

激光与光电子学进展

基于分数阶傅里叶变换的分布式光纤振动识别

孔小红, 张明*, 管翰林, 蒋陵, 郭闯

国网江苏省电力有限公司南京供电分公司, 江苏 南京 210000

摘要 针对当前分布式光纤振动传感对振动干扰事件的识别容易过拟合以及泛化能力不强的问题, 提出了一种基于分数阶傅里叶变换(FrFT)的分布式光纤振动事件识别方法。采用FrFT对时域振动信号进行时频变换, 相比传统的时域方法多了一个新的分析维度。相比传统时频域方法, 该方法不仅解决了时间分辨率和频率分辨率相互制约的问题, 还增强了时频数据的特征丰富度, 更利于深度模型的学习, 可有效防止模型过拟合。户外实地实验表明, FrFT方法的识别准确率达到98.5%, 且在专门的泛化测试集上依然能保持98%以上的准确率。同时引入更可靠的评估指标 f1-score (f1-score是精确率和召回率的调和平均数)来综合评估精确率和召回率, 该方法识别各事件的 f1-score 均高于0.975。

关键词 光纤传感; 分布式光纤传感; 分数阶傅里叶变换; 分布式光纤振动传感

中图分类号 TN29

文献标志码 A

DOI: 10.3788/LOP230789

Distributed Fiber Optic Vibration Recognition Based on Fractional Fourier Transform

Kong Xiaohong, Zhang Ming*, Guan Hanlin, Jiang Ling, Guo Chuang

State Grid Jiangsu Electric Power Co., Ltd., Nanjing Power Supply Branch, Nanjing 210000, Jiangsu, China

Abstract At present, the recognition of vibration events by distributed fiber optic vibration sensing is easy to overfit and the generalization ability is insufficient. We propose a distributed fiber optic vibration recognition method based on fractional Fourier transform (FrFT). The method uses FrFT for the time-frequency conversion of the time-domain vibration signals, which means adding a new analysis dimension compared with the traditional time-domain method. Compared with the traditional time-frequency domain method, this method not only solves the problem of mutual constraints of time resolution and frequency resolution but also enhances the feature richness of time-frequency data. It is more conducive to the learning of deep models and can effectively prevent model overfitting. Outdoor field experiments show that the recognition accuracy of the FrFT method reaches 98.5%, and the accuracy can still maintain more than 98% on the special generalization test set. At the same time, a more reliable evaluation index f1-score is introduced. The f1-score is the harmonic mean of precision and recall. It is used to comprehensively evaluate precision and recall. The f1-score of each event recognized by this method is higher than 0.975.

Key words fiber optics sensors; distributed optical fiber sensing; fractional Fourier transform; distributed fiber optic vibration sensing

1 引言

分布式光纤振动传感(DVS)技术是分布式光纤传感技术的一种,能实时从光纤内传递的光信号中提取出沿光纤分布的振动信号,并依此对光纤周边的振动源进行判断。该技术具有分布式光纤传感技术的各项优点,如抗电磁干扰、抗腐蚀、无源等,还具有振动灵敏度高、结构简单、监测距离长等优点。DVS技术能

应用于周界安防^[1-2]、地铁电缆防外力^[3]、油气管道防泄漏^[4-5]、地震海啸预警^[6-7]等各种安防监测领域。相比传统的传感器和安防方式,DVS技术成本更低,更方便,监测范围更广,但是目前DVS振动监测还存在泛化性和稳定性不足的问题,这是环境的振动多样性,DVS信号的不稳定性、动态性和不可预测性以及传统算法不足等原因导致的^[8]。

目前的DVS振动事件识别技术主要分为两类:一

收稿日期: 2023-03-07; 修回日期: 2023-04-18; 录用日期: 2023-04-28; 网络首发日期: 2023-05-08

基金项目: 国网江苏省电力有限公司科技项目(J2022102)

