

一种融合双通道 GAF 与树突网络的光缆事件识别方法

杜娟

(桂林聚联科技有限公司, 广西 桂林 541004)

摘要: 针对传统光缆故障识别方法中信号特征提取复杂、识别准确率不高的问题, 提出一种融合双通道格拉姆角场(GAF)与树突(DD)网络的识别方法。该方法首先对一维光时域反射仪(OTDR)时序信号进行标准化与极坐标编码, 通过双通道 GAF 技术将其转换为格拉姆角和场(GASF)与格拉姆角差场(GADF) 2 种二维图像, 以保留时序特征并增强多模态故障差异; 随后利用 DD 网络挖掘图像中数据间的逻辑关系, 构建高精度分类模型。实验结果表明, 所提方法在自建 OTDR 数据集上的分类准确率达到 $98.67\% \pm 1.06\%$, 优于小波包分解、经验模态分解、变分模态分解等传统特征提取方法, 也高于其它主流分类模型, 验证了其在光缆事件识别任务中的有效性与优越性。

关键词: 格拉姆角场; 树突网络; 光缆事件识别

中图分类号: TN913.7 文献标志码: A 文章编号: 1002-5561(2025)06-0089-07

DOI: 10.13921/j.cnki.issn1002-5561.2025.06.017

Optical cable event recognition method integrating dual-channel GAF and dendritic network

DU Juan

(Guilin Julian Technology Co., Ltd., Guilin Guangxi 541004, China)

Abstract: To address the issues of complex signal feature extraction and low recognition accuracy in traditional optical cable fault identification methods, this paper proposes a recognition method that integrates dual-channel Gramian angular field (GAF) and dendritic (DD) network. The method first standardizes and polar coordinate-encodes one-dimensional optical time domain reflectometer (OTDR) time-series signals, then converts them into two types of two-dimensional images—Gramian angular summation field (GASF) and Gramian angular difference field (GADF)—using dual-channel GAF technology, thereby preserving temporal features and enhancing multimodal fault differences. Subsequently, the DD network is employed to mine logical relationships within the image data and construct a high-precision classification model. Experimental results demonstrate that the proposed method achieves a classification accuracy of $98.67\% \pm 1.06\%$ on a self-built OTDR dataset, outperforming traditional feature extraction methods such as wavelet packet decomposition, empirical mode decomposition, and variational mode decomposition, as well as other mainstream classification models, validating its effectiveness and superiority in optical cable event recognition tasks.

Key words: Gramian angular field, dendritic network, optical cable event recognition

0 引言

光时域反射仪(OTDR)作为分析光缆故障状态的

收稿日期: 2025-06-12。

作者简介: 杜娟(1974—), 女, 湖南常德人, 学士, 工程师, 主要研究方向为光通信技术。曾担任产品经理, 主持光时域反射仪(OTDR)与光缆普查仪(OCID)两类产品的设计规划、研发实施及市场推广的全程管理工作。现主要从事质量与可靠性方面的研究工作。



关键设备, 通过向光纤中注入光脉冲并接收瑞利散射与菲涅尔反射信号, 生成反映光纤线路状态的检测曲线, 从而为故障定位与分析提供直观依据^[1-4]。根据其表现形式, 光缆故障通常分为反射事件和非反射事件 2 类, 二者在 OTDR 曲线中的特征差异显著, 识别难度也有所不同。

在 OTDR 检测曲线的分析方面, 已有诸多研究尝试从不同角度提升识别性能。例如, KING D 等人^[5]结合快速傅里叶变换与人工神经网络, 构建 3 层前馈网

