

基于多时频图和注意力机制的 Φ -OTDR相似事件识别方法施 羿¹,梁立功^{2*},封 皓³

(1.汕头大学 工学院,广东 汕头 515063;

2.新疆浩源供水有限公司,新疆 哈密 839000;3.天津大学 精密仪器与光电子工程学院,天津 300072)

摘要:为提升相位敏感型光时域反射仪(Φ -OTDR)系统对振动事件径向距离的识别能力,特别是在低信噪比条件下的识别效果。提出一种基于多时频图与注意力机制的识别方法,通过梅尔谱变换(Mel)和离散-连续小波变换(CWT)增强信号时频特征,并构建多通道SE-ResNet50网络,引入通道注意力机制以自适应融合多源特征。实验结果表明,该方法在0~9 m径向距离范围内的相同事件识别准确率达到98.66%,相比单一Mel图、CWT图分别提升5.35%和3.61%,有效增强了 Φ -OTDR在复杂环境下的特征表达与识别能力。

关键词:相位敏感型光时域反射仪;时频分析;注意力机制;事件识别

中图分类号:TP212 **文献标志码:**A **文章编号:**1002-5561(2025)05-0078-06

DOI:10.13921/j.cnki.issn1002-5561.2025.05.014

Recognition method for similar events in Φ -OTDR based on multi-time-frequency diagram and attention mechanismSHI Yi¹, LIANG Ligong^{2*}, FENG Hao³

(1. College of Engineering, Shantou University, Shantou Guangdong 515063, China; 2. Xinjiang Haoyuan Water Supply Co., Ltd., Hami Xinjiang 839000, China; 3. School of Precision Instruments and Opto-Electronics Engineering, Tianjin University, Tianjin 300072, China)

Abstract: To enhance the recognition capability of phase-sensitive optical time-domain reflectometer(Φ -OTDR) systems for identifying the radial distance of vibration events, especially under low signal-to-noise ratio (SNR) conditions, a recognition method based on multi-time-frequency maps and an attention mechanism is proposed. This approach employs Mel-spectrogram transformation and discrete-continuous wavelet transform (CWT) to enhance the time-frequency features of the signal, and constructs a multi-channel SE-ResNet50 network incorporating a channel attention mechanism to adaptively fuse multi-source features. Experimental results demonstrate that the proposed method achieves a recognition accuracy of 98.66% within a radial distance range of 0~9 m for identical events, representing improvements of 5.35% and 3.61% compared to using only Mel-spectrograms or CWT maps, respectively. The method effectively enhances the feature representation and recognition performance of Φ -OTDR in complex environments.

Key words: phase-sensitive optical time-domain reflectometer, time-frequency analysis, attention mechanism, event recognition

0 引言

近年来,随着光纤传感技术的飞速发展,相位敏

收稿日期:2025-05-20。

基金项目:国家重点研发计划项目(2022YFC3203802)资助。

作者简介:施羿(1990—),男,博士,本科和博士均毕业于天津大学,现任汕头大学副教授,硕士生导师,主持国家自然科学基金和广东省自然科学基金项目,研究方向为分布式光纤传感技术、深度学习技术、智能识别技术。

*通信作者:梁立功(1976—),男,高级工程师,主要研究方向为水利工程和基于光纤传感的长输水管道检测与智能分析技术。



感型光时域反射仪(Φ -OTDR)因其高灵敏度、动态响应能力、长距离监测和抗电磁干扰等特性,在基础设施安全监测^[1]、油气管道泄漏检测^[2-3]、周界安防^[4-5]、地震检测以及海缆监测^[6-8]等领域展现出重要应用价值。振动信号探测中事件识别不强一直是困扰 Φ -OTDR系统应用的主要问题之一。深度学习技术的发展和引入,极大地增强了 Φ -OTDR系统的信号识别能力。2019年,SHI Y等人^[9]将传感信号整理为时空矩阵,输入卷积神经网络(CNN),在5类事件识别中的识别准确率达到96.67%。2020年,WU H等人^[10]通过结合CNN和长短时记忆(LSTM)网络实现了对时间和空间