通信作者: *guanhl111@163.com

种是基于特征提取和模式识别的传统 DVS 振动识别技术^[9-10];另一种是近几年流行的基于深度学习的 DVS 振动识别技术^[11-13]。Liu 等^[14]采用混合特征的方式来丰富振动样本的特征,人工设计了频率、均值、方差、能量等特征作为事件判断的特征,最后交由支持向量机等机器学习算法进行模式识别,该方法的平均识别准确率达 97%。吴俊等^[15]利用卷积神经网络(CNN)的强大特征提取能力,直接将采集的振动信号进行预处理后便输入 CNN 训练,最终实现了 96.59% 的端到端的振动事件识别准确率。可以看出,传统 DVS 技术需要进行特征设计,设计的特征合适与否决定着模型的识别效果。而基于深度学习的 DVS 技术相比传统技术可以自动学习大量的干扰振动特征,凭借 CNN 的强大非线性学习和决策能力可以达到理论上更好的分类效果。但是目前研究的样本大都是时域和时频域数据,所包含的特征信息并不复杂,无法发挥好深层 CNN 的强大能力,所以经常会出现过拟合的现象,导致模型的泛化性不强。并且时频域数据往往存在时间和频率分辨率相矛盾的问题,实际应用中,时间域的窗长和窗函数是固定不变的,只能降低时间域采样率换取更高的频率采样率,相反也同理。

为了解决这些问题,本文结合分数阶傅里叶变换(FrFT)的信号特征维度丰富且不受时间和频率分辨

率制约的特点,提出了将 FrFT 生成的时频数据作为输入,将具有强大非线性特征提取能力的残差 CNN 作为模型的识别方法,实现了对不同振动事件泛化能力更强、更高效准确的识别。

2 数据采集和处理

2.1 基于相敏光时域反射(φ -OTDR)的 DVS 系统

采用的 DVS 技术是基于 φ -OTDR 系统的光纤传感技术。所提系统主要结构如图 1 所示,窄线宽光源输出的高相干光经过调制后变为脉冲光,经过掺铒光纤放大器放大后输入埋在地下地下的待测光缆中,脉冲光在光纤内部传输时,与光纤的微观粒子发生碰撞产生散射现象,部分瑞利散射光会向与入射光相反方向传输,这部分散射光从光缆的入射端输出通过环形器被光电探测器探测,最后经过数模转换形成沿光纤分布的瑞利散射波形。系统的光源是高相干光源,同一脉冲下的这部分散射光之间会发生干涉现象,因此如果光缆任意位置附近的地面上发生扰动事件,其振动通过土地传递到光缆,该处的折射率和光纤长度会发生变化,导致该处干涉的瑞利散射光的相位发生变化,从而使最终的瑞利散射波形发生明显变化。将振动前后两次波形相减便可以得到振动反射的位置。

