(Un-Available Time, UAT)。在网络管理系统中,这些性能参数通常以固定的时间周期(如 15 min 和 24 h 等)进行定期计算和统计。当误码类性能值为“0”时,表示当前网络无误码,网络性能良好;若误码类性能值为非“0”,则表明存在误码,网络性能下降,需采取必要的维护措施以恢复网络性能。


随着 AI 技术的快速发展,机器学习和深度学习在数据特征挖掘和趋势预测方面展现出了卓越的性能。然而,在 OTN 误码相关性能的预测方面,仍面临巨大挑战。网络在大部分运行时间内,其误码性能值维持在“0”状态。因此,直接使用这些误码性能值进行误码趋势预测变得极具挑战性。

然而,根据实际网络运维经验统计,OTN 误码

问题 90% 以上的根源在于光域问题。为此,本文创新性地提出了利用光信道 BER 来预测 OTN 帧误码概率的方法。这一方法的可行性主要基于以下两点理论和实践基础:

首先,光信道 BER 呈现出连续变化的特性,这一特性使得我们可以利用机器学习或深度学习算法来有效地预测光信道 BER 的趋势;

其次,OTN 采用的是“分层”架构^[7-9],OTU 开销监控的电域帧信号范围与光域光信道范围是一致的,如图 1 所示。



注:ROADM 为可重构光分插复用器;OLA 为光线路放大器;OTS 为光学传输段层;OMS 为光复用段层;OCh 为光通道;ODU 为光数据单元。

图 1 OTN 组网结构

Figure 1 OTN networking architecture

因此,本文提出了一种实现 OTN 帧误码的预测方法。该方法首先借助机器学习或深度学习算法,对未来特定时间段内的光信道 BER 进行预测;随后,通过机器学习算法构建光信道 BER 与帧误码之间的关系模型;最终,依据预测所得的光信道 BER,计算出未来时段的帧误码概率。

关于 OTN 帧误码与光信道 BER 之间的关系,需要进一步阐述。在 OTN 帧结构中,除了帧头部分的开销外,帧的末尾部分包含了 OTU 前向纠错(Forward Error Correction, FEC)^[9]开销。FEC 通过在发送端向帧数据流中添加特定的纠错码(也称为冗余码或校验码),使得接收端具备检测并纠正一定数量比特错误的能力。因此,即便在光域 BER 不为零的情况下,OTN 帧仍能在一定范围内确保数据的无误码传输。这一机制对于提高数据传输的可靠性和稳定性具有重要意义。

2 光信道 BER 的预测算法

光信道 BER 作为一种典型的时间序列数据,其预测方法主要包括以自回归差分移动平均(Auto Regressive Integrated Moving Average, ARIMA)^[10]为代表的机器学习算法以及以循环神经网络(Recurrent Neural Network, RNN)^[11]为代表的深度学习算法。

应用 ARIMA 模型最重要的是数据的“平稳

性”，而光信道 BER 数据恰恰不满足数据的“平稳性”。因此，在利用 ARIMA 算法对光信道 BER 进行机器学习训练时，需首先解决数据“平稳性”的问题。文献[12]提出的数据对数化、数据动态偏置、数据幂指变换和数据差分的方法组合解决了光信道数据平稳性的问题。利用文献[12]所提方法可实现利用 ARIMA 模型对光信道 BER 的预测。由仿真实验结果可知，在短期光信道的预测上可以达到较高的预测精度(如图 2 所示)，但对于长期的预测，会出现“均值填充”的情况(如图 3 所示)，无法捕捉到长期趋势或结构变化。另外，由于 ARIMA 模型的性能高度依赖于参数 (p, d, q) (p 为 ARIMA 模型中自回归部分的阶数，即模型中使用的过去观测值的数量； d 为对时间序列数据进行差分的次数，以使其变为平稳序列； q 为 ARIMA 模型中移动平均部分的阶数，即模型中使用的过去误差项的数量。)的选择^[10,12]，为了确定这些参数，通常涉及到对自相关函数(Auto Correlation Function, ACF^[10])和偏自相关函数(Partial Auto Correlation Function, PACF)^[10]图的分析。这个过程可能既费时又具有主观性，而且很难找到最优的参数组合，尤其是 q 值(移动平均项数)的选择，如果 q 值太小，模型可能无法捕捉到时间序列的随机波动，但如果 q 值太大，则可能导致模型过拟合。

