

doi:10.13756/j.gtxyj.2026.240183.

光传感与检测技术

张剑羽,徐瑞晚,沈力,等. 基于 CNN 的通信光缆事件检测技术研究[J]. 光通信研究, 2026(1): 240183.

Zhang J Y, Xu R W, Shen L, et al. Research on Event Detection Technology for Fiber Optic Cable based on CNN[J]. Study on Optical Communications, 2026(1): 240183.

基于 CNN 的通信光缆事件检测技术研究

张剑羽¹,徐瑞晚²,沈力²,于文海²,梅亮²

(1. 武汉邮电科学研究院,武汉 430074; 2. 烽火通信科技股份有限公司 网络产出线,武汉 430205)

摘要:【目的】光纤故障识别是无源光网络中的重要功能。随着信息技术的高速发展与通信容量需求的不断升级,光网络体系结构变得越来越复杂,对于其中光纤链路事件点的定位检测也越发困难。光时域反射仪(OTDR)作为光纤故障检测的重要手段,能够定位光纤中的事件位置和评估光纤的状态。针对目前 OTDR 事件检测方法存在阈值固定、噪声干扰和定位精度不高等问题,文章提出了一种以卷积神经网络(CNN)为主要框架的 OTDR 事件检测新方法。【方法】模型采用仿真数据进行训练,以经过预处理后的时域曲线及其对应的方差和差分曲线作为输入,并预测 OTDR 迹线上事件的精确位置。在 CNN 模型的基础上构建高效通道注意力(ECA)机制。通过增强通道间的特征表示,自适应地调整不同通道的重要性,学习 OTDR 迹线的多层次特征,提升模型的性能。【结果】文章中实验以 OTDR 为基础完成测试数据采集。在采集的数据集上,模型预测事件的召回率达到 93.0%,精确率达到 94.7%。【结论】相比传统的事件检测方法,文章所提方法无需阈值选择,仅通过归一化预处理就可以自动学习和提取特征进行事件识别。实验结果显示,该方法具有较高的识别准确率与数据适应性,为相关的实践开发提供了有效的理论验证与实例展示。

关键词:光通信;光时域反射仪;卷积神经网络;事件检测

中图分类号:TN929

文献标志码:A

Research on Event Detection Technology for Fiber Optic Cable based on CNN

ZHANG Jianyu¹, XU Ruiwan², SHEN Li², YU Wenhai², MEI Liang²

(1. Wuhan Research Institute of Posts and Telecommunications, Wuhan 430074, China; 2. Network Output Line, FiberHome Telecommunication Technologies Co., Ltd., Wuhan 430205, China)

Abstract: 【Objective】Fiber fault identification is an important function in passive optical networks. With the rapid development of information technology and the continuous upgrading of communication capacity demand, the optical network architecture has become increasingly complex, and the location and detection of event points in fiber links have thus become more challenging. Optical Time-Domain Reflectometer (OTDR), as an important means of fiber fault detection, is able to locate the events in the fiber and assess the state of the fiber. Aiming at the problems of fixed threshold, noise interference, and low localization accuracy that exist in the current OTDR event detection methods, this paper proposes a new OTDR event detection method using Convolutional Neural Networks (CNN) as the main framework. 【Methods】The model is trained with simulated data, taking the preprocessed time-domain curves as well as their corresponding variances and difference curves as input, and predicts the precise locations of events on the OTDR traces. Efficient Channel Attention (ECA) mechanism is constructed on the basis of CNN model. By enhancing the feature representation between channels, adaptively adjusting the importance of different channels, and learning the multilevel features of OTDR traces, the performance of the model is improved. 【Results】The experiments are completed with OTDR as the basis for test data acquisition. On the experimental dataset, the model could allocate events with recall of 93.0% and precision of 94.7%. 【Conclusion】Compared with traditional event detection methods, this event detection method can automatically learn and extract the features only using normalized OTDR data that is independent of the chosen threshold. The results show that the method has high detection accuracy and data adaptability, which provides an effective theoretical validation and example demonstration for the practical development.