杜娟:一种融合双通道GAF与树突网络的光缆事件识别方法

络以实现信号特征分类;YONGMIN K等人^[6]基于二阶卡尔曼滤波器建立线性模型,通过优化衰减因子提升事件检测能力;MUHAMMAD U等人^[7]则利用矢量索引与数值差分方法提取特征,完成故障类型的判别。此外,TABI-FOUDA B M等人^[8]提出2级振动识别框架。JUN W等人^[9]开发了轻量化的多尺度一维卷积网络。JEAN P等人^[10]采用自适应正则化滤波识别异常点。WANG Y等人^[11]结合小波分解与相关向量机实现了88.60%的识别准确率。LI M等人^[12]采用时频域特征与支持向量机相结合的方法处理事件并发场景。张佐星等人^[13]基于三阶差分与霍夫变换提出模板匹配策略。臧益鹏等人^[14]则通过改进小波去噪与融合模极大值法提升事件检测鲁棒性。尽管上述方法在OTDR信号特征提取与故障识别方面取得了一定进展,但仍存在以下主要局限:首先,传统特征提取方式对反射事件与非反射事件的复杂模态变化适应性不足,易导致误判;其次,现有神经网络方法识别准确率仍有提升空间;此外,多故障点识别能力不足,且一维信号特征维度有限,制约了识别性能的进一步提高。

针对上述问题,本文提出一种融合双通道格拉姆角场(GAF)与树突(DD)网络的光缆事件识别方法,旨在通过增强特征表达与分类能力,实现对光缆故障更精确的识别。

1 光缆事件识别方法

本文的光缆事件识别方法工作原理如下:首先,采用双通道GAF技术对一维OTDR事件序列进行处理,在充分保留原始时序特征的基础上,通过双射映射机制将一维序列转化为二维图像;随后,利用DD网络对二维图像中所包含的时序特征及新增的空间特征进行深度挖掘,从而完成对光缆故障事件特征的学习,并构建识别模型,最终实现对光缆故障事件的精准识别。

1.1 GAF技术特征

GAF技术是一种常用于一维时间序列编码的方法^[15-16]。其基本原理是:首先将笛卡尔坐标系下的时间序列转换为极坐标形式,然后通过三角运算生成对应的格拉姆矩阵,从而实现一维时间序列到二维图像的转化。本文基于OTDR检测曲线识别光缆故障事件。OTDR数据的特点与GAF技术的特征提取能力高度适配,具体表现在以下几个方面:

1)OTDR数据具有强时序依赖性:OTDR信号的衰减和反射特征随采样点(对应光缆长度)连续变化,相

邻采样点之间存在强相关性,且故障特征(如反射峰值、衰减突变)的位置与前后时序信息紧密关联。GAF技术通过“从左上角到右下角”的图像表征方式,将时间维度映射为图像空间维度,使相邻采样点的时序关系转化为图像像素的空间邻接关系,从而完整保留了OTDR数据的时序依赖性,避免了传统特征提取方法(如小波分解)可能导致的时序断裂问题。

2)OTDR信号功率值动态范围大:信号功率值可能跨越多个数量级(例如,反射事件峰值功率与非反射事件平缓段功率之间的差异可达 10^3 倍以上),容易导致特征提取过程中“强特征掩盖弱特征”。GAF技术通过归一化处理将原始信号缩放到 $[-1,1]$ 区间,有效压缩了信号的动态范围,并将功率值映射为角度参数,使得某些原本不明显的特征在角度维度上得到增强,从而提高了特征提取的均衡性。

3)OTDR数据具有多模态故障特征:反射事件表现为“尖锐峰值”的局部强特征,而非反射事件则表现为“平缓突变”的全局弱特征,2类特征模态差异显著。通过联合使用格拉姆角和场(GASF)与格拉姆角差场(GADF),GAF技术能够将OTDR时序信号分别映射为2种图像表示,有效保留不同故障模式的时序特征,从而实现对OTDR信号中多种故障类型的全面特征提取。

