



DOI: 10.12086/oee.2021.200254

分布式光纤入侵信号检测与识别

张永康, 尚盈, 王晨, 赵文安, 李常, 曹冰, 王昌*

齐鲁工业大学(山东省科学院)激光研究所, 山东 济南 250014

摘要: 分布式光纤声波传感(DAS)技术通过接收相干瑞利散射光的相位信息来探测声波或振动信号, 具有灵敏度高、动态范围广等特性, 可利用线性定量测量实现对信号的高保真还原。随着实际应用的需求不断提高, 光纤入侵检测领域对事件的定位和识别提出了更高的要求, 表现为对入侵事件的准确分类, 因此将分布式光纤声波传感技术与模式识别(PR)技术相结合是目前研究的热门, 有利于推动分布式光纤传感技术的应用发展。本文总结了近年来在分布式光纤入侵检测的模式识别技术中所应用的特征提取和分类算法的研究进展, 回顾了几种实现入侵事件信号识别的特征提取方法及其在不同应用场合面临的特征选择难点, 同时对特定事件识别算法的优劣进行分析归纳。

关键词: 分布式声波传感; 模式识别; 特征提取; 分类算法

中图分类号: TN29

文献标志码: A

张永康, 尚盈, 王晨, 等. 分布式光纤入侵信号检测与识别[J]. 光电工程, 2021, 48(3): 200254

Zhang Y K, Shang Y, Wang C, et al. Detection and recognition of distributed optical fiber intrusion signal[J]. *Opto-Electron Eng*, 2021, 48(3): 200254

Detection and recognition of distributed optical fiber intrusion signal

Zhang Yongkang, Shang Ying, Wang Chen, Zhao Wen'an, Li Chang, Cao Bing, Wang Chang*

Laser Institute of Shandong Academy of Sciences, Qilu University of Technology (Shandong Academy of Sciences), Jinan, Shandong 250014, China

Abstract: Distributed acoustic sensing (DAS) technology can detect acoustic or vibration signals with high sensitivity and wide dynamic range by receiving the phase information from coherent Rayleigh scattered light. Linear quantization is used to measure high fidelity restoration of the signals. With the increasing demand of practical applications, the optical fiber intrusion detection field has put forward higher requirements for event location and identification, which is manifested as the accurate classification of intrusion events. Therefore, the combination of distributed acoustic sensing and pattern recognition (PR) technology is a hot research topic at present. This is beneficial to promote the application and development of distributed optical fiber sensing technology. The research progress of the pattern recognition technology applied to distributed optical fiber intrusion detection in recent years is summarized in this paper, which can be used for feature extraction and classification algorithm research progress. In this paper, several feature extraction methods for realizing intrusion event signal recognition and their feature selection difficulties in different application situations are reviewed. Meanwhile, the advantages and disadvantages of specific event recognition algorithm are analyzed and summarized.

收稿日期: 2020-07-10; 收到修改稿日期: 2020-11-20

基金项目: 山东省自然科学基金资助项目(ZR2019QF011); 山东省重大科技创新工程项目(2019JZZY010113); 山东省重点研发计划(2019GSF111065); 山东省高等学校青创科技支持计划(2019KJJ004)

作者简介: 张永康(1997-), 男, 硕士研究生, 主要从事分布式光纤传感技术方面的研究。E-mail: ooozyk@163.com

通信作者: 王昌(1977-), 男, 博士, 研究员, 主要从事智能材料与光纤传感技术方面的研究。E-mail: ch_wangs@163.com

版权所有©2021 中国科学院光电技术研究所

Keywords: distributed acoustic sensing; pattern recognition; feature extraction; classification algorithms

1 引言

传统的 Φ -OTDR采用直接探测^[1]的方式，通过探测光纤后向瑞利散射光的光强变化来对入侵信号进行检测和定位。为了提高 Φ -OTDR的信噪比和传感范围，后来又提出了相干探测^[2]的方法，建立了相位与外界信号之间的线性关系，通过相位解调技术获取外界声波信号的幅度、频率以及相位信息。分布式声波传感技术(Distributed acoustic sensing, DAS)是在 Φ -OTDR基础上发展起来的一种使用相干探测的新型分布式光纤传感技术，该技术具有精度高、响应速度快、动态范围广等优点，现已广泛应用于周界安防^[3]、地震勘探^[4]、轨道交通^[5]、管道运输^[6]等领域。

目前国内外有很多是针对提升DAS性能^[7-9]的报道，通过提高信噪比、提升响应速度来快速定位入侵事件，增长测量距离，对于监测系统的安全性有了较大提高。但随着应用不断深入，简单判断是否出现入侵信号已经不能满足实际应用的需要，并且随着安防、铁路、管道等领域对预警准确率、漏报率和微弱信号探测的要求不断提高，如何消除背景噪声^[10]造成的滋扰报警以及从复杂信号中识别出不同类型的入侵事件，目前已成为分布式光纤入侵检测领域内所关注的焦点。因此基于DAS的模式识别技术研究日趋重要。

本文首先结合近年来研究分布式光纤入侵信号识别技术的相关文献，对不同文献所使用的技术进行归纳总结，然后针对特征提取和模式分类方法着重介绍其原理和应用特点。

2 DAS系统结构和原理

DAS系统是以声波相位传感为基础，通过空间差

分干涉技术解调后向瑞利散射光的相位信息，进而实现重构外界振动信号的一种新型分布式光纤声波传感技术。本文介绍的系统原理图如图1所示，由窄线宽分布反馈光纤激光器(DFB-FL)发出的激光经声光调制器(AOM)调制成脉冲光，再经掺铒光纤放大器(EDFA)放大后进入传感光纤，光纤的后向瑞利散射信号经环形器进入 3×3 耦合器，耦合器另一侧的两个端口连接两个法拉第旋转镜(FRM)，光程差 s 为5 m，组成迈克尔逊干涉仪，入射光分成两束经法拉第旋转镜反射在耦合器发生干涉，干涉信号被三个探测器(PD1~3)接收，最后采集到上位机进行数据处理。

当有外界入侵事件作用于传感光纤时，传感区域光纤的长度 L 和纤芯折射率 n 会发生变化，进而导致光纤中光波相位发生变化，通过计算不同时刻后向瑞利散射光的差值，即可准确定位入侵事件的位置。

将光纤中的后向瑞利散射看做一维脉冲响应模型来描述DAS系统，假设一束频率为 f 、脉冲宽度为 ω 的高相干脉冲光入射到光纤上，后向瑞利散射信号可表示为

$$E_{bs}(t) = \sum_{m=1}^N E_0 \cos[2\pi f(t - \tau_m)] \exp\left(-\alpha \frac{c\tau_m}{n_f}\right) \text{rect}\left(\frac{t - \tau_m}{\omega}\right), \quad (1)$$

式中： α 为光纤衰减系数， n_f 为光纤折射率， c 为真空中光速，当 $0 \leq [(t - \tau_m)/\omega] \leq 1$ 时矩形函数 $\text{rect}[(t - \tau_m)/\omega] = 1$ ，其他情况矩形函数为0。 τ_m 为光纤上第 m 个散射点的时间延迟，其与从输入端到光纤第 m 个散射点的光纤长度 l_m 的关系为

$$\tau_m = \frac{2n_f l_m}{c} = m \frac{2n_f \Delta l}{c} = m \tau_0. \quad (2)$$

当后向瑞利散射光返回到环形器时，在环形器作

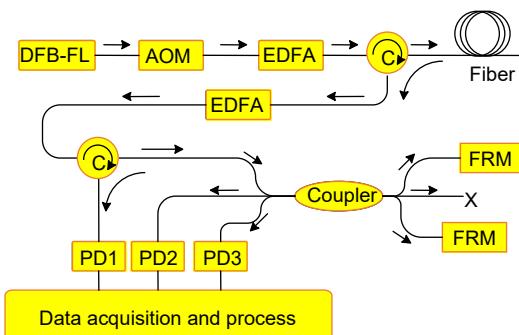


图1 DAS系统结构

Fig. 1 DAS system structure

用下发生第一次干涉，此时光强表示为

$$I_{\text{bs}} = \sum_{m=1}^N \sum_{i=m+1}^N a_m a_i \cos \varphi_{mi} \operatorname{rect}\left(\frac{t-\tau_m}{\omega}\right) \cdot \operatorname{rect}\left(\frac{t-\tau_i}{\omega}\right), \quad (3)$$

相对相位 $\varphi_{ij} = 4\pi f n_f \Delta l(j-i)/c$ 。

经过第一次干涉的后向瑞利散射光进入光程差为 s 的迈克尔逊干涉仪后会发生第二次干涉，此处干涉仪会引入延迟 $\tau_s = 2n_f s/c$ ，延迟信号振幅表示为

$$E_d(t) = \sum_{n=1}^N E_0 \cos[2\pi f(t - \tau_n - \tau_s)] \cdot \exp\left(-\alpha \frac{c\tau_m}{n_f}\right) \operatorname{rect}\left(\frac{t - \tau_n - \tau_s}{\omega}\right). \quad (4)$$

延时信号与后向瑞利散射信号对应关系为 $n = m + s$ ，因此通过第二次干涉之后在 3×3 耦合器处得到的光强表示为

$$\begin{aligned} I(t) &= [E_{\text{bs}}(t) + E_d(t)] \cdot [E_{\text{bs}}(t) + E_d(t)]^* \\ &= I_{\text{bs}} + \sum_{n=1}^N \sum_{j=1}^N a_n a_j \cos \varphi_{nj} \operatorname{rect}\left(\frac{t - \tau_n - \tau_s}{\omega}\right) \operatorname{rect}\left(\frac{t - \tau_j - \tau_s}{\omega}\right) \\ &\quad + 2 \sum_{m=1}^N \sum_{n=1}^N a_m a_n \cos \varphi_{mns} \operatorname{rect}\left(\frac{t - \tau_m}{\omega}\right) \operatorname{rect}\left(\frac{t - \tau_n - \tau_s}{\omega}\right), \end{aligned} \quad (5)$$

式中：相对相位为 $\varphi_{mns} = 4\pi f n_f \Delta l(n-m)/c + 4\pi f n_f s/c$ 。外界扰动会造成传感光纤上某点在不同时刻后向瑞利散射光功率发生变化，由此可对干涉信号的变化曲线进行分析，进而实现外界扰动的信息重构。

通过 DAS 系统可获得载有入侵信号的波函数，再经上位机解调即可获取入侵信号的幅值、频率、相位等信息，且信噪比高。对于入侵信号模式识别来说，完整、准确地提取原始信号是进行特征提取的重要前提，信号还原度越好，提取的特征作为判断入侵事件的依据则越精确，进而可以准确进行分类识别。

3 入侵信号特征提取

DAS 系统的光纤入侵信号识别主要包括如图 2 所

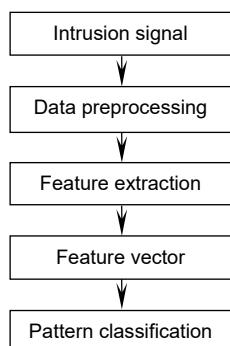


图 2 入侵信号识别流程

Fig. 2 Intrusion signal recognition process

示的流程：首先将 DAS 系统收集到的入侵信号进行滤波、降噪等预处理，提高信号的还原度；然后从信号中提取有效特征，组成可用于描述入侵事件类型的特征向量；最后选择合适的分类识别算法，实现未知入侵信号分类识别。

在整个流程中，特征提取是影响最终入侵事件识别的关键因素。特征提取的目的是从 DAS 系统采集到的干涉信号中提取出有意义的、可用于表征不同事件特征的信息，所提取的特征应具备四个条件：普遍性、唯一性、稳定性和可数据量化。结合不同的实际需求，选择不同方式的特征提取方法，可以提高入侵信号检测的准确率。目前较为广泛使用的特征提取方法主要有三类：时域特征、频域特征和时频域特征，下面分别对三种不同的特征进行简要介绍。