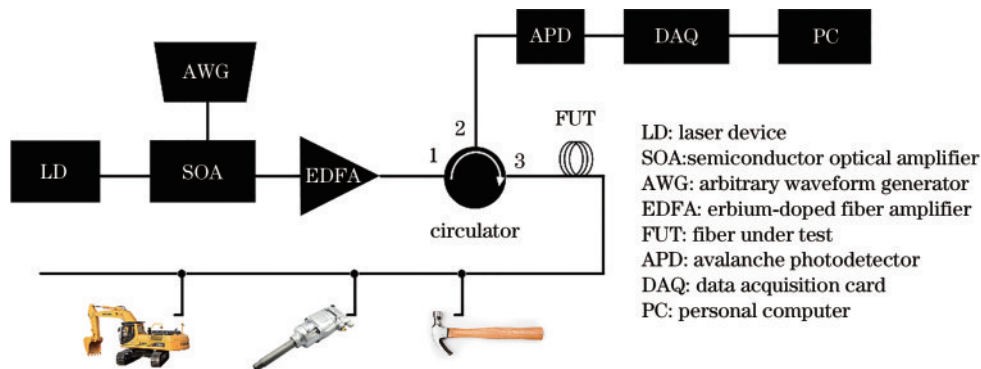


图 1 基于 φ -OTDR 的 DVS 系统

Fig. 1 DVS system based on φ -OTDR

2.2 户外实验与采集

选用上述 DVS 系统结构在户外进行实验采集大量振动干扰数据,主要振动事件有锤子敲击、风镐作业和挖掘机作业,这些振动都是电缆、油气管道、火车铁路等设施常需要的待告警事件。系统的空间分辨率为 5 m,脉冲重复频率为 1 kHz,实验光缆总长度为 25 km。从长度为 20 km 的光缆附近引出 100 m 左右的光缆埋于深度为 0.8~1.0 m 的泥土里。利用该实验平台在不同位置采集锤子、风镐、挖掘机和环境噪声 4 种事件信号,分别模拟人工破坏、中小型机械作业、大型机械作业以及无作业环境事件,其中:锤子敲击事件 3332 组;风镐作业事件 3558 组;挖掘机作业事件 3359 组;环境噪声事件 3400 组。这些样本的强度归一化时域曲线如图 2 所示,

每个事件样本时长为 256 ms,采样间隔为 1 ms。图 2(a)为利用工具对光缆附近土壤进行人工破坏所产生的信号,因为人工破坏的频率不会很高,所以样本存在一个强度最高的短时冲击,同时周围伴随短时的“余震”效果,有明显的衰减过程。图 2(b)为风镐作业引起的振动信号,风镐的频率极快,因此能在短时间内产生多次周期性的短时冲击。挖掘机作业事件振动信号如图 2(c)所示,由于挖掘机引起的振动非常强烈且复杂,所以信号往往振幅较大,没有多少规律。图 2(d)为无作业时的环境噪声信号,环境噪声包含各种其他事件,信号特征多样,有无强烈振幅的信号,也有振幅较大的信号。实际采集了大量的环境噪声事件,为了保证不同振动事件样本数量的均匀性,随机选择 3400 组作为环境噪声样本。

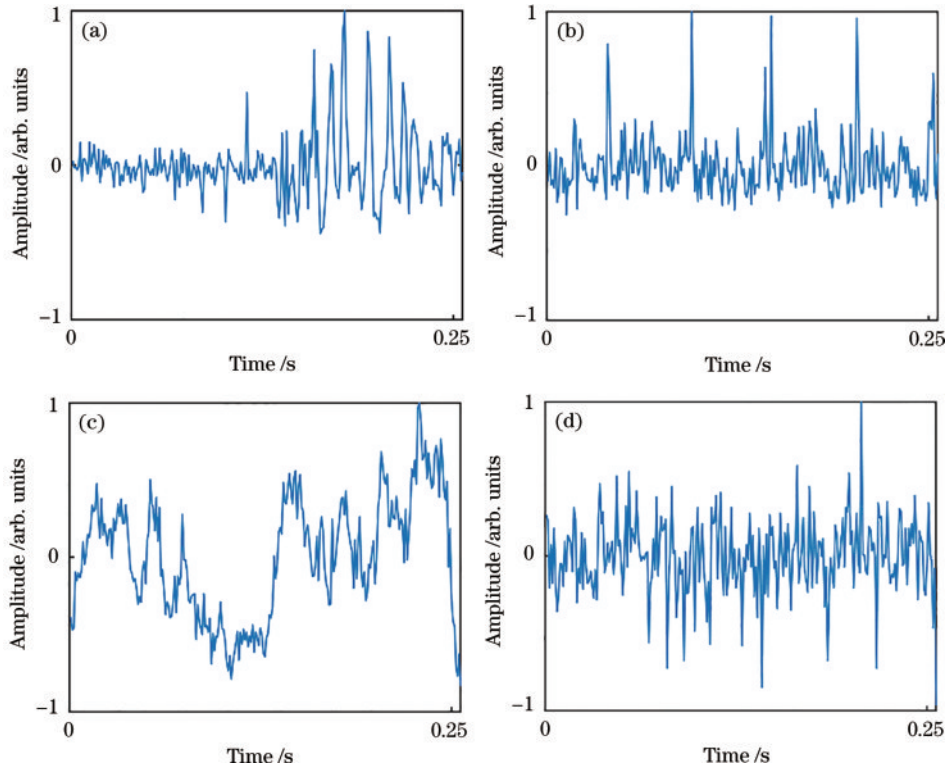


图 2 不同振动事件的强度归一化时域曲线。(a)锤子敲击;(b)风镐作业;(c)挖掘机作业;(d)环境噪声
Fig. 2 Time domain curves of different vibration events. (a) Hammering; (b) air pick operation; (c) excavator operation; (d) ambient noise