综上所述,GAF技术具有保持时间依赖性的显著优势,为后续的特征挖掘提供了高质量的数据基础。

1.2 DD网络优势

在分类任务中,传统机器学习算法通常依赖数据本身的特征进行类别划分,其目标在于确定合适的分类曲线或曲面以实现有效判别。相比之下,DD网络^[16]通过挖掘输入数据之间的逻辑关系实现分类,这一机制使其更适用于光缆故障识别任务。DD网络的优势主要体现在以下四方面:

1)DD网络具备“白盒特性”:与传统机器学习方法不同,DD网络借助哈达姆积实现特征的高阶交互与关联挖掘,训练后生成输入与输出之间的关系谱,清晰展示故障特征与类别标签之间的逻辑对应关系,从而为识别结果提供可验证的理论依据。

2)DD网络在特征处理上不依赖非线性激活函数:该网络通过多层模块组合构建高精度的多项式逻辑表达式,能够有效捕捉OTDR信号中时序与空间特征的耦合关系,克服了传统算法仅聚焦单一维度特征的局限。

3)DD网络具备可控的模型复杂度与良好的泛化

能力;其结构复杂度可通过DD模块数量精确调节,从而根据故障特征的复杂程度动态调整模型精度。此外,该网络具有较强的抗过拟合能力,适用于光缆故障数据的处理。

4)DD网络识别准确率高:与K近邻算法(KNN)^[17]、支持向量机(SVM)^[18]、极限学习机(ELM)^[19]、卷积神经网络(CNN)^[20]等方法相比,对比结果如表1所示。可以看出,DD网络识别准确率达到 $98.67\% \pm 1.06\%$ 。

表1 不同分类方法识别准确率

分类方法	识别准确率/%
KNN	93.21 ± 3.12
SVM	91.13 ± 1.22
ELM	92.34 ± 2.45
CNN	97.12 ± 2.39
DD网络	98.67 ± 1.06

综上所述,针对光缆故障识别的核心需求,DD网络凭借其逻辑关系的深度挖掘能力与“白盒特性”,有效弥补了传统算法在特征关联建模与结果可信度方面的不足,适用于光缆故障识别任务。

1.3 光缆事件识别流程

本文提出一种融合双通道GAF与DD网络的光缆事件识别方法,其流程图如图1所示。具体步骤如下:

1)生成双通道OTDR图像数据:首先对一维OTDR时序信号进行极坐标映射与格拉姆矩阵编码,利用GASF与GADF技术构建双通道图像数据。该转换过程在完整保留原始信号时序特征的基础上,将维度为 $n \times 1$ 的一维序列升维至 $n \times n \times 2$ 的二维结构,为后续深度特征提取提供多维数据支持。

2)数据集划分:将生成的GAF二维时频图数据按比例划分为训练集、验证集与测试集。训练集用于模型参数学习,验证集用于训练过程中模型性能的动态调优,测试集用于最终性能评估。

3)DD网络模型训练:利用DD网络提取数据间逻辑关系的特性,对双通道OTDR图像进行分类。首先配置网络初始参数并完成模型结构初始化,随后通过反向传播算法迭代优化模型参数以降低损失函数值,训练过程中使用验证集监测模型收敛情况。若未收敛则继续迭代,直至收敛完成训练。

4)模型测试与结果输出:使用训练完成的DD网络模型对测试集数据进行光缆故障事件分类,输出分类结果并计算准确率。




图1 融合双通道GAF与DD网络的光缆事件识别方法流程图

2 实验仿真

2.1 实验数据采集

为模拟光纤复合架空地线(OPGW)光缆线路的故障情况,本文采用一条长约15 km的裸纤,通过在光纤不同位置进行熔接、弯折、拉伸及连接法兰等操作,模拟实际运行中可能出现的故障类型;利用OTDR共采集5 000组数据作为实验样本。OTDR的具体测试参数设置如表2所示。

表2 OTDR测试参数设置

测试参数	取值
量程	根据被测光缆的参数设定
脉宽	可调节
测量时长/s	15
激光波长/nm	1 550
折射率	1.468 50
非反射门限	可调节
结束门限	5