3.1 时域特征

当外界扰动作用在传感光纤上时，后向瑞利散射光功率会随时间变化，且效果直观、显著。通过统计一定时间内信号在时域上所呈现出来的某种规律性变化可以区分入侵事件。

2007 年，饶云江^[11]等人采用小波多尺度边缘检测方法对信号分割，提取边缘、峰值、长度、幅度等特征来设定阈值，并建立报警模式来判断报警，经现场实验证明了系统可靠性。2009 年，Mahmoud^[12]等人提出一种基于自适应动态阈值(level crossing, LC, 用 T_{LC} 表示)的特征提取方法，用于区分入侵事件和滋扰事件(如降雨、大风)。首先根据经验确定一个动态阈值 T ，根据实际噪声动态调整，然后对入侵信号按时间规律分割为不同区域，统计其每个区域过阈值的次数，定义为

$$T_{\text{LC}} = \sum_{n=0}^{N-1} \Psi\{(x(n) \geq T) \& (x(n-1) < T)\}, \quad (6)$$

式中： x 为长度 N 的信号， T 阈值始终为正值，且正好高于系统噪声，函数 Ψ 判断为真时取 1，判断为假时取 0。根据每个区域的 LC 可提取以下特征：指定时间段内最大 LC 值、最小 LC 值、平均 LC 值、标准差以及信号 LC 总和，将上述特征值组成特征向量输入到模式分类中进行识别。图 3 展示了在暴雨期间攀爬事件的监测信号，可以明显看出攀爬事件(圈出部分)在时域图中并不明显，通过计算信号的 LC 值可以很容易区分该事件与暴雨信号。将该方法用于围栏入侵检测，准确率达 95%，但该方法对于事件类型识别准确率较低，且由于实际环境影响，存在阈值选取仅凭

经验的缺点。

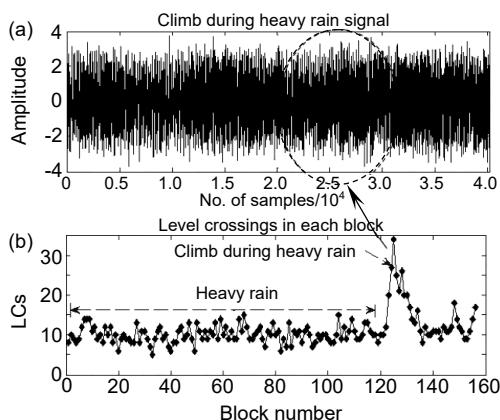


图 3 暴雨期间攀爬事件监测信号。

(a) 时域信号; (b) LC 值^[12]

Fig. 3 Signal representing a climb during torrential rain as detected. (a) Time domain representations; (b) LC vs. block number^[12]

在实际应用中，环境噪声(如风、雨等)会对入侵事件的识别造成较大影响。因此 2013 年，贾波^[13]等人借鉴了语音信号端点检测方法，通过对短时能量和过零率两种方法的分析，实现了入侵信号和环境噪声的准确区分。短时能量适用于噪声幅值较小，待检测信号与噪声幅值相差较大的情况；短时过零率则适用于噪声频率较小，待检测信号与噪声频率相差较大的情况。

2014 年，王思远^[14]等人提出了短时平均频率-时间特性进行模式识别，运用短时过零率提取信号不同频率之间的差值，结合动态时间规划(DTW)算法计算与原始信号之间的欧氏距离，筛选出最佳模型作为特征向量，实验对敲打、拉伸、摇晃、踩踏四类入侵事件

进行识别，平均识别率达 97%以上。刘琨^[15]等人提出短时能量比以及降采样法，通过提取最大值对应帧数的加权平均值来对扰动点进行定位，减少了运算时间，定位准确度达 93.47%，但由于仅提取了两种时域特征，可用于滤除自然界的无用信号，无法对入侵信号进行进一步识别。同年，朱程辉^[16]等人提出两级判别法识别入侵信号，第一级将时域信号分帧，计算短时能量和短时过零率用于判断是否有振动信号产生，第二级则提取振动信号复小波域特征，两级结合用于区分敲击栏杆、攀爬、大风、暴雨、飞鸟降落 5 种事件，其识别准确率达 90%以上。2017 年，朱程辉^[17]又在之前两级判别基础上同样引入了相空间重构，结合主成分分析方法得到贡献最多的特征组成特征向量，实验对跺脚、敲击栅栏、连续跺脚、脚踩、手拍击栅栏、连续晃动栅栏的识别准确率达 94.1%以上。2019 年，刘琨^[18]等人将信号作分段处理，然后把每段计算得到的过零率组成特征向量，实验对剪切、晃动、攀爬、敲击和无入侵 5 种事件进行信号监测，图 4 为 5 种事件的原始信号，选取 6 个过零率作为特征向量，则 5 种事件的分段过零率分布图如图 5 所示，取 60 组样本数据进行识别，用时仅 0.0680 s，识别准确率达 97.12%。

3.2 频域特征

通过提取入侵信号的时域特征来对事件分类，优点是方便、简单、响应速度快，然而缺点是易受噪声影响，波动较大。由于光纤振动信号的非平稳特点，有些入侵事件的时域特征并不好区分，特别是在检测微弱信号时会出现误报漏报情况，而不同类型的振动信号其频谱分布是存在差异的，因此通过分析入侵信号的频域特征，精度也会更高。

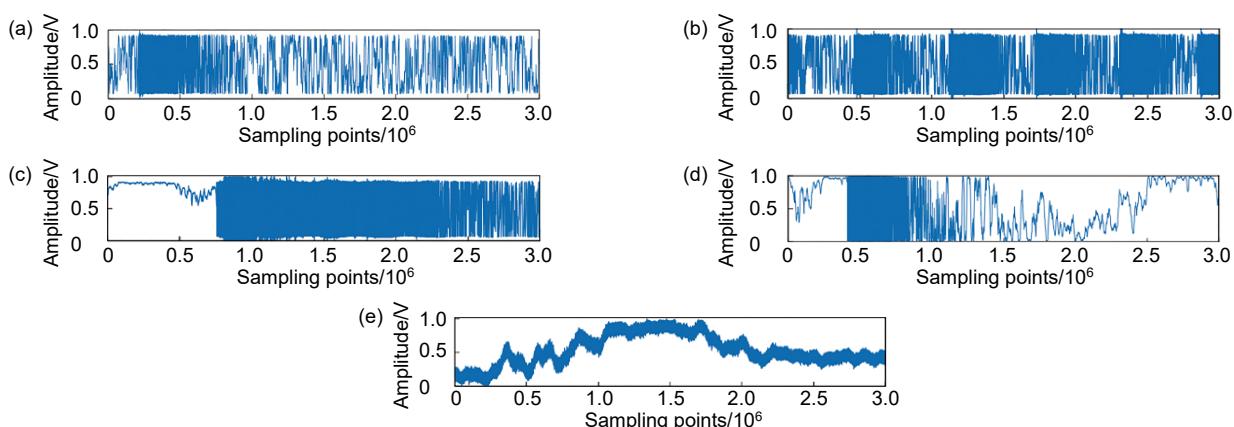
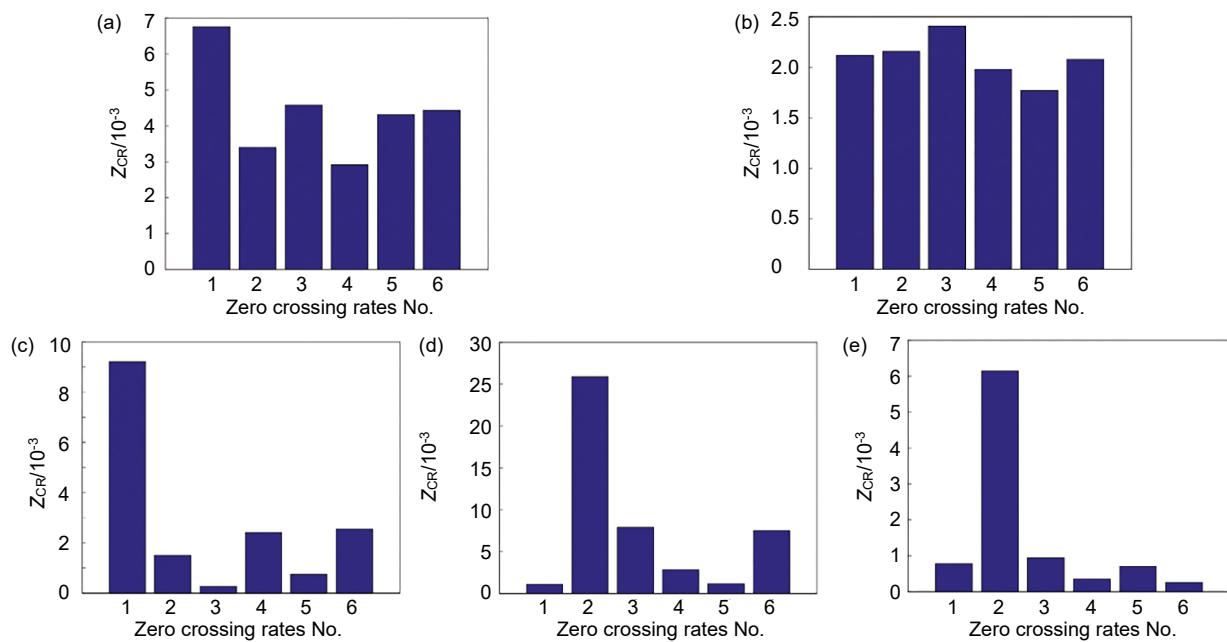


图 4 5 种事件原始信号。(a) 剪切; (b) 晃动; (c) 攀爬; (d) 敲击; (e) 无入侵^[18]

Fig. 4 Original signals of five events. (a) Cutting; (b) Wagging; (c) Climbing; (d) Knocking; (e) No intrusion^[18]

图 5 5 种事件分段过零率。(a) 剪切; (b) 晃动; (c) 攀爬; (d) 敲击; (e) 无入侵^[18]Fig. 5 Segment zero-crossing rates of five events. (a) Cutting; (b) Wagging; (c) Climbing; (d) Knocking; (e) No intrusion^[18]

2015 年, 王照勇^[19]等人采用短时能量和短时平移差分两个时域特征对信号进行初步提取, 然后再进行快速傅里叶变换(FFT), 将信号分成几个特定频段, 观察能量分布, 不同的能量分布可以代表不同类型的振动信号, 其频谱特征可作为入侵信号的特征向量。FFT 特征提取框图如图 6 所示。

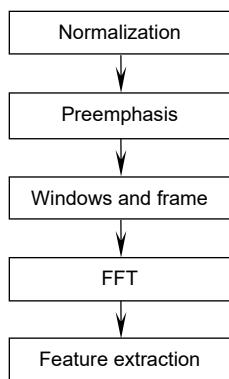


图 6 FFT 特征提取流程图

Fig. 6 FFT feature extraction flow chart

归一化后的入侵信号进行快速傅里叶变换提取的频谱特征为

$$F(k) = \sum_{n=1}^M x(n) \exp\left(-\frac{i2\pi kn}{M}\right), \quad (7)$$

对其进行多次平均作为频谱模板, 再计算未知入侵信号频谱与模板频谱的欧氏距离来区别踢墙、踹墙与原地跑三种入侵信号, 实验表明该方法的处理时间小于动态

时间规划(DTW)的 1/10。

同年, Cao^[20]等人通过 FFT 对信号进行频谱分析, 选取了特征 1(低频能量与总能量之比)、特征 2(总能量)和特征 3(峰值与均值之比)组成特征向量, 对 5 类入侵事件进行识别, 平均识别率有 92.62%。2017 年, 黄翔东^[21]等人提出一种综合特征的识别方法, 引入了全相位滤波器组, 通过对入侵信号进行广义离散傅里叶逆变换, 结合截止频率和上限频率得到全相位子 FIR 滤波器, 对应了信号不同频段的能量分布, 再与每段信号的短时过零率一起组成特征向量, 实验对攀爬、敲击、晃动、剪切四种入侵事件进行识别, 平均准确率达 88.5725%。

