

激光与光电子学进展

基于 Φ -OTDR 的光纤分布式传感信号处理及应用

吴慧娟^{1*}, 刘欣雨¹, 饶云江^{1,2**}

¹电子科技大学光纤传感与通信教育部重点实验室, 四川 成都 611731;

²光纤传感研究中心之江实验室, 浙江 杭州 310000

摘要 基于相位敏感光时域反射(Φ -OTDR)原理的光纤分布式振动/声传感(DVS/DAS)技术在国家基础设施及城市安全监测中发挥着重要作用,但受城区强噪声背景、多源干扰及未知地理条件的影响,DVS/DAS对目标事件检测识别的准确率成为制约其规模及应用的重大技术瓶颈。因此,在电子科技大学光纤光学研究中心对DVS/DAS硬件技术研究的基础上,分析了目前光纤DVS/DAS信号处理的难点问题,回顾了近年来DVS/DAS信噪分离、基于机器学习模型的多维信号检测识别算法的研究进展及重要应用案例,并对DVS/DAS信号处理的发展方向及趋势进行了展望。

关键词 测量与计量; 相位敏感光时域反射; 光纤传感; 信号处理; 安全监测

中图分类号 TH74

文献标志码 A

doi: 10.3788/LOP202158.1306003

Processing and Application of Fiber Optic Distributed Sensing Signal Based on Φ -OTDR

Wu Huijuan^{1*}, Liu Xinyu¹, Rao Yunjiang^{1,2**}

¹Key Laboratory of Fiber Optic Sensing and Communication, Ministry of Education, University of Electronic Science and Technology of China, Chengdu, Sichuan 611731, China;

²Fiber Optic Sensing Research Center, Zhijiang Laboratory, Hangzhou, Zhejiang 310000, China

Abstract Fiber optic distributed vibration/acoustic sensing (DVS/DAS) technology based on the principle of phase-sensitive optical time-domain reflectometry (Φ -OTDR) plays an important role in the national infrastructure and urban safety monitoring. However, due to the influence of strong noise background, multi-source interference and unknown buried conditions in urban areas, the accuracy of DVS/DAS detection and recognition of target has become the biggest technical bottleneck restricting its scale application. Therefore, on the basis of DVS/DAS hardware technology research at the Fiber Optics Research Center of University of Electronic Science and Technology of China, this paper analyzes the difficult problems of the current optical fiber DVS/DAS signal processing, reviews the research progress and important application cases of DVS/DAS signal-to-noise separation, multi-dimensional signal detection and recognition algorithms based on machine learning models in recent years, and the development direction and trend of DVS/DAS signal processing are prospected.

Key words measurement and metrology; phase-sensitive optical time-domain reflectometry; optic fiber sensor; signal processing; safety monitoring

OCIS codes 120.4825; 130.6010

收稿日期: 2021-04-12; 修回日期: 2021-05-11; 录用日期: 2021-05-19

基金项目: 国家自然科学基金(61301275, 61290312, 41527805)、教育部长江学者和创新团队发展计划(IRT1218)、高等学校学科创新引智计划(111计划)(B14039)

通信作者: *hjwu@uestc.edu.cn; **yjrao@uestc.edu.cn

1 引言

基于相位敏感光时域反射(Φ -OTDR)原理的光纤分布式振动/声传感(DVS/DAS)技术^[1]利用大范围铺设的通信光缆对周围环境中的各种振动源进行高灵敏感知和精确定位,在国家及城市基础设施,如光电信息线缆^[2]、长输油气管道^[3]、供水管网^[4]、桥梁隧道^[5-6]及区域周界^[7]的安全监测领域具有广泛应用,已成为近年来光纤传感领域的研究热点。

目前,DVS/DAS的硬件指标已逐渐趋于成熟^[8-15],国际知名光纤传感公司如OptaSense、Silixa已研发了比较成熟的产品,国内研发的产品硬件感知与检测能力也与国外水平相当。电子科技大学光纤光学研究中心在基于 Φ -OTDR的DVS/DAS硬件技术上也有多年的研究积累,并在监测距离等指标上多次打破国际记录^[12,14]。但复杂环境下DVS/DAS的智能感知能力还不能满足实际应用的需求,特别是在城区复杂地面生活场景及未知地理条件下,DVS/DAS的高灵敏感知优势会导致实际误报率偏高,检测识别的准确率也成为制约DVS/DAS在城市安全监测中应用及推广的最大技术瓶颈。

基于 Φ -OTDR传感原理的DVS/DAS信号检测识别方法一直在不断完善。第一阶段(2017年以前)中,一方面通过二维图像边缘算子^[16]、小波变换^[17]和Hilbert-Huang变换^[18]等手段提高检测信号的信噪比(SNR),降低光源频率漂移(频漂)等系统噪声及平稳背景环境对检测结果的影响;另一方面,通过人为特征提取和对传统机器学习识别模型的探索提高检测信号的信噪比。提取的特征包括时域信号幅值水平过零率^[19]、步态周期特征^[20]、频谱能量分布特征^[21-22]、时空域图像形态学特征^[23-24]、时频域特征(如小波/小波包能量谱)^[25-26]等;识别模型则以传统神经网络^[25]、支持向量机(SVM)^[27]为主。这些多域分析方法丰富了检测信号的提取信息,但以“固定人工特征提取+特定识别模型”为主的经验学习方法无法适应大批量分布节点的数据变化模式,环境适应能力差。第二阶段(2017年至今)中,借鉴深度学习在图像/语音处理中的成功应用,人们开始使用深度学习网络提取和抽象DVS/DAS信号特征进行检测识别^[28-30],避免了人为提取特征复杂性高、识别准确率低、对复杂环境适应性差的

问题,且在算法的开发效率方面有明显提升。

综上所述,国内外DVS/DAS信号检测识别方法具以下共同趋势。1)DVS/DAS时间维度信息比较丰富,相关研究最多,包括单尺度到多尺度结构特征及上下文关系,传统人为经验到深度网络特征提取方式,但还没有实现时间域多层次特征同步自动提取到识别的端对端一体化网络。2)DVS/DAS时频、时空等多维度信息逐渐受到了人们的关注,但全方位多维度信息的提取还有很大的研究空间。此外,这类研究对重要信息的关注及提取特征的有效性评估不够,基于DVS/DAS时频空立体化多维信息提取的端对端识别网络未见报道。3)已有研究大多以单源信号检测识别为主,对多目标干扰及未知地理条件下多源混叠信号的检测识别方法未见报道。针对上述问题,本文综述了电子科技大学光纤光学研究中心基于 Φ -OTDR的光纤分布式传感信号处理方法的研究进展及重要应用案例,在 Φ -OTDR信噪分离、基于机器学习模型的多维信号检测识别及定位算法等方面都给出重要的解决方案,并展望了国内外DVS/DAS信号处理的发展方向及趋势。

2 基于 Φ -OTDR的DVS/DAS原理及其信号处理挑战

2.1 基于 Φ -OTDR的DVS/DAS传感原理

为了进一步提高DVS/DAS系统的检测识别性能,国内外学者结合多种机器学习模型,在提取特征的丰富性和识别模型的智能性方面进行了优化,具体模型如表1所示。其中,XGBoost为极端梯度提升算法,F-ELM为Fisher特征选择极限学习机,1D-CNN、2D-CNN和MS-CNN分别为一维、二维和多尺度卷积神经网络(CNN),GMMs为高斯混合模型,CPL为卷积原型学习,HMM为隐马尔可夫模型,PNN为概率神经网络,LSTM为长短期记忆网络,ALSTM为基于注意力机制的LSTM,BiLSTM为双向LSTM。

基于 Φ -OTDR技术的DVS/DAS原理如图1所示。其中,硬件主要由探测光缆、光信号解调设备、信号处理主机三个部分组成。探测光缆通常采用普通单模通信光纤,一般沿地下管道、输电电缆、城镇道路埋地铺设,也可直接利用沿管道或道路铺设的通信光缆空余纤芯。光信号解调设备是该系统的核心,其内部组成器件主要包括光学器件和电

表 1 结合机器学习模型的 DVS/DAS 信号检测识别方法

Table 1 DVS/DAS signal detection and recognition method combined with machine learning model

Institutional unit	Feature extraction dimension	Recognition network or model	Attention mechanism	End-to-end network	Ref.
Beijing Jiaotong University	temporal	XGBoost	no	false	[31]
	temporal	F-ELM	no	false	[32]
University of Electronic Science and Technology of China	temporal	1D-CNN	no	true	[33]
University of San Pablo Central European University	temporal	GMMs	no	false	[34]
	temporal contextual sequence	GMMs+HMM	no	false	[35]
University of Electronic Science and Technology of China	temporal structure and contextual sequence	HMM	no	false	[36]
Tianjin University	multiscale temporal	MS-CNN+CPL	no	true	[37]
Anhui University	multiscale temporal	MS-CNN	no	true	[38]
Transportation, Security, Energy & Automation Systems Business Sector	time-frequency	2D-CNN	no	false	[28]
Beijing Institute of Technology	time-frequency	2D-CNN	no	false	[29]
Zhejiang University	time-frequency	2D-CNN+SVM	no	false	[30]
Shanghai Maritime University	time-frequency	PNN	no	false	[39]
University of Cologne	time-frequency	ALSTM	yes	false	[40]
Tianjin University	spatial-temporal	2D-CNN	no	false	[41]
University of Electronic Science and Technology of China	spatial-temporal	1D-CNN+BiLSTM	no	true	[42]
Sichuan University	spatial-temporal	2D-CNN+ LSTM	no	false	[43]

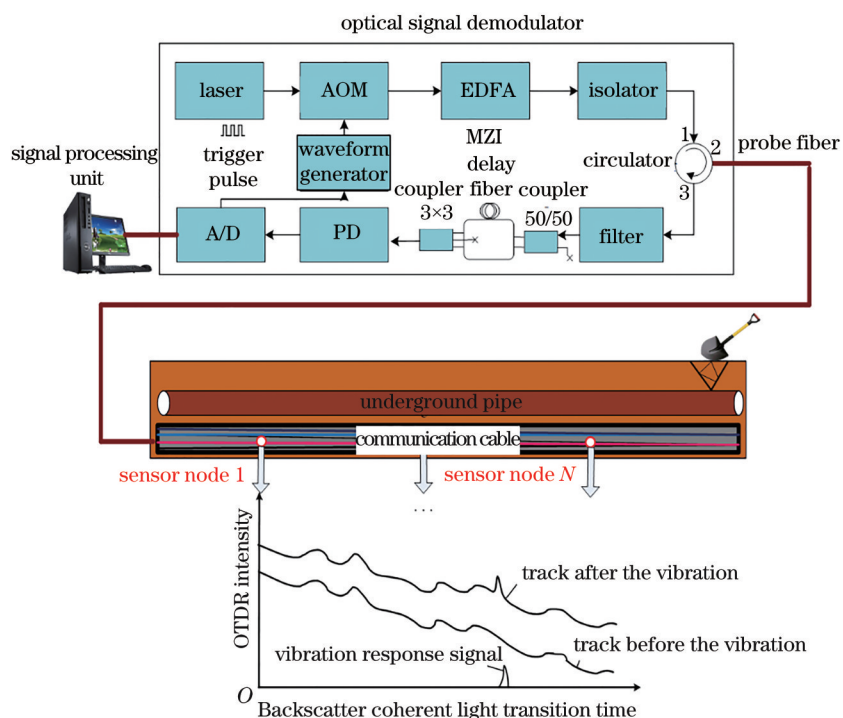


图 1 基于 Φ -OTDR 的 DVS/DAS 原理

Fig. 1 Principle of the DVS/DAS based on Φ -OTDR

学器件两类。由超窄线宽激光器产生一路连续相干光信号,经声光调制器(AOM)调制成光脉冲信号;光脉冲信号由掺铒光纤放大器(EDFA)集中放大,放大后的光脉冲信号依次经隔离器、环形器的端口1、端口2注入探测光缆;光脉冲信号沿光缆传输过程产生瑞利散射,其后向瑞利散射光信号沿光缆返回,由环形器的端口2、端口3接收,再经光学滤波器滤除噪声信号后经第1耦合器耦合后将其注入一个非平衡马赫-曾德尔干涉仪(MZI),由 3×3 的第2耦合器输出3路相位差为 120° 的外界扰动信号。引入的相位变化信息,通过相位解调获得声波及振动在光纤上的作用信号。解调出的光信号由光电探测(PD)转换成电信号,再由波形发生卡控制的同步触发模数(A/D)转换器进行信号同步采集,数字电信号通过网络等接口实时传输给信号处理主机。信号处理主机为普通电脑主机(PC)或嵌入式主板,用于光纤探测信号的分析、处理。通过特定信号处理算法得到引起声波、振动的事件信息,由光时域反射原理确定其位置,并对检测事件进行智能识别和分类。