2.3 FrFT

φ -OTDR 信号具有非平稳性,这也是目前大量 DVS 的应用误报率高的原因之一,不同时间不同地点测量的相同事件特征可能发生一定的变化,导致以前训练的网络模型无法具有较好的泛化能力,单单一个时域特征并不完全可靠。所以很多研究对时域信号进行时频分析,比如通过短时傅里叶变换(STFT)将时域样本转换为时频域样本,让深度学习从时域和频域两个维度对振动事件进行学习^[16]。但对于 DVS 来说,原始信号具有一定的复杂度,随着复杂度的提高,很多情况下,传统时频变换方法无法获得非常有效的结果,如传统的时频分析方法往往无法兼顾频率分辨率和时间分辨率,时间分辨率越高,频率分辨率就越低,反之亦然。因此传统的时频变换方法获得的时频域数据无法呈现更丰富的时频特征。

为了克服这些问题,引入了 FrFT^[17]。对于图 3 的信号时-频域分布^[17](横轴代表信号的时域,纵轴代表信号的频域):STFT 的作用是将信号在这个时-频域分布中进行 90°且只能 90°的旋转;而在时频平面,坐标 (μ, ν) 相对于原始坐标 (t, ω) 旋转角度 α ,这就是 FrFT 的时频旋转特性——可以实现任意角度的旋转,旋转的角度与 FrFT 的阶次相关,即可以将信号任意变化到 时域和频域之间的分数域中。所以通过 FrFT 可以不断遍历 时频域之间的分数域,从而增加更多维的信号分析维度。




图 3 FrFT 时-频旋转特性^[17]
Fig. 3 Time-frequency rotation characteristics of FrFT^[17]

FrFT 的阶次 p 与角度 α 的关系为

$$p = 2\alpha/\pi, \tag{1}$$

当 $p=1$ 时,FrFT 的旋转角度为 90°,代表信号从时域变换到频域。因此可以将傅里叶变换看作是 FrFT 的一个特例。通过 FrFT 得到的时频图的频率分辨率由角度 α 决定,可以根据需求设置,本文 α 取 4.5°。时间分辨率也由系统的时间域采样率决定,所以 FrFT 可以较好地解决两者相制约的问题。

对原始时域信号进行 FrFT 然后归一化,得到的样本如图 4 所示。样本尺寸为 256 pixel × 256 pixel,相比传统的时频图,由 FrFT 产生的时频图时频特征更丰富。从图 4 可以看出:锤子敲击事件的频率主要