信息的分别提取,并在5类事件识别中的识别准确率达到97%。2024年,CAO J等人^[11]通过萨格纳克干涉仪结合神经网络技术实现对光纤在±120°扭转角度的有效识别。2025年,CHEN J等人^[12]通过重构特征空间,利用类间距离分类,对已知和未知事件的识别准确率分别达到91.85%、90.31%。同年,LI X等人^[13]利用改进多时空域CNN结合二维时域卷积网络设计识别框架,在5个监测位置对5类事件识别的识别准确率达到92.78%。然而,现有的研究主要针对传感光纤附近的振动类型识别,对振动事件的其它属性分析的研究则较少。虽然Φ-OTDR系统灵敏度高,能分析振动属性(如距离远近),但当振动源离光纤较远时,信号会严重衰减,导致现有识别方法的识别准确率下降甚至完全失效。

为了研究Φ-OTDR系统对探测事件的径向距离识别能力,并解决低信噪比下特征模糊问题,本文提出一种基于多时频图和注意力机制的Φ-OTDR相似事件识别方法。

1 基于多时频图和注意力机制的Φ-OTDR相似事件识别方法

1.1 Φ-OTDR检测原理与多时频分析

Φ-OTDR系统采用超窄线宽激光器作为探测源,并向传感光纤中持续发射窄脉冲激光。探测激光在传感光纤沿线激发瑞利散射光,当传感光纤受到外界扰动时,探测激光及其瑞利散射光的光相位将受到相应调制。由于探测光本身具有极长的空间干涉距离,多个位置的背向瑞利散射光之间仍能发生自干涉,从而将光相位变化转化为光强度变化,并最终被光纤首端的光电探测器捕获。具体地,每次发射一个探测脉冲时,会在传感光纤沿线激发瑞利散射;这些散射光信号经干涉后,在光电探测器处形成一条检测迹线,该迹线上的时间延迟与光纤中的空间距离呈正比关系(对应快轴方向)。系统通过多次发射探测脉冲,实现对所有空间位置的实时监测。通过提取多条迹线在某一特定传感位置的检测信号,即可获得该位置的时域感知结果(慢轴),其示意结果如图1所示。

通常可以直接选取外界扰动位置及其临域内的信号排列为二维时空图(ST图),作为后续信号识别的




图1 Φ-OTDR数据示意图

数据样本,相关工作^[14-15]亦证明了其在多类型事件识别中的有效性。但是在相近事件识别中,由于ST图本身主要表征数据的时域和空域特征,且振动信号在整体图形中的面积占比不高,容易导致后续识别网络学习到的信号特征不够显著。另一方面,当信号信噪比降低时,时域信号特征容易被噪声淹没,增加了后续识别网络的特征提取难度。因此,本文进一步引入信号变换方法,通过提取扰动位置的时域信号,并借助时频变换将其转换为特征更显著时频特征图。考虑到地理光纤所感知的信号受土壤天然滤波作用的影响,其频率成分整体较低,故选择以梅尔谱变换(Mel-spectrogram)为基础构建时频表示,生成梅尔谱图(Mel图)。梅尔谱 S_{MEL} 的计算如下:

$$S_{MEL}(m, n) = \ln \left(\sum_{f=0}^{f_s/2} |X_n(f)|^2 H_m(f) \right) \quad (1)$$

其中, $X_n(f)$ 表示信号的第 n 段时域部分的频谱, $H_m(f)$ 表示第 m 个梅尔滤波器的频谱, $0 \leq m \leq M$, $0 \leq n \leq N$, N 为信号分段数目, M 为梅尔滤波器数量, f_s 为信号的时域采样频率, f 为真实频率,其中梅尔滤波器的频谱和频率分别如式(2)和式(3)所示。

$$H_m(f) = \begin{cases} 0, & f < F(m-1) \\ \frac{2(f - F(m-1))}{(F(m+1) - F(m-1))(F(m) - F(m-1))}, & F(m-1) \leq f < F(m) \\ \frac{2(F(m+1) - f)}{(F(m+1) - F(m-1))(F(m) - F(m-1))}, & F(m) < f \leq F(m+1) \\ 0, & f > F(m+1) \end{cases} \quad (2)$$

$$F(m) = 2595 \times \log(1 + f_s/1400) \times m/M \quad (3)$$

Mel谱能够有效放大信号的成分在整体时频图中的比重,即可以增加有效图像像素数量在整体图像像素数量中的比重。然而,当扰动事件距离传感光纤较远时,扰动信号的信噪比会显著下降,加之土壤的滤