基于周期性触发脉冲采集各空间点的振动或声音信号,第 k 个触发脉冲周期内采集的整个监测线路信号 \mathbf{X}_k 可表示为

$$\mathbf{X}_k = \{x_{ki} (i = 1, \dots, N)\} = [x_{k1}, \dots, x_{kN}], \quad (1)$$

式中, N 为数据空间的采集长度。沿时间轴进行累积,构建一个 N 维空间、 T 维时间的时空信号响应矩阵 \mathbf{A} ,如图2所示。其中, L_N 为整条光缆监测信号采集的空间长度, T_{1i} 、 T_{2i} 分别为第1、第2个脉冲发送间隔内信号采集的时间长度。 \mathbf{A} 可表示为

$$\mathbf{A} = \{x_{ki} (k = 1, \dots, T; i = 1, \dots, N)\}. \quad (2)$$




图2 Φ -OTDR信号的时空结构^[44]

Fig. 2 Spatio-temporal structure of the Φ -OTDR signal^[44]

2.2 DVS/DAS信号处理面临的挑战

目前,DVS/DAS信号处理方法面临的主要挑战如下。

1) 在大范围复杂生活场景下存在多源干扰,目标信号检测困难。一方面,由于长距离探测信号衰减及各种器件和环境噪声的叠加,使探测信号的SNR较低,DVS/DAS弱信号的检测困难;另一方面,城区通信光缆以埋地管道铺设为主,地面各种交通(地铁、高铁、公路车辆等)、工厂生产、人类生活噪声的来源类型多,多种振动源从地面到地下光纤传播过程中相互叠加。同时,地下复杂地质结构多径干扰影响的混合方式未知,干扰信号分离困难,导致混叠信号中少数具有威胁的目标振动源(如机械施工、人为破坏)信号检测困难。

2) 复杂地面干扰及未知地理条件下的多源混淆,使目标信号识别困难。城区地理条件下DVS/DAS探测信号是振动源与地表及其在传播过程中与地下结构相互作用的结果。通信光缆跨越范围大,时空多变的复杂地面环境中干扰振动来源多,未知突发事件多,使多源信号的识别本身就极具挑战性;地面振动源传播到地下光纤,经过大地滤波后,可分辨的高频信息被滤掉,只剩下信息量相对较少的低频信息,增加了识别的难度。此外,地下结构差异大,埋设环境不可预知,且同一地面振动源在地下不同光纤接收点处的探测信号响应不一致。因此,DVS/DAS系统的漏报、误报成为一对不可调和的矛盾,目标振动源信号的准确识别难度很大。现有基于人为特征提取、深度特征提取及各种分类器设计的DVS/DAS信号识别方法,均处于初级阶段,特征提取的全面性、有效性及提取方式的智能性还有待进一步研究。

3) 未知复杂地理条件下地面振动源在二维空间的被动定位困难。通常DVS/DAS定位指的是基于光时域反射(OTDR)原理沿光纤线路的纵向定位,而在实际应用中,振动源偏离光纤的横向垂直距离(垂距)及其威胁级别对于精准预警也具有重要作用。但地面振动源在地下传播过程中,通过多层混合土壤介质、水泥或金属管廊、空气等多种介质传播到光缆,振动波在地下传播速度不固定,同时受复杂多径干扰的影响,导致基于时延差及波达方向估计的阵列信号定位方法(水/空气均匀介质)不能直接应用。因此,面对非均质复杂地下结构的埋设条件,基于DVS/DAS阵列信号的地面振动源二维空间被动定位也是一个具有挑战性的难题。

3 DVS/DAS 弱信号检测方法

3.1 基于短时傅里叶变换的 Φ -OTDR 信号增强与去噪方法

基于短时傅里叶变换 (STFT) 的 Φ -OTDR 信号增强与异常检测的步骤^[45]: 1) 对累积的 OTDR 轨迹在时间轴进行平滑滤波; 2) 去噪后在空间轴对 OTDR 轨迹的每一个局部空间窗口进行 STFT, 计算 STFT 窗口能量并减去局部背景噪声能量; 3) 对空间能量曲线的奇异点进行检测与定位; 4) 对 OTDR 信号异常点进行检测与定位。

基于 STFT 的去噪及异常检测结果如图 3 所示, 其中, 横轴为信号采样点, 纵轴为幅度。图 3(a) 为原始噪声淹没的人为扰动 Φ -OTDR 轨迹; 图 3(b) 为整个空间的 STFT 能量曲线; 图 3(c) 为去掉背景噪声后的 STFT 能量曲线, 相比图 3(b) 信号的 SNR 有一定提升; 图 3(d) 为能量曲线的奇异值定位结果; 图 3(e) 为原始信号的异常点定位结果。表 2 为实际检测统计结果, 相比能量阈值检测法、小波模极大法, 基于 STFT 的方法检测准确率 (PD) 较高, 可达到 98.76%, 虚警率 (NAR) 降为 24 小时 2 次 (2/24 h)。

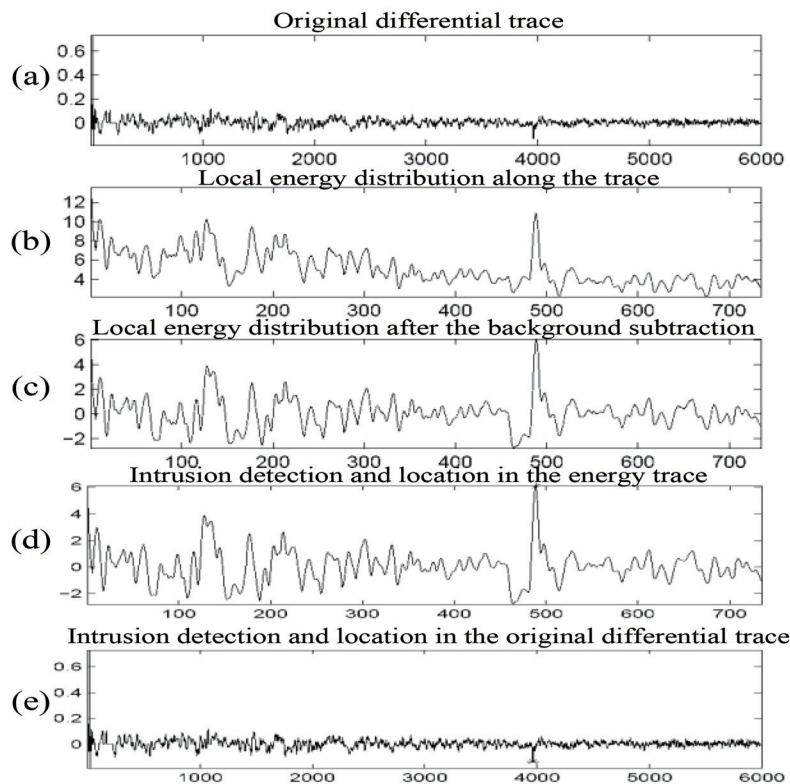


图 3 基于 STFT 的去噪及异常检测结果。(a) 原始差分轨迹; (b) 沿轨迹的局部能量分布图; (c) 背景噪声去除后的能量分布图; (d) 能量分布图上的入侵检测定位结果; (e) 原始差分轨迹上的入侵检测定位结果^[45]

Fig. 3 De-noising and anomaly detection results based on STFT. (a) Original differential trace; (b) local energy distribution along the trace; (c) local energy distribution after the background subtraction; (d) intrusion detection and location in the energy trace; (e) intrusion detection and location in the original differential trace^[45]

表 2 不同方法的实际检测结果

Table 2 Actual detection results of different methods

Different detection method	Energy threshold detection method	Modular maximum method of wavelet transform	STFT-based method
PD/%	76.73	95.65	98.76
NAR(24 h)	287	161	2

3.2 基于多尺度小波分解的信噪分离方法

为了进一步提高检测准确率, Wu 等^[44]提出了一

种基于多尺度小波分解的信噪分离方法, 其原理如图 4 所示, 其中, f_s 为信号的采样频率。采用 db6 小波

进行 6 层分解,通过频带细分,将入侵信号从起伏的背景噪声中分离出来,分离过程及结果如图 5 所示。其中, d_1, \dots, d_6 分别为 6 层分解的细节分量, $a_1 \sim a_6$ 分别为 6 层分解的近似分量。图 5(a) 为叠加了起伏背景背景的混合信号,经过多尺度小波分解得到的背景噪声与扰动信号如图 5(b) 和图 5(d) 所示,图 5(c) 为其他分量。图 6 为多次测试的 Φ -OTDR 轨迹^[46],从图 6(a) 中分离前的轨迹可以发现,去噪前入侵点完全被背景淹没,无法进行准确检测定位;图 6(b) 为基于多尺度小波分解去噪后的 Φ -OTDR 轨迹,可以发现,检测信号的 SNR 可提升 25.25 dB,这表明多尺度小波分解对信号的去噪效果较好。

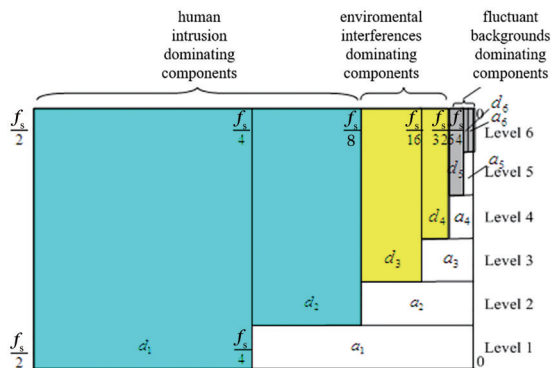


图 4 基于多尺度小波分解的信噪分离方法^[44]

Fig. 4 Signal-noise separation method based on multi-scale wavelet decomposition^[44]

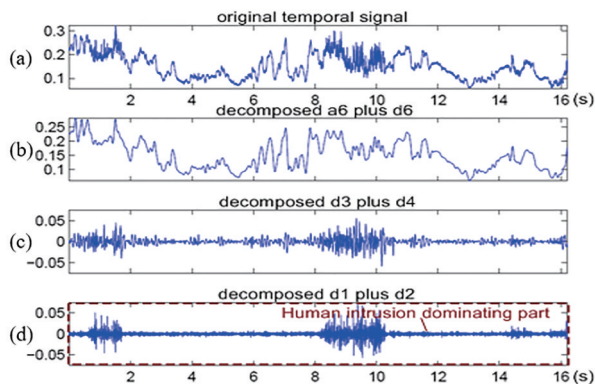


图 5 基于多尺度小波分解的信噪分离结果。(a) 原始时间信号; (b) a_6 和 d_6 的合成分量; (c) d_3 和 d_4 的合成分量; (d) d_1 和 d_2 的合成分量^[44]

Fig. 5 Signal-noise separation results based on multi-scale wavelet decomposition. (a) Original temporal signal; (b) combined component of a_6 and d_6 ; (c) combined component of d_3 and d_4 ; (d) combined component of d_1 and d_2 ^[44]