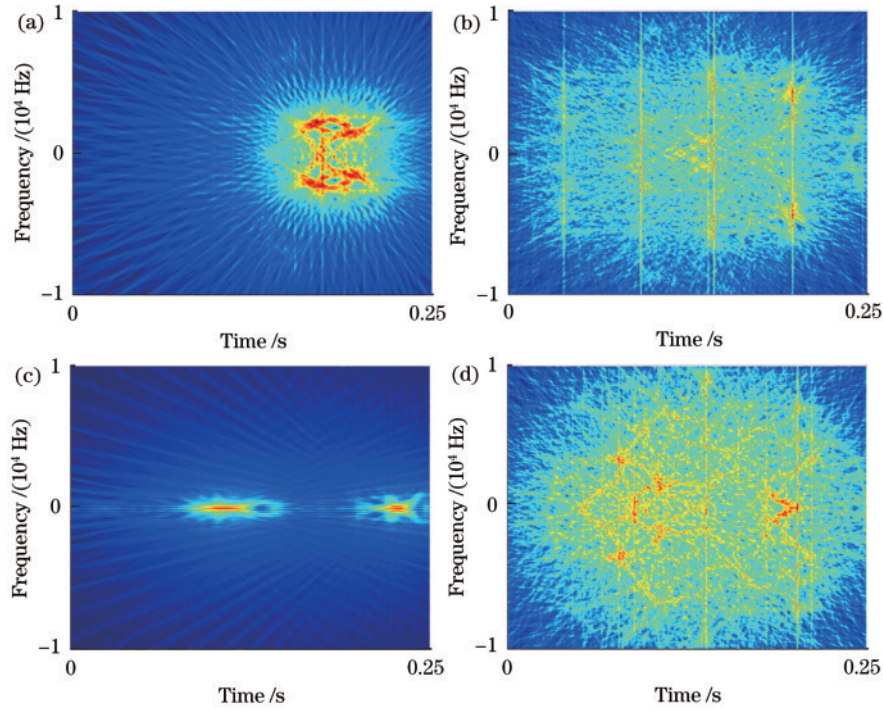


图4 不同振动事件的时频图。(a)锤子敲击;(b)风镐作业;(c)挖掘机作业;(d)环境噪声

Fig. 4 Time-frequency graphs of different vibration events. (a) Hammering; (b) air pick operation; (c) excavator operation; (d) ambient noise

分布在中低频;风镐事件和环境噪声事件的特征遍布时频图;挖掘机事件的振动频率较低。

3 残差网络模型

3.1 CNN和残差结构

CNN是深度学习技术中的一项应用非常广泛的技术,目前被运用在图像识别和分类、自然语言处理、目标检测等各领域。CNN主要由卷积层、池化层和全连接层组成^[18]。卷积层通过卷积核和激活函数将输入数据的边角等局部特征提取出来,将原始数据映射到隐层特征空间。卷积层本质为一个可学习的滤波器,其参数随梯度下降算法被训练,使得最终CNN输出的结果与训练集中的每个样本的标签相吻合。池化层的作用是减少数据样本的空间尺寸,大大减轻网络的参数数量,减少无意义的计算,让模型更容易拟合。全连接层将学习的特征表示映射到样本的标记空间,实现分类或回归的功能。

对于DVS,CNN的本质和传统的特征提取以及模式识别方法并无区别,CNN中卷积层池化层的功能便是特征提取和特征选择的作用,全连接层的功能便是进行模式识别。只是CNN的特征提取由训练集的特性来决定而不是人为设计的。所以对于CNN来说,训练集的组成和CNN的模型结构尤为重要。CNN特征提取的能力主要由模型的深度决定,一般来说,卷积层更多的网络具有更好的识别和泛化能力。但是当模型卷积层到达一定数量时,会出现梯度消失和网络“退化”等问题,导致模型难以训练和收敛^[19]。

残差网络通过其独特的捷径连接(shortcut)功能,将输入特征跳过卷积层直接与卷积层的输出相叠加,有效缓解了深层网络梯度消失和退化的问题。

3.2 模型结构和参数

使用的残差网络结构如图5所示,主要分为三个部分:第一部分由一个卷积层、批量归一化(BN)层、激活函数(ReLU)和池化层(pooling)组成,该部分主要对输入的信号数据进行升维和池化,其中,卷积核大小为 7×7 ,通道数为1,步长为2;第二部分主要由8个残差块组成,残差块结构如图5虚线部分所示,通道数依次为64、64、128、128、256、256、512、512;第三部分由池化层和全连接(FC)层组成。最终结果为柔性最大值传输函数(Softmax)输出的一个 1×4 的向量。

根据上述网络结构,在Python 3.8、PyTorch 1.7的环境下搭建好模型,设置好参数,其中:学习率为0.001;批次为64;反向传播算法为Adam;损失函数为交叉熵(cross entropy)损失;为了便于比较,训练迭代周期都为100次。为了防止训练周期过长导致的过拟合,选择验证集损失函数最小的周期为最佳周期,该周期下的模型为最优模型。