梅尔频率倒谱系数(MFCC)是语音信号识别的一种方法, MFCC 是从梅尔尺度频域提取的倒谱参数, 它描述了感知声音频率的非线性特征, 流程图如图 7 所示。

2016 年, 邹东伯^[22]等人借鉴了该算法, 并对比了 FFT 算法与 MFCC 算法对下雨信号和入侵信号的识别效果, 结果显示使用 MFCC 进行频谱分析的误报率要比 FFT 降低 20%, 但该文献仅通过设定报警阈值来区分下雨振动信号和入侵振动信号, 并未对入侵信号进一步分类。2018 年, 贾波^[23]等人在此基础上在围栏进行了实验, 提取信号低频部分, 选择了 12 维 MFCC 参数组成特征向量, 梅尔倒谱系数(k_{Mel})与频率 f 之间

的关系可表示为

$$k_{\text{Mel}}(f) = 2595 \times \log \left(1 + \frac{f}{700} \right) . \quad (8)$$

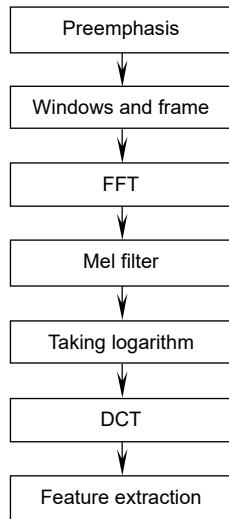


图 7 MFCC 特征提取流程图

Fig. 7 MFCC feature extraction flow chart

首先对信号分割为帧信号并加窗处理，然后通过快速傅里叶变换计算各帧信号的频谱，使用梅尔滤波器对采集到的频谱进行滤波处理，得到梅尔频谱，计再每个梅尔频谱的对数能量，得到对数频谱，最后经离散余弦变换计算得到梅尔倒谱，表示为

$$c_j = \sqrt{\frac{2}{M} \sum_{j=1}^L m_j \cos\left(\frac{\pi i}{M}(j-0.5)\right)}, i=1, \dots, I , \quad (9)$$

式中： M 是滤波器数量， L 是倒谱设定长度， I 为每帧信号中数据的数量。实验完成了对敲击、剪切、吹风、下雨四种入侵事件的识别，总识别准确率达 98.13%。

3.3 时频域特征

频域特征分析方法虽然获取了信号的内在频谱特征，但非平稳信号也是随时间而不断变化的，单纯提取频域信息只能对某一帧信号进行频谱分析，忽略了时域信息。时频域特征分析是将时间和频率结合起来分析信号的方法，这样得到的不仅是某一时间段内的频谱特性，还能得到每个频段随时间变化情况。

傅里叶变换只对信号频率分析，不能反映频率随时间变化情况，而短时傅里叶变换(STFT)的思想是将非平稳信号进行时间分割，看作许多短时平稳信号的集合。2017 年，Tejedor^[24-25]等人采用短时傅里叶变换提取每一帧信号的频带能量并归一化作为特征向量，结合高斯混合模型(GMM)的方法对大型、小型挖掘机、气锤、板式压路机四种机器活动事件进行分类，

准确率达到 55%以上。2018 年，李志辰^[26]等人对入侵信号进行短时傅里叶变换得到频谱图，结合奇异值分解得到信号的奇异值组成特征向量，实验对攀爬围栏、敲击光缆、晃动围栏三种事件进行识别，准确率在 90%以上。

2019 年，陈沛超^[27]等人将短时傅里叶变换(STFT)应用到光纤周界安防系统中。首先用特定的窗函数将时间序列分成许多时间段，对分割后的每段信号作傅里叶变换，进而得到每段时间内的频谱信息，通过改变窗函数的参数实现对时间上的遍历，以此得到近似的频率随时间的关系，可表示为

$$S(z, f) = \int_{-\infty}^{\infty} i(z) g(z-\tau) \exp(-j2\pi f z) dz , \quad (10)$$

式中： $i(z)$ 为入侵信号， $g(z-\tau)$ 为以 τ 为中心的窗函数， $\exp(-j2\pi f z)$ 是调制算子。实验对敲击、摇晃、刮风和下雨四种入侵事件进行监测，采用窗长 4800 的汉宁窗和旁瓣 0.5 的凯塞窗作 STFT，结果如图 8 所示，再通过对图像作二值化处理获取图像特征，用来作为卷积神经网络的特征向量，同时添加高斯噪声来验证方法的稳健性，实验最终准确率达 93%以上。

经验模态分解(EMD)方法是一种新的非平稳信号处理方法，最早由 Huang^[28]等人于 1998 年提出。EMD 算法将时域信号按照不同频率尺度逐级分解，得到一组具有不同特征尺度的本征模函数(IMF)，不同类型的人侵信号，得到的 IMF 分量也不相同。2015 年，Liu^[29]等人采用经验模态分解算法将人侵信号分解，由不同尺度的 IMF 组成，计算所有 IMF 分量的峭度并归一化，表示为

$$T_i = \frac{1}{n} \times \sum_{k=1}^n c_{ik}^4 , T'_i = \frac{T_i}{\sum_{i=1}^m T_i} , \quad (11)$$

式中： T_i 表示第 i 个 IMF 分量， k 表示离散点在该分量中的位置， m 表示 IMF 的分量个数。从中选取可以表征信号特性的 j 个 IMF 分量的归一化峭度构成特征向量，用 $\mathbf{T} = [T'_1, T'_2, \dots, T'_j]$ 来表示。实验对爬网、敲击、晃动、切割四种入侵事件进行监测，各采集 120 组数据并作归一化处理。图 9 表示对 4 种入侵信号作 EMD 分解后的前 8 个 IMF 分量图形， s 代表原始信号， i 表示第 i 个 IMF 分量，从图中可以看出入侵信号的峭度主要分布在前 6 个 IMF 分量中，因此选取 IMF1~IMF6 分量组成特征向量，每种事件的时域信号和归一化峰值特征向量如图 10 所示，根据 IMF 分量占比可以明显区分 4 种入侵事件，为后续事件识别打下良好基础，实验最终平均识别率在 85.75%以上。

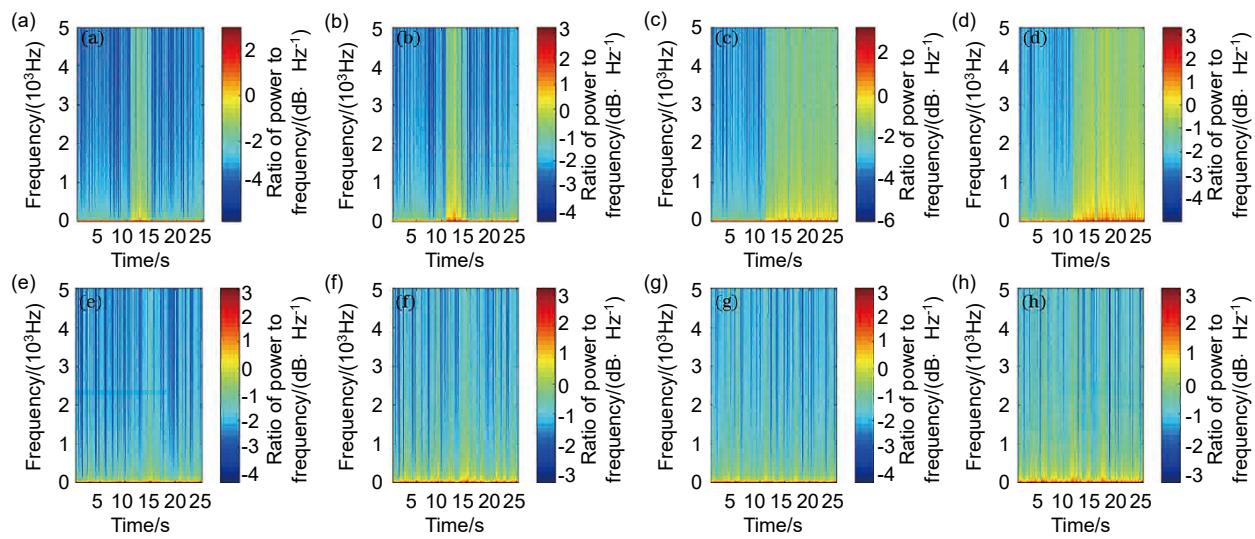


图 8 两种窗函数处理 4 种入侵事件的 STFT 图。(a), (c), (e), (g) 敲击、摇晃、刮风、下雨经过汉宁窗处理后的时间频图; (b), (d), (f), (h) 敲击、摇晃、刮风、下雨经过凯塞窗处理后的时频图^[27]

Fig. 8 STFT time-frequency diagrams of two kinds of window functions for processing four intrusion events. (a), (c), (e), (g) Time-frequency diagrams of knocking, shaking, winding, and raining signals after passing through the Hanning window; (b), (d), (f), (h) time-frequency diagrams of knocking, shaking, winding, and raining signals after passing through the Kaiser window^[27]

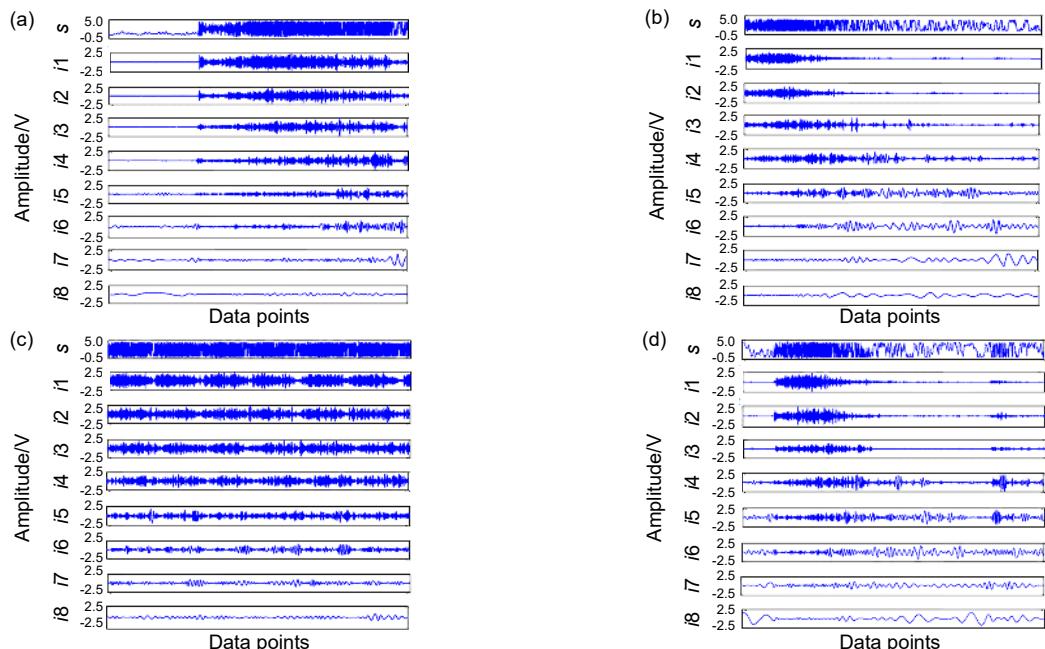


图 9 4 种入侵信号及其 IMF 分量。(a) 爬网; (b) 敲击; (c) 晃动; (d) 切割^[29]

Fig. 9 Fence invasive signals and their IMF components through EMD.