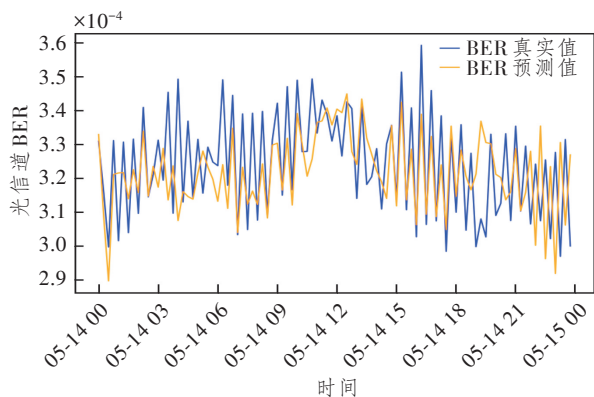


图 2 ARIMA 模型的短期预测性能

Figure 2 The ARIMA model performance for short-term prediction

鉴于 ARIMA 算法在预测光信道 BER 方面存在的局限性，RNN 算法则能够有效地解决这些问题。RNN 作为深度学习的一种形式，通过运用多层神经网络来深入挖掘数据的复杂模式，特别是其独

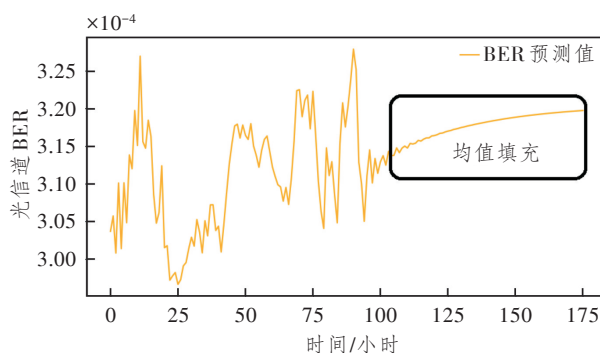


图 3 ARIMA 模型的长期预测性能

Figure 3 The ARIMA model performance for long-term prediction

特的结构^[11]使其在处理序列数据方面展现出卓越的性能。RNN 不仅能够处理任意长度的时序数据，而且易于扩展(仅需增加输入层和隐藏层)。RNN 在时序数据上的卓越表现源于其在 t 时间片时，能够将 $t-1$ 时间片的隐节点作为当前时间片的输入，这种机制使得 RNN 能够捕捉并记忆历史信息，进而提升预测的准确性。

尽管 RNN 在处理序列数据时表现卓越，但在执行长期趋势预测任务时，其预测准确性通常会下降。这一现象主要归因于 RNN 的“长期依赖^[13]”问题。所谓的“长期依赖”是指在序列长度不断增加的过程中，信息在时间步之间的传递可能会迅速衰减或增长，从而导致在序列早期阶段学习到的有价值信息在序列后期阶段无法得到有效的利用。

为了应对“长期依赖”问题，业界普遍采用长短期记忆(Long Short-Term Memory, LSTM)^[14]网络。LSTM 网络作为 RNN 的一种变体，通过引入“门控机制”和“细胞状态”(cell state)来维护长期记忆。具体而言，LSTM 网络包含 3 个门^[15](输入门、遗忘门和输出门)以及一个 cell 状态，这些结构可以有效地控制信息的流入、保留和流出，从而解决传统 RNN 的梯度消失和梯度爆炸问题，使得 LSTM 能够学习并捕捉长期依赖关系。如图 4 所示，该图展示了利用 7 天的光信道 BER 历史数据来预测未来两天的光信道 BER。其中，采用 LSTM 算法的橙色线较好地预测了光信道 BER 的变化趋势，而采用 RNN 算法的灰色线虽然预测值接近真实值，但并未很好地捕捉到光信道 BER 的变化趋势。