3.3 评价指标

评估三种方法的识别效果和泛化能力需要有一个强大可靠的评价指标,通常采用混淆矩阵参数来衡量,即准确率(accuracy)、精确率(precision)、召回率(recall)和F1值(f1-score),其中f1-score是精确率和召回率的调和平均值,通常作为最终评价指标。4个评价指标的计算方法为

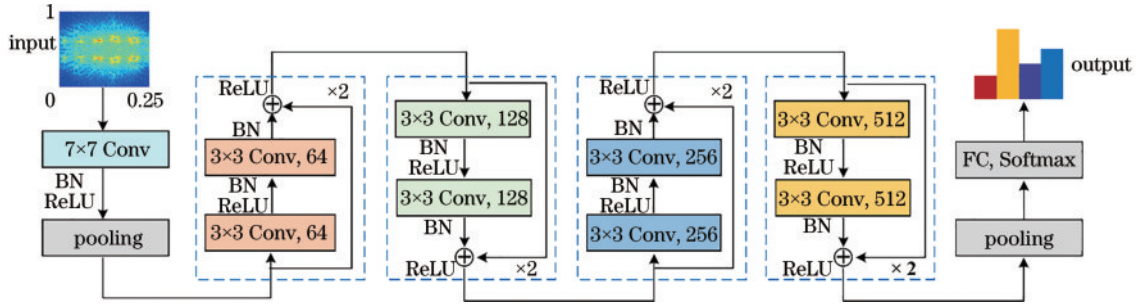


图 5 残差 CNN 结构

Fig. 5 Residual CNN structure

$$A = \frac{T_p + T_n}{T_p + T_n + F_p + F_n}, \quad (2)$$

$$P = \frac{T_p}{T_p + F_p}, \quad (3)$$

$$R = \frac{T_p}{T_p + F_n}, \quad (4)$$

$$f = \frac{2 \times P \times R}{P + R}, \quad (5)$$

式中: A 表示准确率; P 表示精确率; R 表示召回率; f 表示 f1-score; T_p (true positive) 为正确的正例; F_n (false negative) 为错误的反例; F_p (false positive) 为错误的正例; T_n (true negative) 为正确的反例。

4 实验结果与讨论

为了评估所提 FrFT 和 CNN 算法的性能, 将其他文章中常用的时域和时频域方法与所提时频域方法对比。选用同样的原始数据, 对于基于时域的 CNN 算法, 选用相同结构的一维 CNN 对时域数据进行训练; 对于基于时频域的 CNN 算法, 选用最常用的 STFT 算法, 其中快速傅里叶变换 (FFT) 长度为 256, 帧移为 25, 窗函数为矩形窗。

为了保证对比的有效性, CNN 模型的网络层数、残差结构、迭代次数、反向传播算法等全部相同。将数据集按 8:1:1 分为训练集、验证集和测试集, 各类事件分布均匀。三种方法的识别结果如表 1 所示, 可以看出三种方法在识别环境噪声和风镐时表现良好, 基于 FrFT 的方法具有最高的识别准确率, 达到 98.5%。另两种方法对于锤子敲击和挖掘机事件的识别准确率相对偏低。综合指标 f1-score 表明基于 FrFT 的方法的性能相比其他方法要好一些。

由于 φ -OTDR 信号具有非平稳性和时变性, 与训练集具有相似特征分布的测试集无法很好地衡量模型的泛化能力, 因此一周后在不同地点重新采集新的振动数据作为泛化测试集, 其中: 锤子样本 268 组; 风镐样本 330 组; 挖掘机样本 277 组; 为了保证不同事件样本数量的均匀性从大量新采集的噪声数据中随机选择 300 组环境噪声样本。测试结果如表 2 所示, 可以看出, 基于 FrFT 的方法相比 STFT 方法并未发生明显的