波作用,其高频成分也会大幅衰减。当频率降低后,Mel图中的有效像素占比也将下降,可能出现特征模糊的问题。

为了更好地凸显低信噪比和低频率下的信号特征,本文引入离散-连续小波变换(DWT-CWT)。首先,利用DWT分解原信号为小波分量,在各个小波分量内对噪声进行自适应多尺度抑制,之后再合成为去噪信号,最后利用CWT变换将去噪信号变换为连续平滑的时空图像(CWT图)。其过程如式(4)~式(8)所示。

$$X(t) = A(t) + \sum_{j=1}^L C_j(t) \quad (4)$$

$$\hat{C}_j(t) = \text{sgn}(C_j(t))(|C_j(t)| - H_j) \quad (5)$$

$$\hat{X}(t) = A(t) + \sum_{j=1}^L \hat{C}_j(t) \quad (6)$$

$$S_{\text{CWT}}(a, \tau) = \int_{-\infty}^{+\infty} \hat{X}(t) \psi_a(t - \tau) dt \quad (7)$$

$$\psi_a(t) = \frac{1}{\sqrt{a}} \psi\left(\frac{t}{a}\right) \quad (8)$$

其中, $X(t)$ 为信号的时域部分, $A(t)$ 为信号小波分解的近似分量, $C_j(t)$ 为信号小波分解后的细节分量, L 为分解总层数, H_j 为第 j 层噪声抑制阈值, S_{CWT} 为连续小波变换结果, a 为连续小波伸缩尺度值, τ 为时间延迟, $\psi_a(t)$ 为连续小波基函数。若记连续小波基函数的中心频率为 F_c ,则可将伸缩尺度与实际信号频率相关联,记为

$$f(a) = F_c / (af_s) \quad (9)$$

其中, $f(a)$ 为伸缩变换后的频率。在DWT去噪过程中,各尺度系下的噪声阈值选取尤为关键,本文结合通用自适应阈值和Stein无偏风险估计法的结合设计阈值,记为

$$H_j = \text{median}(|C_j - \text{median}(C_j)|) / 0.6745 \times \sqrt{2 \log T_j} \quad (10)$$

其中, $\text{median}(\cdot)$ 为取中值函数, T_j 为细节分量 C_j 的长度。

CWT中,冗余的小波分析过程较多,因此可以进一步增强有效频率成分在时频结果图中的满级占比,同时这些冗余分析也有助于提升低信噪比时的特征显著性,降低后续特征提取的难度。

1.2 数据整合与多通道注意力机制的识别网络

ST图、Mel图、CWT图能够提供信号在不同方面的特征,因此考虑对其进行数据融合后,送入识别网络以提供更丰富的特征。但是,无效的特征会模糊网络的识别能力,导致网络的判断出现错误。因此,本文引入通道注意力机制,帮助识别网络自主学习和处

理不同特征之间的权重,以提高最终识别效果。压缩和激励网络(SENNet)通过在全局空间对信息进行压缩,然后在通道维度对特征进行学习,利用反向误差传播,形成对各个通道的重要性权重。之后,通过激励网络实现对通道权重的重新分配,从而形成注意力分配效果。本文选取ResNet50网络作为基础识别网络,在其中嵌入多个SE模块,形成SE-ResNet50。从特征分析角度看,ST图所提供的是外界扰动的时空轮廓特征,其特征尺度相对较大,而Mel图及CWT图所提供的是频率对比特征,其特征尺度相对较小,在各个特征尺度上均需要考虑不同的特征权重分配。因此,本文选择将SE模块嵌入多个尺度,为不同尺度的特征赋予自适应的加权重。所获得的SE-ResNet50结构如图2所示。





