

全智能化分布式光纤声波传感器的信号处理方法

吴慧娟^{1*}, 王新蕾¹, 廖海贝¹, 矫玺本¹, 刘一羽¹, 舒新建¹, 王璟伦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 简要回顾了从基于传统机器学习的普通感知型分布式光纤声波传感器(DAS)到基于深度学习的全智能化DAS的转变历程,深入分析了基于多维信息提取的DAS监督学习及半监督、无监督和跨场景迁移等深度学习方法的研究现状,概括了不同识别模型的构建思路、特点,及其识别性能、处理时间等评价指标,也论述了DAS从单源检测到多源混叠检测、从单任务到多任务处理等智能感知能力提升面临的新挑战,最后对全智能化DAS的信号处理发展方向及新趋势进行了展望。

关键词 光纤物联网; 相敏光时域反射; 分布式光纤声波传感器; 智能感知; 信号处理

中图分类号 TH74 文献标志码 A

DOI: 10.3788/AOS231384

1 引言

基于相敏光时域反射(φ -OTDR)原理的分布式光纤声波传感器利用大面积铺设的普通通信光缆作为敏感单元,成功应用于自然灾害预警^[1-3]、油气勘探^[4-5]、海

洋监测^[6-7]、周界安防^[8-9]、智能交通^[10-11]、基础设施安全^[12-15]等多个领域(图1),为城市物联网提供了长距离、高灵敏、大容量、低成本的全天候、全空间声波/振动感知技术基础,势必将引领新一代光纤地听、水听技术及其应用的蓬勃发展的。



图1 新一代城市物联网的感知基础——基于通信光缆感知的分布式光纤声波传感器

Fig. 1 Foundation of the next-generation fiber optic Internet of Things—fiber-optic distributed acoustic sensor based on optical communication cable sensing

收稿日期: 2023-08-10; 修回日期: 2023-09-22; 录用日期: 2023-10-09; 网络首发日期: 2023-10-19

基金项目: 国家自然科学基金(U21A20453, 41527805, 61301275, 61290312)、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(B14039)、四川省自然科学基金面上项目(2023NSFSC0382)

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

从国内外研究现状看,分布式光纤声波传感器(DAS)在振动及声波传感信号的解调保真度^[16-19]、传感距离^[20]、检测带宽^[21-22]和灵敏度^[23-25]等硬件技术指标提升上正趋于成熟。但随着不同应用的深入开展,大范围监测环境条件复杂多变,DAS技术高灵敏感知的优势也带来了高误报率的问题,对感知振动及声波目标难以实现高精度检测、识别与定位,这已成为制约DAS技术规模化应用的最大技术瓶颈。近年来,在先进信号处理及人工智能技术发展的推动下,实际复杂应用环境中高准确率、高实时性的全智能化DAS的信号处理方法,成为光纤传感领域的研究热点和焦点。

目前,从普通感知型DAS的噪声抑制/信号增强、多域人工特征提取及传统机器学习方法,到全智能化DAS的端对端网络深度学习方法都已有大量研究成果^[26-29]。面对实际复杂环境及应用需求的多样化挑战,人工智能技术的快速发展对DAS信号检测、识别及定位等后处理方法将产生更加深远的影响。因此本文总结了进入深度学习阶段全智能化DAS的信号处理方法研究现状,从主流的监督学习到无监督、半监督及迁移学习,从单源检测到多源混叠检测,以及从识别或定位的单任务到识别与定位的多任务同步实现等,

并对未来进一步提升DAS智能处理性能及感知能力的可能研究方向进行了预测。

2 DAS感知机理及其智能信号处理研究现状

2.1 基于 φ -OTDR的DAS系统结构及感知机理

基于 φ -OTDR的DAS系统的基本感知原理为:通过解调受振动或声波调制的传感光纤中瑞利后向散射光的相位变化,得到振动或声源在时间、空间上的分布信息。典型的DAS系统结构如图2所示,由超窄线宽激光器产生一路连续相干光信号,此信号经声光调制器(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,通过环形器周期性地发射到传感光纤。随后,经过外部振动或声波调制的瑞利后向散射光经过光环形器进入解调器,并通过非平衡马赫-曾德尔光纤干涉(MZI)和 3×3 耦合器^[16](图2)或I/Q解调^[17-18]等技术进行线性解调,其相位变化由光电探测器(PD)接收,并经数据采集(DAQ)模块转换为数字电信号。最后将数字电信号通过网络等接口实时传输给信号处理主机,用于光纤感知信号的分析 and 处理。

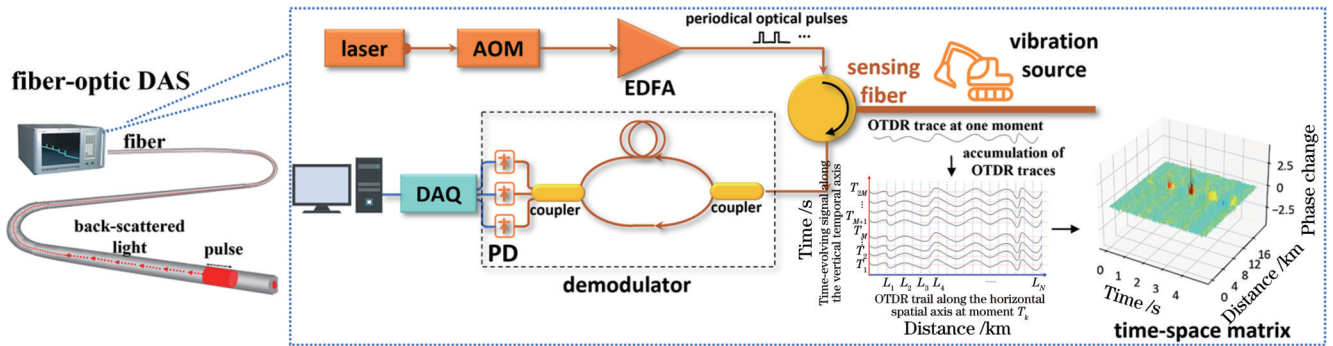


图2 DAS典型系统结构及振动/声波感知机理

Fig. 2 Typical DAS system structure and vibration/sound sensing mechanism

基于 φ -OTDR的振动或声波感知原理建立理论模型,当瑞利后向散射光沿长度为 L 的光纤传播时,相位延迟 ϕ 可表示为 $\phi = \beta L$, β 代表光纤中的光相位常数, L 为光纤长度。光相位常数是指在光纤中传输每单位长度光信号所需的时间延迟。这个延迟时间取决于光纤的折射率、几何形状,以及光波长。此外,温度、应力等环境扰动因素也影响光相位常数。窄带激光器保证了光的相干性,从而可以忽略光波长的影响。光相位改变随外界扰动的关系^[4,30]描述为

$$\Delta\phi = \beta \cdot \Delta L + L \cdot \Delta\beta = \beta L \cdot \frac{\Delta L}{L} + L \cdot \frac{\partial\beta}{\partial n} \cdot \Delta n + L \cdot \frac{\partial\beta}{\partial\alpha} \cdot \Delta\alpha, \quad (1)$$