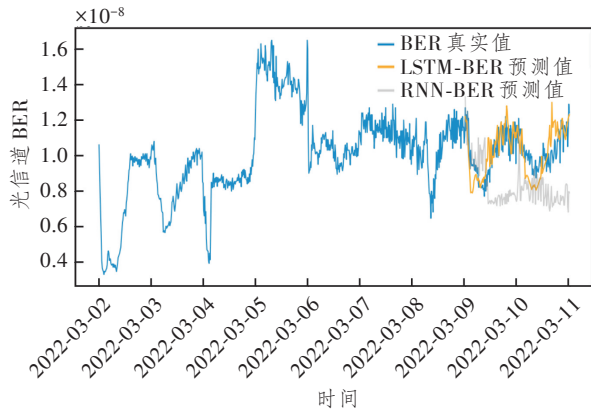


图4 LSTM vs RNN 算法预测光信道 BER 效果

Figure 4 The prediction effect of LSTM and RNN algorithms on optical channel BER

3 基于对数几率回归的 OTN 帧误码概率预测建模

对数几率函数,又称为逻辑函数,在统计学、机器学习和生物学等领域中有着广泛的应用。对数几率函数通常被定义为

$$y = \frac{1}{1 + e^{-z}}, \quad (1)$$

式中, y 为模型计算的输出值,为介于0~1之间的连续概率值。当变量 z 的取值在0“附近”时, y 快速从0附近变到1附近。该函数的特性与帧误码概率的变化相似,当光信道 BER 较低时,其帧误码概率接近于0,当光信道 BER 接近某一临界值时,误码概率略微变化,将导致误码概率大幅度变化,其概率值由0附近变为趋向于1。因此,可以采用对数几率回归建模方法,利用光信道 BER 计算 OTN 帧误码概率。令 $z = \mathbf{w}^T \mathbf{x} + b$,对数几率回归模型构建如下:

$$y = \frac{1}{1 + e^{-(\mathbf{w}^T \mathbf{x} + b)}}, \quad (2)$$

式中: \mathbf{x} 为一维向量,即为连续 $n(n \geq 1)$ 个光信道 BER; \mathbf{w} 和 b 为机器学习中需学习与训练的参数,也是一维向量, \mathbf{w} 为权重^[16],表示输入特征 \mathbf{x} 对输出 y 的影响程度, b 为偏置^[16],用于调整模型的输出。

对数几率回归属于监督学习,需对数据进行标注。根据第1节的阐述,OTN 帧段监控(Section Monitoring, SM)开销(即 OTU 开销)监控的网络范围与光信道范围一致,且运维中关注的重点是误码是否存在。因此,采集光信道 BER 及其 SM 层对应的 BIP 类误码性能值,如 SM-EB、SM-BBE、

SM-ES 和 SM-SES 等,选取依据为“预测目标”。若预测目标是未来时段 SM-BIP 的概率,则选择 SM-BIP 对应的性能值;若预测目标是未来时段的 EB,则选择 SM-EB 的性能值。以 SM-BIP 为例,数据标注 y' 可设计为

$$y' = \begin{cases} 1, & \text{if } x_{\text{SM-BIP}} \neq 0 \\ 0, & \text{if } x_{\text{SM-BIP}} = 0 \end{cases}, \quad (3)$$

式中, $x_{\text{SM-BIP}}$ 为对是否误码的判断, $x_{\text{SM-BIP}} \neq 0$ 时表示有误码, $x_{\text{SM-BIP}} = 0$ 时表示无误码。

为了从上述标注的数据中学习模型所需的最优参数 \mathbf{w} 和 b ,需要定义损失函数,并不断优化模型参数,从而获得最佳拟合数据的模型,即损失函数的最优解。损失函数 L 可定义为

$$L = -[y' \ln(y) + (1 - y') \ln(1 - y)], \quad (4)$$

式中, y' 为标注值,其取值为0或1。由损失函数可知,其机器学习优化求解就是求得使 L 最小的 \mathbf{w} 和 b ,即

$$(\mathbf{w}, b) = \arg \min_{\mathbf{w}, b} L(\mathbf{w}, b). \quad (5)$$

采用“梯度下降法”,求解模型参数 (\mathbf{w}, b) :

$$\mathbf{w} \leftarrow \mathbf{w} - \alpha \frac{\partial L}{\partial \mathbf{w}}; b \leftarrow b - \alpha \frac{\partial L}{\partial b}, \quad (6)$$