图2 SE-Resnet50结构图

2 实验及结果分析

2.1 实验数据介绍

本文采用自制的Φ-OTDR系统进行数据采集,系统设置如图3所示。Φ-OTDR系统激光线宽为3 kHz,脉冲宽度为200 ns,AOM驱动频率为200 MHz,脉冲重复频率为10 kHz,采集卡采样率为100 MHz。实验选择在沙草地上进行,传感光纤为G.652单模光纤,外有聚氯乙烯覆层,内嵌钢丝加固,埋深为5 cm,长度为2 km。为了测试Φ-OTDR传感性能和算法的事件识别效果,



Laser: 激光器; AOM: 声光调制器; EDFA: 掺铒光纤放大器; Cir: 环形器; PD: 光电探测器; DAC: 数据采集卡; PC: 电脑。

图3 实验设置

本文采集了同一事件在不同光纤径向距离下的测试数据。此外,为保证振源本身的可重复性,采用重为0.855 kg的砖块从高约为1 m处自由落下所产生的振动作为振源,分别采集了距离传感光纤径向距离为0~9 m(间隔1 m)的传感数据(图中为示意距离的方向),以每1 s的传感数据作为一个数据样本。其中,ST图样本选取振动位置为中心,两端各25 m以内的数据为样本;Mel图和CWT图采用振动位置处时长为1 s的时域信号作为原始数据,经过Mel及DWT-CWT变换后,获得对应的时频图。在上述处理过程中,所有数据的时域方向均进行一次高通滤波,截止频率为5 Hz,以消除时域信号中的缓变波动和直流分量,降低无用特征。此外,在Mel变换中,取分窗长度为256,梅尔滤波器组数为24。在DWT去噪过程中,选取dB4小波,分解为4层;在CWT变换中,取Cmor200~2.0小波。最终,将所获得的数据样本以3:1:1的形式分为训练集、验证集和测试集,样本分布情况如表1所示。典型的信号数据样本如图4所示。图中红框为振动事件的时频特征。可以看出,与0 m处相比,4 m处的CWT图频率成分丰富度下降(条纹明显减少),且其Mel图特征也开始模糊;至9 m处,ST图和Mel图中的特征已难以用肉眼观测,CWT图也仅剩少量低频信息。这表明随着径向距离的增加,信号信噪比逐渐降低。

表1 数据样本分布情况

径向距离/m	样本数		
	训练集	验证集	测试集
0	336	84	84
1	336	84	84
2	316	79	79
3	316	79	79
4	328	82	82
5	240	60	60
6	336	84	84
7	256	64	64
8	244	67	67

2.2 识别实验及结果

2.2.1 特征表征能力测试

本文采用在ImageNet下预训练的ResNet50参数作为基础网络,以振动事件距离传感光纤的米数为数据标签,分别测试ST图、Mel图以及CWT图在ResNet50下的识别结果。识别结果如表2所示,不同特征表征方法在距离分类任务上的混淆矩阵如图5所示。图5中,




图4 典型信号数据样本

表2 特征表达测试结果

类型	准确率/%	精确率/%	召回率/%	F ₁ -score/%
ST图	66.80	67.55	66.80	66.73
Mel图	93.31	93.47	93.31	93.22
CWT图	95.05	95.13	95.05	95.05

矩阵的行和列均以径向距离值(单位:m)作为类别标签,分别代表事件的真实距离类别和模型的预测距离类别。结合表2和图5可知,3种特征表征方法的性能差异显著,其中CWT图在准确率、精确率、召回率和F₁-score指标上均取得最高值。ST图仅表达时域和空域特征,对相同振动事件在不同距离下的表征能力有限。随着径向距离增加,其信噪比下降(表现为振动图样越发模糊),但特征随距离变化的区分度不明显,导致基于ST图的识别模型面临较大困难,其总体识别准确率最低,仅为66.80%。相比之下,时频特征(Mel图和CWT图)能更有效地捕捉土壤滤波效应随距离变化的特性,从而为分类模型提供更具判别性的信息。因此,二者均取得了较高的总体识别准确率(Mel图:93.31%;CWT图:95.05%)。然而,二者的优势距离范围不同。Mel图在近距离(0~4 m)表现极为优异,该距离段内混淆矩阵对角线值均高于0.99,计算得其近距离平均准确率达98.77%;但其在远距离(5~9 m)性能下降明显(对角线值逐渐降至0.71),平均识别准确率降至86.72%。CWT图则展现了更强的鲁棒性和一致性,其在近距离(0~4 m)的平均识别准确率(95.34%)