(a) EMD of climbing; (b) EMD of knocking; (c) EMD of wagging; (d) EMD of cutting^[29]

EMD 算法需要逐个求取每个 IMF 的峭度值, 会历经多次复杂的迭代, 存在模态混叠的缺点。2015 年, 蒋立辉^[30]等人提出总体平均经验模态分解(EEMD), 在计算 IMF 分量过程中加入均匀分布的白噪声用于解决模态混叠问题, 并定义了 EEMD 能量熵排除虚警信号, 选取归一化峭度值组成特征向量, 实验对攀爬、敲击

两种入侵信号以及汽车、风两种虚警信号进行识别, 识别时间大大缩短, 且准确率达 90% 以上。2018 年, 李静云^[31]等人将时域特征与 EMD 算法相结合组成两级判别模型, 短时能量和短时过阈值率作为一级预判用于判别是否有人侵信号发生, 然后通过 EMD 获得信号时频特征, 将时频熵与高低频段重心频率作为时

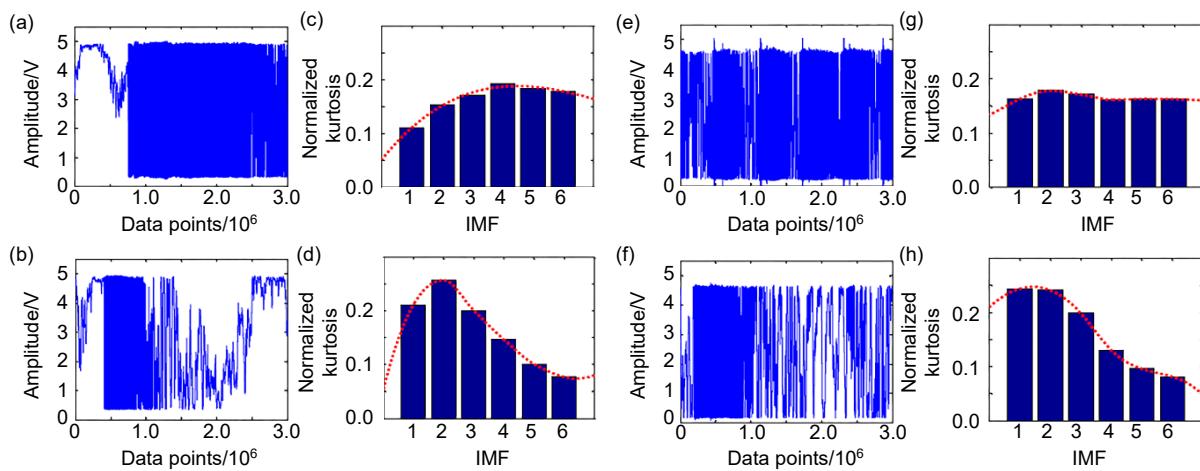


图 10 4 种入侵信号及其峰值特征向量。(a) 爬网; (b) 敲击; (c) 爬网特征向量; (d) 敲击特征向量;
(e) 晃动; (f) 切割; (g) 晃动特征向量; (h) 切割特征向量

Fig. 10 Signals and their kurtosis eigenvectors of four cases. (a) Climbing signal; (b) Knocking signal; (c) Eigenvectors of climbing;
(d) Eigenvectors of knocking; (e) Wagging signal; (f) Cutting signal; (g) Eigenvectors of wagging; (h) Eigenvectors of cutting

频特征，和时域特征一起组成特征向量，实验对无入侵、敲击和攀爬三种事件进行识别，准确率达 96.67% 上。2020 年，朱程辉^[32]等人针对 EEMD 算法自适应性不强的问题，提出自适应经验模态分解(AEMD)，采用顺序统计滤波器上下包络线均值求取 IMF，选择能量熵和峭度组成特征向量，实验对敲击、剪切、晃动、脚踩四种事件进行识别，准确率达 93.8% 以上，与 EEMD 相比时间更短。

小波变换是一种常见的信号处理方法，它可以有效提取入侵信号的时频特性。2010 年，张景川^[33]等人把小波变换应用到油气管道检测中，提取出的小波能量谱和小波信息熵组成特征向量，实验对管道泄漏、人工挖掘、机械挖掘三种入侵事件进行识别，准确率达 98.5%。2013 年，李彦^[34]等人则在此基础上，把小波能量信息熵归一化处理，小波信息熵定义为

$$E_n = -\sum_k p_{jk}^2 \log p_{jk}^2, \quad (12)$$

式中： E_{jk} 表示各频段能量， p_{jk} 用于评价信号不确定度。再对得到的信息熵归一化处理，即 $e = (E - E_{\max}) / (E_{\max} - E_{\min})$ ，得到归一化后的小波能熵。不同的入侵信号，熵值也不相同，实验据此对敲击光缆、爬光缆、大风和环境噪声四种入侵事件进行识别，准确率达 80% 以上。2015 年，Wu^[35]等人利用正交镜像滤波器组(QMFs)对信号进行 dB6 小波分解，把相对能量分布作为特征向量，对无入侵、人为入侵、拍手三种事件识别，准确率达 89.19%。

由于小波分解存在无法分辨高频信号的缺点，2014 年，喻晓芒^[36]等人先用小波阈值收缩去噪法滤除

噪声，然后采用小波包分解对信号进行处理，将其分成了三层，把所有的频带能量值作成特征向量，实验对行人、汽车、小动物三种入侵事件识别，平均准确率达 96.9%。2015 年，李凯彦^[37]等人提出了双门限判定法和小波包分解相结合的复合特征提取方法，首先检查信号的包络幅度是否大于所设门限来滤除干扰噪声段，然后利用最大能量和信噪比挑选出有效特征段，再对信号进行小波包分解提取能量谱，将小波包能量谱、有效信号持续时间与衰减率组成特征向量，实验对无扰动、大雨、大风、剪网、攀爬 5 种事件进行识别，平均识别率达 99.5967%。

2017 年，Wu^[38]等人针对输油管道中的振动入侵信号，对比研究了小波分解和小波包分解的特征提取方法，如图 11 所示。实验对背景噪声、人工挖掘、车辆经过 3 种入侵事件进行 3 层小波分解和小波包分解，分别得到 5 个频段和 8 个频段。三种事件的 WE 和 WPE 分布曲线如图 12、图 13 所示，从图中可以明显看出 WE 分布曲线人工挖掘事件的两个频段能量与背景噪声几乎重叠，而 WPE 分布曲线图可以清晰分辨三种事件的不同频段能量分布趋势，说明 WPE 是一种更好的频谱分析方法。实验最后结合神经网络对事件分类，小波分解的平均准确率为 91.1%，小波包分解的准确率为 94.4%，高于小波分解算法。

2019 年，彭宽^[39]等人采用了时域特征和小波包分解相结合的方法，首先用正交小波分解对振动信号进行去噪处理，然后提取时域特征，包括平均片段间隔、片段长度和 PAR 特征，再通过小波包分解提取信号不

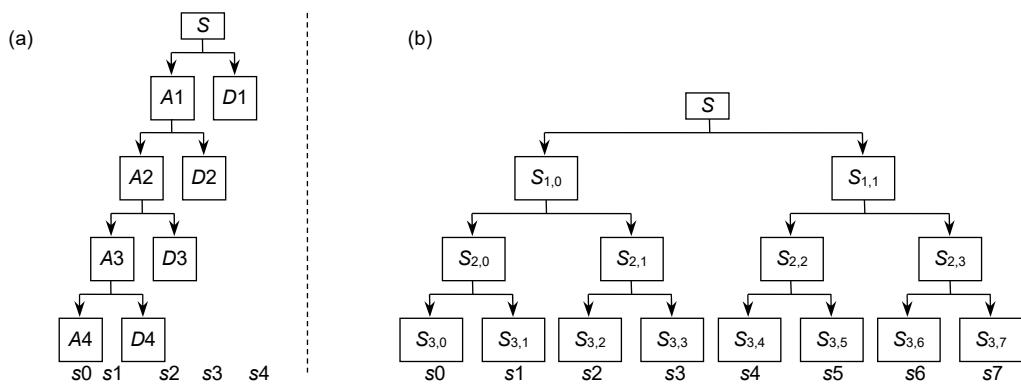
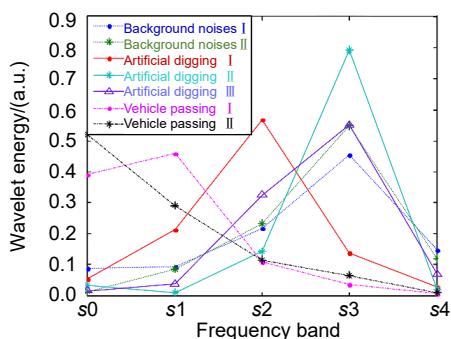


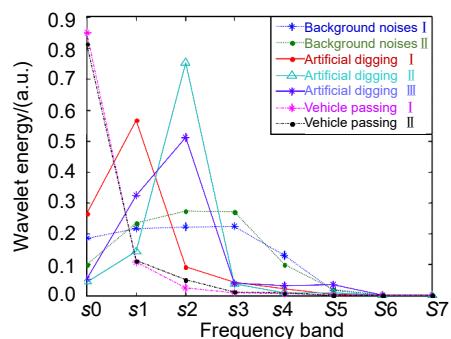
图 11 多尺度分解树。(a) 小波分解; (b) 小波包分解

Fig. 11 Multi-scale decomposition tree. (a) Wavelet decomposition; (b) Wavelet packet decomposition

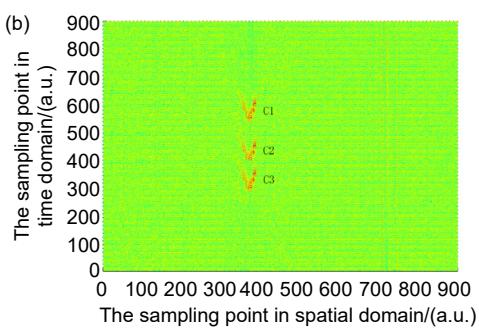
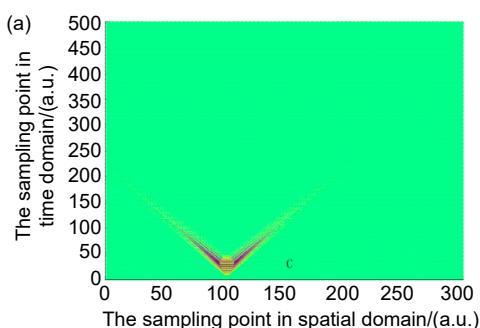
图 12 三种事件 WE 分布^[38]Fig. 12 WE distribution for three typical events^[38]

同频段能量分布，两者结合组成复合特征向量，对行人、自行车、拍击、剪切四种入侵事件进行识别，准确率达 98.33%。

除了对信号的时间-频域特性进行分析之外，随着图像处理技术的发展，出现了提取入侵信号时间-空间域特征用于信号的分类。2015 年，Sun^[40]等人提出脉冲成像形态特征提取方法，通过采集振动信号随时间变化的瀑布图，利用阈值分割及噪声处理方法得到入侵事件影响区域，将区域的幅值、大小、形状、间隔等特征组成特征向量。入侵事件用瀑布图可表示为一

图 13 三种事件 WPE 分布^[38]Fig. 13 WPE distribution for three typical events^[38]

个斑点，不同类型事件的斑点形状、大小都不一样，图 14 为车辆经过的仿真信号 C 和实验信号 C1、C2、C3，可以看出两者之间虽然存在差异，但基本相同。实验结合相关向量机对行走、挖掘、车辆经过三种入侵事件识别，准确率达 97.8%。2019 年，陈沛超^[27]等人采用凯塞窗函数对入侵信号作短时傅里叶变换得到时频图，然后对图像作二值化处理得到图像信息，将其组成特征向量，实验对敲击、摇晃、刮风、下雨四种事件进行识别，同时添加高斯噪声来验证方法的稳健性，识别准确率达 93.83%以上。

图 14 (a) 车辆经过仿真信号; (b) 车辆经过实验信号^[40]Fig. 14 (a) Calculated signal of vehicle passing; (b) Experimentally measured signal of vehicle passing^[40]

4 入侵信号分类算法

对入侵信号提取时频域特征组成特征向量后，下一步即对信号进行分类。分类包括两种，无监督学习和有监督学习。无监督学习即入侵信号数据集没有标签，缺乏足够的先验知识，通常采用聚类的方法进行识别，常见的算法有 K-means 算法、DBSCAN 算法、高斯混合模型(GMM)等；有监督学习即数据集带有标签，可以通过训练学习到一个将数据映射到标签的函数，常见的算法模型有向量机(SVM)、人工神经网络(ANN)、卷积神经网络(CNN)等。

4.1 聚类

无监督学习中最典型的为聚类。在模式识别中，聚类就是按照某个标准将一个数据集分割成不同的类或簇，使得同一个簇内全部数据相似度尽可能大，不同簇之间相似度尽可能小。通常基于划分的方法有 k-means，基于密度的方法有 DBSCAN(density-based spatial clustering of applications with noise)，基于模型的方法有高斯混合模型(GMM， Gaussian mixture models)。