表 1 测试集上三种方法的识别结果比较

Table 1 Comparison of the recognition results of the three methods in the test set

| Class | Event type | P | R | f |
|-------------|---------------|-------|-------|--------------|
| Time-domain | Ambient noise | 0.981 | 0.994 | 0.987 |
| | Hammering | 0.959 | 0.976 | 0.967 |
| | Air pick | 0.989 | 0.992 | 0.990 |
| | Excavator | 0.981 | 0.947 | 0.964 |
| STFT | Ambient noise | 0.980 | 0.997 | 0.988 |
| | Hammering | 0.944 | 0.953 | 0.949 |
| | Air pick | 0.997 | 0.967 | 0.982 |
| | Excavator | 0.960 | 0.965 | 0.963 |
| FrFT | Ambient noise | 0.994 | 0.991 | 0.993 |
| | Hammering | 0.976 | 0.982 | 0.979 |
| | Air pick | 0.984 | 0.995 | 0.989 |
| | Excavator | 0.987 | 0.971 | 0.979 |

表 2 泛化测试集上三种方法的识别结果比较

Table 2 Comparison of recognition results of the three methods on the generalized test set

| Class | Event type | P | R | f |
|-------------|---------------|-------|-------|--------------|
| Time-domain | Ambient noise | 0.993 | 1.000 | 0.996 |
| | Hammering | 0.951 | 0.802 | 0.870 |
| | Air pick | 0.909 | 0.970 | 0.938 |
| | Excavator | 0.905 | 0.964 | 0.934 |
| STFT | Ambient noise | 0.987 | 0.980 | 0.983 |
| | Hammering | 0.835 | 0.966 | 0.896 |
| | Air pick | 0.974 | 0.809 | 0.884 |
| | Excavator | 0.928 | 0.982 | 0.954 |
| FrFT | Ambient noise | 0.980 | 0.997 | 0.988 |
| | Hammering | 0.978 | 0.974 | 0.976 |
| | Air pick | 0.991 | 0.973 | 0.982 |
| | Excavator | 0.971 | 0.978 | 0.975 |

准确率下降, 而 STFT 方法和时域方法均出现了一定的准确率下降的情况, 特别是锤子和风镐事件, 其 f1-score 下降明显。时域方法的锤子敲击事件的 f1-score 仅有 87%, 相比表 1 的 96.7% 下滑 9.7 个百分点; 基于 STFT 的时频域方法, 其锤子敲击事件和风镐事件的 f1-score 均低于 90%, 相比表 1 的 94.9% 和 98.2% 下

滑了 5.3 和 9.8 个百分点,表明在训练时出现了过拟合,导致泛化性能不强。基于 FrFT 的方法的 f1-score 基本保持不变,表明 FrFT 丰富的时频特征能够较好地帮助 CNN 区分非平稳且时变的 φ -OTDR 信号。

5 结 论

提出了一种基于 FrFT 的深度学习 DVS 振动识别方法,将 FrFT 和深度残差网络相结合,一方面利用 FrFT 产生的时频数据不受频率和时间分辨率的制约,具有更多的分析信号维度的特点,另一方面充分利用 CNN 强大的非线性特征提取和识别能力,避免了传统振动事件识别容易过拟合的问题。通过对锤子敲击、风镐作业、挖掘机作业和环境噪声 4 种实际应用中常遇到的传感事件进行测试,并与时域和传统时频域方法进行对比,验证了该方法的有效性。测试结果表明,基于 FrFT 的方法的 f1-score 和识别准确率都能达到 98% 及以上,明显优于另外两种方法。同时,为了验证所提方法的泛化性,避免 φ -OTDR 信号的非平稳性导致的系统误报,重新在不同地点不同日期采集了新的振动事件样本作为泛化测试集,基于 FrFT 的方法的识别准确率和 f1-score 仍然保持在 97.5% 以上,基本维持不变,表明该方法产生的时频数据能有效缓解模型的过拟合,增强泛化能力。

由于很多 DVS 振动事件,如挖掘机数据难以大量采集,数据也难以通过仿真的方式模拟,所以目前实验所采集的有效数据仍然不够丰富,这也是这个研究领域共同面临的一大挑战,之后将展开该问题的研究工作。时下非常火的扩散模型(diffusion model)可以从高斯噪声中一步步去噪生成符合需要的图片或数据,这能为仿真不同振动事件下的 φ -OTDR 信号提供帮助。