式中: n 为芯折射率; α 为芯径; $\Delta\phi$ 为相位变化量; ΔL 为光纤长度变化量; Δn 为芯折射率变化量; $\Delta\alpha$ 为芯径变化量。当某一位置 z 的光纤受到外界扰动时,光纤

长度、芯折射率和芯径都会发生相应的变化,从而导致瑞利后向散射光的相位产生 $\Delta\phi$ 的变化量。 $\beta L \cdot \frac{\Delta L}{L}$ 、 $L \cdot \frac{\partial\beta}{\partial n} \cdot \Delta n$ 和 $L \cdot \frac{\partial\beta}{\partial\alpha} \cdot \Delta\alpha$ 分别代表由光纤形变、光弹性效应和泊松效应引起的相位变化。通过解调沿传感光纤的瑞利后向散射轨迹,获得光纤感知的扰动信号。

在每个脉冲发射周期中,DAS形成一条随光纤空间位置变化的OTDR迹线。通过累积不同时刻接收的OTDR迹线,形成一个在二维空间表示所感知扰动事件的时空矩阵,用于振动或声波等目标信号的检测分析。

2.2 全智能化DAS系统及其信号处理研究现状

智慧城市监测应用中全智能化DAS(sDAS)的系统架构极为简单,如图3所示,一台监测仪器包括光发

送、光接收、光解调及信号处理模块,当仪器接入监测的光纤链路时,可实现整个线路沿途的破坏性事件监测和报警输出。该系统利用普通单模通信光纤感知地面及地下多种振动及声源,包括地震、火山等自然灾害及机械施工、人为开挖等破坏性事件产生的振动及声音,也包括人们正常生产生活噪声,例如:火车、地铁、公路车辆等引起的交通振动噪声,工厂生产产生的振

动、冲击噪声等。它的核心作用就是将光纤沿线感知到的振动、声波信号,通过智能信号处理算法转换为目标事件信息(如振动或声源的事件类型及其位置等)进行报警提示,以此指导城市相关管理人员及时采取干预措施,避免巨大的人员伤亡和经济损失,利用该系统还可以实现大范围、低成本、快速便捷的城市基础设施维护。

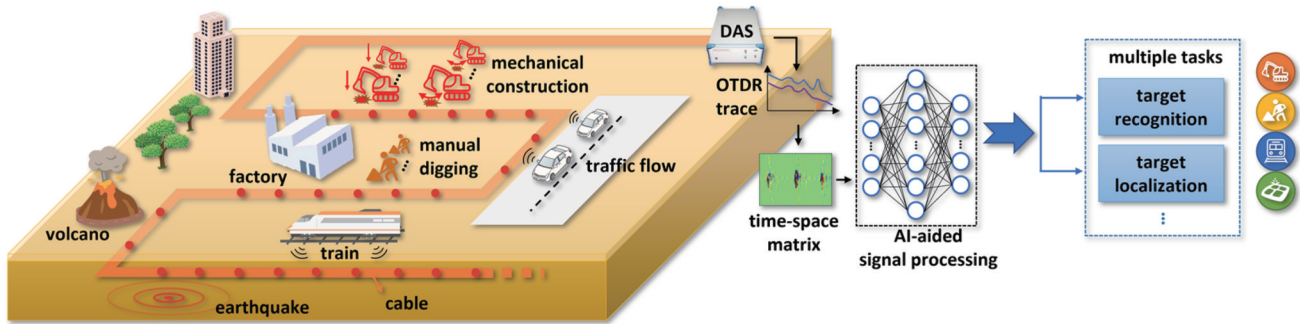


图 3 智慧城市监测应用中全智能化 DAS 系统及其信号处理架构

Fig. 3 Smart fiber-optic DAS and its signal processing architecture in smart city monitoring applications

后端的信号处理方法相当于 DAS 仪器的大脑,直接决定整个系统的智能感知能力,是 sDAS 的核心模块。DAS 信号处理包括去噪预处理和信号智能识别两个环节。首先,为了进一步提高 DAS 检测信号的信噪比,常通过小波多尺度分解^[31]、自适应滤波^[32]、相关去噪^[33]及深度学习去噪^[34]等预处理手段实现信号增强。预处理后的 DAS 信号智能识别方法又分为传统机器学习和深度学习两个阶段^[26-29]。

第一阶段,以专家经验特征提取和分类器设计为主^[35]。以专家经验为主的人工特征包括时域的信号幅值水平过零率^[36]、步态周期特征^[37]等,频域中频谱的能量分布特征^[38-39],时空域图像形态学特征^[40-41],时频域如小波/小波包能量谱^[31,42]、梅尔倒谱系数(MFCC)^[43]和其他模型参数特征^[43]等。分类器则以更加多样化形式呈现,从基本的神经网络(ANN)^[44]、多层感知机(MLP)^[45]、概率神经网络(PNN)^[46],到支持向量机(SVM)^[47]及其各种变形形式,如邻类支持向量机(NC-SVM)^[48]、线性支持向量机(L-SVM)^[49]、相关向量机(RVM)^[41,50]等,还有极限学习机(ELM)^[51]、随机森林(RF)^[52-53]、最近邻分类器(KNN)^[48]、极端梯度提升(XGBoost)^[54-55]等分类器,基于高斯混合矩阵(GMM)的概率预测模型^[56],挖掘短时特征间上下文时序关系的隐马尔可夫(HMM)模型^[43]及 GMM-HMM 组合模型^[57]等。在这些传统机器学习方法中,提取特征的维度和质量直接决定了整个检测识别算法的性能。此外,不同分类器在不同应用场景下的性能也有较大差异,因此通过分类性能比较选择最优分类器^[58]或通过投票方法^[59]得到最优决策结果。这些多域多维的特征提取与分析方法极大丰富了 DAS 检测信号的信息,多种分类器的实现也提升了信号特征到事件类别的非线性映射

能力。但以“固定专家经验特征提取+分类器设计”为主的传统机器学习方法无法跟上大范围分布节点的海量数据变化模式,环境适应能力差,算法模型更新周期较长。

第二阶段,借鉴深度学习在图像及语音信号处理中的成功应用,国内外研究者开始使用深度学习网络来自动提取抽象信号特征并对其进行深度表征和端对端的检测识别,以卷积神经网络(CNN)、循环神经网络(RNN)为代表的深度学习工具的使用进入白热化阶段,也标志着 DAS 的全智能化信号处理进入了一个新时代。2016 年, Makarenko^[60]在 DAS 的周界安防应用中用到深度学习的识别方法,通过将采集的时空数据进行各通道滤波和时频域特征提取及主成分分析(PCA)降维后,将构建的时空二维特征数据块输入 3 个 CNN,对 7 类事件实现两级分类,这初步展示了深度学习方法的有效性。Bublin^[61]通过现场测试证明深度学习网络可以有效避开人工提取特征的麻烦,其识别准确率、对较复杂环境的适应性及算法的开发效率都有明显提升。当前大部分的深度学习方法是基于 CNN 和长短时记忆网络(LSTM)等及其不同形式的演化和组合为主的监督型学习网络,按网络的输入信号结构或提取信息的维度又可分为:基于一维时间信号输入的深度学习方法和基于时频、时空、空频等二维信号输入的深度学习方法两大类。近年来,为提升识别模型的泛化能力,DAS 无监督、半监督及跨场景迁移学习方法也纷纷出现。此外,面向 DAS 多源混叠检测、振动/声波目标的二维/三维定位、识别与定位的多任务处理等新的挑战应用需求,很多国内外单位也正在开展深入研究。