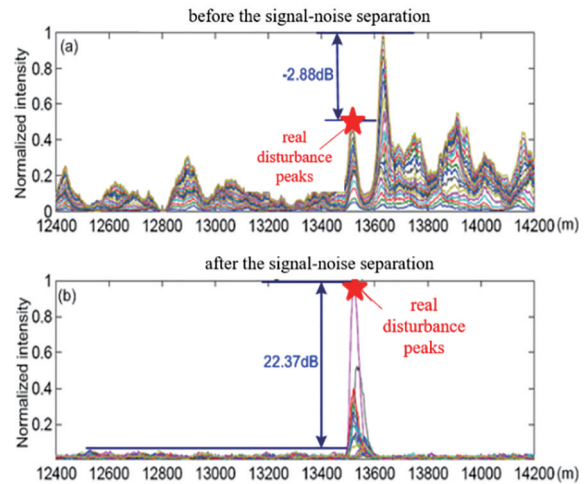


图 6 基于多尺度小波分解的信噪分离结果。(a) 信噪分离前; (b) 信噪分离后^[45]

Fig. 6 Signal-noise separation results based on multi-scale wavelet decomposition. (a) Before the signal-noise separation; (b) after the signal-noise separation^[45]

4 DVS/DAS 的振动/声源识别方法

4.1 基于隐马尔可夫模型的 DVS/DAS 信号时序信息挖掘与识别方法

为了丰富 DVS/DAS 信号的特征信息, Wu 等^[36]提出了一种基于 HMM 的 DAS 信号时序信息挖掘与识别方法。在短时信号单元(SU)多域特征提取的基础上,基于 HMM 挖掘短时特征信息间的时序演化关系,整个信号处理的流程如图 7 所示,主要分为数据准备、特征提取、HMM 离线训

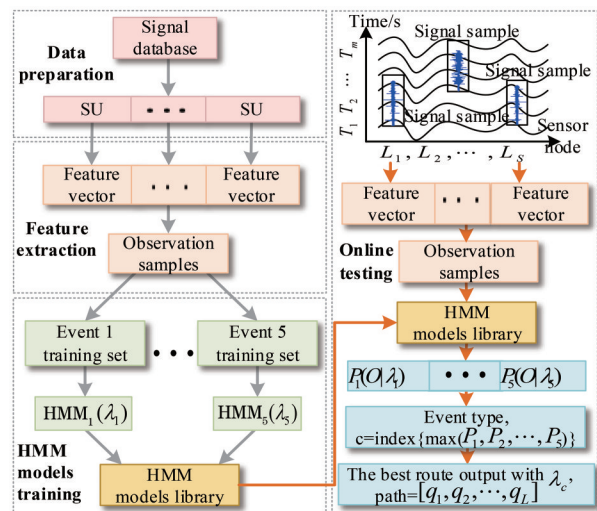


图 7 基于 HMM 的时序信息挖掘及识别处理流程^[36]

Fig. 7 Mining and recognition processing flow of sequential information based on HMM^[36]

练以及在线测试四部分。具体方法:1)数据准备基于各空间点采集的信号分别构建不同类型事件数据库;2)通过各信号样本中短时单元的多域特征提取,将信号样本转换为训练HMM需要的特征矢量及特征矢量序列;3)离线训练典型事件HMM,组建该点的事件HMM库;4)在线识别时,根据模型匹配思路计算测试信号输入各事件模型的输出概率。其中, $\lambda_1, \dots, \lambda_5$ 分别为基于特征序列隐状态关系构建的各类事件的HMM, P_1, \dots, P_5 分别为同一个观测序列 O 在不同HMM下的识别概率,将概率最高的模型作为该测试信号的事件判断类型。此外,可以将判定为该事件模型的最优隐状态序列 q_1, \dots, q_L 作为事件的演化过程即时序信息输出。

短时SU的时长为1s,长时信号样本时长为30s。每个短时SU提取的特征矢量如表3所示,其中,MFCC为梅尔频率倒谱系数,PSD为功率谱密度,信号特征的维数 $D=44$ 。提取特征后按时间先后顺序将 n 个特征矢量拼接成一个特征矢量序列,如图8所示。将特征矢量序列作为HMM训练和测试的观测短时SU输入,挖掘特征间的状态转移关系。HMM的观测序列可表示为

$$\mathbf{O}^{(k)} = [\mathbf{o}_1^{(k)}, \dots, \mathbf{o}_t^{(k)}, \dots, \mathbf{o}_n^{(k)}], \quad (3)$$

式中, $\mathbf{o}_t^{(k)} (1 \leq t \leq n)$ 为特征矢量序列集中第 t 个短时SU的特征矢量, n 为一个长时信号样本中SU的数量, k 为该观测样本在数据库中的序号。将一个

表3 短时SU的局部结构特征

Table 3 Local structural features of the short-term SU

Feature type	Feature name
Time domain	main impact strength, short time average magnitude, short time average energy
Frequency domain	frequency band variance of PSD, frequency band information entropy of PSD, mean of amplitude of PSD, procrustes mean shape of PSD, amplitude standard deviation of PSD, shape standard deviation of PSD, amplitude of skewness of PSD, shape of skewness of PSD, amplitude of kurtosis of PSD, shape of kurtosis of PSD
Transformation domain	wavelet packet energy spectrum, information entropy of wavelet packet, MFCC
Model feature	autoregression model coefficient, linear prediction model coefficient

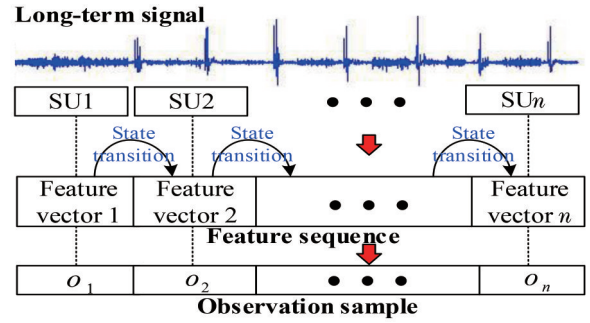


图8 短时SU特征间的状态转移关系^[36]

Fig. 8 State transition relationship between short-term SU features^[36]

包含 K 组长时信号样本的原始数据库经特征提取后,转化为包含 K 组特征矢量序列的集合,即观测序列集,可表示为

$$\mathbf{O}' = [\mathbf{O}^{(1)}, \dots, \mathbf{O}^{(k)}, \dots, \mathbf{O}^{(K)}], \quad (4)$$

式中, \mathbf{O}' 的维度为 $D \times n \times K$ 。

经过HMM离线训练,构建各类物理事件的HMM库,即可进行在线测试。在线识别时,根据模型匹配思路,通过Viterbi算法计算当前测试特征矢量序列在HMM库中各模型下的贝叶斯后验概率,并将概率最高的模型作为该测试信号的事件判断类型。同时,输出概率最大模型下该测试信号的隐状态序列,作为当前长时信号样本的时序演化过程。图9为管道安全监测中常见的5类典型事件信号,图10为基于HMM挖掘的对应隐状态序列即时序关系,其中,纵坐标表示幅度,单位为任意单位A. u。图9(a)为平稳的背景噪声,对应的平稳状态演化过程如图10(a)所示。图9(b)为人为挖掘的信号,可以观察到挖掘时出现的冲击信号,图10(b)的隐状态序列在对应冲击位置由状态2切换到状态1,这表明隐状态序列的演化规律与挖掘动作时序关系的吻合度较高。图9(c)为机械挖掘的信号,对应的隐状态序列在前期一直处于状态1,当挖掘信号出现冲击后,隐状态序列会切换到状态2;持续进行挖掘动作时,状态2也一直持续,这表明机械挖掘的隐状态序列与信号发生规律一致,能准确反映当前有无挖掘动作及挖掘动作的持续时间。图9(d)为交通干扰信号,交通信号的复杂性和随机性与路段状况、车的大小及种类等关系密切,可以发现,交通干扰信号在一些时刻出现了冲击性,且幅度大小不同,其隐状态序列如图10(d)所示。一般交通信号持续在状态1,而路面不平导致的冲击信号使其状态切换为3,与信

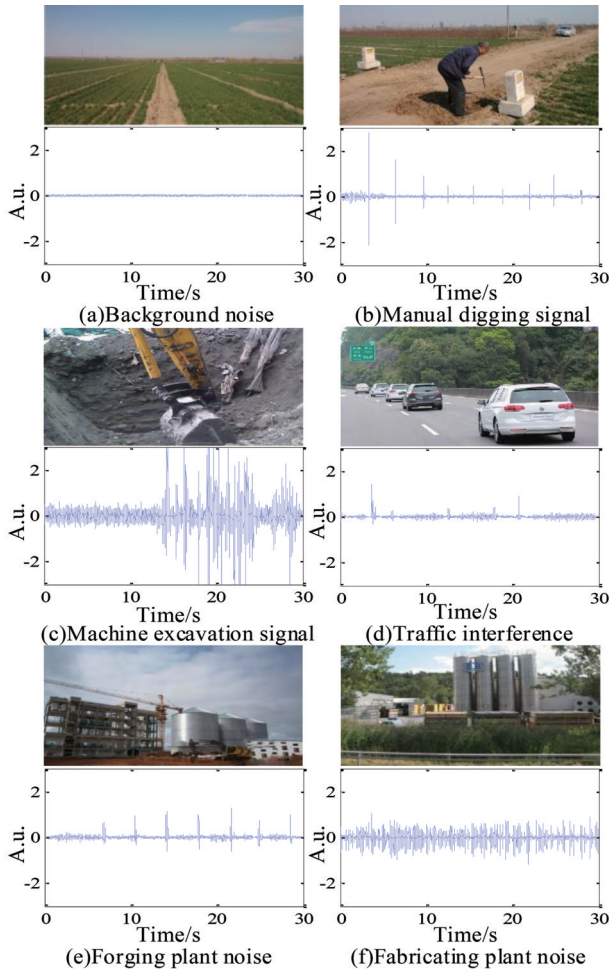


图9 常见的典型事件信号。(a)背景噪声;(b)人为挖掘;(c)机械挖掘;(d)交通干扰;(e)锻压厂噪声;(f)洗砂厂噪声^[36]

Fig. 9 Common typical event signals. (a) Background noise; (b) manual digging signal; (c) machine excavation signal; (d) traffic interference; (e) forging plant noise; (f) fabricating plant noise^[36]

号演化规律一致。图9(e)为锻压厂噪声,每隔2 s会产生约持续1 s的冲击变化,其对应的隐状态变化如图10(e)所示。可以发现,正常情况信号处于状态2,当有锻压动作时隐状态切换到状态1,且持续1~2 s;相比人工挖掘的冲击信号,该隐状态下的冲击持续时间长、规律性强。图9(f)为洗砂厂噪声信号,图10(f)为其对应的隐状态序列,可以发现,该工厂干扰持续频繁发生,其信号隐状态基本上稳定在状态3,偶尔信号幅度较小时会切换到状态2。