2015 年，王照勇^[19]等人提出可以快速响应的频谱欧氏距离法(EDFS)，首先对采集到的信号作预处理，提取频域特征，选择可表征不同类型入侵事件特征的信息进行平均，得到最终的特征向量，以此作为参考模板，然后挑选待测入侵信号的频谱信息与全部模板做对比，用欧氏距离作为判决依据，公式为

$$d_E = \left\{ \sum_{k=1}^M [F_{\text{signal}}(k) - F_{\text{model}}(k)]^2 \right\}^{1/2}, \quad (13)$$

式中： F_{signal} 和 F_{model} 分别是待测信号频谱和参考模板频谱， M 为频谱序列长度。对比不同模板可给出不同欧氏距离值，与设定阈值相比可实现入侵事件的识别。实验对踢墙、踹墙和原地跑三类事件与动态时间规划(DTW)算法做对比，结果 DTW 识别事件需要 5.05 s，而 EDFS 仅需 0.11 s。2017 年，Tejedor^[25]等人提取信号归一化频域能量，使用上下文特征提取方法选取不同时间长度，采用 3 层 MLP 输出串联特征向量，将后验概率最高的类用于系统性能评估，对每个时间长度的数据执行 GMM 模式分类，最终找到 GMM 模型的最佳拟合结果。对入侵事件的识别准确率为 54.92%。

2020 年，Suleyman^[41]等人提出一种数据挖掘方法监测地下隧道入侵事件，第一步对数据进行时域分析确定活跃信道，第二步对数据进行空间分析确定当前活动信道，第三步将两个数据集组合成二维矩阵用于

标记可疑信道，利用 DBSCAN 算法对可疑信道进行检测，分离高密度报警区域和低密度报警区域，消除误报。图 15 为该算法分类原理，最后确定由信道组成的群集。实验验证了利用 DBSCAN 算法在隧道入侵检测中的可靠性，解决了多点同时扰动情况定位与时间判断问题。该方法减小了噪声影响，提高了事件定位的精度，但仅用于事件的定位，并未对入侵事件作进一步分类。

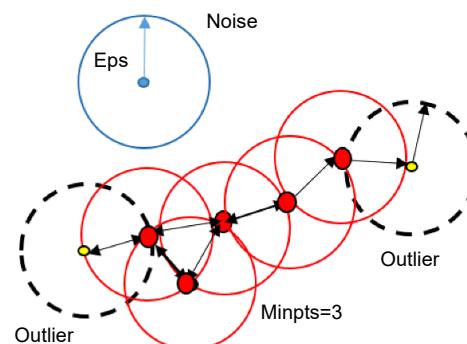


图 15 DBSCAN 算法的核心点和边缘点^[41]

Fig. 15 DBSCAN core and outlier points^[41]

无监督学习相关算法可用于入侵事件报警，且能够减少误报率，方法简单、响应速度快，但由于其本身算法的局限性，针对入侵事件进一步分类效果并不好。有监督学习相关算法因有训练集的存在，可以通过采集大量数据进行学习，再对入侵事件进行判别，大大提高了识别准确率，因此光纤分布式入侵检测更多采用的是有监督学习算法模型。

4.2 向量机

支持向量机(SVM)是 Vapnik^[42]等人提出的统计学习理论方法，在模式识别中，支持向量机本质上是解决二分类问题的算法，但是在光纤入侵事件识别系统中大多遇到的是多分类问题，因此需要对其进行改进。通常解决思路有一对一、一对多、有向无环图以及决策树法。

2009 年，Qi^[43]等人对信号进行 FFT 变换，提取不同区间的频率特征，把功率谱密度^[44-45]作为特征，结合主成分分析法(PCA)和支持向量机(SVM)对入侵事件识别，准确率达到 88.9%。2015 年，蒋立辉^[30]等人针对 IMF 分量峭度值组成的特征向量，采用两个基本的二值分类器，对于线性不可分的样本集 $(x_i, y_i), i=1, 2, \dots, n, x_i \in R^n, y \in \{-1, +1\}$ ，映射到高维空间后，需要求解的最优超平面的目标函数表示为

$$\max \left\{ \sum_{i=1}^n \alpha_i - \frac{1}{2} \sum_{i,j=1}^n \alpha_i \alpha_j y_i y_j [\Phi(x_i) \cdot \Phi(x_j)] \right\}, \quad (14)$$

式中: α_i 为拉格朗日系数, $\Phi(x)$ 表示非线性映射函数。实验将两个 SVM 组成双重支持向量机用于识别敲击光缆、攀爬围栏、虚警信号 3 种入侵事件, 识别率达 92% 以上。2017 年张俊楠^[46]等人将二叉树结构与支持向量机相结合, 设计了四个分类器实现了对踩压、敲击和浇水三个事件的识别, 准确率达 94% 以上。

相关向量机(RVM)是 Tipping^[47]基于贝叶斯学习理论提出的一种新的机器学习算法。与支持向量机相比, RVM 所需训练样本数据少、泛化能力强, 同时克服了 SVM 规则化系数确定困难、核函数受 Mercer 条件限制等局限性问题^[48]。

2014 年, 孙茜^[49]等人采集小波能谱和小波信息熵作为特征向量, 由相关向量机对管道安全振动信号进行识别, 其 RVM 的分类模型为

$$y(x, w) = \sum_{i=1}^N \omega_i K(x, x_i) + \omega_0 = \Phi w, \quad (15)$$

式中: N 为数据长度, w 是权值向量, Φ 是大小为 $N \times (N+1)$ 的矩阵。为了避免过拟合, 对权值向量 w 进行约束, 通过求取超参数 α 重新估价权重的后验均值, 反复迭代直至满足收敛, 根据最大后验权值输出 RVM 模型。图 16 为有向无环图实现三类事件分类流

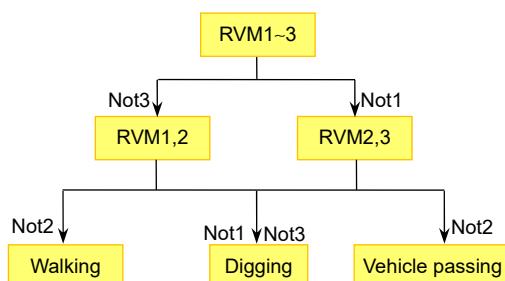


图 16 有向无环图 RVM^[49]
Fig. 16 Directed acyclic graph of RVM^[49]

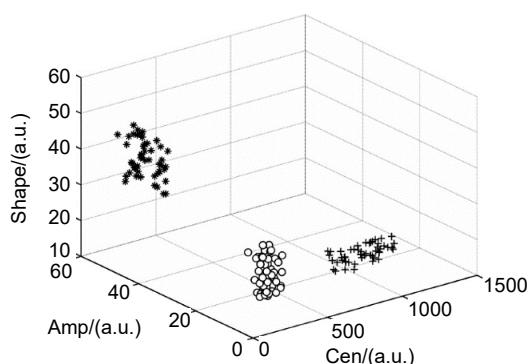


图 17 三类事件特征分布^[40]
Fig. 17 Feature distribution of three events^[40]

程。结合小波分析实现了行走、挖掘和大车路过三种事件的分类识别, 识别准确率达 90% 以上。

2015 年, 孙茜^[40]又提出一种基于形态学的特征提取方法, 把形态特征作为特征向量, 分类算法采用了相关向量机, 核函数选用高斯径向基核函数, 通过一对多分类器对三类入侵事件分类, 分类结果如图 17 所示, 平均识别率达 97.8%。

4.3 神经网络

人工神经网络(ANN)是受人脑神经系统的工作方式启发而构造的数学模型, 神经元是构成神经网络的基本单元, 多个神经元一起协作便组成了神经网络。在光纤入侵信号检测领域中, 输入为入侵信号的特征向量, 每个神经元都有相对应的权重。对输入加权求和, 再通过激活函数, 最后输出判断结果。

BP 神经网络是一种典型的多层前馈网络, 它是采用了由 Rumelhart^[50]等人提出的误差反向传播算法(back propagation), 利用输出层计算得出的误差逐层反向修改每层神经元权值, 当输出层的误差小于设定阈值时停止计算。典型结构如图 18 所示。

2014 年, 李小玉^[51]等人提出了一种基于时间序列奇异谱特征的检测方法, 将信号能量在状态空间中的分布情况作为特征向量, 结合 BP 神经网络对入侵事件识别, 准确率高于 90%。同年, 谢鑫^[52]等人以自适应动态阈值作为特征向量, 设计了一个包含 5 个神经元的隐藏层的 BP 神经网络, 实验对小动物、人为攀爬、长棍滑动、温度上升四种事件识别率达 96.83%。2015 年, Wu^[35]等人以小波分解提取频谱分布作为特征向量, 结合 BP 神经网络对入侵事件分类, 准确率达 89.19%。

2017 年, 沈隆翔^[53]等人提取了入侵信号的形态学特征组成特征向量, 结合 BP 神经网络进行分类识别。

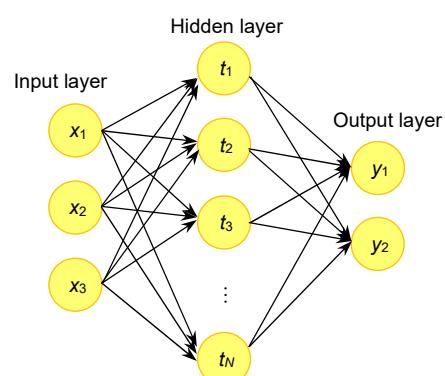


图 18 三层 BP 神经网络结构
Fig. 18 Three-layer BP neural network structure

首先计算在 Sigmoid 激活函数作用下的输出 O_i ，根据实际输出与期望值求出误差，然后分别对隐藏层到输出层、输入层到隐藏层的权值 V_{ij} 与 W_{ij} 进行校正，校正公式为

$$\begin{cases} V_{iju} = V_{ij} - [A\Delta V_{ij} + B(Y_i - d_i)O_j] \\ W_{iju} = W_{ij} - \left(a\Delta W_{ij} + b \frac{\partial E}{\partial W_{ij}} \right) \end{cases}, \quad (16)$$

式中： A 和 B 为隐藏层到输出层的重量因子， a 和 b 为输入层到隐藏层的重量因子。不断重复上述过程，直至误差达到允许范围内即停止训练。在实验条件下实现了汽车驶过振动、人为扰动和 PZT 振动三种事件的识别，准确率达 97.78%。

径向基神经网络(RBF)同样是一种前馈网络，包含隐含层和输出层，与 BP 神经网络相比，RBF 在隐藏层使用径向对称的径向基函数来对输入数据实现非线性变换，并采用局部逼近的方法，比 BP 神经网络的收敛速度更快。

2015 年，Liu^[29]等人提取 IMF 分量峭度值作为特征向量，结合 RBF 神经网络对入侵事件分类，识别率在 85.75% 以上。2017 年，黄翔东^[21]等人将 RBF 神经网络作为分类识别算法，把特征向量输入到神经网络中，输出的判决值表示为

$$Z_p = \sum_{i=1}^h \omega_{i,p} \cdot \rho(F, c_i), p = 1, \dots, P, \quad (17)$$

式中： h 为隐藏层节点个数， c_i 和 $\omega_{i,p}$ 分别是第 i 个隐藏层节点对应的中心和权重； $\rho(F, c_i)$ 是径向基函数，定义为样本数据 F 到数据中心 c_i 之间欧氏距离的单调减函数， σ_i 是该节点函数围绕中心半径，公式为

$$\rho(F, c_i) = \exp \left[-\frac{\|x - c_i\|}{2\sigma_i^2} \right]. \quad (18)$$

总共有 P 个人侵事件，将未知入侵事件的特征向量通过 RBF 神经网络，设置其对应的入侵事件输出为 1，其余为 0，然后不断优化内部参数，包括权重 $\omega_{i,p}$ 、中心 c_i 以及方差 σ_i ，在输出层得到 P 个输出，其中最接近 1 的输出被判定为该事件类型。通过数据采集和分析，最终实现了攀爬围栏、敲击光缆、晃动和盗剪四种入侵事件的识别，平均识别准确率达 88.5725%。