杜娟:一种融合双通道GAF与树突网络的光缆事件识别方法

将采集到的信号根据反射事件和非反射事件2种故障类型进行截取与分类,共构建包含5 000组OTDR事件的数据集,其中反射事件与非反射事件各2 500组。对2类事件分别标注标签:反射事件标记为0,非反射事件标记为1,并对所有数据的顺序进行随机打乱。随后,将数据集的70%划分为训练集,剩余30%作为测试集;在训练集中再随机抽取30%作为验证集,以满足模型训练与验证的需要。

本文基于Python环境,使用Pytorch框架与Pyts工具库搭建双通道GAF-DD网络光缆故障事件识别模型。模型运行的硬件配置与软件运行环境如表3所示,模型相关参数设置如表4所示。

表3 硬件配置版本与软件运行环境


硬件/软件	型号配置/版本参数
OS	Windows10(64位)
CPU	Intel(R) Core(TM) i7-10875H
GPU	RTX 2060
RAM	DDR4 16GB
Python	3.9
Pytorch	1.10.1
CUDA	11.6

表4 模型相关参数设置


参数	取值
batch_size	128
学习率	1e-4
weight_decay	5e-4

2.2 反射事件分析

本文以图2(a)所示的OTDR反射事件进行分析。首先对OTDR反射事件的时间序列进行GAF变换,生




(a) OTDR反射事件图




(b) 格拉姆矩阵点积成像

图2 反射事件的格拉姆矩阵点积成像

成如图2(b)所示的单通道二维图像;结合GASF与GADF,构建双通道GAF,结果如图3所示。对比两图可见,二者存在明显差异。从图3可以看出,反射事件



(a) GASF图像



(b) GADF图像

图3 双通道GAF反射事件二维图像

对应的GASF图像中元素分布明显向1集中,而GADF图像中的元素分布则相对均匀。在对称性方面,GASF图像主对角线两侧数据呈对称分布,而GADF图像主对角线位置的数值为0,两侧数据呈现镜像分布特征。

2.3 非反射事件分析

本文选取图4(a)所示的OTDR非反射事件进行分析。首先对OTDR非反射事件的时间序列进行GAF变换,生成如图4(b)所示的格拉姆矩阵点积成像;结合GASF与GADF,构建双通道GAF,结果如图5所示。






图4 非反射事件的格拉姆矩阵点积成像

从图5可以看出,非反射事件对应的GASF图像中元素分布未出现明显向1集中的趋势,而是呈现平缓的渐变分布。在对称性方面,GASF图像主对角线两侧数据虽具有一定对称性,但相比反射事件有所减弱,整体呈现出随信号平缓变化而连续渐变的对称分布形态。非反射事件下的GADF图像元素分布同样相对均匀,主对角线数值接近0,两侧数据呈现镜像分布



(a) GASF图像



(b) GADF图像

图5 双通道GAF非反射事件二维图像

特征。由于非反射事件信号变化平缓,这种镜像分布的细节变化更为柔和连续,未出现因尖锐反射峰导致的突兀分布差异。

2.4 实验结果分析


为验证所提光缆故障识别模型的优越性,本文设计了3组对比实验。3组实验均采用相同的DD网络分类算法,但使用不同的信号处理方法进行处理,即:小波包分解^[21]、经验模态分解^[22]与变分模态分解^[23]。各方法的输出信号被分别输入DD网络,最终通过对比其准确率以评估性能。为保证实验结果可靠,各方法均重复实验20次,平均分类准确率(下文简称准确率)如表5所示。可以看出,本文所提方法准确率优于其它识别方法,其优越的分类性能主要源于三方面创新:充分考虑光缆信号的时序分段特性;通过一维信号转二维图像实现特征空间升维扩展;采用双通道机制增强特征表达的丰富性。这些技术改进共同促成