从图10可以发现,信号在HMM库下输出的最优隐状态序列在某种程度上可以解释和描述信号的演化过程,对当前物理事件信号的信息有重要补

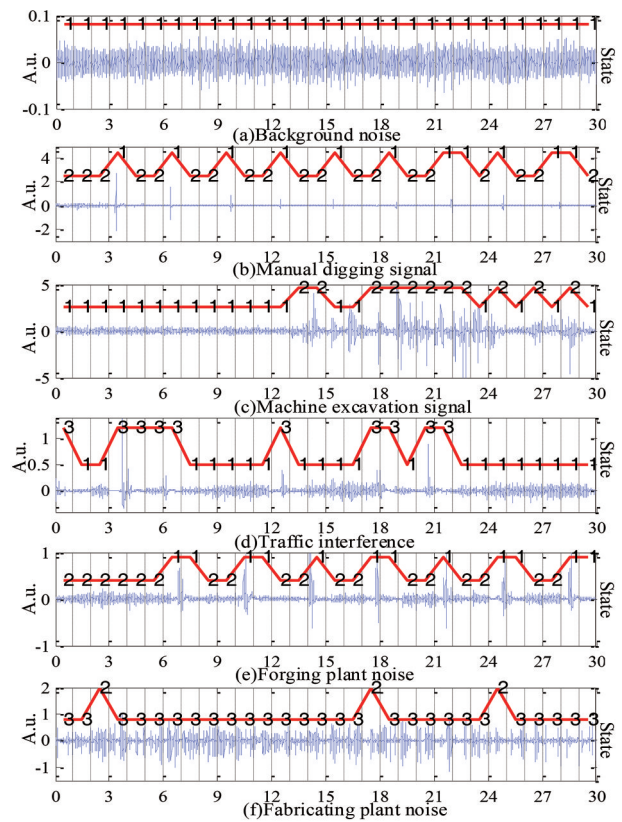


图10 基于HMM挖掘的隐状态序列。(a)背景噪声;(b)人为挖掘;(c)机械挖掘;(d)交通干扰;(e)锻压厂噪声;(f)洗砂厂噪声^[36]

Fig. 10 Hidden state sequence mined by HMM. (a) Background noise; (b) manual digging signal; (c) machine excavation signal; (d) traffic interference; (e) forging plant noise; (f) fabricating plant noise^[36]

充作用。同时,信号的隐状态序列对于一些随机和偶然的干扰不敏感,比信号特征更稳定。常见的SVM、随机森林(RF)、Xgboost(XGB)、决策树(DT)、贝叶斯网络(BN)模型与HMM对5类典型事件的精确率、召回率、F-值(F检验的统计量值)和平均识别率如表4所示。可以发现,基于HMM挖掘的时序关系对事件的平均识别率最高,可达到98.2%。这表明在短时SU的局部结构特征基础上增加HMM挖掘的时序关系,能进一步提高识别率。

4.2 基于CNN的时间结构特征深度提取与识别

CNN广泛应用于图像处理领域中,对1D信号如语音、传感信号进行处理分析时,需将1D信号通过某种变换转化为图像。Aktas等^[28]将原始 Φ -OTDR信号进行STFT,并基于2D-CNN对生成的RGB(Red, Green, Blue)时频图像进行分类;Jiang等^[29]借鉴语音信号的处理方法,提取原始 Φ -OTDR

表 4 不同模型的性能

Table 4 Classification performances of different models

Model	Average recognition rate	Type	Precision	Recall	F-value
HMM	0.982	1	1.0000	1.0000	1.0000
		2	1.0000	1.0000	1.0000
		3	1.0000	1.0000	1.0000
		4	0.9524	1.0000	0.9756
		5	1.0000	0.9130	0.9545
SVM	0.919	1	1.0000	1.0000	1.0000
		2	0.7500	1.0000	0.8571
		3	1.0000	1.0000	1.0000
		4	0.8974	0.8750	0.8861
		5	1.0000	0.8261	0.9048
RF	0.928	1	1.0000	0.9524	0.9756
		2	0.8667	0.8667	0.8667
		3	0.9231	1.0000	0.9600
		4	0.9000	0.9000	0.9000
		5	0.9130	0.9130	0.9130
XGB	0.937	1	0.9524	1.0000	0.9756
		2	0.8667	1.0000	0.9286
		3	1.0000	1.0000	1.0000
		4	0.9750	0.8667	0.9176
		5	0.8696	0.9524	0.9091
DT	0.892	1	1.0000	0.9524	0.9756
		2	0.8125	0.8667	0.8387
		3	1.0000	1.0000	1.0000
		4	0.8611	0.7750	0.8158
		5	0.7407	0.8696	0.8000
BN	0.783	1	0.9524	1.0000	0.9756
		2	0.6667	0.4545	0.5405
		3	1.0000	0.9231	0.9600
		4	0.5750	0.7931	0.6667
		5	0.9565	0.8148	0.8800

信号的 MFCC 生成图像,并用 2D-CNN 进行识别分类。


表 5 不同维数 CNN 的参数量

Table 5 Parameters of CNN with different dimensions

Network	1D-CNN	2D-CNN (T-F matrix)	2D-CNN RGB image
C1	$(1 \times 5 + 1) \times 32 = 192$	$(5 \times 5 + 1) \times 32 = 832$	$(1 + 5 \times 5) \times 32 = 832$
C2	$(1 + 5) \times 64 = 384$	$(5 \times 5 + 1) \times 64 = 1664$	$(1 + 5 \times 5) \times 64 = 1664$
C3	$(1 + 5) \times 96 = 576$	$(5 \times 5 + 1) \times 96 = 2496$	$(1 + 5 \times 5) \times 96 = 2496$
FC1	$64 \times 96 \times 1000 = 614400$	$2 \times 16 \times 96 \times 1000 = 3072000$	$13 \times 16 \times 96 \times 1000 = 19968000$
FC2	$1000 \times 1000 = 1000000$	$1000 \times 1000 = 1000000$	$1000 \times 1000 = 1000000$
Total number of parameters	about 16000	about 40800	about 20000

1D-CNN 处理 1D 时间信号时具有很大优势,原因是输入 1D 数据时不需要进行任何处理,可提升处理速度;且 1D 数据保持了原始数据的结构信息,保障了网络的识别性能。表 5 为 1D-CNN 与文献 [28-29] 中 2D-CNN 每一层参数的对比,其中, C1、C2、C3 分别为 3 个卷积层,FC1、FC2 为 2 个全连接层。对于 2D-CNN,存在两种数据输入方式,包括时频 (T-F) 矩阵与 RGB 时频图像。可以发现,相比 2D-CNN,1D-CNN 的参数量有大幅度减少,网络结构更简单、更容易训练。

Wu 等^[33]基于 1D-CNN 对 DVS/DAS 的时间信号直接进行特征提取和识别,并用 1D-CNN 与两种 2D-CNN 训练实际数据。其中一种 2D-CNN 是提取 1×508 信号的时频信息,并将其转换为 9×122 的 T-F 矩阵;另一种 2D-CNN 是对 1D 信号进行 STFT,得到尺寸为 $125 \times 100 \times 3$ 的 RGB 时频图像,训练过程如图 11 所示。可以发现,1D-CNN 经过 3000 次迭代后已趋于稳定,而两种 2D-CNN 网络分别在 5500、9000 次迭代后才趋于稳定,且 1D-CNN 的收敛过程更平稳。

图 11 不同 CNN 的训练损失^[33]Fig. 11 Training losses of different CNNs^[33]

用优化后的 1D-CNN 对典型信号的分类效果与迭代速度进行测试,结果如图 12 所示。可以发现,相比基于 T-F 矩阵和 RGB 图像的 2D-CNN,1D-CNN 的分类准确率分别提高了 2%、3%,迭代用时

分别为 2D-CNN 的 1/2、1/10。将 1D-CNN 的 Softmax 层替换为其他分类器,得到不同网络的识别准确率如图 13 所示。可以发现,将 1D-CNN 深度提取的特征与 SVM、RF、XGB 分类器结合后,网络的识别准确率分别提升至 98.85%、98.76%、99%。图 14 为不同网络的十折交叉分类效果,可以发现,相比单独的 1D-CNN,与其他 3 种分类器组合后的网络在识别准确率上均有明显提升,且表现稳定。其中,1D-CNN+XGB 的表现最好,十折交叉验证结果均在 99% 以上。




图 12 不同 CNN 的分类结果^[33]

Fig. 12 Classification results of different CNN^[33]




图 13 1D-CNN 结合不同模型后的分类结果^[33]

Fig. 13 Classification results of 1D-CNN combined with different models^[33]

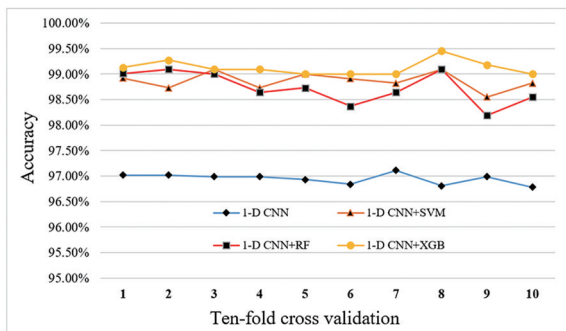


图 14 1D-CNN 结合不同模型后的十折交叉分类结果^[33]

Fig. 14 Ten-fold cross classification results of 1D-CNN combined with different models^[33]

4.3 基于 CNN-BiLSTM 的时空特征深度提取与识别

目前,DVS/DAS 信号的识别方法大多利用单个空间点的时间信号基于机器学习或深度学习模型识别事件类型。这种识别模式仅利用了时间维度的信息,忽略了 DVS/DAS 的空间分布特点,也没有利用相邻传感节点之间的空间关系。因此,Wu 等^[42]结合 CNN 与 LSTM 的网络特点,提出了一种基于 CNN-BiLSTM 的 DVS/DAS 时空信号特征深度提取与识别方法,其信号处理流程如图 15 所示。先用 1D-CNN 模块提取时间信号特征,得到每个空间点的特征向量,再利用 BiLSTM 模块提取信号的空间分布特征。

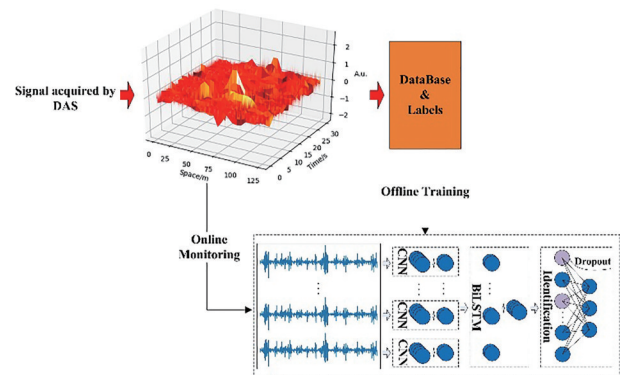


图 15 基于 CNN-BiLSTM 的时空特征提取流程^[42]

Fig. 15 Spatio-temporal feature extraction process based on CNN-BiLSTM^[42]

利用线性判别分析(LDA)降维可视化 CNN-BiLSTM 模型提取的时空特征,并与在 1D 时间信号的人工特征、2D-CNN 提取的时空特征以及人工特征基础上利用 BiLSTM 模型提取的空间分布特征进行对比,4 种模型提取的归一化特征如图 16 所示^[42]。可以发现,不同模型对 5 类事件提取的特征都具有一定的分辨性,其中,时空信号特征的分辨性优于人工提取的时间信号特征,而 CNN-BiLSTM 提取的时空信号特征分辨性优于 2D-CNN 和 BiLSTM。

用基于人工特征的 XGB 模型在 1D 时间信号数据库上进行训练和测试,用基于人工特征的 LSTM 模型^[40]、自动提取时空特征的 2D-CNN 模型^[41]、CNN-BiLSTM 模型在 2D 时空信号数据库上进行训练和测试,结果如图 17 所示^[42]。可以发现,CNN-BiLSTM 模型具有较好的稳定性,平均识别率可以达到 97.7%。1D 时间信号模型的平

