

面向电力通信网的光纤感知事件智能识别方法研究

张宏坡*, 黄钿捷, 林心影, 庄亚惠, 李婉玲, 柳玲玲

国网泉州供电公司信通中心, 泉州 362011, 福建, 中国

摘要: 针对电力通信网光纤感知事件识别中存在的时空特征混淆、复杂噪声干扰及误报率高等问题, 提出一种融合多域特征提取与智能分类的混合模型。首先, 构建基于深度可分卷积与 Log-Mel 的时空特征提取框架, 通过并行提取振动信号的时间依赖性与空间关联性, 有效区分挖掘、敲击等时空特征相似事件; 其次, 引入 EMA 注意力机制动态优化特征权重, 结合 Deformable Attention ViT 捕捉数据间的时空依赖, 提升对复杂现场环境下产生的低信噪比事件的识别鲁棒性; 最后, 采用更低计算量的神经网络结构作为主体, 提高检测实时性。我们在电网光纤监测情景下进行数据收集, 共收集了 6478 个样本, 捕获了 29 种类型的事件, 该方法在数据集上的识别准确率达 94.5%, 显著优于传统方法。本研究为电力通信光缆的智能化运维提供了有益的技术参考。

关键词: 电力通信网; 光纤感知事件; 智能识别; 分布式光纤传感

An Intelligent Recognition Method for Optical Fiber Sensing Events in Power Communication Networks

HongPo Zhang*, DianJie Huang, XinYing Lin, Yahui Zhuang, WanLing Li, LingLing Liu

Information and Communication Center, State Grid Quanzhou Power Supply Company, Quanzhou 362011, Fujian, China

Abstract: To address the confusion of spatio-temporal features, complex noise interference and high false-alarm rates in the recognition of optical fiber sensing events in power communication networks, a hybrid model that combines multi-domain feature extraction with intelligent classification is proposed. First, a spatio-temporal feature extraction framework based on depthwise separable convolution and Log-Mel spectrograms is constructed; by extracting the temporal dependency and spatial correlation of vibration signals in parallel, events with similar spatio-temporal characteristics, such as excavation and knocking, are effectively distinguished. Second, an EMA attention mechanism is introduced to dynamically optimize feature weights, and a Deformable Attention ViT is used to capture spatio-temporal dependencies among the data, improving the robustness of recognition for low signal-to-noise ratio events generated in complex field environments. Finally, a neural network structure with lower computational cost is adopted as the backbone to improve real-time detection performance. Data were collected in a power grid optical fiber monitoring scenario, yielding 6478 samples covering 29 event types. The proposed method achieves a recognition accuracy of

Copyright © 2026 by author(s) and Ufascience Publisher.

This work is licensed under the Creative Commons Attribution international License (CC BY 4.0)

<http://creativecommons.org/licenses/by/4.0/>



文章引用: 张宏坡, 黄钿捷, 林心影, 庄亚惠, 李婉玲, 柳玲玲. 面向电力通信网的光纤感知事件智能识别方法研究[J]. 现代工程与应用, 2026, 4(4): 1-8.

DOI: <https://doi.org/10.61784/mea2037>

94.5% on this dataset, significantly outperforming conventional methods. This study provides a useful technical reference for the intelligent operation and maintenance of power communication optical cables.

Keywords: Power communication network; Optical fiber sensing event; Intelligent recognition; Distributed acoustic sensing

一、引言

电力通信网作为电网的“神经中枢”，其光缆线路的安全稳定运行直接关系到电力调度与信息传输的可靠性。传统光纤监测技术（如视频监控、电子传感器）存在供电依赖性强、监测盲区多等缺陷，而分布式光纤传感技术 DAS 凭借其全分布式、高灵敏度的特性，已成为光纤状态监测的主流方案[1-4]。然而，实际工程中光缆受施工挖掘、自然环境（如雨天、桥梁悬空）及人为破坏等复杂事件干扰，导致 DAS 信号中混杂大量噪声与相似振动特征，传统基于固定阈值或机器学习的方法难以实现高精度分类。因此，开发面向电力通信网的高效光纤感知事件智能识别方法具有重要的理论与应用价值。