3 基于深度学习的全智能化 DAS 处理方法

3.1 基于多维信息提取的 DAS 监督学习方法

3.1.1 基于时域信息提取的 DAS 信号识别模型

1) 基于一维卷积神经网络(1D-CNN)的识别模型

CNN 广泛应用于图像、语音、传感信号识别等领域,但以图像处理使用的二维卷积神经网络(2D-CNN)为主。语音及传感信号处理通常是将一维时间信号通过时频变换等手段转化为二维信息,再利用 2D-CNN 进行特征提取和信号识别。2019 年, Wu 等^[58]设计了与 DAS 单通道时间信号结构匹配的 1D-CNN,直接输入小波去噪后的时域信号,自动提取振

动信号的时间结构特征,并用 SVM 分类器取代 CNN 的 softmax 层,形成如图 4 所示的 1D-CNN 监督识别模型,结果证明了该方法的识别准确率优于基于人工特征提取的传统机器学习方法。之后, Zhang 等^[62]和 Liu 等^[63]分别提出了 1D-CNN 的变形密集卷积网络(DenseNet)和深度置信网络-门控循环单元(DBN-GRU),也都能实现高效实时的在线处理。梁惠康等^[64]针对一维时间信号的噪声问题提出了一种基于新阈值函数的深度残差收缩网络(DRSN-NTF),进一步改进了基于 1D-CNN 的 DAS 识别性能。通常,1D-CNN 比 2D-CNN 模型收敛速度更快,单样本处理时间更短,适用于在线实时处理,但是 1D-CNN 只提取了信号时间维度的局部结构信息,对 DAS 感知对象的表达能力有限。

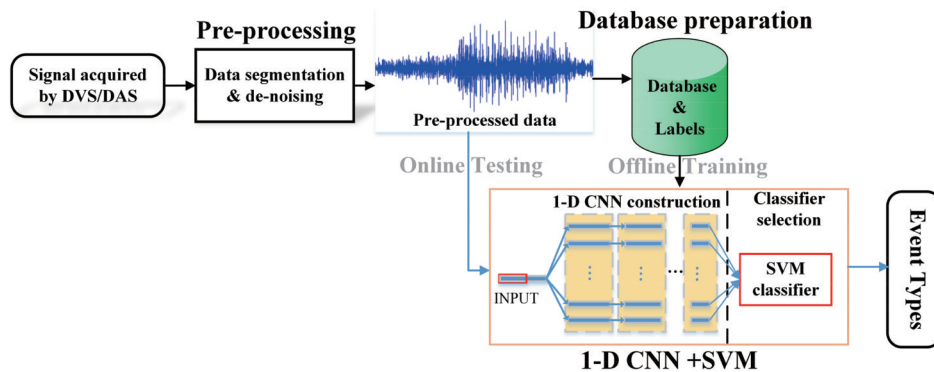


图 4 基于一维卷积神经网络的监督识别模型^[58]

Fig. 4 One-dimensional convolution neural network based supervised recognition model^[58]

2) 基于多尺度卷积神经网络(MSCNN)的识别模型

在提取 DAS 一维时域信号特征时,固定尺度的卷积核提取特征单一,吴俊等^[65]通过应用图 5 所示的多尺度一维卷积神经网络(MS-1D CNN)提取并融合不同尺度的深度特征以提升 DAS 识别性能。该方法利用多个一维卷积核与输入的时间信号进行不同尺度的卷积,自动提取时域信号中多个尺度的特征信息,最后通过多尺度特征拼接进行融合。此后, Lü 等^[66]将 MSCNN 和原型学习网络相结合,在多尺度特征学习基础上利用聚类思想提高模型对新样本的适应能力。多尺度卷积网络模型相对于典型的 1D-CNN,结构上并行增加了多条卷积路线,虽牺牲了计算效率但有效补充了 DAS 信号在时间维度的多尺度信息,识别准确率更高。

3) 多尺度深度学习特征与时序关系结合(mCNN-HMM)的识别模型

在时域多尺度卷积基础上, Wu 等^[67]将多尺度短时深度特征按时间顺序调整后,利用隐马尔可夫模型挖掘其前后的时序关系,提出多尺度短时深度特征与时序关系相结合(mCNN-HMM)的监督识别模型,如图 6 所示。该模型挖掘出图 7 所示的信号时序规律,避

免了短时特征的不稳定,进一步提高了监督识别模型提取特征的丰富性和稳定性,取得了较好的测试结果。此外,基于正确/错误预测概率间欧氏距离提出特征有效性的直接评估方法,该方法补充了之前只能通过分类结果对特征进行间接评估的方式,这是继 Tejedor 等^[57]通过长、中、短时传统特征同步提取优化 DAS 识别性能后信号处理的又一次智能化进步。2023 年王鸣等^[68]利用 LSTM-CNN,同步提取 DAS 信号的时间结构和时序关系,也达到了较好的识别效果。综合来看,基于深度学习网络同步提取多个尺度的局部时间结构特征和上下文关系的全局时序演化特征的方法,比其他时域信息提取方法更加全面和智能。

3.1.2 基于时频、时空、频空等二维信息提取的识别模型

1) 基于时频二维信息提取的识别模型

将 DAS 各空间点的时间信号通过 MFCC^[69]、短时傅里叶变换(STFT)^[59,70]等技术转换为二维时频信息,利用图像处理领域现有的 2D-CNN 进行特征提取和识别,是最早利用深度学习网络的基本识别架构。例如, Li 等^[69]将基于短时信号帧的 MFCC 构建的二维时频矩阵作为 2D-CNN 的输入,如图 8 所示; Aktas 等^[70]、 Xu 等^[59]使用 STFT 工具将不同类型的 DAS 信