4.4 深度学习

近年来，随着模式识别技术的不断成熟，深度学习的应用领域得以拓宽。为了让模型自动学习出好的特征表示，提升准确率，人们开始构建具有一定“深

度”的模型，神经网络可以很好地解决贡献度分批问题，所以各种具有深度的神经网络得以发展起来。

卷积神经网络(CNN)是深度学习中最具有代表性的，它是一种具有局部连接、权重共享等特性的深层前馈网络，目前主要应用于图像识别和视频分析等领域，并且准确率远远超出其他类型的神经网络。卷积神经网络主要包括输入层、卷积层、汇聚层、全连接层和输出层，典型结构如图 19 所示。

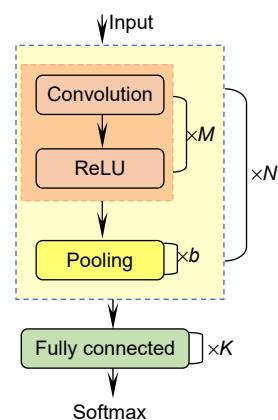


图 19 卷积神经网络典型结构

Fig. 19 Typical structure of CNN

2017 年，Aktas^[54]等人采用短时傅里叶变换(STFT)对信号提取时频域信息，并进行相位补偿，以时频图为特征结合卷积神经网络(CNN)对步行、挖掘、大风、设备噪声进行识别分类，准确率达 93% 以上。

2018 年，Xu^[55]利用短时傅里叶变换得到入侵信号的时频特征，将不同类型的振动信号转换成频谱图以获取更丰富的信息，如图 20 所示，再输入到 CNN 网络中，在卷积层提取一个局部区域的特征，不同的卷积核相当于不同的特征提取器，然后对图像进行卷积运算，得到特征映射 Y^p ：

$$\begin{cases} Z^p = W^p \otimes X + b^p = \sum_{d=1}^D W^{p,d} \otimes X^d + b^p \\ Y^p = f(Z^p) \end{cases}, \quad (19)$$

其中 $f(\cdot)$ 选用 ReLU 函数作为激活函数。之后经过汇聚层进行特征选择，降低特征数量，避免过拟合。池化层也可以看做是一个特殊的卷积层，卷积核大小为 $K \times K$ ，步长为 $S \times S$ ，卷积核选择 mean 函数。最后经过全连接层和 Softmax 层得到输出结果，实现了对挖掘、行走、车辆行驶和破坏四种入侵事件的识别分类，准确率达 90% 以上。

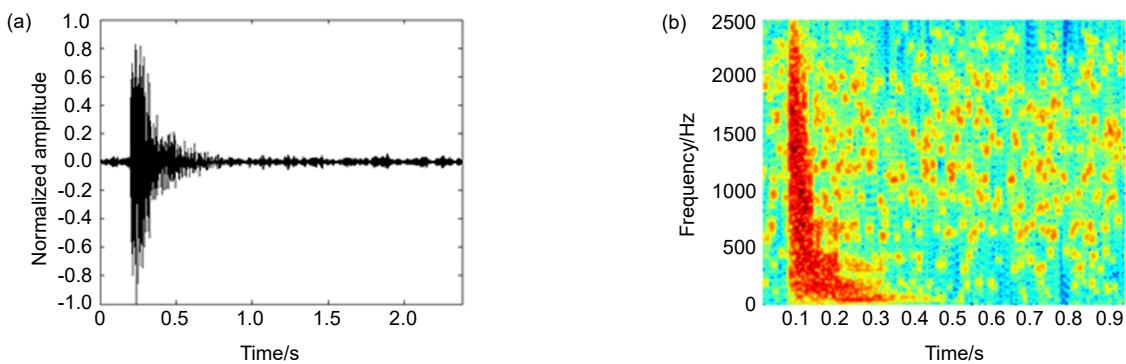


图 20 谱减法后的振动信号。(a) 去噪后敲击信号; (b) 去噪后敲击信号频谱分布^[55]
Fig. 20 The effect of spectral subtraction on the vibration signal. (a) The time-domain waveform of the knocking signal after noise reduction; (b) The spectrogram of the knocking signal after noise reduction^[55]

2019 年, Shi^[56]等人直接利用瀑布图进行简单的带通滤波和灰度变换预处理。为了防止运算量过大、精度低以及过拟合问题, 选择 GoogleNet 的 Inception-v3 结构为基础, 提出了一种新的小型 CNN 结构, 如图 21 所示。经过 CNN 算法处理后即可实现五类入侵事件的分类, 分类混淆矩阵如图 22 所示, 准确率达 96.67%。

由于使用二维卷积对图像特征处理时, 会存在数据量大、处理速度慢、效率低等缺点。2019 年, Wu^[6]等人提出了一维 CNN 网络, 输入特征向量为一维矢量, 在卷积层中, 用 $1 \times M$ 的一维卷积核替代大小为 $N \times M$ 的二维卷积核, 同时选择支持向量机作为卷积神经网络的 Softmax 层, 处理速度达 0.0027 s, 识别准确率达 98.19%。同年, 吴俊^[57]等人在一维 CNN 基础上, 提出多尺度一维卷积神经网络(MS 1-D CNN), 直接对预处理后的入侵信号进行多尺度卷积, 获取的不同尺度的时频特征组成特征向量直接进入 CNN 网络进行训练与识别, 实验同时对比了 2-D CNN 和 1-D CNN 两种分类算法, 处理速度更快, 且识别准确率达 96.59%。

深度学习促进了神经网络模型的发展, 不仅出现了上百层的卷积神经网络, 而且还出现了许多其他类型的神经网络。

生成对抗网络(GAN)是 Goodfellow^[58]等人提出的一种深度生成模型。在 GAN 中, 存在两个对抗训练的网络: 一个是判别网络, 判断样本来自真实数据还是由生成网络产生; 一个是生成网络, 生成判别网络无法区分来源的样本, 两者目标相反, 最后生成符合真实数据分布的样本。GAN 网络的一个具体模型如图 23 所示。

2018 年, Shiloh^[59]等人开发了一种计算机模拟生成数据集的方法, 提取信号的时间空间信息组成图像作为特征, 并结合 GAN 网络模拟真实入侵事件的数据。首先获取一小部分实际入侵信号, 通过 GAN 网络生成样本, 得到一个与输入信号相似的结果, 然后交替迭代, 最终, GAN 网络可以估测出样本数据的分布情况。将判别网络和生成网络合并, 则整个 GAN 网络的目标函数可以看做 Minmax Game:

$$\min_{\theta} \max_{\phi} [E_{x \sim p(x)} [\log D(x; \phi)] + E_{x \sim p_{\theta}(x)} [\log(1 - D(G(z; \theta); \phi))]] \quad (20)$$

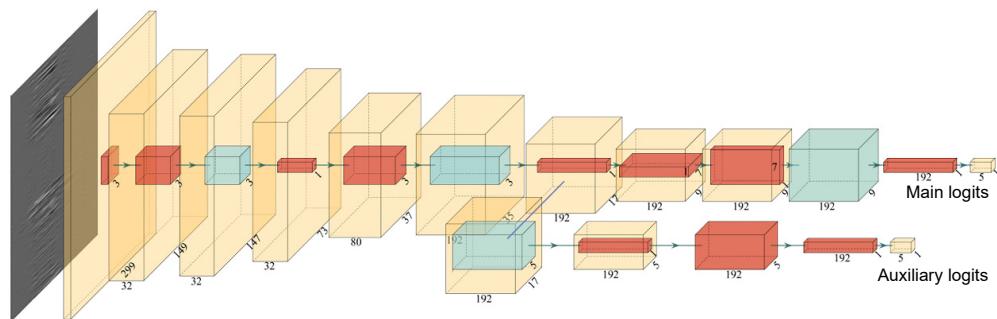


图 21 优化后的 CNN 网络结构(红色方块表示卷积运算, 蓝色方块表示池化运算)^[56]
Fig. 21 The optimized network structure (the red cube denotes convolution operation and the blue cube denotes pooling operation)^[56]

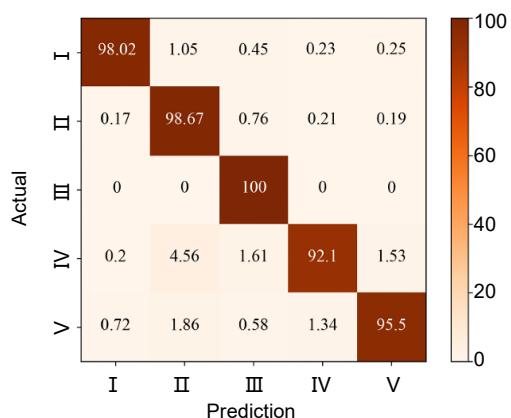
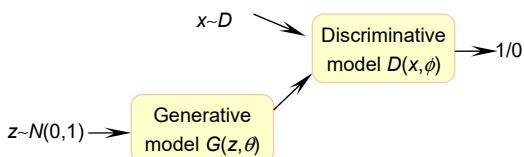
图 22 5类事件混淆矩阵^[56]Fig. 22 Confusion matrix of five events' classification^[56]

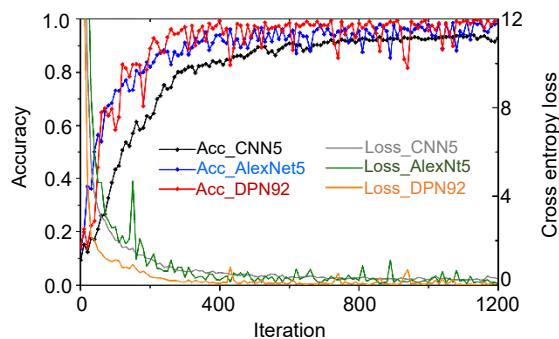
图 23 生成对抗网络流程图

Fig. 23 GAN flow chart

由于 GAN 的训练比较难，往往不太稳定，因此需要平衡两个网络的能力。在训练数据有限的情况下，如果判别网络能力太强，会导致过拟合，从而模型无法收敛，但是判别能力也不能太弱，否则针对生成网络也无法得到满意的结果。实验对行走和环境噪声进行了数据拓展与识别，准确率达 94%。

2019 年，Li^[60]等人采用 CFAR 自适应设定阈值，结合基于 Dropout 的随机配置网络(SCN)对挖掘、敲击、电钻三种入侵事件进行识别，同时和传统人工神经网络作比较，时延降低了约 2.5 倍，识别率达 94.67%。

同年，Cai^[61]等人提出 92 层双路径网络(DPN)用

图 24 不同训练算法测试集的准确率和损失值^[61]Fig. 24 Accuracy and loss of testing datasets at different training algorithms^[61]

于事件识别，首先提取信号的空间-时频谱三维图，对幅度作归一化处理，然后将图片转换为三通道 RGB 图像，再将图像大小调整为 224 pixels×224 pixels 作为 DPN 的样本，之后即可使用图像识别方法进行后续处理。为验证系统性能，引入了 5 层 CNN 网络和 AlexNet 用作对比，图 24 显示了 3 种深度学习算法对于测试集损失值和准确率的变化趋势，可见 DPN92 精度最高，鲁棒性强，同时采用图形处理单元(GPU)加快训练速度，保证了系统实时性，实验对 7 种入侵事件进行识别，准确率达到了 97%。

在前馈神经网络中，信息传递是单向的，每次的输入都是独立的，并且使用前馈神经网络处理时序数据时，输入和输出的维数都是固定的，这也是一个局限性。循环神经网络(RNN)是一种具有短期记忆能力的神经网络，它可以接受自身的信息，形成具有环路的网络结构。长短期记忆网络(LSTM)是循环神经网络的一个变体，它通过引入门控机制有效解决了简单 RNN 的梯度爆炸或消失问题。

2020 年，Chen^[62]等人为了减少计算复杂度，提高神经网络处理信息能力，将注意力机制引入 LSTM 网络中，形成新的 ALSTM 神经网络，通过自上而下的信息选择机制来过滤大量无关信息，先用谱减法对信号去噪处理，然后将短时能量、短时过零率和 MFCC 组成的特征向量输入进网络，实验中的 LSTM 网络的循环单元结构如图 25 所示。