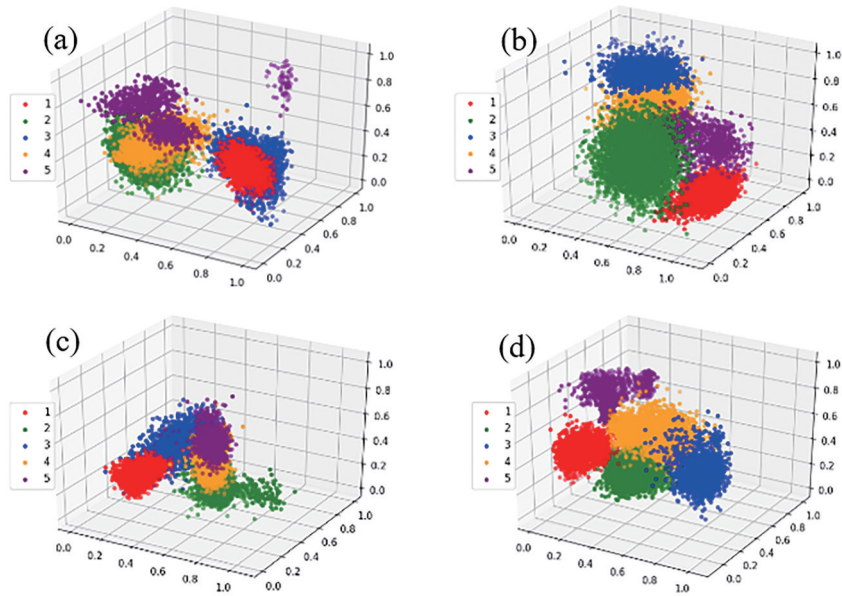


图 16 不同特征的可视化结果。(a)人工特征;(b) 2D-CNN 特征;(c) BiLSTM 特征;(d) CNN-BiLSTM 特征^[42]
 Fig. 16 Visualization results of different features. (a) Artificial features; (b) 2D-CNN features; (c) BiLSTM features; (d) CNN-BiLSTM features^[42]

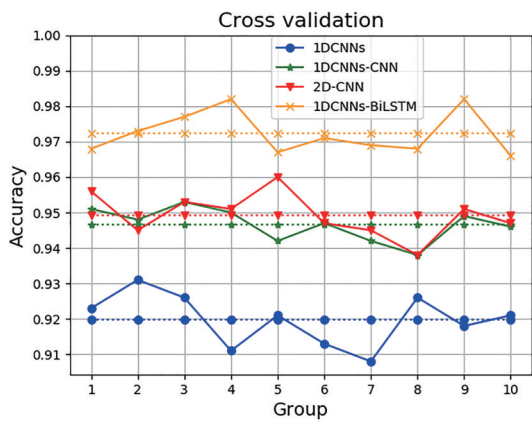


图 17 不同模型的十折交叉验证结果^[42]
 Fig. 17 Ten-fold cross-validation results of different models^[42]

均识别率最低,为 93.3%,且稳定性也最差。此外,考虑空间信息的 2D-CNN 模型和 BiLSTM 模型平均识别率分别为 95.1% 和 95.2%,稳定性也较好。这表明引入空间信息不仅可以提升识别率,还可以提高模型的稳定性,且利用 2D 时空信息的模型在各项评价指标上都优于只利用 1D 时间信息的模型。相比 2D-CNN 模型和 BiLSTM 模型, CNN-BiLSTM 模型先用 CNN 提取局部时间特征,再用 BiLSTM 提取空间分布特征,识别效果更好。

此外,在典型处理设备配置参数(CPU 为 I7-9700K, GPU 为 1080Ti, 内存为 32 G)下,以 36 km

光缆全线监测为例,系统空间的采样间隔为 5 m,共监测 7200 个空间点,不同模型识别单个时空样本的时间如图 18 所示^[42]。可以发现,1D 时间信号模型 XGB 识别每个样本的时间为 0.0062 s,全线识别需要 44.64 s;基于 2D 时空信号的模型,每次识别的样本是由 25 个相邻空间点(空间范围为 125 m)组成的区域,全线时空样本为 288 个,2D-CNN、BiLSTM、CNN-BiLSTM 对应的全线识别时间分别为 0.7776 s、2.3904 s、1.4112 s,均小于全线样本的累积时间(30 s)。虽然 CNN-BiLSTM 比 2D-CNN 模型的运行时间略长,但该模型仍满足全线实时监测的要求。




图 18 单个样本的识别时间^[42]
 Fig. 18 Recognition time of single sample^[42]

5 DVS/DAS 振动/声源的二维空间定位方法

DVS/DAS 振动/声源的二维空间位置一方面由其沿光纤线路的纵向定位决定,另一方面由振动源偏离光纤的横向垂直距离(垂距)决定。沿光纤的纵向位置由光时域反射定位原理确定,但偏移距离的垂距估计较难;且近距离条件下的时延估计偏差较大,波达方向(DOA)方法受到远场条件约束,无法直接应用。因此,Wu 等^[46]基于

DVS/DAS 阵列信号空间能量分布特征提出了一种垂直偏移距离估计及威胁级别的判断方法。经过快速傅里叶变换(FFT)和窄带滤波后,计算某一垂距下不同光纤接收点上滤波后的信号功率,得到阵列接收信号的空间能量衰减曲线如图 19 所示,可表示两种不同垂距下的空间能量衰减特征。结合集成学习模型识别不同垂距下的空间能量规律,估计垂距的流程如图 20 所示。为了提高识别精度,集成学习模型采用 4 个 SVM 分类器与一个 RF。

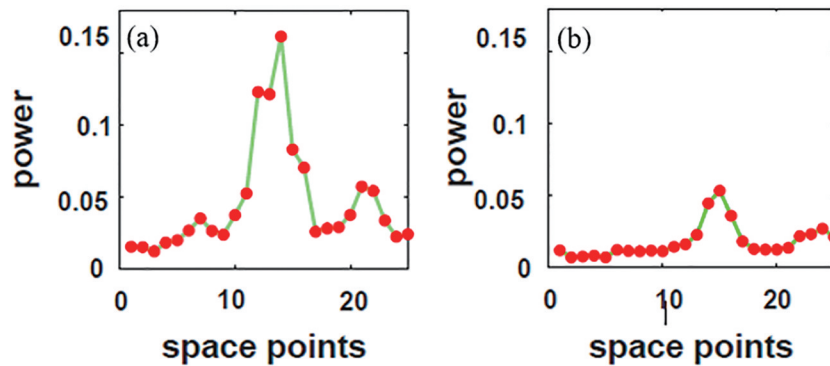


图 19 不同垂距下阵列信号的空间能量衰减特征。(a) 6 m; (b) 14 m^[46]

Fig. 19 Spatial energy distribution characteristics with different vertical distances. (a) 6 m; (b) 14 m^[46]

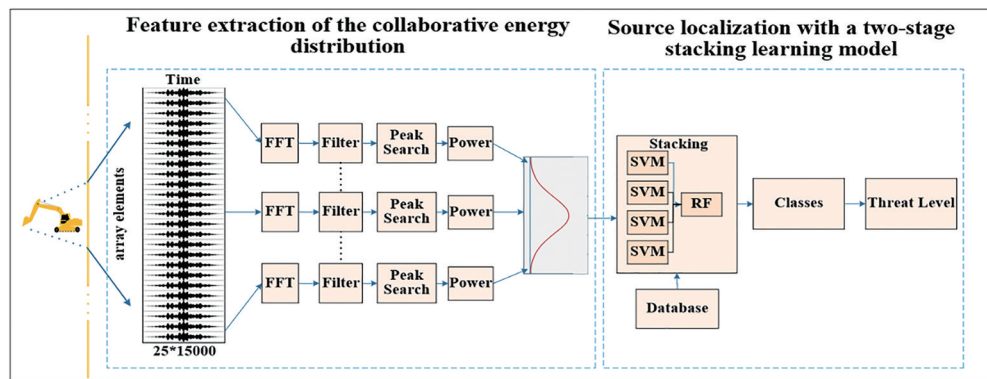


图 20 基于空间能量分布和集成学习模型的垂距估计方法^[46]

Fig. 20 Vertical distances estimation method based on spatial energy distribution and integrated learning model^[46]

通过机械敲击和机械挖掘验证该垂距估计方法的有效性,其中,敲击测试表示规律性振动事件,按垂距奇偶分为 2 组测试,该事件下采集的信号如图 21 所示,不同垂距下的空间能量衰减曲线如图 22 所示。可以发现,垂距越大,靠近中心的能量峰越弱,曲线越平坦;反之,靠近中心的能量峰越强,曲线越尖锐。将相邻 3 个类别进行合并,即按照 ± 1 m 的定位误差计算位置分类的准确性;同时将相邻 5 个类别进行合并,按照 ± 2 m 的定位误差计算位置分类的准确性。按照垂距的大小分为 3 个威胁级别,分别为 I(0~4 m)、II

(5~10 m)、III(11~15 m)级。最终得到垂距估计及威胁级别的判断准确率如表 6 所示。其中, ± 1 m 和 ± 2 m 定位误差内的分类准确率分别为 92.25% 和 100%,威胁级别预测的平均准确率为 99.06%。

挖掘测试时的机械动作不规律,信号时强时弱,如图 23 所示,对应的能量曲线如图 24 所示,其垂距分类及威胁级别判断准确率如表 7 所示。可以发现,挖掘测试与敲击测试时信号随垂距的变化规律相似。 ± 1 m 和 ± 2 m 定位误差内的预测准确率分别为 83.5%、86.7%,威胁级别预测

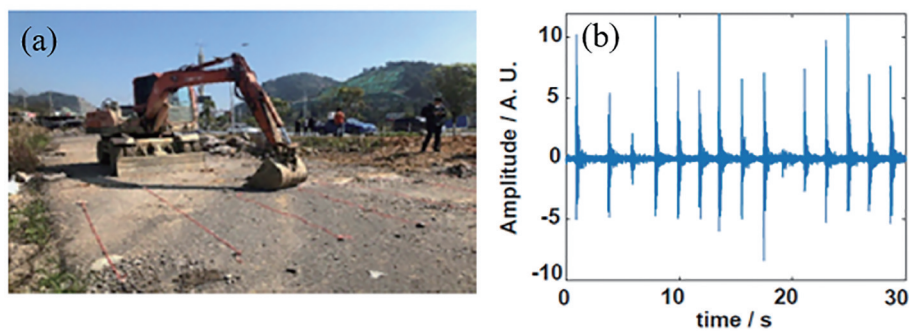


图 21 机械敲击的测试信号。(a)敲击现场;(b)时域信号图^[46]

Fig. 21 Test signal of the mechanical knocking. (a) Knocking scene; (b) time domain signal diagram^[46]

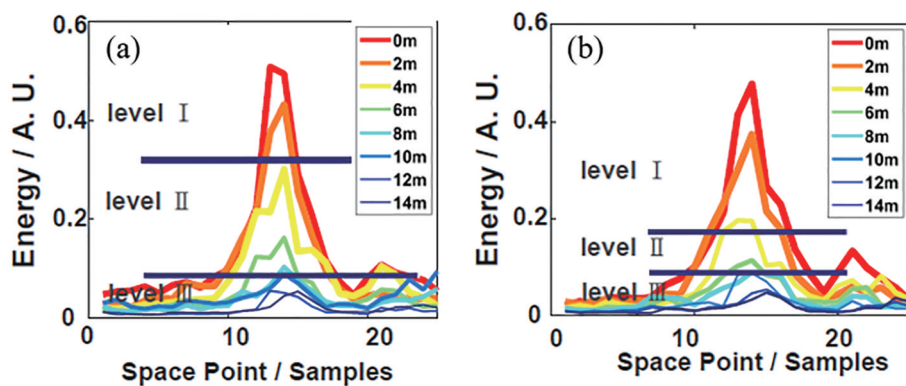


图 22 机械敲击信号的空间能量衰减曲线。(a)第 1 组;(b)第 2 组^[46]

Fig. 22 Spatial energy attenuation curves of the machine knocking signals. (a) Group 1; (b) group 2^[46]

表 6 机械敲击事件的模型识别结果^[46]

Table 6 Model recognition results of the mechanical knock events^[46]

Distance / m	Error accuracy (±1 m) / %	Error accuracy (±2 m) / %	Threat level	Accuracy rate / %
0	100	100		
1	100	100		
2	100	100	I	100
3	100	100		
4	100	100		
5	100	100		
6	100	100		
7	100	100		
8	71	71	II	90.8
9	87	100		
10	83	100		
11	100	100		
12	100	100		
13	100	100	III	100
14	100	100		
15	89	100		

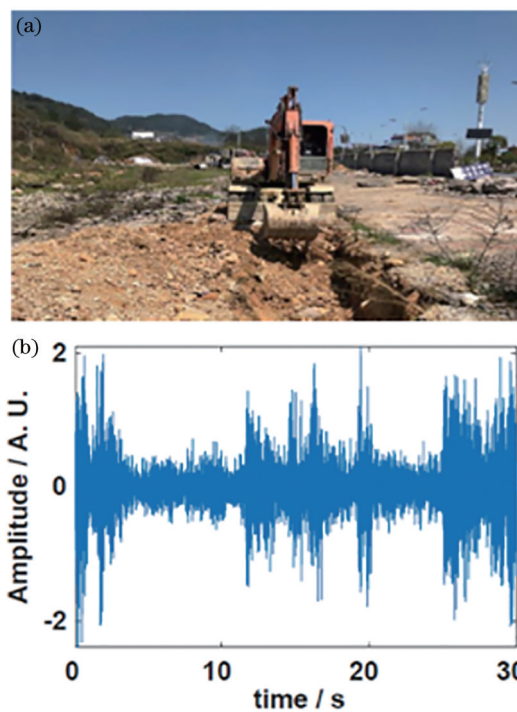


图 23 机械挖掘的测试信号。(a)挖掘现场;(b)时域信号图^[46]

Fig. 23 Test signal of the mechanical excavation.