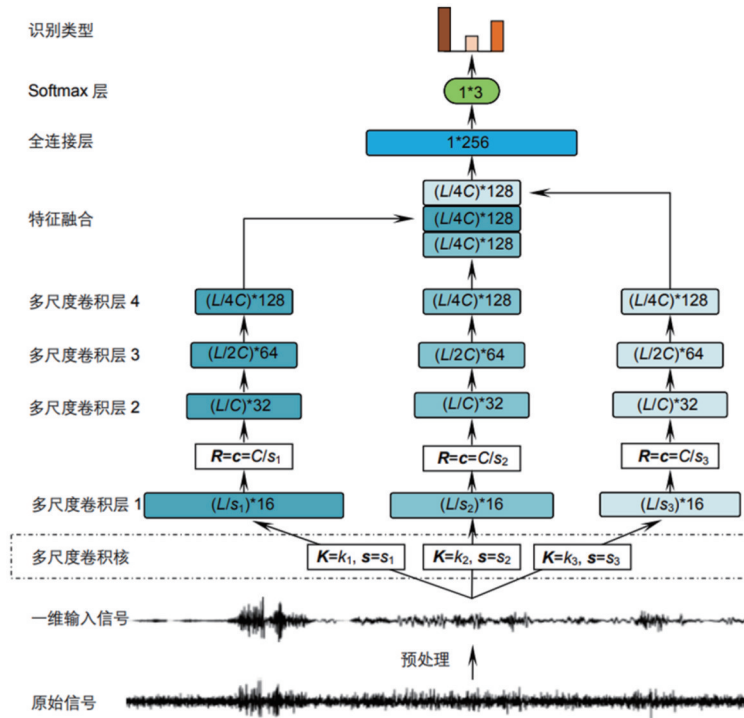


图 5 基于 MS-1D CNN 的监督识别模型^[65]
Fig. 5 MS-1D CNN based supervised recognition model^[65]

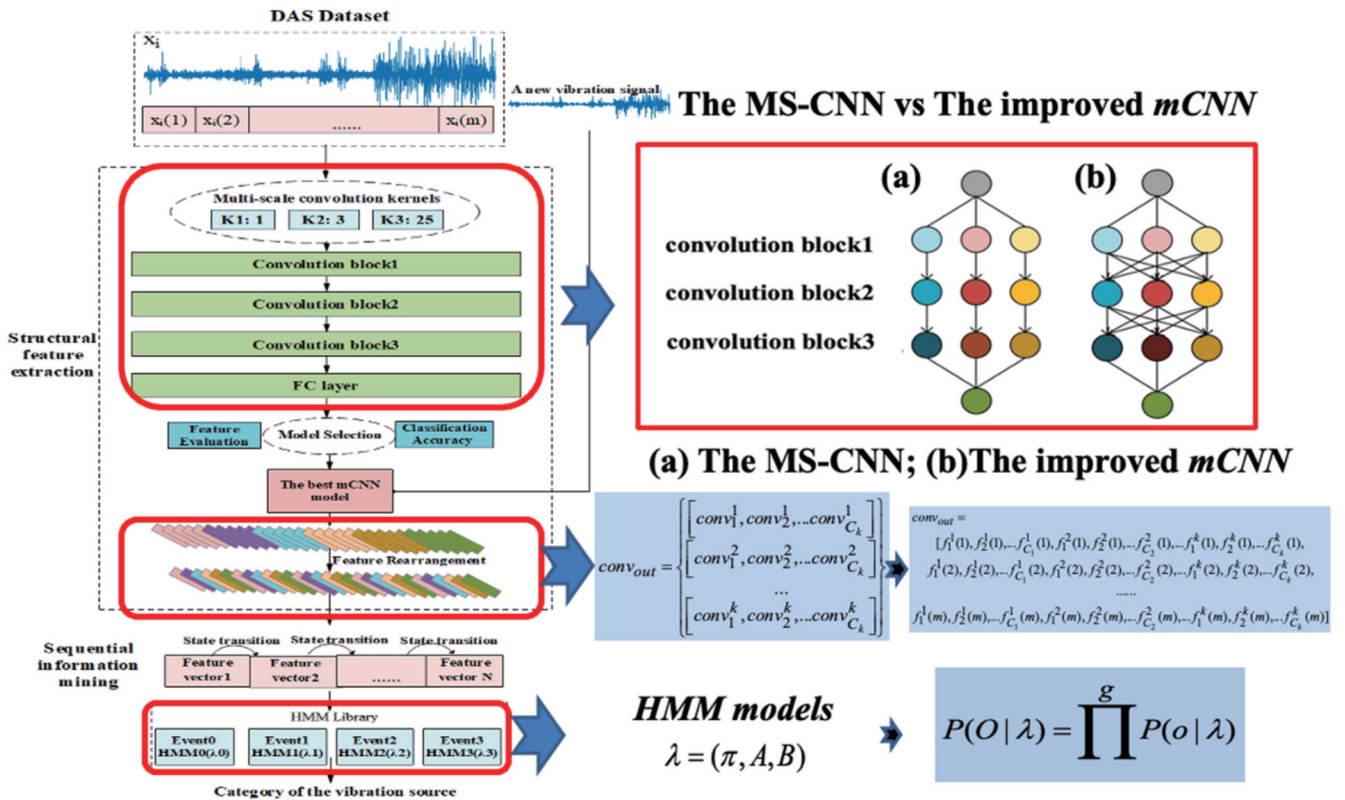


图 6 多尺度深度特征与时序关系结合 的识别模型^[67]
Fig. 6 Recognition model combining multi-scale depth features with temporal relationships^[67]

号转为时频矩阵或时频图,如图 9 所示,并采用降噪手段增强 DAS 信号的时频特征;胡胜等^[71]利用格拉姆角场(GAF)表示技术将 DAS 感知的一维时间信号转为

二维信号,如图 10 所示。时频信息能够同时反映信号在时间尺度和频率成分的变化,包含的信息比一维时间信号更加丰富,因此通过以上不同的信息转换技术,

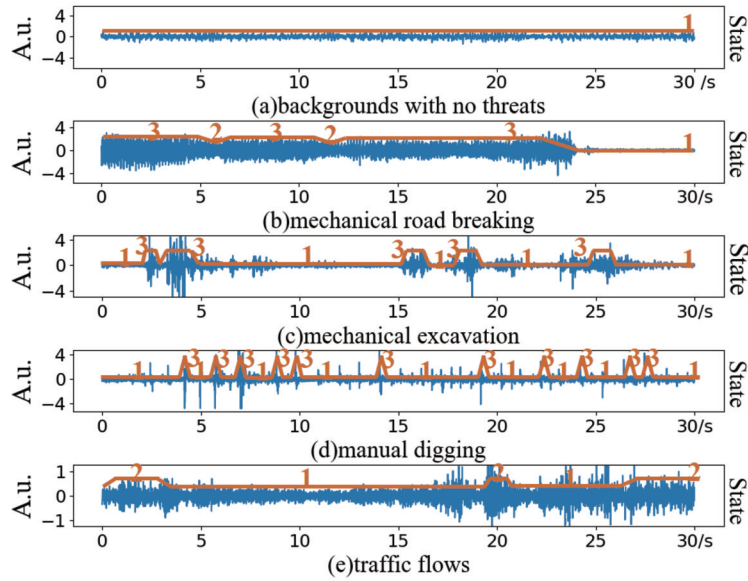


图 7 基于HMM挖掘的多尺度深度特征间的时序关系^[67]

Fig. 7 Temporal sequential relationship among multi-scale deep features based on HMM^[67]