式中, α 为学习率^[16],是机器学习训练中需要调整的超参数,学习率过大可能导致模型不收敛,过小则收敛太慢。 (\mathbf{w}, b) 在机器学习中的学习更新方法为

$$\mathbf{w}^{(k+1)} \leftarrow \mathbf{w}^{(k)} - \alpha \frac{1}{n} \sum_{i=1}^n (y_i' - y_i^{(k)}) \cdot x_i^{(k)}, \quad (7)$$

$$b^{(k+1)} \leftarrow b^{(k)} - \alpha \frac{1}{n} \sum_{i=1}^n (y_i' - y_i^{(k)}), \quad (8)$$

式中: k 为机器学习训练的轮次; $x_i^{(k)}$ 为参与第 k 轮更新训练的 x_i ; $y_i^{(k)}$ 为上一轮所更新的模型参数 $\mathbf{w}^{(k)}$ 和 $b^{(k)}$ 计算得到的预测值; y_i' 为输入数据 x_i 所对应的真实标签值。

在历经多轮机器学习训练并达到收敛之后,我们得以确定最优的参数值 \mathbf{w} 和 b ,从而完成建模过程。将第2节中利用 LSTM 模型预测的光信道 BER 值输入该模型,得出相应的帧误码概率,即对未来时段的帧误码概率进行预测。

4 仿真实验

因本研究针对网络设备运维问题,单纯地通过训练数据集和测试数据集验证结果并不能充分体现其工程适用性。故而,本仿真实验采用两端 10 Gbit/s OTN 设备构建点对点网络进行实证研究。在正常运行情况下,OTN 设备不会出现误码。然而,为了

模拟网络设备的误码情况,实验中采用了一块在高低温测试中表现出“问题”的光放大盘。将其仿真网络置于高低温箱中,通过调节温度变化来诱发误码。鉴于误码概率约为 0.5 的情况并无实际意义,因此定义误码概率超过 0.8 为劣化状态(即误码),预测概率小于 0.2 为健康状态(即无误码)。图 5 所示为部分仿真实验结果。

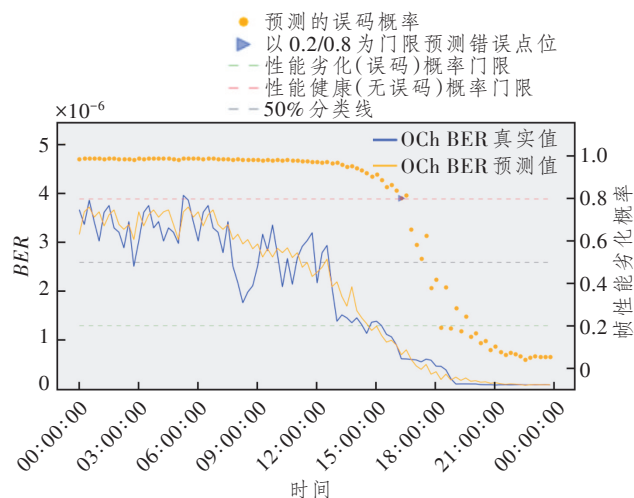


图 5 仿真实验结果

Figure 5 The simulation results

图中包含 96 个 15 min 的性能预测数据,当帧性能劣化概率 >0.8 时判断为误码;当帧性能劣化概率 <0.2 时判断为无误码。在不考虑预测概率介于 0.2~0.8 之间的情况下,预测错误仅出现 1 例,如图中蓝色三角所示。该时刻的实际状况为无误码,而模型预测为误码,预测准确率超过 95%。若以 50% 的分类线为基准,则在上述仿真实验中,共有 5 个点位预测错误(包括预测劣化概率介于 0.5~0.8 之间的 4 个点位及蓝色三角点位),预测准确率仍超过 90%。此外,由图中蓝色与黄色折线的变化趋势可知,利用 LSTM 算法预测的光信道 BER 变化趋势准确地反映了实际 BER 的变化趋势。