在 LSTM 网络中引入了一个新的内部状态 $c_t \in \mathbb{R}^D$ 专门进行线性循环信息传递，同时输出信息给隐藏层的外部状态 $h_t \in \mathbb{R}^D$ 。可用公式表达为

$$\begin{cases} c_t = f_t \times c_{t-1} + i_t \times \tanh(W_c \cdot X + b_c) \\ h_t = o_t \times \tanh(c_t) \end{cases}, \quad (21)$$

式中： f_t 、 i_t 、 o_t 为三个门(gate)来控制信息传递路径。

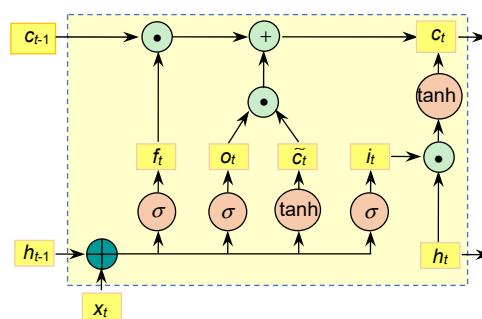


图 25 LSTM 网络的循环单元结构

Fig. 25 Cyclic unit structure of LSTM network

实验对挖掘、步行、车辆通过、下雨四种入侵事件进行分类识别，准确率达 94.3%。

同年，Li^[63]等人提出一种卷积神经网络和循环神经网络相结合的卷积长短期记忆神经网络（ConvLSTM），CNN 提取空间特征，LSTM 提取时间特征，两者组成时空域特征向量，实验对高铁轨道附近爬墙、破墙、穿越铁网三种入侵事件进行识别，在强背景噪声下识别率为 85.6%。表 1 为近几年分布式光纤入侵检测系统较为重要的模式识别技术总结。

5 总 结

本文系统叙述了基于 DAS 系统的模式识别技术中应用的主要方法。从特征提取和分类算法两大方面进行介绍，可以看出针对不同应用场景以及不同种类的扰动信号，选择合适的特征提取方法与分类算法是尤为重要的。目前大多数对于入侵信号识别分类的研究虽然识别率较高，但仍处于实验阶段，对于实际应用环境中的入侵事件识别率较低。除此之外，入侵信号的检测对响应速度的要求也不断上升。因此，如何简单、高效、准确地对振动信号识别分类成为目前 DAS 系统模式识别技术的发展难题。近年来，随着深度学习领域的快速发展，神经网络算法不断被优化，这也使得信号识别的准确率不断提升，相信基于 DAS 系统的模式识别技术未来必将会在周界安防、管道检测等

领域中发挥更加重要的作用与潜力。

参考文献

- [1] Juarez J C, Maier E W, Choi K N, et al. Distributed fiber-optic intrusion sensor system[J]. *J Light Technol*, 2005, **23**(6): 2081–2087.
- [2] Pan Z Q, Liang K Z, Ye Q, et al. Phase-sensitive OTDR system based on digital coherent detection[J]. *Proc SPIE*, 2011, **8311**: 83110S.
- [3] Juarez J C, Taylor H F. Field test of a distributed fiber-optic intrusion sensor system for long perimeters[J]. *Appl Opt*, 2007, **46**(11): 1968–1971.
- [4] Lindsey N J, Martin E R, Dreger D S, et al. Fiber - optic network observations of earthquake wavefields[J]. *Geophys Res Lett*, 2017, **44**(23): 11792–11799.
- [5] Cedilnik G, Hunt R, Lees G. Advances in train and rail monitoring with DAS[C]//Proceedings of the 26th International Conference on Optical Fiber Sensors, 2018: ThE35.
- [6] 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]. *J Light Technol*, 2019, **37**(17): 4359–4366.
- [7] Johannessen K, Drakeley B, Farhadroushan M. Distributed acoustic sensing-a new way of listening to your well/reservoir[C]//SPE Intelligent Energy International, Utrecht, the Netherlands, 2012: 149602.
- [8] Bao X Y, Zhou D P, Baker C, et al. Recent development in the distributed fiber optic acoustic and ultrasonic detection[J]. *J Light Technol*, 2017, **35**(16): 3256–3267.
- [9] Muanenda Y. Recent advances in distributed acoustic sensing based on phase-sensitive optical time domain reflectometry[J]. *J Sens*, 2018, **2018**: 3897873.
- [10] Adeel M, Shang C, Zhu K, et al. Nuisance alarm reduction: using a correlation based algorithm above differential signals in direct

表 1 DAS 模式识别技术发展历程

Table 1 The development of DAS pattern recognition technology number

	Time	Researchers	Feature extraction	Classification algorithm	Recognition rate/%
1	IEEE,2009	Qi,et al.	FFT+PSD	PCA+SVM	88.9
2	IEEE,2010	Mahmoud,et al.	LC	ANN	
3	APS,2014	Wu,et al	SSA	BP	> 90
4	ACPC,2015	Cao,et al	FFT	SVM	92.62
5	JLT,2015	Wu,et al	WD	BP	89.19
6	JLT,2015	Liu,et al	EMD	RBF	85.75
7	Sensors,2015	Sun,et al	MFE	RVM+GPU	97.8
8	JLT,2016	Tejedor,et al	STFT	GMM	> 55
9	PS,2017	Wu,et al	WPD	ANN	94.4
10	ISOP,2017	Aktas.M,et al.	STFT	2-D CNN	> 93
11	ICOFS,2018	Shiloh,et al.	RGB	GAN	94
12	JLT,2019	Wei,et al	CFAR	SCN	94.67
13	JLT,2019	Wu,et al	WPD	1-D CNN+SVM	96.59
14	OE,2019	Wang,et al	RGB	DPN+GPU	97
15	MOTL,2020	Chen,et al	STE+ZCR+MFCC	ALSTM	94.3
16	OE,2020	Li,et al	STW	ConvLSTM	85.6

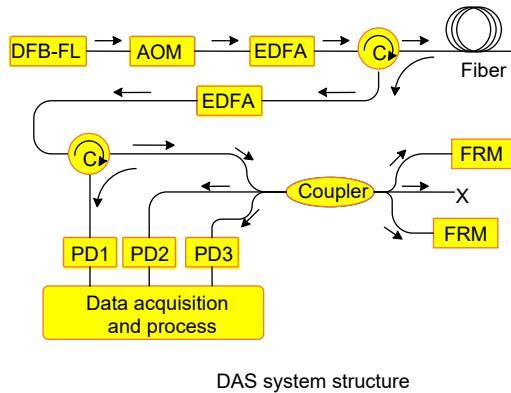
- detected phase-OTDR systems[J]. *Opt Express*, 2019, **27**(5): 7685–7698.
- [11] Rao Y J, Wu M, Ran Z L, et al. A fiber-optic intrusion alarm system based on quasi-distributed FBG sensors[J]. *Chin J Sens Actuators*, 2007, **20**(5): 998–1002.
饶云江, 吴敏, 袁曾令, 等. 基于准分布式 FBG 传感器的光纤入侵报警系统[J]. 传感技术学报, 2007, **20**(5): 998–1002.
- [12] Mahmoud S S, Katsifolis J. Elimination of rain-induced nuisance alarms in distributed fiber optic perimeter intrusion detection systems[J]. *Proc SPIE*, 2009, **7316**: 731604.
- [13] Wu H Y, Jia B, Bian P. Study on endpoint detection technology based on fiber perimeter security system[J]. *Chin J Sci Instrum*, 2013, **34**(4): 743–748.
吴红艳, 贾波, 卞虎. 光纤周界安防系统端点检测技术的研究[J]. 仪器仪表学报, 2013, **34**(4): 743–748.
- [14] Wang S Y, Lou S Q, Liang S, et al. Pattern recognition method of fiber distributed disturbance sensing system based on M-Z interferometer[J]. *Infrared Laser Eng*, 2014, **43**(8): 2613–2618.
王思远, 娄淑琴, 梁生, 等. M-Z 干涉仪型光纤分布式扰动传感系统模式识别方法[J]. 红外与激光工程, 2014, **43**(8): 2613–2618.
- [15] Liu K, He C, Liu T G, et al. An endpoint detection method for fiber perimeter security system[J]. *J Opto Laser*, 2014, **25**(11): 2136–2140.
刘琨, 何畅, 刘铁根, 等. 一种用于光纤周界安防系统的端点检测方法[J]. 光电子·激光, 2014, **25**(11): 2136–2140.
- [16] Zhu C H, Qu Y Z, Wang J P. The vibration signal recognition of optical fiber perimeter based on time-frequency features[J]. *Opto-Electron Eng*, 2014, **41**(1): 16–22.
朱程辉, 瞿永中, 王建平. 基于时频特征的光纤周界振动信号识别[J]. 光电工程, 2014, **41**(1): 16–22.
- [17] Wang J P, Hao Z, Zhu C H. Research on vibration signal recognition of optical fiber perimeter based on phase space reconstruction[J]. *J Hefei Univ Technol (Nat Sci)*, 2017, **40**(5): 643–648.
王建平, 郝钊, 朱程辉. 基于相空间重构的光纤周界信号识别算法研究[J]. 合肥工业大学学报(自然科学版), 2017, **40**(5): 643–648.
- [18] Liu K, Weng L F, Jiang J F, et al. Zero-crossing rate based efficient identification of intrusion events in fiber perimeter security systems[J]. *Acta Opt Sin*, 2019, **39**(11): 1106002.
刘琨, 翁凌峰, 江俊峰, 等. 基于过零率的光纤周界安防系统入侵事件高效识别[J]. 光学学报, 2019, **39**(11): 1106002.
- [19] 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]. *Chin J Lasers*, 2015, **42**(4): 0405010.
王照勇, 潘政清, 叶青, 等. 用于光纤围栏入侵警报的频谱分析快速模式识别[J]. 中国激光, 2015, **42**(4): 0405010.
- [20] Cao C, Fan X Y, Liu Q W, et al. Practical pattern recognition system for distributed optical fiber intrusion monitoring system based on phase-sensitive coherent OTDR[C]//Asia Communications and Photonics Conference 2015, 2015: ASu2A.145.
- [21] Huang X D, Zhang H J, Liu K, et al. High-efficiency intrusion recognition by using synthesized features in optical fiber perimeter security system[J]. *Acta Phys Sin*, 2017, **66**(12): 124206.
黄翔东, 张皓杰, 刘琨, 等. 基于综合特征的光纤周界安防系统高效入侵事件识别[J]. 物理学报, 2017, **66**(12): 124206.
- [22] Zou D B, Liu H, Zhao L, et al. Research of signal recognition of distributed optical fiber vibration sensors[J]. *Laser Technol*, 2016, **40**(1): 86–89.
邹东伯, 刘海, 赵亮, 等. 分布式光纤振动传感信号识别的研究[J]. 激光技术, 2016, **40**(1): 86–89.
- [23] Shuai S, Wang J, Wu H Y, et al. A signal recognition method for distributed optical fiber sensor system[J]. *J Fudan Univ (Nat Sci)*, 2018, **57**(5): 611–618.
帅师, 王蔚, 吴红艳, 等. 一种分布式光纤传感系统的信号识别方法[J]. 复旦学报(自然科学版), 2018, **57**(5): 611–618.
- [24] Tejedor J, Martins H F, Piote D, et al. Toward prevention of pipeline integrity threats using a smart fiber-optic surveillance system[J]. *J Light Technol*, 2016, **34**(19): 4445–4453.
- [25] Tejedor J, Macias-Guarasa J, Martins H F, et al. A novel fiber optic based surveillance system for prevention of pipeline integrity threats[J]. *Sensors*, 2017, **17**(2): 355.
- [26] Li Z C, Liu K, Jiang J F, et al. A high-accuracy event discrimination method in optical fiber perimeter security system[J]. *Infrared Laser Eng*, 2018, **47**(9): 0922002.
李志辰, 刘琨, 江俊峰, 等. 光纤周界安防系统的高准确度事件识别方法[J]. 红外与激光工程, 2018, **47**(9): 0922002.
- [27] Chen P C, You C T, Ding P F. Pattern recognition of intrusion events in perimeter defense areas of optical fiber[J]. *Chin J Lasers*, 2019, **46**(10): 1006001.
陈沛超, 游赐天, 丁攀峰. 光纤周界防区入侵事件的模式识别研究[J]. 中国激光, 2019, **46**(10): 1006001.
- [28] Huang N E, Shen Z, Long S R, et al. The empirical mode decomposition and the Hilbert spectrum for nonlinear and non-stationary time series analysis[J]. *Proc Math Phys Eng Sci*, 1998, **454**(1971): 903–995.
- [29] Liu K, Tian M, Liu T G, et al. A high-efficiency multiple events discrimination method in optical fiber perimeter security system[J]. *J Light Technol*, 2015, **33**(23): 4885–4890.
- [30] Jiang L H, Gai J Y, Wang W B, et al. Ensemble empirical mode decomposition based event classification method for the fiber-optic intrusion monitoring system[J]. *Acta Opt Sin*, 2015, **35**(10): 1006002.
蒋立辉, 盖井艳, 王维波, 等. 基于总体平均经验模态分解的光纤周界预警系统模式识别方法[J]. 光学学报, 2015, **35**(10): 1006002.
- [31] Li J Y, An B W, Chen Y L, et al. Research on optical fiber vibration pattern recognition based on time-frequency characteristics[J]. *Opt Commun Technol*, 2018, **42**(7): 55–59.
李静云, 安博文, 陈元林, 等. 基于时频特征的光纤振动模式识别研究[J]. 光通信技术, 2018, **42**(7): 55–59.
- [32] Zhu C H, Zhu R, Wang J P, et al. Intrusion signal recognition of optical fiber security & protection system based on adaptive EMD[J]. *Transducer and Microsystem Technologies*, 2020, **39**(4): 26–30.
朱程辉, 朱睿, 王建平, 等. 基于自适应 EMD 的光纤安防系统入侵信号识别[J]. 传感器与微系统, 2020, **39**(4): 26–30.
- [33] Zhang J C, Zeng Z M, Lai P, et al. A recognition method with wavelet energy spectrum and wavelet information entropy for abnormal vibration events of a petroleum pipeline[J]. *J Vib Shock*, 2010, **29**(5): 1–4.
张景川, 曾周末, 赖平, 等. 基于小波能谱和小波信息熵的管道异常振动事件识别方法[J]. 振动与冲击, 2010, **29**(5): 1–4.
- [34] Li Y, Liang Z T, Li L J, et al. Pattern recognition of fiber-optic micro vibration sensor based on wavelet and SVM[J]. *Transducer Microsyst Technol*, 2013, **32**(2): 43–45, 49.
李彦, 梁正桃, 李立京, 等. 基于小波和支持向量机的光纤微振动传感器模式识别[J]. 传感器与微系统, 2013, **32**(2): 43–45, 49.
- [35] 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]. *J Light Technol*, 2015, **33**(15): 3156–3162.
- [36] Yu X M, Luo G M, Zhu Z M, et al. The multi target recognition of intrusion signal of perimeter security with distributed fiber-optic sensor[J]. *Opto-Electron Eng*, 2014, **41**(1): 36–41.