将准备的二维时频信息输入到 2D-CNN 进行自动特征提取和识别分类,成为 DAS 深度学习的基础网络。

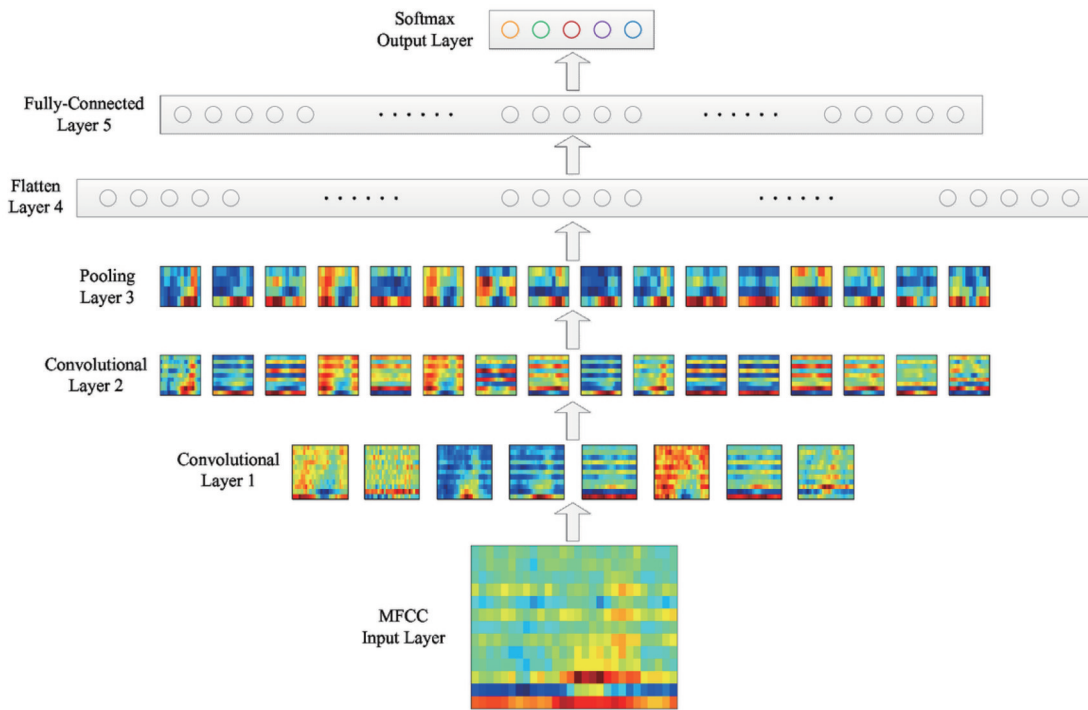


图 8 基于 MFCC 时频输入的 2D-CNN 识别模型^[69]

Fig. 8 2D-CNN recognition model with time-frequency input of MFCC^[69]

此外,研究人员对基于时频输入和变形或演化的卷积神经网络的识别方法也有一些探索。Liu 等^[72]利用深度残差网络(ResNet)和注意力模块(CBAM)提取 DAS 二维时频矩阵输入信息,如图 11 所示,引入 ResNet 残差块优化网络结构,并利用通道和局部结构注意力模块增加对时频图的自适应的特征细化和注意,快速聚焦 DAS 信号的关键时频信息,进一步提高了特征提取的充分性和有效性。

2) 基于时空二维信息提取的识别模型

以上基于单个空间点信号进行信息提取的 DAS 信号识别方法,忽略了光纤不同位置的空间关系。DAS 采集信号原本是时空结构的二维矩阵,因此将时空矩阵或时空图像直接输入到变形或演化的卷积神经网络,形成了另外一类基于时空二维信息提取的识别模型。2020 年, Li 等^[73]将 DAS 获得的二维时空图(图 12)直接输入至二维卷积神经网络,实现简便的局部时




图 9 基于 STFT 的不同信号二维时频图^[59]。(a)挖掘;(b)行走;(c)车辆通过;(d)破坏

Fig. 9 2D spectrograms of different types of signals via STFT^[59]. (a) Digging; (b) walking; (c) vehicle-passing; (d) damaging

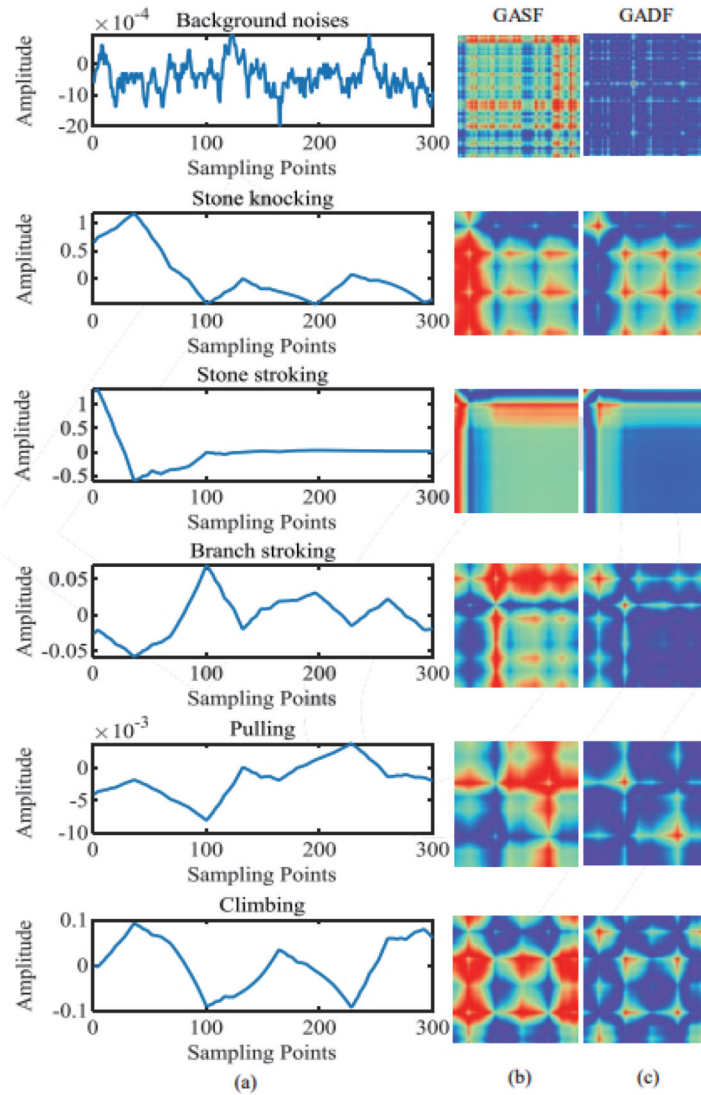


图 10 基于 GAF 转换的不同类型信号的二维图像^[71]。(a)窗口划分信号;(b)格拉姆角差场(GADF)编码示意图;(c)格拉姆角和场(GASF)编码示意图

Fig. 10 2D images of different types of signals via GAF transform^[71]. (a) Window partition signal; (b) schematic diagram of Gramian angular difference field (GADF) coding; (c) schematic diagram of Gramian angular summation field (GASF) coding