施羿,梁立功,封皓: 基于多时频图和注意力机制的 Φ -OTDR相似事件识别方法

图5 3种特征表征方法在不同距离分类任务上的混淆矩阵

虽略低于Mel图,但在远距离(5~9 m)仍能维持高达94.70%的平均识别准确率(其远距离对角线值依然稳定在0.90以上)。这是由于距离较远、信噪比下降时,卓越的频率分辨能力显得更为关键。Mel变换基于短

时傅里叶变换,其采用固定时窗,频率分辨率恒定。因此,在低信噪比环境下,其对微弱频率成分的分析能力有限,在图像上表现为难以判别的短暂尖峰。相比之下,CWT具有多尺度分析的冗余特性,其频率分辨率随尺度变化而自适应调整(低频高分辨,高频低分辨)。当信噪比下降时,多个尺度的小波基会对残余的弱频率成分(尤其是低频)产生重叠响应,这种重叠有效地整合并增强了低能量特征,最终在图像上呈现出更清晰、更连续的频率结构,实现了在恶劣条件下更有效的特征表达。

2.2.2 混合特征能力表征测试


在上一节测试中,Mel图与CWT图均表现出了较好的识别效果,且其特征表达和识别特性均有一定的互补性,因此本文进一步使用特征融合的手段,将其各自的优点进行融合。首先,将Mel图和CWT图进行灰度化,再与ST图一起进行组合,形成4种不同组合的输入形式:Mel+ST、CWT+ST、CWT+Mel以及CWT+Mel+ST。然后,分别使用ResNet50和SE-ResNet50进行训练,记录识别结果,结果如表3所示。可以看出,相比于ResNet50,使用了通道注意力机制的SE-ResNet50在各个输入组合下的识别结果可以提高约2%~4%,这说明通道注意力机制可以帮助网络更有效地平衡各个输入通道的权重情况。另一方面可以看出,无论是Mel+ST、CWT+ST还是Mel+CWT+ST组合,均比其不加入ST图时的准确率低。这是因为ST图难以提供有效特征,且其在远距离数据上的表现非常差,当ST图加入输入数据时,反而模糊了其它图像特征。即使使用通道注意力机制改善了ST图在网络识别过程中的权重,也难以将其负面影响完全消除。此外,Mel图和CWT图由于特征具有一定的互补性,组合后可以获得更好的识别能力,实现了比单Mel图和单CWT图更好

表3 组合数据识别结果


输入数据	ResNet50				SE-ResNet50			
	准确率/%	精确率/%	召回率/%	F ₁ -score/%	准确率/%	精确率/%	召回率/%	F ₁ -score/%
Mel+ST	81.93	82.75	81.93	82.03	86.35	87.06	86.35	86.42
CWT+ST	83.27	83.69	83.27	83.22	87.55	88.02	87.55	87.64
Mel+CWT	96.79	96.84	96.79	96.79	98.66	98.68	98.66	98.66
Mel+CWT+ST	93.44	93.70	93.44	93.46	95.58	95.86	95.58	95.57

的识别效果。

有无通道注意力机制的情况下,Mel+CWT组合的混淆矩阵如图6所示。可以看出,经过通道注意力机制的互相融合,在自适应权重的调整下,Mel+CWT特征能够实现更好地互补,从而将识别准确率进一步提升至98.66%,相比与单一Mel图(93.31%)和单一CWT图(95.05%)作为输入,识别准确率分别提升了5.35%和3.61%,相比于ST图(66.8%)作为输入,识别准确率提升了31.86%。