近年来，深度学习技术为光纤事件识别提供了新思路。如基于 1DCNN-BiLSTM 的时空特征提取模型[5]，但模型计算量大，实时性差，且 BiLSTM 的遗忘机制易导致早期特征丢失；还有基于深度学习卷积神经网络对 Φ -OTDR 进行分类[6]，但仅考虑时空图像的图形特征，未充分考虑数据的频域细节；也有学者基于 SVM 分类框架，在三类事件识别中取得 94% 的准确率[7]，但 SVM 分类在噪声混合施工事件情况下分类效果会变差，对于复杂场景噪声干扰抑制有限。现有方法的核心瓶颈在于：

时空频特征耦合不足：多数模型仅独立提取时间或空间或频域特征，忽视三者间的交互关系；

算法实时性较差：依靠堆叠参数和进行大量计算拟合数据集，对于设备性能和实时性不友好；

模型泛化能力弱：噪声干扰抑制有限，对小样本、低信噪比事件的适应性不足。

针对上述问题，本研究提出以下创新点：

多域特征融合架构：结合深度可分卷积与梅尔谱图，构建端到端的时空频特征交互模型，有效区分时空特征相似事件（如敲击与挖掘）；

注意力优化机制：通过跨空间学习的高效多尺度注意力 EMA 注意力层动态分配特征权重[8-11]，使语义特征在每个特征组内分布均匀，提升对弱信号小目标事件的识别能力；

轻量化计算策略：采用深度可分卷积[8]、CSPNet[10]、Deformable Attention ViT 作为提取特征的核心神经网络[9]，在保证模型性能的同时降低计算复杂度，满足工程实时性需求。

二、实验系统与数据收集

面向电力通信网的光纤感知系统如图 1 所示，分布式光纤声波传感（DAS）技术利用传感光缆作为探测元件，通过解调沿光缆背向传播的瑞利散射光，实现对周围声波信号的实时、定量监测。光缆上的每个点均具备感测能力，使其如同一条超长距离的麦克风阵列，能够连续、精准地拾取沿线的声波和振动信号。

通过搭建的光纤感知系统，实时监测电力通信网的震动信号，实现对各采样段的震动波形监测，由于单次采样即可获得同一时间下的震动的空间信息，对采样数据根据时序进行记录即可得到震动的时间变化情况，因此本文的信号存储采用二维矩阵式存储，列数据记录同一时间下不同采样点的震动分布情况，行数据记录不同时间下同一采样点的震动变化情况。




Figure 1 Optical Fiber Sensing System for Power Communication Networks

图 1 面向电力通信网的光纤感知系统

三、基于深度学习的光纤感知事件智能识别方法

(一) 基于时空频特征的多分类模型

为解决现有方法的核心瓶颈, 结合时间、空间、频域上的数据信息, 在高实时性的同时保持模型泛化能力, 设计 CNN-RFFT-ViT 光纤感知事件时空频特征提取模型如图 2 所示, 该模型能对于采集到的数据进行 29 种不同类别分类。




Figure 2 CNN-RFFT-ViT Spatio-Temporal-Frequency Feature Extraction Model for Optical Fiber Sensing Events

图 2 CNN-RFFT-ViT 光纤感知事件时空频特征提取模型

对本文使用的深度学习网络在性能上的提升理论上进行验证, DW-CONV 计算量相较于标准 CONV, 计算量变化如公式(5)所示, 以下计算公式中, C 为特征图通道数, H 和 W 为特征图尺寸, K 为卷积核大小, 本文均采用 K=3。

标准 CONV 计算量:

$$\text{FLOPs}_{\text{std}} = K \times K \times C_{\text{in}} \times C_{\text{out}} \times H \times W \quad (1)$$