表5 不同诊断方法下准确率对比


序号	识别方法	准确率/%
第1组	小波包分解+DD模型	93.58 ± 2.11
第2组	经验模态分解+DD模型	95.52 ± 3.14
第3组	变分模态分解+DD模型	96.76 ± 3.35
本文	双通道GAF+DD模型	98.67 ± 1.06

了特征提取精度的显著提升,验证了本方法在光缆事件识别任务中的有效性与鲁棒性。

为比较 GASF-DD、GADF-DD、GASF-GADF-DD (下文简称 GAF-DD) 这3种成像方式的识别效果,本文以 DD 网络为基础模型,采用随机梯度下降(SGD)算法优化器进行训练。综合考虑各方面因素,本文对学习率设置采用分阶段策略:前50次迭代学习率设为0.001,超过50次后调整为0.000 1。3种成像方法的训练过程如图6所示,对应的准确率如表6所示。



(a) 准确率变化



(b) 损失函数变化

图6 3种成像方法的训练过程

表6 不同成像方法对应的准确率

成像方式	准确率/%
GASF-DD	97.45
GADF-DD	97.31
GAF-DD	98.67

从表6与图6可知,采用GAF-DD成像方式时,DD网络具有更快的收敛速度、更低的训练损失和更高的分类准确率。其中,GASF-DD模型约经10次迭代后,测试准确率曲线与损失函数曲线分别收敛至97.45%和0.16;GADF-DD模型约经30次迭代后分别收敛至97.31%和0.25;GAF-DD模型同样约经10次迭代后分别收敛至98.67%和0.13。

在整个训练过程中,GASF-DD与GAF-DD成像方式对应的识别准确率较为接近,而GADF-DD成像的识别准确率显著低于前2种方法。这表明在构建双通道GAF用于光缆故障识别时,其识别效果不低于单通道GAF。结合特征维度分析可知,GAF-DD双通道成像方式能够涵盖更丰富的时序与空间特征,从而为后续识别模型提供了更全面的信息支撑。鉴于此,本文最终确定将GAF-DD双通道成像方法作为最优图像生成方案。

3 结束语

本文提出了一种融合双通道GAF与DD网络的光缆故障识别方法,通过将一维OTDR信号转换为双通道图像,有效保留了时序特征并扩展了特征空间。实验表明,该方法识别准确率达98.67%±1.06%,显著优于小波包分解、经验模态分解等传统方法及KNN、SVM、CNN等分类模型。

双通道GAF结构有效增强了多模态故障特征的特征能力,DD网络则凭借其白盒特性提升了分类性能。本文为光缆故障识别提供了新的技术方案,对光纤智能监测系统的发展具有实践意义。

参考文献:

- [1] CHAOJU H, JUN L. The application of wavelet transform in analysis of OTDR curve[C]//IEEE. Proceedings of 2010 Second International Conference on Intelligent Human-Machine Systems and Cybernetics. Nanjing: IEEE, 2010: 216-219.
- [2] RAMJI T, PRASANT K S. Dynamic range enhancement of OTDR using lifting wavelet transform-modified particle swarm optimization scheme [J]. IET Optoelectronics, 2019, 13(6): 295-302.