参 考 文 献

- [1] Lü C G, Huo Z Q, Liu Y G, et al. Robust intrusion events recognition methodology for distributed optical fiber sensing perimeter security system[J]. IEEE Transactions on Instrumentation and Measurement, 2021, 70: 9505109.
- [2] Ma P F, Liu K, Jiang J F, et al. Probabilistic event discrimination algorithm for fiber optic perimeter security systems[J]. Journal of Lightwave Technology, 2018, 36(11): 2069-2075.
- [3] Wang Z Y, Zheng H R, Li L C, et al. Practical multi-class event classification approach for distributed vibration sensing using deep dual path network[J]. Optics Express, 2019, 27(17): 23682-23692.
- [4] 王辰, 刘庆文, 陈典, 等. 基于分布式光纤声波传感的管道泄漏监测[J]. 光学学报, 2019, 39(10): 1006005.
Wang C, Liu Q W, Chen D, et al. Monitoring pipeline leakage using fiber-optic distributed acoustic sensor[J]. Acta Optica Sinica, 2019, 39(10): 1006005.
- [5] Wu H J, Qian Y, Zhang W, et al. Feature extraction and identification in distributed optical-fiber vibration sensing

system for oil pipeline safety monitoring[J]. Photonic Sensors, 2017, 7(4): 305-310.

- [6] Williams E F, Fernández-Ruiz M R, Magalhaes R, et al. Distributed sensing of microseisms and teleseisms with submarine dark fibers[J]. Nature Communications, 2019, 10: 5778.
- [7] Ide S, Araki E, Matsumoto H. Very broadband strain-rate measurements along a submarine fiber-optic cable off Cape Muroto, Nankai subduction zone, Japan[J]. Earth, Planets and Space, 2021, 73(1): 1-10.
- [8] Kandamali D F, Cao X M, Tian M L, et al. Machine learning methods for identification and classification of events in φ -OTDR systems: a review[J]. Applied Optics, 2022, 61(11): 2975-2997.
- [9] Zhu H, Pan C, Sun X H. Vibration pattern recognition and classification in OTDR based distributed optical-fiber vibration sensing system[J]. Proceedings of SPIE, 2014, 9062: 906205.
- [10] Adeel M, Shang C, Hu D Y, et al. Impact-based feature extraction utilizing differential signals of phase-sensitive OTDR[J]. Journal of Lightwave Technology, 2020, 38(8): 2539-2546.
- [11] Shiloh L, Eyal A, Giryas R. Efficient processing of distributed acoustic sensing data using a deep learning approach[J]. Journal of Lightwave Technology, 2019, 37(18): 4755-4762.
- [12] Wang M N, Deng L, Zhong Y Z, et al. Rapid response DAS denoising method based on deep learning[J]. Journal of Lightwave Technology, 2021, 39(8): 2583-2593.
- [13] Xu W J, Yu F H, Liu S Q, et al. Real-time multi-class disturbance detection for φ -OTDR based on YOLO algorithm[J]. Sensors, 2022, 22(5): 1994.
- [14] Liu K, Sun Z S, Jiang J F, et al. A combined events recognition scheme using hybrid features in distributed optical fiber vibration sensing system[J]. IEEE Access, 2019, 7: 105609-105616.
- [15] 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 1-D CNN [J]. Opto-Electronic Engineering, 2019, 46(5): 180493.
- [16] Xu C J, Guan J J, Bao M, et al. Pattern recognition based on time-frequency analysis and convolutional neural networks for vibrational events in φ -OTDR[J]. Optical Engineering, 2018, 57(1): 016103.
- [17] Almeida L B. The fractional Fourier transform and time-frequency representations[J]. IEEE Transactions on Signal Processing, 1994, 42(11): 3084-3091.
- [18] Karpathy A. Cs231n: convolutional neural networks for visual recognition[EB/OL]. [2023-05-06]. <http://cs231n.stanford.edu/2017/>.
- [19] He K M, Zhang X Y, Ren S Q, et al. Deep residual learning for image recognition[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), June 27-30, 2016, Las Vegas, NV, USA. New York: IEEE Press, 2016: 770-778.