(a) Excavation scene; (b) time domain signal diagram^[46]

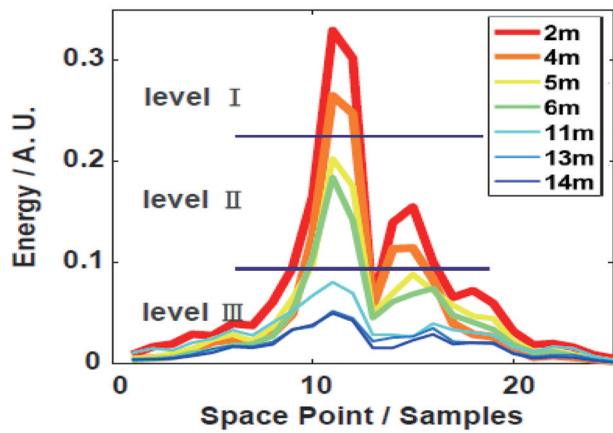


图 24 挖掘信号的空间能量衰减曲线^[46]

Fig. 24 Spatial energy attenuation curves of the excavation signals^[46]

准确率为 82.03%。当不考虑 II 级威胁时, I、III 级的准确率可以达到 89.4%。这表明该方法可克服地下复杂非均质埋设条件下难以利用阵列信号的多信号分类(MUSIC)谱估计^[47]和近距离振动事件复杂地理条件传播时延估计不准^[48]的困难。

6 安全监测中的典型应用

6.1 新疆边境管控及安防

针对边境管控需求, Wu 等^[7]将自行研制的分布

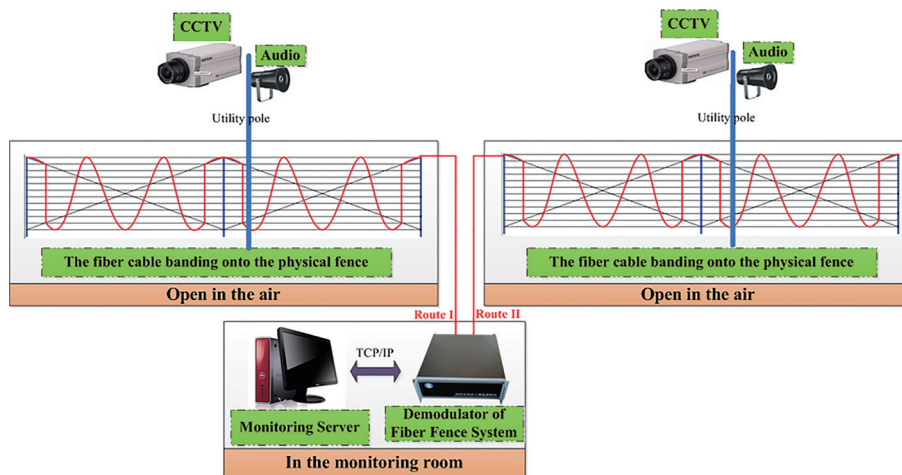


图 25 边境管控及安防技术的原理^[7]

Fig. 25 Principles of border control and security technology^[7]

6.2 油气管道安全监测

针对长距离输油管道防开挖和防盗的应用需求, Wu 等^[49]利用分布式光纤振动传感技术在河北中石化 65 km 输油管道上成功进行了示范工程应

表 7 机械挖掘的定位结果^[46]

Table 7 Location results of the mechanical excavation^[46]

Distance/ m	Error accuracy (±1 m)/%	Error accuracy (±2 m)/%	Threat level	Accuracy rate/%
2	86	86		
3	100	100	I	95.3
4	100	100		
6	33	66	II	65.8
8	100	100		
11	80	80		
13	100	100		
15	80	100	III	85
17	60	60		

式光纤振动传感系统应用于 220 km 的新疆国防边境线上,利用四套系统进行分段监控,每段监控范围为 40~60 km 不等,整个监测方案如图 25 所示,与闭路电视(CCTV)监控系统联动能实现感知与可视互补。解调设备与监控服务器的通信基于网络通信协议,即传输控制协议/因特网互联协议(TCP/IP)。挂缆、埋地铺设方式及去噪前后的监测信号如图 26 所示。2012 年 8 月开始测试,至今系统的软硬件仍稳定运行,对边境线上的异常入侵行为探测率高、定位准确;且能实现报警信息与音视频监控系统的实时联动,大大减轻了人工巡逻执勤的繁重任务,真正意义上实现了全天候无人值守边防管控,在我国国境线的边防管控中发挥了重要作用。

用。测试石油管道埋地 1~2 m 深,系统的空间分辨率为 24.5 m,时间采样率为 508 Hz,探测光纤与石油输送管道同步埋设。监测现场及系统装置如图 27 所示,提取常见长输油管道 6 类典型信号特

征, 获得的特征雷达图如图 28 所示。其中, F1~F7 分别为特征选择后排在前列的人工特

征。可以发现, 特征的分辨性较高, 可进行安全事件的准确分类识别。

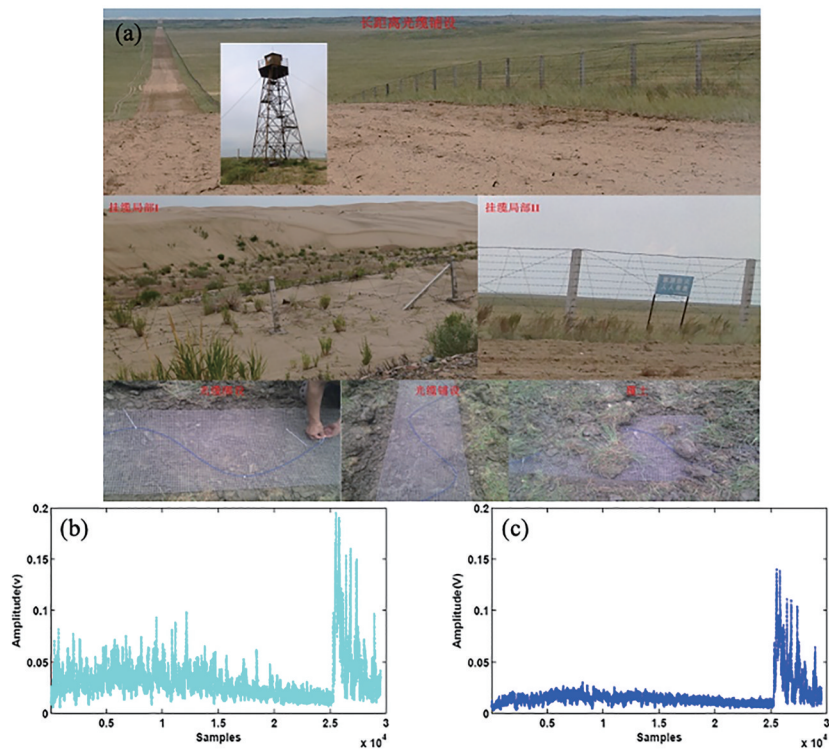


图 26 光缆的铺设方式及去噪前后的监测信号。(a)光缆的铺设方式;(b)去噪前的监测信号;(c)去噪后的监测信号^[7]

Fig. 26 Laying method of optical cable and the monitoring signal before and after noise removal. (a) Laying method of the optical cable; (b) monitoring signal before denoising; (c) monitoring signal after denoising^[7]



图 27 长距离输油管道防开挖的监测现场。(a)监控设备;(b)加油站;(c)现场测试环境^[49]

Fig. 27 Monitoring site for excavation prevention of long-distance oil pipelines. (a) Monitoring equipment; (b) gas station; (c) on-site test environment^[49]




图 28 输油管道中典型事件的特征雷达图。(a)背景噪声;(b)人工挖掘;(c)机械挖掘;(d)交通干扰;(e)工厂干扰

Fig. 28 Characteristic radar chart of typical event in an oil pipeline. (a) Background noise; (b) manual excavation; (c) mechanical excavation; (d) traffic disturbance; (e) factory interference

6.3 管道光缆防盗及运维监测

为了解决电力行业中大规模长距离光缆通信网络运维管理困难和人为破坏问题,针对贵州电网公司在光缆运维智能化方面的需求,将自主研发的多通道分布式光纤振动传感系统应用于电力管道光缆的运维及防盗综合安全监测中,系统架构如图 29 所示,基于电子地图的在线监测系统界面及管辖光缆信息统计如图 30 所示。可以发现,贵州电网

信息通信分公司管辖的光电缆(总计 108 条)有 3 条在 40 km 及以上,最长约为 100 km,长度大于 40 km 的只占 2%;长度为 30~40 km 的光电缆占 2%,96% 的光电缆长度小于 20 km。每 3 km 悬挂一个电子标签,6 条光缆共计悬挂 30 个电子标签,使用手持电子标签(RFID)终端与主机通过通用无线分组业务(GPRS)进行无线通信,实现线路在线监测与巡检的一体化操作。

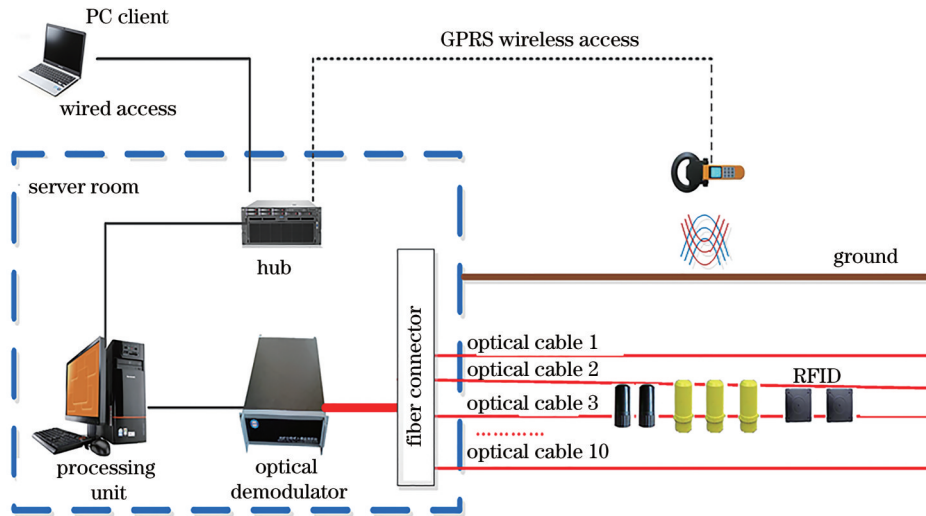


图 29 管道光缆防盗及运维监测系统的原理

Fig. 29 Principle of the pipeline optical cable anti-theft and operation and maintenance monitoring system