- [3] LU L, LIANG Y, LI B, et al. Maintenance of the OPGW using a distributed optical fiber sensor[C]//IEEE. Proceedings of 2014 International Conference on Power System Technology. Chengdu: IEEE, 2014: 1251–1256.
- [4] CUI H M, ZHAO R M, HOU Y L. Improved threshold denoising method based on wavelet transform [J]. Physics Procedia, 2012, 33: 1354–1359.
- [5] KING D, LYONS W B, FLANAGAN C, et al. An optical fibre ethanol concentration sensor utilizing Fourier transform signal processing analysis and artificial neural network pattern recognition[J]. Journal of Optics A Pure and Applied Optics, 2003, 5(4): S69–S75.
- [6] YONGMIN K, JINGHAO S, SUNG R H, et al. Analyzing OTDR measurement data using the kalman filter [J]. IEEE Transactions on Instrumentation and Measurement, 2008, 57(5): 947–951.
- [7] MUHAMMAD U, SAJID S M. Vector indexing algorithm for post processing of OTDR data[C]//IEEE. Proceeding of 2013 18th European Conference on and Optical Cabling and Infrastructure. Graz: IEEE, 2013: 257–262.
- [8] TABI FOU DA B M, HAN D, AN B, et al. Events detection and recognition by the fiber vibration system based on power spectrum estimation [J]. Advances in Mechanical Engineering, 2018, 10(11): 1687814018808679–1–1687814018808679–10.
- [9] JUN W, LUYANG G, MING B, et al. Vibration events recognition of optical fiber based on multi-scale 1-D CNN[J]. Opto-Electronic Engineering, 2019, 46(5): 180493–1–180493–8.
- [10] JEAN P, MARIO H S, JOAQUIM D G. Adaptive filter for automatic identification of multiple faults in a noisy OTDR profile [J]. Journal of Lightwave Technology, 2016, 34(14): 3418–3424.
- [11] WANG Y, WANG P, DING K, et al. Pattern recognition using relevant vector machine in optical fiber vibration sensing system[J]. IEEE Access, 2019, 7: 5886–5895.
- [12] LI M, GU J, LUO X, et al. Pattern recognition of fiber disturbance based on support vector machine in polarization optical time domain reflectometry[C]//SPIE. Proceeding of 2019 International Conference on Optical Instruments and Technology: Optical Sensors and Applications. Beijing: SPIE, 2020, 11436: 241–249.
- [13] 张佐星, 施冬钢, 胡龙舟, 等. 喇曼复用 OTDR 模式识别算法研究[J]. 光通信技术, 2019, 43(7): 21–24.
- [14] 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.
- [15] WANG Z, OATES T. Imaging time-series to improve classification and imputation[C]//AAAI Press. Proceedings of the Twenty-Fourth International Joint Conference on Artificial Intelligence: IJCAI-15. Buenos Aires: AAAI Press, 2015: 3939–3945.
- [16] LIU G, WANG J. Dendrite net: a white-box module for classification, regression, and system identification[J]. IEEE Transactions on Cybernetics, 2021, 52(12): 13774–13787.
- [17] XING W, BEI Y. Medical health big data classification based on KNN classification algorithm[J]. IEEE Access, 2019, 8: 28808–28819.
- [18] SOMVANSHI M, CHAVAN P, TAMBDE S, et al. A review of machine learning techniques using decision tree and support vector machine [C]//IEEE. Proceeding of 2016 International Conference on Computing Communication Control and Automation (ICCUBEA). Greater Noida: IEEE, 2016: 1–7.
- [19] CAO J, ZHANG K, LUO M, et al. Extreme learning machine and adaptive sparse representation for image classification[J]. Neural Networks, 2016, 81: 91–102.
- [20] ACHARYA U R, OH S L, HAGIWARA Y, et al. A deep convolutional neural network model to classify heartbeats[J]. Computers in Biology and Medicine, 2017, 89: 389–396.
- [21] HUANG D, ZHANG W A, GUO F, et al. Wavelet packet decomposition-based multiscale CNN for fault diagnosis of wind turbine gearbox [J]. IEEE Transactions on Cybernetics, 2021, 53(1): 443–453.
- [22] QIU X, REN Y, SUGANTHAN P N, et al. Empirical mode decomposition based ensemble deep learning for load demand time series forecasting[J]. Applied Soft Computing, 2017, 54: 246–255.
- [23] MIAO Y, ZHAO M, LIN J. Identification of mechanical compound-fault based on the improved parameter-adaptive variational mode decomposition[J]. ISA Transactions, 2019, 84: 82–95.