由仿真实验结果可知,本研究提出的通过光层和电层对应关系,利用光信道 BER 预测 OTN 帧性能的方法具备有效性,达到了工程化应用要求。然而,实验结果显示,在仿真场景中,所训练模型对“误码”与“无误码”的概率判断分界线约为 0.8,而理论概率判断分界线应在 0.5 左右。此现象源于网络配置和运行环境等因素导致的训练数据与实际运行数据差异。因此为确保模型与现网数据高度匹配,建议点对点链路之间通过周期性训练,定期构建并更新模型,以更好地适应复杂多变的工程化应用场景。

5 结束语

本研究针对 OTN 中的误码预测难题,提出了利用 OTN 光层光信道 BER 来预测 OTN 帧误码的解决方案。具体而言,本研究首先借助深度学习技术对光信道误码进行预测,然后基于预测的光信道误码,通过机器学习模型进一步预测 OTN 误码概率。经过仿真实验的验证,本研究提出的 OTN 误码预测方法准确率超过 90%,为工程应用奠定了基础。

参考文献:

- [1] Agrawal G P. Fiber-optic Communication Systems[M]. New York, US: Wiley, 2010.
- [2] 杨猛. 光传送网(OTN)技术应用阐述[J]. 移动信息, 2023, 45(1):68-70.
Yang M. Discussion on the Application of Optical Transport Network (OTN) Technology [J]. Mobile Information, 2023, 45(1): 68-70.
- [3] 张旭, 邓庆林, 陈鹏, 等. 基于 Telemetry 的 OTN 设备性能采集系统研究[J]. 光通信研究, 2023(6):45-50.
Zhang X, Deng Q L, Chen P, et al. Research on OTN Equipment Performance Collection System based on Telemetry Architecture [J]. Study on Optical Communications, 2023(6):45-50.
- [4] 杨刚刚, 邵珠贵, 姜先荣. 基于机器学习的 OTN 业务时延估算方法研究[J]. 光通信研究, 2024(6):230114.
Yang G G, Shao Z G, Jiang X R. Research on OTN Service Delay Estimation Method based on Machine Learning [J]. Study on Optical Communications, 2024(6):230114.
- [5] 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.
- [6] 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.
- [7] ITU-T G. 870/Y. 1352-2004, Terms and Definition for Optical Transport Network(OTN)[S].
- [8] ITU-T G. 798-2012, Characteristics of Optical Transport Network (OTN) Hierarchy Equipment Functional Blocks[S].
- [9] 赵梓森. 数字光纤通信系统原理[M]. 北京:科学出版社, 1984.
Zhao Z S. Principles of Digital Fiber Optic Communica-

- tion Systems [M]. Beijing, China: Science Press, 1984.
- [10] Hamilton J D. Time Series Analysis [M]. Princeton, New Jersey, US: Princeton University Press, 2020.
- [11] Lipton Z C, Berkowitz J, Elkan C, et al. A Critical Review of Recurrent Neural Networks for Sequence Learning [EB/OL]. (2015-10-17) [2024-04-22]. <https://arxiv.org/abs/1506.00019v4>.
- [12] 何舟,张鹏,肖泳,等. 一种基于机器学习的光信道误码率预测方法:中国,202311318561.1[P]. 2023-12-23. He Z, Zhang P, Xiao Y, et al. A Machine Learning-based Method for Predicting Optical Channel Bit Error Rate: China,202311318561.1[P]. 2023-12-23.
- [13] Zaremba W, Sutskever I, Vinyals O. Recurrent Neural Network Regularization [EB/OL]. (2015-02-19) [2024-04-22]. <https://arxiv.org/abs/1409.2329v5>.
- [14] Hochreiter S, Schmidhuber J. Long Short-term Memory[J]. Neural Computation, 1997, 9: 1735–1780.
- [15] Chung J, Gulcehre C, Cho K, et al. Empirical Evaluation of Gated Recurrent Neural Networks on Sequence Modeling [EB/OL]. (2014-11-11) [2024-04-22]. <https://arxiv.org/abs/1412.3555v1>.
- [16] 周志华. 机器学习[M]. 北京:清华大学出版社, 2016. Zhou Z H. Machine Learning[M]. Beijing, China: Tsinghua University Press, 2016.