深度可分卷积计算量:

$$\text{FLOPs}_{\text{pw}} = 1 \times 1 \times C_{\text{in}} \times C_{\text{out}} \times H \times W = C_{\text{in}} \cdot C_{\text{out}} \cdot H \cdot W \quad (2)$$

$$\text{FLOPs}_{\text{dw}} = K \times K \times C_{\text{in}} \times H \times W \quad (3)$$

$$\text{FLOPs}_{\text{ds}} = \text{FLOPs}_{\text{dw}} + \text{FLOPs}_{\text{pw}} = C_{\text{in}} \cdot H \cdot W \cdot (K^2 + C_{\text{out}}) \quad (4)$$

深度可分卷积与普通卷积的计算量比值:

$$\frac{FLOPs_{ds}}{FLOPs_{std}} = \frac{C_{in} \cdot H \cdot W \cdot (K^2 + C_{out})}{K^2 \cdot C_{in} \cdot C_{out} \cdot H \cdot W} = \frac{K^2 + C_{out}}{K^2 \cdot C_{out}} = \frac{1}{C_{out}} + \frac{1}{K^2} \quad (5)$$

CSPNet 计算量变化公式如公式(7)所示, α 为运算通道系数, 本文均采用 $\alpha=0.5$ 。

$$FLOPs_{cps} = K^2 \times (\alpha C_{in}) \times (\alpha C_{out}) \times H \times W \quad (6)$$

$$\frac{FLOPs_{cps}}{FLOPs_{std}} = \frac{\alpha^2 \times K^2 \times C_{in} \times C_{out} \times H \times W}{K^2 \times C_{in} \times C_{out} \times H \times W} = \alpha^2 \quad (7)$$

本文通过上述结构实现实时性提高的情况下, 由于 ViT 存在当模型较小时, 混合模型的表现要更好, 但是随着模型的增大, ViT 的表现超过了混合模型的特性[12-14], 根据我们的数据和任务特性, 需要轻量化的模型且拥有较多的数据集, 所以在进行 ViT 之前采用部分 CNN 网络进行局部性和偏置归纳, 引入更多时空数据的先验信息, 增强模型的最终表现。

(二) 特征提取方式

DAS 设备采集的数据中, 时域、空间域、频率域都有丰富的信息存在, 通过结合时空特征数据, 可对一些简单的事件数据进行分类, 而面对复杂的现场环境, 仅依赖时空特征, 类别的细化难度会提高, 对于一些微弱事件, 可能只有在频域才能发现存在痕迹, 因此本文选取的时-空-频三域特征融合的方式, 具体方式如图 3 所示。




Figure 3 Fusion Scheme of Time-Space-Frequency Tri-Domain Features

图 3 时-空-频三域特征融合方式

设备采集、组合、划分后的原始数据为 $640 \times 256 \times 1$ 的灰度数据, 由于可视化需要, 需要渲染成 shape 为 $640 \times 256 \times 3$ 的彩色数据如图 4, 并以此作为算法模型的原始输入。图 4 中, 列数据标识不同采样点采集的外部数据, 行数据表示一个采样点在不同的时间节点下的外部数据变化情况。




Figure 4 Device Data after Visual Rendering

图 4 可视化渲染后的设备数据

Step3 中实现完整的时-空-频三域数据特征融合, 分为两个分支:

(1) 由于输入数据是基于时空数据成像的, 所以融合时空数据可以从原始输入图像中直接做卷积进行特征提取, 采用图 3 的双层深度可分卷积完成局部性和偏置归纳。

(2) 频域数据通过快速傅里叶变换完成梅尔谱图的频域特征提取, 行数据表示单个采样点的时序变化情况, 因此行数据中含有对应采样点的频域信息。频域特征需要与 CNN 分支的时空特征做特征拼接, 通道数与时空特征图通道数一致, 所以先对渲染后的数据进行下采样得到 32 个均匀采样的行数据 ($640 \times 32 \times 3$), 再对渲染后的图像进行灰度化还原 ($640 \times 32 \times 1$), 最后进行快速傅里叶变换, 构造 log-mel, 得到 shape 与卷积分支完全一致的特征图。