空二维信息深度学习。考虑到事件在时间和空间上的连续性,在局部时空经二维深度学习得到的时空标签矩阵如图 13 所示,对识别结果进行融合校正,以减少行人、交通等因素造成的虚警。

2021 年, Bublin 等^[61]将采集的挖掘机与非挖掘机

事件的时空信号转为 2D 灰度图,输入 2D-CNN,在现场测试中与传统机器学习方法进行比较,证明了基于 CNN 的深度学习算法比传统机器学习方法识别准确率高,而且计算速度更快。杨震等^[74]对原始时空数据进行归一化、滤波去噪及数据增强等预处理后,再使用

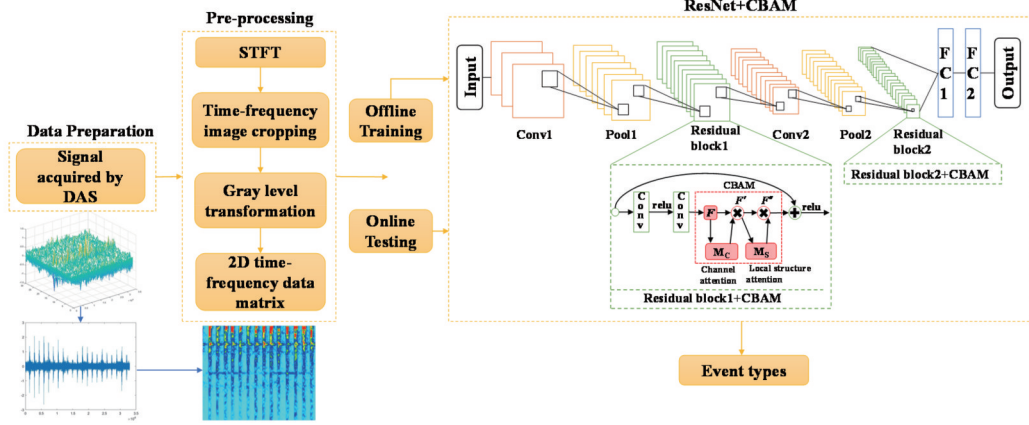


图 11 基于注意力机制和深度残差网络(ResNet-CBAM)的监督识别模型^[72]

Fig. 11 Supervised recognition model based on attention mechanism and ResNet-CBAM^[72]

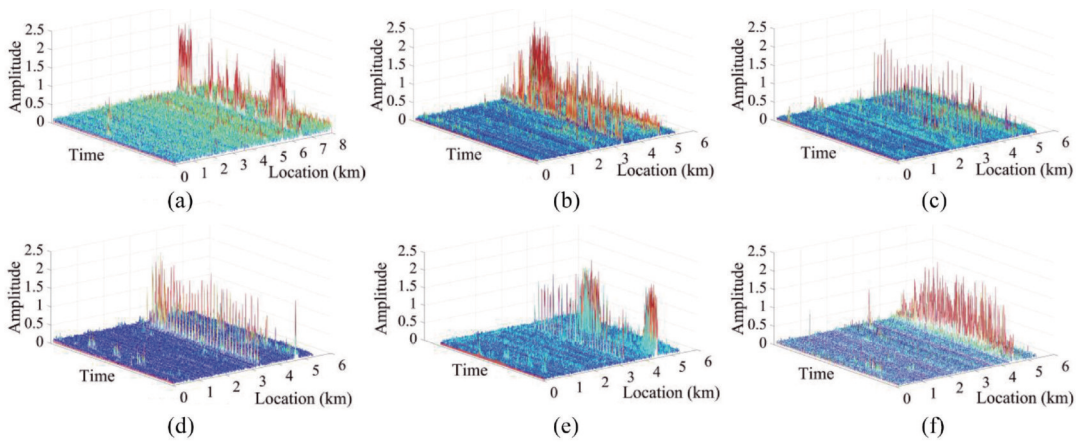


图 12 第三方干扰的不同振动信号时空图^[73]。(a)挖掘机;(b)电锤;(c)铲;(d)锤子;(e)鹤嘴锄;(f)地铁

Fig. 12 Time-space waterfall figures of vibration signals due to various third-party interference^[73]. (a) Excavator; (b) electrical hammer; (c) shovel; (d) hammer; (e) pickaxe; (f) metro

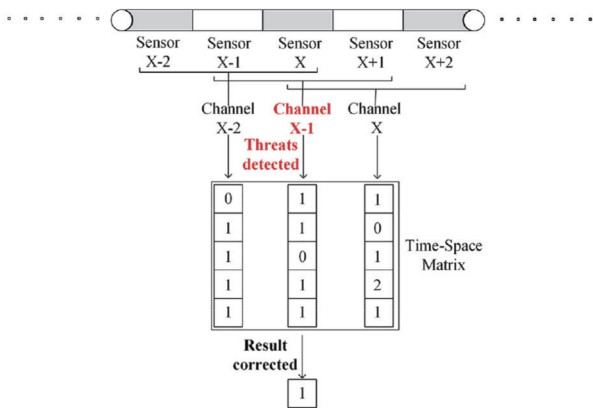


图 13 基于时空标签矩阵的识别结果融合校正^[73]

Fig. 13 Recognition result fusion correction based on time-space label matrix^[73]

改进的YOLOv3网络进行识别,以提升输油管道入侵事件二维时空图的识别性能和泛化能力。然而,DAS采集的二维时空矩阵的空间信息反映了事件的空间分布差异,时间信息则包含了更丰富的事件操作过程演化规律。Wu等^[75]根据DAS特殊的时空信号结构,设

计了一维卷积神经网络与双向长短时记忆网络结合(1D CNN-BiLSTM)的监督识别模型,如图 14 所示。使用 1D-CNN 在每个空间节点提取信号时间结构信息,并采用双向 LSTM 自动挖掘节点信号间的空间关系,更深层次地挖掘 DAS 信号的时空信息。结果表明,CNN-BiLSTM 模型比 1D-CNN、1D CNNs-CNN、2D-CNN 等模型提取的时空特征更具可分辨性。

随着深度学习网络的不断演化,基于时空信息输入的各种变形的二维卷积网络也纷纷应用于 DAS 信号识别中,例如 100G-Net (100 Groups Convolutional Neural Networks)^[76]、Faster-RCNN (Faster Region Convolutional Neural Network)^[77]、YOLO (You Only Look Once)^[78]等模型。群卷积神经网络的 100G-Net,采用 100 个卷积核提取不同位置 DAS 时空信号的振动变化特征;Faster-RCNN 引入区域建议网络(RPN)在 CNN 提取的特征图上寻找感兴趣区域(RoI);YOLO 算法将 Darknet 53 提取的时空图像特征传入特征金字塔网络(FPN)以生成不同尺度的特征映射。以上方法均利用高性能的卷积网络变形进一步提升检