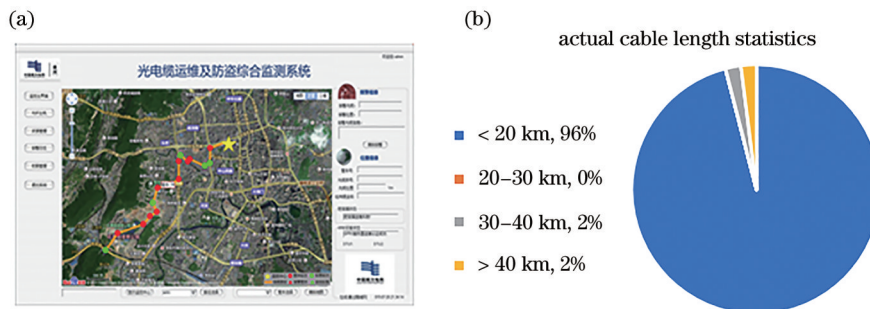


图 30 在线监测与巡检界面。(a) 基于百度地图的在线定位与巡检;(b) 光缆信息的统计结果

Fig. 30 Interface of online monitoring and inspection. (a) Online positioning and inspection based on Baidu map; (b) statistical results of optical cable information

6.4 海缆防破坏监测

针对长距离海底电缆载流测量、张力监测、防抛锚破坏的需求,利用分布式光纤温度、应变、振动多参数综合监测技术,在大型风电场柔性直流输电接入技术与开发项目中搭配广东省汕头地区南澳岛配套建设的±160 kV/200 MW 柔性多端直流输电系统,对后江湾段 32.5 km 的海缆进行监测和实时防护,避免船只抛锚等因素导致的海缆破坏,工程现场如图 31 所示。

6.5 架空线缆风舞监测

用 DVS/DAS 系统对山西电网 48 km 长、500 V 的高压忻风架空线进行风舞监测测试^[49-50],架空输电线路风舞监测现场如图 32 所示。将系统接到架空输电线路的光纤复合架空地线(OPGW)光缆上,可以有效测量电缆舞动的幅度大小和频率,风致舞动频率集中在 0.3 Hz、0.75 Hz 两个频率点上。2017 年 6 月 15 日 2 个时间段内线缆风舞的频空分布如图 33

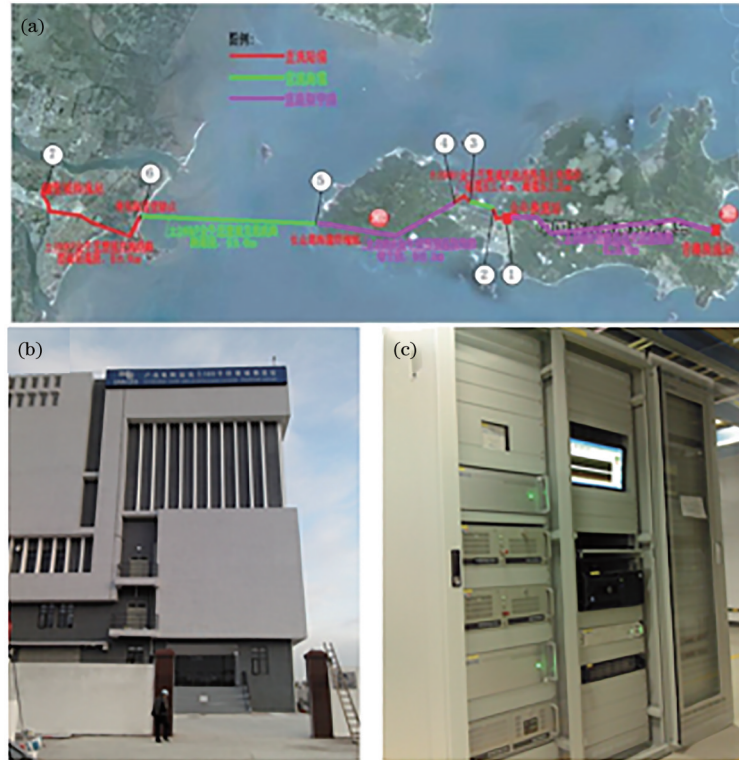


图 31 海缆安全监测的工程现场。(a) 监测海域; (b) 监控中心; (c) 监控设备

Fig. 31 Project site of submarine cable safety monitoring. (a) Monitored marine area; (b) monitoring center; (c) monitoring setup




图 32 架空输电线路的监测现场及测试设备。(a) 监控中心; (b) 监控设备^[49]

Fig. 32 Monitoring site and test equipment of overhead transmission cables. (a) Monitoring center; (b) monitoring setup^[49]

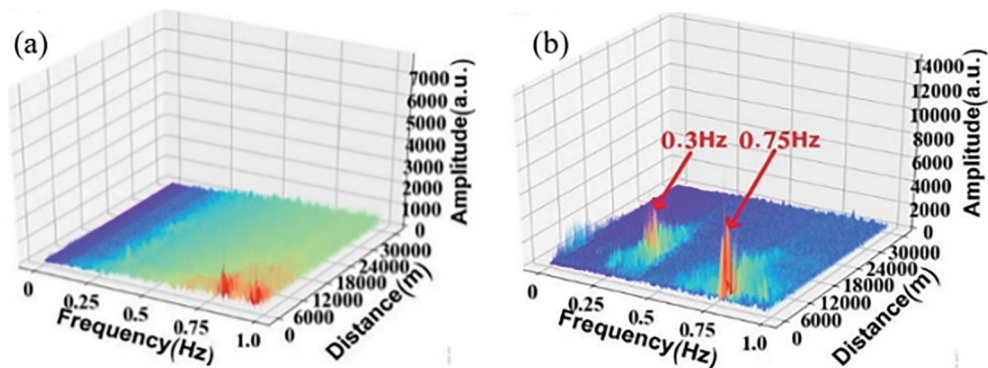


图 33 线缆风舞的频空分布图。(a) 1:00—2:00; (b) 14:00—15:00^[50]

Fig. 33 Frequency and space distribution of cable wind dance. (a) 1:00—2:00; (b) 14:00—15:00^[50]

所示,可以发现,该系统能反映丰富的电缆风舞事件信息,对电缆风舞事件响应灵敏、定位准确,且能同时在强电磁干扰及雷电等恶劣天气条件下稳定工作,可适用于长距离架空输电线缆风舞监测应用。

6.6 地下供水管网的安全监测

吴慧娟等^[4]将 DVS/DAS 系统在某城市供水管道上进行了现场测试,整体测试方案及安装过程如图 34 所示。测试时选取一段靠近郊区区长为 440 m 的压力输水管道,测试光缆长度为 800 m,在测试段管道的一端将长为 360 m 的光纤连接到光纤振动传感解调主机上。该段压力输水管道从该市区某水库到一条直径为 2 m、壁厚为 2 cm 普通钢制压力输水管道,管道埋地铺设,距离地面大约 2 m。

选取普通单模通信光纤作为测试光缆,在管道

内壁上用直线铺设方法铺设,如图 34(c)所示。先对铺设光缆的管道内壁进行机械打磨,以去除铺设光缆周围的杂质,再将传感光缆通过环氧树脂粘接到管道内壁上。室外测试时压力输水管道的内压力为 0.27 MPa,分别测量了泄漏阀开半圈(泄漏量为 11 L/s)、一圈(泄漏量为 25 L/s)、两圈(泄漏量为 101 L/s)、三圈(泄漏量为 125 L/s)4 种情况下系统的泄漏响应。泄漏阀开半圈(泄漏量为 11 L/s)前后的泄漏响应如图 35 所示,可以发现,440 m 泄漏阀位置处泄漏信号幅度明显高于非泄漏点处的强度。这表明该系统在城镇实际复杂背景下能检测出泄漏量大于 11 L/s 的泄漏点。泄漏响应信号随开阀圈数的增加越来越稳定,当泄漏量大于 101 L/s 时系统能获得长时间稳定的泄漏响应。

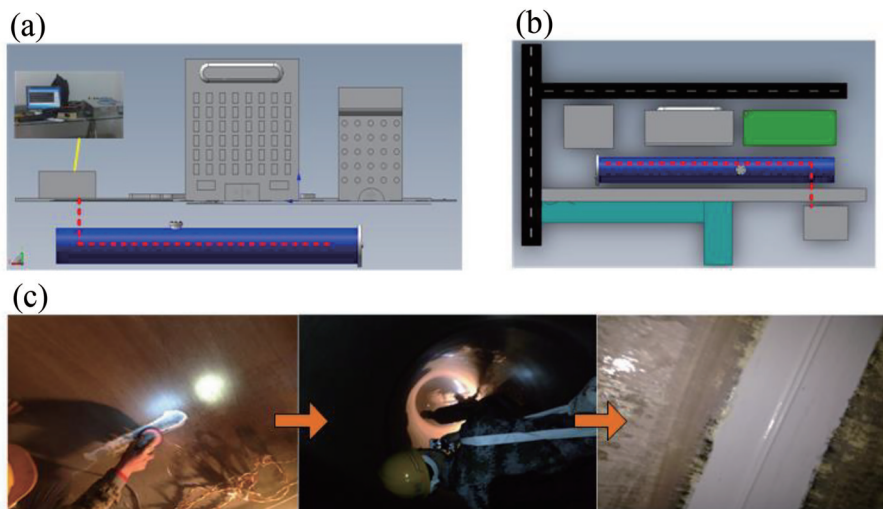


图 34 室外光缆安装布线图。(a)剖面图;(b)俯视图;(c)安装过程^[4]

Fig. 34 Installation wiring diagram of outdoor optical cable. (a) Sectional view; (b) top view; (c) installation process^[4]

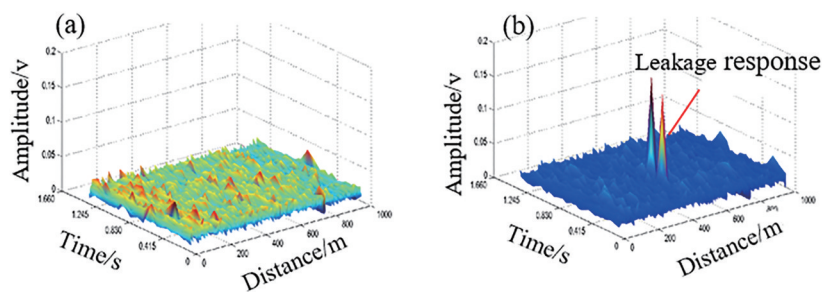


图 35 DVS/DAS 系统的泄漏响应信号。(a)未开阀时泄漏量的响应图;(b)开阀时泄漏量的响应图^[4]

Fig. 35 Leak response signal of the DVS/DAS system. (a) Response graph of leakage when the valve is not opened;

(b) response graph of leakage when the valve is opened^[4]

7 结 论

总结了基于 Φ -OTDR 的 DVS/DAS 信号处理

方法的研究进展及典型应用案例。结果表明,现有基于传统人为特征提取、深度特征提取及各种分类器设计的 DVS/DAS 信号检测识别方法还处于初

级阶段,信息获取的全面性、有效性及提取方式的智能性还有待进一步研究。未来研究 DVS/DAS 信号处理时,还需结合多种机器学习模型,进一步提升 DVS/DAS 信号特征信息提取的全面性、有效性,以提升系统在实际复杂环境中对感知对象识别的准确率和稳定性。此外,结合人工智能算法可以实现 DVS/DAS 信号特征信息提取及目标信号识别的智能化。通过信号处理方法可进一步增强 DVS/DAS 系统的智能感知能力,除了对振动源的识别外,还可以提供振动源在 2D 及 3D 空间的方位等信息。对于复杂地面干扰及未知地理条件,还需要进一步研究多源混叠信号的分离检测与识别方法。