(a) 无通道注意力机制时



(b) 有通道注意力机制时

图6 Mel+CWT输入下的混淆矩阵

3 结束语

本文提出了一种基于时频特征的信号表征方法,通过融合多通道注意力机制,结合Mel谱图与CWT图谱在特征表达上的互补优势,在0~9 m径向距离范围内的相同事件识别任务中实现了98.66%的识别准确率。与原始ST图方法相比,识别准确率提高了31.86%;相较于单一使用Mel图或CWT图的识别方法,也分别

提升了5.35%和3.61%。此外,本文所提出的信号变换与深度学习分析框架,可进一步应用于其它振动属性分析任务,为 Φ -OTDR在复杂场景下的应用提供技术支撑。

参考文献:

- [1] ZHOU X, WANG F, YANG C, et al. Hybrid distributed optical fiber sensor for the multi-parameter measurements[J]. Sensors, 2023, 23(16): 7116-1-7116-40.
- [2] WU H, CHEN J, LIU X, et al. One-dimensional CNN-based intelligent recognition of vibrations in pipeline monitoring with DAS[J]. Journal of Lightwave Technology, 2019, 37(17): 4359-4366.
- [3] YAN B, LI H, ZHANG K, et al. Quantitative identification and localization for pipeline microleakage by fiber distributed acoustic sensor[J]. Journal of Lightwave Technology, 2023, 41(16): 5460-5467.
- [4] HE T, SUN Q, ZHANG S, et al. A dual-stage-recognition network for distributed optical fiber sensing perimeter security system[J]. Journal of Lightwave Technology, 2023, 41(13): 4331-4340.
- [5] SHI Y, CHEN J, DAI S, et al. Φ -OTDR Event recognition system based on valuable data selection[J]. Journal of Lightwave Technology, 2024, 42(2): 961-969.
- [6] WILLIAMS E F, FERNÁNDEZ-RUIZ M, MAGALHAES R, et al. Distributed sensing of microseisms and teleseisms with submarine dark fibers[J]. Nature Communications, 2019, 10(1): 5778-1-5778-11.
- [7] ZHAO Y, LI Y, WU N. Distributed acoustic sensing vertical seismic profile data denoiser based on convolutional neural network[J]. IEEE Transactions on Geoscience and Remote Sensing, 2020, 60: 1-11.
- [8] HERNÁNDEZ P D, RAMÍREZ J A, SOTO M A. Deep-learning-based earthquake detection for fiber-optic distributed acoustic sensing[J]. Journal of Lightwave Technology, 2022, 40(8): 2639-2650.
- [9] SHI Y, WANG Y, ZHAO L, et al. An event recognition method for Φ -OTDR sensing system based on deep learning[J]. Sensors, 2019, 19(15): 3421-1-3421-9.
- [10] WU H, YANG M, YANG S, et al. A novel DAS signal recognition method based on spatiotemporal information extraction with 1DCNNs-BiLSTM network[J]. IEEE Access, 2020, 8: 119448-119457.
- [11] CAO J, WANG B, HUANG B, et al. Artificial-neural-network-assisted distributed directional optical fiber torsion sensor with the SSAF-based sagnac interferometer[J]. Journal of Lightwave Technology, 2024, 42(16): 5743-5752.
- [12] CHEN J, SHI Y, WEI C, et al. Φ -OTDR event recognition system based on reconstructed signal feature space[J]. IEEE Internet of Things Journal, 2025, 12(13): 25346-25356.
- [13] LI X, LOU S, GAO W, et al. Simultaneously identify multi-location disturbance events based on SR-CNN and 2D-TCN in Φ -OTDR system[J]. Optical Fiber Technology, 2025, 90: 104130-1-104130-10.
- [14] SHI Y, LIU X, WEI C. An event recognition method based on MFCC, superposition algorithm and deep learning for buried distributed optical fiber sensors[J]. Optics Communications, 2022, 522: 128647-1-128647-10.
- [15] SHI Y, CHEN J, DAI S, et al. Multi-signal feature fusion method with an attention mechanism for the Φ -OTDR event recognition system[J]. Optics Express, 2022, 30(23): 42086-42096.