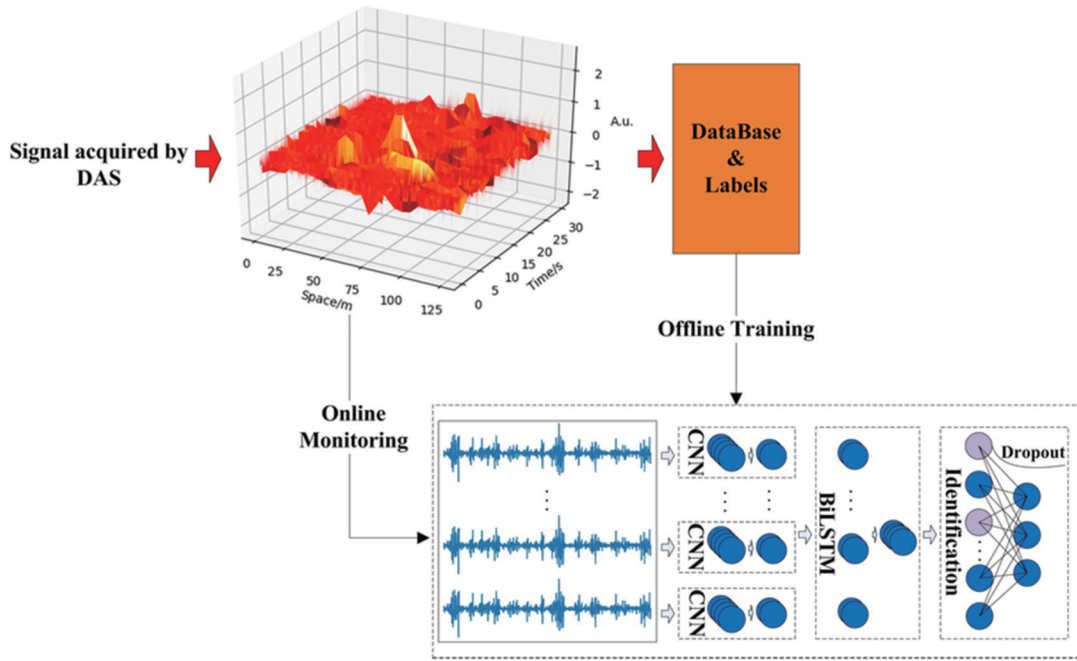


图 14 卷积神经网络与双向长短时记忆结合的监督识别模型^[75]

Fig. 14 Supervised recognition model combining convolutional neural network and bi-directional long short term memory^[75]

测识别性能及效率。此外,尚秋峰等^[79]通过增加时空信号的通道和时序注意机制,提出一种多注意力时间卷积网络(MATCN)模型,进一步提升其周界入侵信号的识别性能。

3) 基于频空二维信息提取的识别模型

Wang 等^[80]考虑到扰动信号的时变特点,构建

具有短时频域和空域特征的频空数据集,并引入一个近百层的深度神经网络——双路径网络(DPN)对 DAS 信号进行识别。DPN 的双路径包括残差路径(RP)和密集连接路径(DCP),如图 15 所示,二者共享权重参数和特定结构,提高了参数使用效率并简化训练,使复杂环境下的监督识别模型更具鲁棒性。

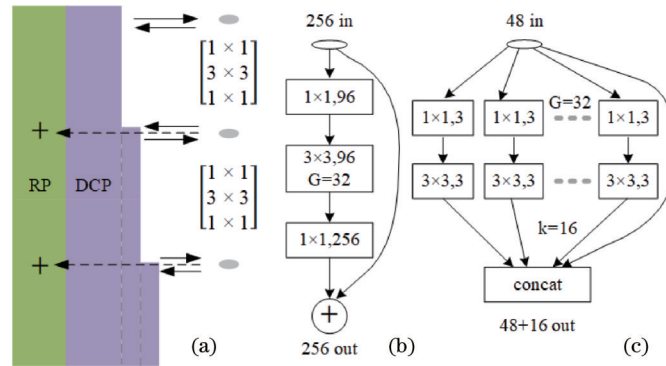


图 15 双路径网络的监督识别模型^[80]。(a)双路径结构;(b)RP 等效块;(c)DCP 等效块

Fig. 15 Supervised recognition model based on dual path network^[80]. (a) Dual path architecture; (b) equivalent block of RP; (c) equivalent block of DCP

3.1.3 其他监督型深度学习网络

DAS 监督学习除了以 CNN 为主的深度学习网络外,还有 LSTM 网络。例如,Chen 等^[81]提出基于注意长短期记忆网络(ALSTM)的 DAS 信号识别方法,如图 16 所示,通过引入新型 LSTM 网络和注意力机制,使模型聚焦表达信号的关键部分即主要特征。结合 LSTM 提取的 MFCC 时频特征和人工提取的时域特征,如短时能量(STE)、短时过零率(ZCR)等生成注意力模块,实现 LSTM 提取的关键特征注意。此外,Wu

等^[75]和 Li 等^[82]分别将 CNN 与 LSTM 网络进行组合,实现更精细的 DAS 时空信号特征提取。

另外,基于专家经验提取的人工特征和基于深度学习网络提取的深度特征存在各自的局限性。人工特征严重依赖于基于有限数据观察的专家知识,包含的信息可能不完整,且跨场景自适应能力差;深度特征的有效性受限于训练数据的特征分布空间,当测试数据特征分布不一致,其识别模型容易出现过拟合问题,且所需的训练数据集规模庞大。因此,Wu 等^[83]将人工

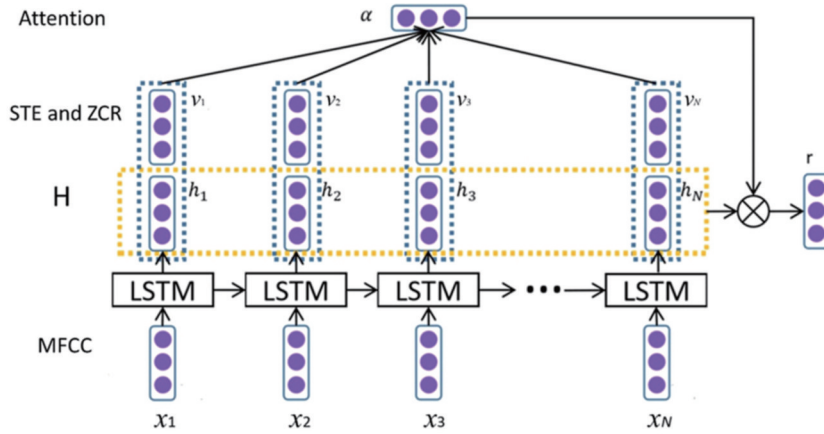


图 16 基于注意长短期记忆网络的监督模型^[81]

Fig. 16 Supervised recognition model based on attention-based long short-term memory network^[81]

特征和深度特征(图 17 包括时域、频域、语义倒谱域、动态模型共 70 维的人工特征和由 4 层 CNN 提取的 1535 维的深度特征)融合,通过特征选择工具去除提取特征的冗余信息,提高了 DAS 识别准确率和模型的鲁棒性。此外,Bublin 等^[61]通过现场测试实验也证明了传统经验规则与深度网络的结合可以进一步降低系统的误警率。