参 考 文 献

- [1] Juarez J C, Maier E W, Choi K N, et al. Distributed fiber-optic intrusion sensor system[J]. *Journal of Lightwave Technology*, 2005, 23(6): 2081-2087.
- [2] Wang P G, Yang B, Li Z, et al. Research for the distributed optical fiber early warning system based on Rayleigh scattering light Φ -OTDR[J]. *Optical Instruments*, 2012, 34(2): 61-66.
王培国, 杨斌, 李泽, 等. 基于 Φ -OTDR 技术的通信光缆险情定位与预警系统设计及实现[J]. *光学仪器*, 2012, 34(2): 61-66.
- [3] Tan D J, Tian X Z, Sun W, et al. An oil and gas pipeline pre-warning system based on Φ -OTDR[J]. *Proceedings of SPIE*, 2014, 9157: 91578W.
- [4] Wu H J, Chen Z Q, Lü L D, et al. Novel pressurized water pipe leak monitoring method based on the distributed optical fiber vibration sensor[J]. *Chinese Journal of Scientific Instrument*, 2017, 38(1): 159-165.
吴慧娟, 陈忠权, 吕立冬, 等. 基于 DOFVS 的新型压力输水管道泄漏在线监测方法[J]. *仪器仪表学报*, 2017, 38(1): 159-165.
- [5] Bao X Y, Zhou D P, Baker C, et al. Recent development in the distributed fiber optic acoustic and ultrasonic detection[J]. *Journal of Lightwave Technology*, 2017, 35(16): 3256-3267.
- [6] Duckworth G L, Ku E M. OptaSense distributed acoustic and seismic sensing using COTS fiber optic cables for infrastructure protection and counter terrorism[J]. *Proceedings of SPIE*, 2013, 8711: 87110G.
- [7] Wu H J, Wang Z N, Peng F, et al. Field test of a fully distributed fiber optic intrusion detection system for long-distance security monitoring of national borderline[J]. *Proceedings of SPIE*, 2014, 9157: 915790.
- [8] Zhang X P, Ding Z W, Hong R, et al. Phase sensitive optical time-domain reflective distributed optical fiber sensing technology[J]. *Acta Optica Sinica*, 2021, 41(1): 0106004.
张旭苹, 丁哲文, 洪瑞, 等. 相位敏感光时域反射分布式光纤传感技术[J]. *光学学报*, 2021, 41(1): 0106004.
- [9] Cai H W, Ye Q, Wang Z Y, et al. Distributed optical fiber acoustic sensing technology based on coherent Rayleigh scattering[J]. *Laser & Optoelectronics Progress*, 2020, 57(5): 050001.
蔡海文, 叶青, 王照勇, 等. 基于相干瑞利散射的分布式光纤声波传感技术[J]. *激光与光电子学进展*, 2020, 57(5): 050001.
- [10] Martins H F, Martin-Lopez S, Corredera P, et al. Distributed vibration sensing over 125 km with enhanced SNR using Phi-OTDR over a URFL cavity [J]. *Journal of Lightwave Technology*, 2015, 33(12): 2628-2632.
- [11] Wang S, Wang B, Liu Q W, et al. Advances of key technologies on optical reflectometry with ultra-high spatial resolution[J]. *Opto-Electronic Engineering*, 2018, 45(9): 170669.
汪帅, 王彬, 刘庆文, 等. 超高空间分辨率光反射仪关键技术进展[J]. *光电工程*, 2018, 45(9): 170669.
- [12] Rao Y J, Luo J, Ran Z L, et al. Long-distance fiber-optic Φ -OTDR intrusion sensing system[J]. *Proceedings of SPIE*, 2009, 7503: 75031O.
- [13] Song M P, Zhuang S W, Wang Y X. High-frequency vibration detection of phase-sensitive optical time-domain reflectometer[J]. *Chinese Journal of Lasers*, 2020, 47(5): 0506001.
宋牟平, 庄守望, 王轶轩. 相位敏感光时域反射计的高频振动检测[J]. *中国激光*, 2020, 47(5): 0506001.
- [14] Wang Z N, Zeng J J, Li J, et al. Ultra-long phase-sensitive OTDR with hybrid distributed amplification [J]. *Optics Letters*, 2014, 39(20): 5866-5869.
- [15] Liu X, Wang Y, Wu R D, et al. Real-time phase-sensitive OTDR based on data matrix matching method[J]. *Sensors*, 2018, 18(6): 1883.
- [16] Zhu T, Xiao X H, He Q, et al. Enhancement of SNR and spatial resolution in Φ -OTDR system by using two-dimensional edge detection method[J]. *Journal of Lightwave Technology*, 2013, 31(17): 2851-2856.

- [17] Qin Z G, Chen L, Bao X Y. Wavelet denoising method for improving detection performance of distributed vibration sensor[J]. IEEE Photonics Technology Letters, 2012, 24(7): 542-544.
- [18] Hui X N, Zheng S L, Zhou J H, et al. Hilbert-Huang transform time-frequency analysis in Φ -OTDR distributed sensor[J]. IEEE Photonics Technology Letters, 2014, 26(23): 2403-2406.
- [19] 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.
- [20] Fang N, Wang L T, Jia D J, et al. Walking intrusion signal recognition method for fiber fence system[J]. Proceedings of SPIE, 2009, 7634: 76341C.
- [21] Wang Z Y, Pan Z Q, Ye Q, et al. Fast pattern recognition based on frequency spectrum analysis used for intrusion alarming in optical fiber fence[J]. Chinese Journal of Lasers, 2015, 42(4): 0405010.
王照勇, 潘政清, 叶青, 等. 用于光纤围栏入侵告警的频谱分析快速模式识别[J]. 中国激光, 2015, 42(4): 0405010.
- [22] Zheng Y, Duan F J, Tu Q C, et al. Monitoring intrusion incidents in different frequencies based on Φ -OTDR[J]. Opto-Electronic Engineering, 2015, 42(5): 68-74.
郑印, 段发阶, 涂勤昌, 等. Φ -OTDR 识别不同频率振动事件研究[J]. 光电工程, 2015, 42(5): 68-74.
- [23] Zhao S Q, Pang F F, He M T, et al. Research on the signal processing in optical fiber coherent optical time domain reflectometer based on grey scale image[J]. Chinese Journal of Lasers, 2015, 42(3): 0305001.
赵世琦, 庞拂飞, 贺梦婷, 等. 基于灰度图像的光纤相干光时域反射计信号处理研究[J]. 中国激光, 2015, 42(3): 0305001.
- [24] Sun Q, Feng H, Yan X, et al. Recognition of a phase-sensitivity OTDR sensing system based on morphologic feature extraction[J]. Sensors (Basel), 2015, 15(7): 15179-15197.
- [25] 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.
- [26] Wang B J, Pi S H, Sun Q, et al. Improved wavelet packet classification algorithm for vibrational intrusions in distributed fiber-optic monitoring systems[J]. Optical Engineering, 2015, 54(5): 055104.
- [27] Zhang J N, Lou S Q, Liang S. Study of pattern recognition based on SVM algorithm for Φ -OTDR distributed optical fiber disturbance sensing system[J]. Infrared and Laser Engineering, 2017, 46(4): 0422003.
张俊楠, 娄淑琴, 梁生. 基于 SVM 算法的 Φ -OTDR 分布式光纤扰动传感系统模式识别研究[J]. 红外与激光工程, 2017, 46(4): 0422003.
- [28] Aktas M, Akgun T, Demircin M U, et al. Deep learning based multi-threat classification for phase-OTDR fiber optic distributed acoustic sensing applications[J]. Proceedings of SPIE, 2017, 10208: 102080G.
- [29] Jiang F, Li H L, Zhang Z H, et al. An event recognition method for fiber distributed acoustic sensing systems based on the combination of MFCC and CNN[J]. Proceedings of SPIE, 2018, 10618: 1061804.
- [30] 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.
- [31] Wang Z D, Lou S Q, Liang S, et al. Multi-class disturbance events recognition based on EMD and XGBoost in Φ -OTDR[J]. IEEE Access, 2020, 8: 63551-63558.
- [32] Jia H Z, Lou S Q, Liang S, et al. Event identification by F-ELM model for Φ -OTDR fiber-optic distributed disturbance sensor[J]. IEEE Sensors Journal, 2020, 20(3): 1297-1305.
- [33] Wu H J, Chen J P, Liu X R, 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.
- [34] Tejedor J, Martins H F, Piote D, et al. Toward prevention of pipeline integrity threats using a smart fiber-optic surveillance system[J]. Journal of Lightwave Technology, 2016, 34(19): 4445-4453.
- [35] Tejedor J, Macias-Guarasa J, Martins H F, et al. A contextual GMM-HMM smart fiber optic surveillance system for pipeline integrity threat detection[J]. Journal of Lightwave Technology, 2019, 37(18): 4514-4522.
- [36] Wu H J, Liu X R, Xiao Y, et al. A dynamic time sequence recognition and knowledge mining method based on the hidden Markov models (HMMs) for pipeline safety monitoring with Φ -OTDR[J]. Journal of Lightwave Technology, 2019, 37(19): 4991-5000.
- [37] Lyu 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: 1-9.
- [38] 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): 79-86.
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): 79-86.
- [39] Marie T F B, Han D Z, An B W, et al. A research on fiber-optic vibration pattern recognition based on time-frequency characteristics[J]. Advances in Mechanical Engineering, 2018, 10(12): 1-10.
- [40] Chen X, Xu C J. Disturbance pattern recognition based on an ALSTM in a long-distance Φ -OTDR sensing system[J]. Microwave and Optical Technology Letters, 2020, 62(1): 168-175.
- [41] Li S Z, Peng R Z, Liu Z L. A surveillance system for urban buried pipeline subject to third-party threats based on fiber optic sensing and convolutional neural network[J]. Structural Health Monitoring, 2020(7): 147592172093064.
- [42] Wu H J, Yang M R, Yang S Q, et al. A novel DAS signal recognition method based on spatiotemporal information extraction with 1DCNNs-BiLSTM network[J]. IEEE Access, 2020, 8: 119448-119457.
- [43] Li Z Q, Zhang J W, Wang M N, et al. Fiber distributed acoustic sensing using convolutional long short-term memory network: a field test on high-speed railway intrusion detection[J]. Optics Express, 2020, 28(3): 2925-2938.
- [44] Wu H J, Xiao S K, Li X Y, et al. Separation and determination of the disturbing signals in phase-sensitive optical time domain reflectometry (Φ -OTDR)[J]. Journal of Lightwave Technology, 2015, 33(15): 3156-3162.
- [45] Wu H, Wang J, Wu X, et al. Real intrusion detection for distributed fiber fence in practical strong fluctuated noisy backgrounds[J]. Sensor Letters, 2012, 10(7): 1557-1561.
- [46] Wu H J, Lu H, Yang S Q, et al. Vertical offset-distance estimation and threat level prediction of vibrations with DAS[J]. IEEE Access, 2020, 8: 177245-177254.
- [47] Liang J J, Wang Z Y, Lu B, et al. Distributed acoustic sensing for 2D and 3D acoustic source localization[J]. Optics Letters, 2019, 44(7): 1690-1693.
- [48] Azadi S, Safavi A A. S-transform based P-wave and S-wave arrival times measurements toward earthquake locating[C]//The 2nd International Conference on Control, Instrumentation and Automation, December 27-29, 2011, Shiraz, Iran. New York: IEEE Press, 2011: 241-246.
- [49] Wu H J, Qian Y, Li H Y, et al. Safety monitoring of long distance power transmission cables and oil pipelines with OTDR technology[C]//CLEO: Applications and Technology 2015, May 10-15, 2015, San Jose, California, United States. Washington, D. C.: OSA, 2015: ATu1M.4.
- [50] Wu H J, Tang B, Xiao Y, et al. Monitoring of the transmission line galloping with a novel distributed optical fibre sensor and its statistical data analysis[J]. IET Generation, Transmission & Distribution, 2020, 14(1): 166-171.