Key words: optical communication; OTDR; CNN; event detection

0 引言

光时域反射仪(Optical Time-Domain Reflectometer, OTDR)能够获取光纤的衰减曲线,并通过该曲线检测异常事件^[1]。传统的 OTDR 事件分析

技术大部分采用两点法结合最小二乘法^[2],这种方法原理简单、易于实现,但容易受到噪声的影响^[3],噪声较大时,测量结果误差也较大^[4]。

近年来,研究人员在此基础上提出了多种 OTDR 迹线分析算法。钟志宏等人研究了一种基于

收稿日期:2024-08-26; 修回日期:2024-09-12; 纸质出版日期:2026-02-10

基金项目:国家重点研发计划基金资助项目(2021YFB1808200)

作者简介:张剑羽(2000—),女,湖北武汉人。硕士,主要研究方向为机器学习和光通信技术。

通信作者:梅亮,正高级工程师。E-mail: lmei@fiberhome.com

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

Gabor 变换的 OTDR 事件分析算法^[5],但当被测信号的信噪比(Signal-to-Noise Ratio, SNR)较低时,该算法的精确度会明显降低;唐良瑞等人提出了一种基于小波变换的分析方法^[6],其中事件定位结果受到了阈值的影响显著;机器学习是当前 OTDR 事件检测算法的研究方向之一^[7-8],Straub 等人构建了基线模型、集成分类器与长短时记忆(Long Short-Term Memory, LSTM)模型^[9]用于对 OTDR 事件进行检测并比较了不同模型的表现,结果显示,集成分类器方法的预测精确率最高,但训练模型用到的数据集规模较小,一定程度上限制了模型的泛化能力。

本文首先根据不同光纤长度和脉冲宽度等条件仿真生成 OTDR 曲线作为训练数据集,并基于此数据集构建了一维(One-Dimensional, 1D)卷积神经网络(Convolutional Neural Networks, CNN)模型。其中,1D 卷积层能够自动提取关键特征^[10],如反射峰的位置和形状等,这些特征对于识别光纤链路上的事件具有重要作用。最后,本文将模型在真实的 OTDR 数据集上进行事件的定位与检测,并对结果进行了评估。

1 实验准备

模型的训练数据由仿真代码生成,噪声采用随机高斯白噪声。仿真过程中,首先通过光纤长度、脉冲宽度和事件位置等随机参数对光纤的输入脉冲响应 $s[n]$ 进行仿真。当光纤中没有事件时,OTDR 探测信号功率随着传输距离增加呈指数下降趋势^[11]。经过对数处理后,图像呈现为一条递减的直线,其斜率为光纤衰减系数。当光纤中存在反射和衰减等事件时,脉冲响应的对应位置将出现功率的增加或降低。采用单脉冲信号 $p[n]$ 测量得到的 OTDR 曲线可表示为 $p[n]$ 与 $s[n]$ 之间的卷积:

$$(s * p)[n] = \sum_{m=-\infty}^{\infty} s[m] \cdot p[n-m],$$

式中, n 为离散采样点索引。

由于探测信号难以避免受到噪声的影响,还需在原信号的基础上根据 SNR 添加高斯白噪声。根据原信号功率 P_s 与设定的 SNR 计算噪声功率 $P_n = \frac{P_s}{\text{SNR}}$,进而得到噪声的标准差 $\sigma_n = \sqrt{P_n}$ 。最终计算噪声 $n[t]$ 为 $n[t] = \sigma_n \cdot \eta[t]$,式中, $\eta[t]$ 为服从标准正态分布的高斯随机变量,其均值为 0、方差为 1。

为了更接近实验室中采集的 OTDR 数据,在生成噪声并得到包含噪声的曲线后,设置一个一阶巴特沃斯滤波器对信号进行滤波处理,去除高于截止频率的噪声成分。滤波器带宽可根据实际 OTDR 设备带宽进行设置。

仿真曲线经过上述步骤处理后,构成一个由 1 500 条 OTDR 曲线及其对应标签文件组成的数据集。标签是与原 OTDR 曲线等长的二值 01 序列,有事件的点标记为 1,没有事件的点标记为 0。为了使模型更好地捕获和学习数据特征,每条曲线数据经过归一化处理后,计算获取其对应的方差与差分曲线,一同作为模型的输入。

此外,由于随机生成的曲线长度不一,在输入模型前将数据统一切成长度固定的切片,并对每个切片标记是否包含事件。为了使模型能够均衡地学习这两类数据的特征,训练集中包含的有事件切片与无事件切片需保持数量相等。

2 基于 CNN 的事件识别

1D-CNN 模型能够保持原始数据的结构,并保障网络的识别性能,在处理 1D 时间信号时具有很大优势。OTDR 数据为光纤损耗随光纤长度变化的 1D 数据,因此适用于 1D-CNN 结构进行处理。