- 喻晓芒, 罗光明, 朱珍民, 等. 分布式光纤传感器周界安防入侵信号的多目标识别[J]. 光电工程, 2014, **41**(1): 36–41.
- [37] Li K Y, Zhao X Q, Sun X H, et al. A regular composite feature extraction method for vibration signal pattern recognition in optical fiber link system[J]. *Acta Phys Sin*, 2015, **64**(5): 054304.
李凯彦, 赵兴群, 孙小菡, 等. 一种用于光纤链路振动信号模式识别的规整化复合特征提取方法[J]. 物理学报, 2015, **64**(5): 054304.
- [38] 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 Sens*, 2017, **7**(4): 305–310.
- [39] Peng K, Feng C, Wang S M, et al. Event discrimination method for distributed optical fiber intrusion sensing system based on integrated time/frequency domain feature extraction[J]. *Acta Opt Sin*, 2019, **39**(6): 0628002.
彭宽, 冯诚, 王森懋, 等. 基于时/频域综合特征提取的分布式光纤入侵监测系统事件识别方法[J]. 光学学报, 2019, **39**(6): 0628002.
- [40] Sun Q, Feng H, Yan X Y, et al. Recognition of a phase-sensitivity OTDR sensing system based on morphologic feature extraction[J]. *Sensors*, 2015, **15**(7): 15179–15197.
- [41] Aslangul S A. Detecting tunnels for border security based on fiber optical distributed acoustic sensor data using DBSCAN[C]//*Proceedings of the 9th International Conference on Sensor Networks*, 2020: 78–84.
- [42] Cortes C, Vapnik V. Support-vector networks[J]. *Mach Learn*, 1995, **20**(3): 273–297.
- [43] Qi X X, Ji J W, Han X W, et al. An Approach of passive vehicle type recognition by acoustic signal based on SVM[C]//*Proceedings of the 2009 Third International Conference on Genetic and Evolutionary Computing*, 2009: 545–548.
- [44] King D, Lyons W B, Flanagan C, et al. A multipoint optical fibre sensor system for use in process water systems based on artificial neural network pattern recognition techniques[J]. *Sens Actuator A Phys*, 2004, **115**(2–3): 293–302.
- [45] Lewis E, Sheridan C, O'Farrell M, et al. Principal component analysis and artificial neural network based approach to analysing optical fibre sensors signals[J]. *Sens Actuator A Phys*, 2007, **136**(1): 28–38.
- [46] 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 Laser Eng*, 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.
- [47] Tipping M E. The relevance vector machine[C]//*Advances in Neural Information Processing Systems*, 2000: 652–658.
- [48] Zhu Y L, Yin J L. Study on application of multi-kernel learning relevance vector machines in fault diagnosis of power transformers[J]. *Proc IEEE Inst Electr Electron Eng*, 2013, **33**(22): 68–74.
朱永利, 尹金良. 组合核相关向量机在电力变压器故障诊断中的应用研究[J]. 中国电机工程学报, 2013, **33**(22): 68–74.
- [49] Sun Q, Zeng Z M, Li J. Application of relevance vector machine in pattern recognition of optical fiber pre-warning system[J]. *J Tianjin Univ (Sci Technol)*, 2014, **47**(12): 1115–1120.
孙茜, 曾周末, 李健. 相关向量机在光纤预警系统模式识别中的应用[J]. 天津大学学报(自然科学与工程技术版), 2014, **47**(12): 1115–1120.
- [50] Rumelhart D E, Hinton G E, Williams R J. Learning internal representations by error propagation[M]//*Parallel Distributed Processing: Explorations in the Microstructure Of Cognition, Vol. 1: Foundations*. Cambridge: MIT Press, 1986: 318–362.
- [51] Li X Y, Wu H J, Peng Z P, et al. A novel time sequence singular spectrum analysis method for φ-OTDR disturbance detection system[J]. *Acta Photo Sin*, 2014, **43**(4): 0428001.
李小玉, 吴慧娟, 彭正谱, 等. 基于时间序列奇异谱特征的 φ-OTDR 扰动检测方法[J]. 光子学报, 2014, **43**(4): 0428001.
- [52] Xie X, Wu H J, Rao Y J. A fiber-optical perimeter intrusion detection system based on the fiber Bragg grating vibration sensors and its identification method[J]. *Acta Photo Sin*, 2014, **43**(5): 0506005.
谢鑫, 吴慧娟, 饶云江. 一种基于光纤布喇格光栅振动传感器的光纤围栏入侵监测系统及其模式识别[J]. 光子学报, 2014, **43**(5): 0506005.
- [53] Shen L X, Feng H, Sha Z, et al. Pattern recognition of heterodyne phase-sensitive optical time-domain reflection technique based on down conversion and IQ demodulation[J]. *Acta Opt Sin*, 2017, **37**(8): 0806005.
沈隆翔, 陈皓, 沙洲, 等. 基于下变频和 IQ 解调的外差型相位敏感光时域反射技术的模式识别[J]. 光学学报, 2017, **37**(8): 0806005.
- [54] Aktas M, Akgun T, Demircin M U, et al. Deep learning based threat classification in distributed acoustic sensing systems[C]//*Proceedings of the 2017 25th Signal Processing and Communications Applications Conference (SIU)*, 2017.
- [55] 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]. *Opt Eng*, 2018, **57**(1): 016103.
- [56] Shi Y, Wang Y Y, Zhao L, et al. An event recognition method for φ-OTDR sensing system based on deep learning[J]. *Sensors (Basel)*, 2019, **19**(15): 3421.
- [57] Wu J, Guan L Y, Bao M, et al. Vibration events recognition of optical fiber based on multi-scale 1-D CNN[J]. *Opto-Electron Eng*, 2019, **46**(5): 180493.
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.
- [58] Goodfellow I J, Pouget-Abadie J, Mirza M, et al. Generative adversarial nets[C]//*Proceedings of the 27th International Conference on Neural Information Processing Systems*, 2014: 2672–2680.
- [59] Shiloh L, Eyal A, Giryes R. Deep learning approach for processing fiber-optic DAS seismic data[C]//*Proceedings of the 26th International Conference on Optical Fiber Sensors*, 2018: ThE22.
- [60] Li W, Zeng Z Q, Qu H Q, et al. A novel fiber intrusion signal recognition method for opfs based on SCN with dropout[J]. *J Light Technol*, 2019, **37**(20): 5221–5230.
- [61] 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]. *Opt Express*, 2019, **27**(17): 23682–23692.
- [62] Chen X, Xu C J. Disturbance pattern recognition based on an ALSTM in a long - distance φ - OTDR sensing system[J]. *Microsc Opt Technol Lett*, 2020, **62**(1): 168–175.
- [63] 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]. *Opt Express*, 2020, **28**(3): 2925–2938.

Detection and recognition of distributed optical fiber intrusion signal

Zhang Yongkang, Shang Ying, Wang Chen, Zhao Wen'an,
Li Chang, Cao Bing, Wang Chang*

Laser Institute of Shandong Academy of Sciences, Qilu University of Technology (Shandong Academy of Sciences), Jinan, Shandong 250014, China



DAS system structure

Overview: Developed on the basis of phase-sensitive optical time domain reflectrometer(Φ -OTDR), distributed acoustic sensing(DAS) is a new type of distributed optical fiber sensing technology. It is a hot topic that how to accurately distinguish the type of intrusion events from complex signals, which attaches greater importance to the research on the pattern recognition technology based on DAS.

Intrusion signal recognition mainly includes two parts, feature extraction and classification algorithm. This paper summarizes the currently widely used feature extraction methods. Generally speaking, the time-domain features are simple, intuitive, and fast in response, but they are susceptible to noise. The frequency-domain features can obtain the inherent spectrum characteristics of the signal, but cannot reflect the frequency changes of the signal at every moment. The time-frequency domain features can express the time-domain and frequency-domain information of the signal, and the extracted feature information is also more accurate.

Classification algorithms include two categories, unsupervised learning and supervised learning. Supervised learning need to collect a large amount of data for training and verification. Therefore, supervised learning algorithms are mostly used in the fiber intrusion detection applications. Support vector machines (SVM) and BP neural networks are relatively common models for classification. In recent years, with the development of deep learning technology, building deep neural network models is very helpful for classification recognition. Therefore, models such as convolutional neural network (CNN), recurrent neural network (RNN), and generative adversarial network (GAN) are used in the field of distributed optical fiber intrusion signal recognition, which have achieved great performance.

In summary, choosing the proper feature extraction method and classification algorithm will greatly enhance the accuracy of intrusion signal recognition. Facing the increasing actual demands, the pattern recognition technology based on the DAS system will definitely play a more important role and fulfill its potential in the future.

Zhang Y K, Shang Y, Wang C, et al. Detection and recognition of distributed optical fiber intrusion signal[J]. *Opto-Electron Eng*, 2021, **48**(3): 200254; DOI: [10.12086/oee.2021.200254](https://doi.org/10.12086/oee.2021.200254)

Foundation item: Natural Science Foundation of Shandong Province (ZR2019QF011), Science and Technology Innovation Project of Shandong Province - Major Special (2019JZZY010113), Key R & D Program of Shandong Province (2019GSF111065), and the Youth Innovation Science and Technology Program of Colleges in Shandong Province (2019KJJ004)

* E-mail: ch_wangs@163.com