在完成两个分支各自特征提取之后, 沿通道维度进行特征拼接, 获得完整的特征图数据。

四、实验结果与讨论

(一) 算法建立

实验系统如图 1 所示, 传感光纤采用电网线路某段通信光纤, 进行 1 个月的数据采集, 通过不同器械的实验数据采集完成基础数据集构建, 主要面向常见的市区器械如挖掘机、破路机、打桩机、人工挖掘等; 由于整条线路采样点数较多, 对全部数据进行同时处理的情况下显存要求过大, 且不进行下采样的情况下实时性差, 进行大步长下采样时又容易导致微弱信号丢失, 因此沿着距离采样方向将原始二维数据分割为多个 640 距离采样点的数据进行数据集构建, 即原始数据形状为 $640 \times 256 \times 1$ 。

本文根据线路路由的地理分布情况, 选取 29 种不同事件附近采样数据, 基于实验前期不同器械实验构建的基础数据集, 对不同事件的采样点数据进行收集、数据清洗和增强, 基于 1 个月的监测数据完成 6478 个样本、29 种事件类型的数据集, 以此 8: 2 的比例划分训练集和验证集进行实验验证[15-16]。

(二) 实验结果验证

对以上数据集进行 CNN-RFFT-ViT 网络的分类训练, 训练结果如图 5 所示。分析图 5 中数据, 可以得出训练过程中进行验证集预测的预测结果中, 真实类别得分第一的概率 (即类别准确率) 最高达到 94.50%, 对应验证轮次中真实类别得分在前五的概率为 99.48%; 并且训练损失与验证损失仍呈现逐步收敛状况, 模型实际能力尚未到极限, 只是随着模型训练过程提升速度放缓, 为避免出现过拟合而触发了早退机制, 提前终止训练; 可继续扩大数据集样本数进行训练, 进行更多类别数据细化[17]。训练模型在验证集上的类别混淆矩阵如图 6 所示。






Figure 5 Visualized Record of the Training Results**图 5** 训练结果可视化记录

(三) 对比实验

为验证时空频特征融合与当前常见的时空融合在多类别细分上的差距, 基于同一早退机制训练模型进行对比。将图 3 中的频域信息特征融合分支改为与时空特征提取分支一致的 DW-CONV 分支, 其余网络结构和数据处理方式完全一致, 在模型完成训练后, 统计类别混淆矩阵, 图 6 为时空频特征融合训练结果, 图 7 为仅时空特征融合训练结果。

**Figure 6** Training Results with Time-Space-Frequency Feature Fusion**图 6** 时空频特征融合训练结果**Figure 7** Training Results with Spatio-Temporal Feature Fusion Only**图 7** 仅时空特征融合训练结果

对比图 6 与图 7 的类别混淆矩阵结果, 基于时空频特征融合训练的模型对角线明显, 各类别准确率更高, 说明结合时空频三域特征的 CNN-RFFT-ViT 网络能够有效提取光纤信号数据在频域的特征, 捕捉时间空间信号下被隐藏的信息。在仅基于时空特征融合的网络中, 第十六类别是异常噪点类别, 主要是一些光纤接头位置受

轻微干扰而产生的反射数据, 从时空图像上并没有直观统一的特征, 因此在图 7 中预测类别被全部误判为其他类别, 准确率 0%; 而混合三域特征的 CNN-RFFT-ViT 成功将此类数据分类准确率提高到 90% 以上, 说明引入此类数据在频域的信息对于此类类别的分辨有明确的作用, 时空频特征耦合在本文实验场景下有正向作用。