本实验构建的 CNN 模型中,模型输入是经过归一化、切片长度为 3 000 的 OTDR 原始曲线、差分曲线和方差曲线,模型输出是长度为 3 000 的取值范围在 0~1 之间的 1D 张量,其中每个点的数值代表该点有事件的概率。每个输入信号分别经过 3 个 1D 卷积层,每层的滤波器个数依次为 8、16 和 32,即每层卷积产生不同个数的特征图。每个特征图对应着从模型输入数据中学到的一个特定的特征模式或滤波器的响应。每层对应的卷积核长度逐渐减小,分别为 500、250 和 125,代表经过各卷积层后每个点包含了其周围 500、750 和 875 个点的特征信息。此外,每次卷积后都对数据进行批量归一化并使用 tanh 激活函数。

在此基础上,于卷积层后构建高效通道注意力(Efficient Channel Attention, ECA)机制^[12-13]。该模块通过以下步骤实现 ECA 机制:首先计算输入张量的通道数,相应进行动态卷积核大小的计算,随后进行全局平均池化与 1D 卷积,再与输入张量进行逐通道乘法以完成通道加权,最终将学习到的权重应用于输入张量的每个通道,实现 ECA 机制。ECA 模块实现流程示意图如图 1 所示,图中, C 为

通道维度; $\psi(C)$ 为根据通道维度自适应计算卷积核大小的函数; k 为进行相应计算后得到的卷积核大小。




图1 ECA 模块实现流程示意图

Figure 1 The flowchart of ECA module

实现 ECA 机制后,使用 sigmoid 激活函数,模型将输出介于 0~1 之间的值,即模型预测的每个点发生事件的概率。整体模型构建示意图如图 2 所示。




图2 整体模型构建示意图

Figure 2 Schematic of the model construction

3 测试与分析

3.1 测试

本实验中的测试数据采用实验室内 OTDR 现场采集。实验室数据采集环节采用 OTDR 模块连接光纤,设置不同档位的量程,包括 2、25、75、100 和 150 km 等。每次测量采用多个不同的脉冲宽度,包括 2、4、10 和 20 μs 等,并为其中的事件点分别添加不同大小的损耗值,包括 0、2、4 和 10 dB 等。图 3 所示为本实验中使用到的 OTDR 实物图与其基本原理示意图。

在本实验中,根据方差变化定位 OTDR 曲线的事件部分与噪声部分的分界点,并对曲线进行预处理。图 4 所示为实验室采集的 OTDR 曲线与其相

应的预处理后的曲线图像。






图3 OTDR 实物与其基本原理示意图

Figure 3 Schematic diagram of OTDR and its basic principle



(a) 预处理前曲线图像

(a) Curve image before preprocessing



(b) 预处理后曲线图像

(b) Curve image after preprocessing

图4 预处理前后 OTDR 曲线图像

Figure 4 OTDR curve before and after preprocessing

3.2 结果分析

模型训练损失在 180 轮左右达到最小值。训练完成后,对实验室数据集进行预测,每条曲线会得到一个取值在 (0,1) 内的预测结果序列。理想的预测结果应与曲线对应的标签类似,有事件的部分预测值接近 1,无事件的部分预测值接近 0。取阈值为 0.5 将预测曲线二值化。由于噪声等影响,预测结果中可能出现事件点外的多余孤立点或凹陷,可以通过形态学开运算与闭运算对结果进行处理以去除噪声和合并事件。

以本实验为例,开运算能够去除目标中额外的噪声部分;闭运算能够将预测结果中的事件中心凹陷部分进行填充或连接距离较近的事件。为了针对

性地处理不同大小的数据,开运算结构元素的大小为当前数据的脉冲宽度对应长度的 $1/4$ 。闭运算结构元素的大小取数据的脉冲宽度对应长度的 $1/2$ 。

本实验中,先进行开运算使序列去噪,再进行闭运算将预测结果中距离较近的结果合并。图5所示为模型输出的 OTDR 曲线的预测结果以及经过处理后的结果对比。




图5 经过处理前后的 OTDR 曲线预测结果图像

Figure 5 Prediction results before and after processing

最后,将经过开运算与闭运算后的预测结果与实验室原始数据进行对比,计算准确率。在实验室采集的 204 条 OTDR 轨迹上对模型进行评估,并使用精确率和召回率作为评价指标。这 204 条真实数据共包含 769 个事件点,其中模型正确识别的事件点有 715 个,漏识别 54 个,错误识别 40 个。事件检测的召回率达到 93.0%,精确率达到 94.7%。

4 结束语

本文针对 OTDR 事件检测传统算法中的阈值选择困难和易受噪声影响等问题,提出了构建 CNN 模型以在复杂光纤网络环境中准确定位事件位置。对此,本文通过仿真生成了不同光纤长度、脉冲宽度和采样间隔等条件下的 OTDR 信号数据,使 CNN 模型更好地理解 and 识别这些特征。

实验结果表明,基于 CNN 的事件检测技术能够有效地提高 OTDR 信号分析中的事件检测与定位能力,即便是在噪声环境中。这项技术为光纤网

络事件检测与监控提供了一种新的、可靠的解决方案。未来的研究将进一步优化模型结构与噪声处理,以提高其在不同环境下的适用性,并探索将其应用于实时监测系统的可能性。

参考文献:

- [1] 刘中华, 龚浩敏, 吴岩, 等. 相干光时域反射仪技术与应用[J]. 光通信研究, 2022(5): 43–48.
Liu Z H, Gong H M, Wu Y, et al. Principle and Application of the C-OTDR[J]. Study on Optical Communications, 2022(5): 43–48.
- [2] 陈诚, 肖逸, 李爱东, 等. 基于RBF神经网络的OTDR小波分析算法[J]. 光通信技术, 2017, 41(2): 21–24.
Chen C, Xiao Y, Li A D, et al. OTDR Events Analysis Algorithm based on Wavelet Transform and RBF Neural Network[J]. Optical Communication Technology, 2017, 41(2): 21–24.
- [3] 孔衡. 光时域反射的事件分析算法研究[D]. 上海: 上海交通大学, 2015.
Kong H. Research on Events Analysis Algorithms in Optical Time Domain Reflectometry [D]. Shanghai, China: Shanghai Jiao Tong University, 2015.
- [4] 臧益鹏, 李现勤, 吴松桂, 等. 基于改进小波变换的 OTDR事件检测方法[J]. 光通信技术, 2024, 48(1): 23–28.
Zang Y P, Li X Q, Wu S G, et al. Event Detection Method of OTDR based on Improved Wavelet Transform [J]. Optical Communication Technology, 2024, 48(1): 23–28.
- [5] 钟志宏, 文科, 王荣. OTDR事件检测和定位算法[J]. 解放军理工大学学报(自然科学版), 2004(5): 22–25.
Zhong Z H, Wen K, Wang R. Event Detection and Location in OTDR Data[J]. Journal of PLA University of Science and Technology (Natural Science Edition), 2004(5): 22–25.
- [6] 唐良瑞, 祁兵, 陈常洪, 等. 一种基于小波变换的光纤故障分析算法[J]. 中国电机工程学报, 2006, 26(2): 101–105.
Tang L R, Qi B, Chen C H, et al. Algorithm of Fiber Fault Analysis based on Wavelet Transform [J]. Proceedings of the CSEE, 2006, 26(2): 101–105.
- [7] Abdelli K, Cho J Y, Azendorf F, et al. Machine Learning - based Anomaly Detection in Optical Fiber Monitoring [J]. Journal of Optical Communications and Networking, 2022, 14(5): 365–375.
- [8] Abdelli K, Tropschug C, Griesser H, et al. Faulty Branch Identification in Passive Optical Networks Using Machine Learning [J]. Journal of Optical Communica-

- tions and Networking, 2023, 15(4): 187–196.
- [9] Straub M, Saier T, Reber J, et al. AI-based OTDR Event Detection, Classification and Assignment to ODN Branches in Passive Optical Networks[C]//49th European Conference on Optical Communications (ECOC 2023). Glasgow, UK: IET, 2024: 10484603.
- [10] 吴俊, 管鲁阳, 鲍明, 等. 基于多尺度一维卷积神经网络的光纤振动事件识别[J]. 光电工程, 2019, 46(5): 180493.
Wu J, Guan L Y, Bao M, et al. Vibration Events Recognition of Optical Fiber based on Multi-Scale 1D CNN[J]. Opto-Electronic Engineering, 2019, 46(5): 180493.
- [11] 徐杰伊. OTDR动态范围提高及事件检测研究[D]. 哈尔滨: 哈尔滨工业大学, 2020.
- Xu J Y. Study on OTDR Dynamic Range Improvement and Event Detection[D]. Harbin, China: Harbin Institute of Technology, 2020.
- [12] Wang Q, Wu B, Zhu P, et al. ECA-Net: Efficient Channel Attention for Deep Convolutional Neural Networks[C]//2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Seattle, WA, USA: IEEE, 2020: 9156697.
- [13] 杨光乔, 李颖, 王国程, 等. 基于ECA改进1D-CNN的柱塞泵故障诊断[J]. 石油机械, 2023, 51(11): 34–40.
Yang G Q, Li Y, Wang G C, et al. Fault Diagnosis of Plunger Pump based on ECA Improved 1D-CNN[J]. China Petroleum Machinery, 2023, 51(11): 34–40.