五、结论

针对电力通信网光纤感知事件识别中存在的时空特征混淆、复杂噪声干扰及误报率高等问题, 提出一种融合多域特征提取与智能分类的混合模型算法。通过实验线路采集的 6478 个样本, 构造 29 种类型的分类数据集, 训练了基于 CNN-RFFT-ViT 的时间、空间、频域特征融合分类网络, 并在划分的验证集上, 正确模式识别率在 94.5% 以上。相较于二分类式的异常检测方法, 该算法在进行事件与噪声判别的同时, 还能够准确地分辨出不同扰动事件, 提高事件报警的正确率。文中所提出的 CNN-RFFT-ViT 算法通过对时间、空间、频域的融合, 具有更强的抗干扰性和准确性, 可为电力通信网光纤感知事件识别进一步提高提供有益参考。

基金项目

国网泉州供电公司揭榜挂帅项目“基于电网 GIS 地图的光缆路径定位技术研究及应用”(B3133025Z007)。

参考文献

- [1] Shang Y, Sun M, Wang C, et al. Research progress in distributed acoustic sensing techniques. *Sensors*, 2022, 22(16): 6060.
- [2] Nishimura T, Emoto K, Nakahara H, et al. Source location of volcanic earthquakes and subsurface characterization using fiber-optic cable and distributed acoustic sensing system. *Scientific Reports*, 2021, 11(1): 6319.
- [3] Huang X D, Zhang H J, Liu K, et al. Fully modelling based intrusion discrimination in optical fiber perimeter security system. *Optical Fiber Technology*, 2018, 45: 64-70.
- [4] Shang Y, Wang C, Zhang Y, et al. Non-intrusive pipeline flow detection based on distributed fiber turbulent vibration sensing. *Sensors*, 2022, 22(11): 4044.
- [5] Wu H, Yang M, Yang S, et al. A novel DAS signal recognition method based on spatiotemporal information extraction with 1DCNNs-BiLSTM network. *IEEE Access*, 2020, 8: 119448-119457.
- [6] Shi Y, Wang Y, Zhao L, et al. An event recognition method for Φ -OTDR sensing system based on deep learning. *Sensors*, 2019, 19(15): 3421.
- [7] Zhang Junnan, Lou Shuqin, Liang Sheng. Study of pattern recognition based on SVM algorithm for ϕ -OTDR distributed optical fiber disturbance sensing system. *Infrared and Laser Engineering*, 2017, 46(4): 0422003.
- [8] Chollet F. Xception: Deep learning with depthwise separable convolutions. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 2017: 1251-1258.
- [9] Xia Z, Pan X, Song S, et al. Vision transformer with deformable attention. *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, 2022: 4794-4803.
- [10] Wang C Y, Liao H Y M, Wu Y H, et al. CSPNet: A new backbone that can enhance learning capability of CNN. *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops*, 2020: 390-391.
- [11] Ouyang D, He S, Zhang G, et al. Efficient multi-scale attention module with cross-spatial learning. *ICASSP 2023 - 2023 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*. IEEE, 2023: 1-5.

-
- [12] Dosovitskiy A. An image is worth 16x16 words: Transformers for image recognition at scale. arXiv preprint arXiv:2010.11929, 2020.
- [13] 王文婷, 田博彦, 吴法宗, 等. 面向智能电网信息物理融合攻击的建模, 检测和防御理论与方法. 电子与信息学报, 2026, 48: 4.
- [14] 王冠鹰, 安春燕, 张东磊, 等. 智能感知在新型电力系统中的应用与发展综述. 智能感知工程, 2026, 3(2): 31-57.
- [15] 李鹏, 毕建刚, 于浩, 等. 变电设备智能传感与状态感知技术及应用. 高电压技术, 2020, 46(9): 3097-3113.
- [16] 叶津江. 面向智能电网的电力电缆故障卷积神经网络监测方法开发. 电工技术, 2026.
- [17] 葛磊蛟, 汪宇倩, 戚嘉兴, 等. 面向城市能源互联网的电力物联网内涵, 架构和关键技术. 电力建设, 2019, 40(9): 91-98.