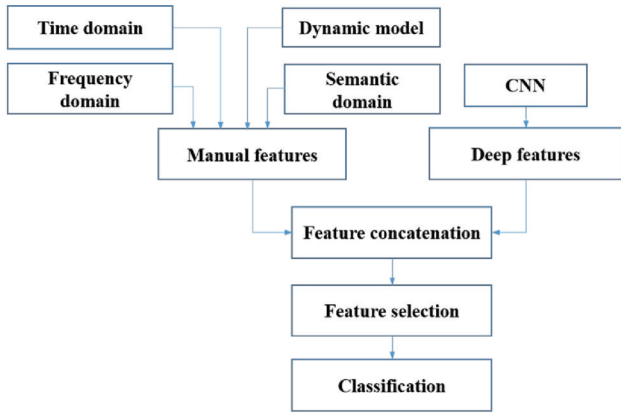


图 17 人工特征和深度特征融合的 DAS 识别模型^[83]

Fig. 17 DAS recognition model based on fusion of manual features and deep features^[83]

3.2 从监督学习到半/无监督及迁移学习

3.2.1 DAS 半监督学习方法

基于深度学习的 DAS 监督识别模型虽然比传统机器学习方法更加高效,识别准确率也有较大提升,但其获取标记数据需要大量的人力、物力资源和时间成本。针对实际应用中新场景下标签样本数量不足的问题,如何基于少量标签数据和大量无标签数据实现 DAS 信号的高精准识别成为新的挑战。因此,He 等^[84]提出了一维半监督生成对抗网络(1D-SSGAN),使用生成对抗网络(GAN)的生成器结构为鉴别器模型提供大量的未标记数据并进行训练,克服 DAS 监督模型在标签样本数量较少时的局限性。Yang 等^[85]使

用无标签数据训练稀疏堆叠自编码器(SSAE)以提取 DAS 信号特征,使用少量标签数据训练全连接网络并进行目标定位和识别,该方法有效提高了无标签数据的利用率及模型的鲁棒性。然而,当样本不均衡时,SSGAN 和 SSAE 都可能会导致模型偏向于标记样本多的类别,而导致标记样本少的类别信号生成结果较差。Wang 等^[86]提出一种基于 FixMatch 的高铁轨道半监督学习方法,对少量标签数据进行监督训练,同时借助伪标签生成方法增强了对大量无标签数据的无监督学习。FixMatch 利用一致性正则化机制解决标签噪声问题,并通过数据增广扩展少数类样本数据集,平衡数据集的样本类别分布,从而增强模型的鲁棒性。

3.2.2 DAS 无监督学习方法

监督学习一般建立在两个假设条件上:1)训练数据包含识别对象的所有分布特征;2)测试数据特征分布与训练数据一致。但实际上,由于 DAS 监测距离远,外部环境条件及光缆埋设条件复杂多变,不可预知,同一类事件不同位置的感知信号差异较大,DAS 完整训练样本库的构建有较大难度。当前监督学习算法中大多采用典型一致数据集构建模型,在实际应用中深度学习算法的泛化能力不足,甚至还有失效的风险。因此,为了提升模型的泛化能力,Wu 等^[87]提出一种近似大脑工作机制的脉冲神经网络(SNN)无监督学习方法,如图 18 所示。该网络结构简单,只有输入层、激活层和抑制层 3 层结构,网络核心是激活层和抑制层,其每一层只有神经元和突触 2 个基本单元构成,前后神经元之间通过突触连接,连接的突触权大小表达前神经元触发脉冲传导到后神经元的导电强弱。该文中,神经元膜电位的变化选择了泄漏整合放电(LIF)模型,突触权的学习更新过程基于无监督的时空依赖可塑性(STDP)机制进行。通过激活和抑制层的控制将输入信号转为触发脉冲序列,最后根据触发脉冲序列的分布情况进行分类识别。结果证明,在不一致坏样本数据集和非均衡数据集上进行测试,无监

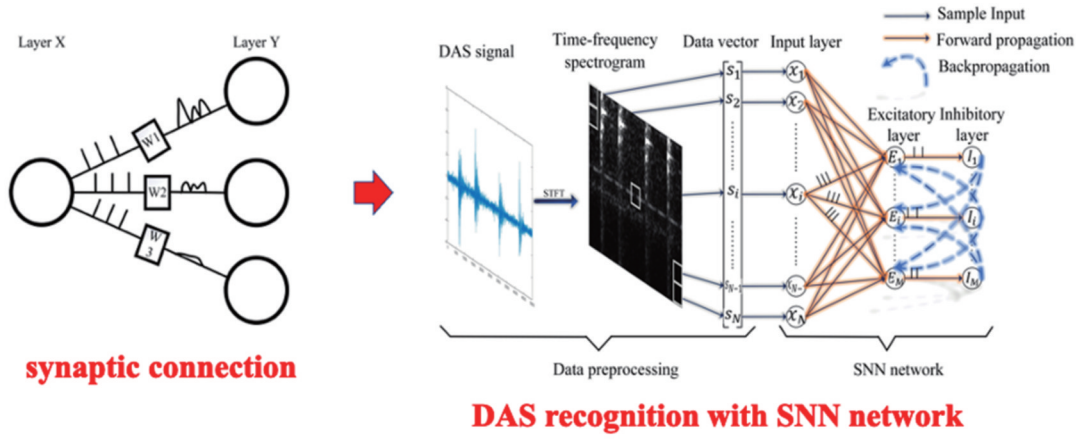


图 18 基于 SNN 的 DAS 无监督学习网络^[87]

Fig. 18 SNN-based DAS unsupervised learning network^[87]

督 SNN 比监督 CNN 性能更加稳定,泛化能力明显提高。

3.2.3 DAS 跨场景迁移学习方法

目前,大多数 DAS 信号识别方法仅在单一场景下有效,在新场景的应用环境下,需要重新收集和标记大量的训练数据,对网络进行再训练,这对学习的硬件计算能力要求较高,而且给 DAS 的长距离跨场景应用带来挑战。迁移学习基于源域的预训练网络(包含目标域的一般分类知识),利用已有知识和新知识之间的相似性,用已有的源域知识来学习目标域的新知识,可以更快更准确地在新场景上构建识别模型。因此,Shi

等^[88]提出了一种基于预训练 AlexNet 的 DAS 迁移学习方法,对于大规模图像数据集上预训练的 AlexNet 网络,用目标域的 DAS 信号样本微调 and 重新训练模型,用于新场景小规模训练集上的快速学习分类。随后,Li 等^[89]为进一步减少模型部署的训练时间,使用相同的预训练 AlexNet 模型提取 DAS 信号的可分辨特征,利用 SVM 对分类器进行优化,如图 19 所示,在不使用图形加速处理器(GPU)的情况下,通过只对 SVM 分类器重新训练得到新场景下的识别模型,将新模型的训练时间缩短至能满足小型嵌入式设备实时监测的需求,从而进一步降低了深度学习的使用门槛。

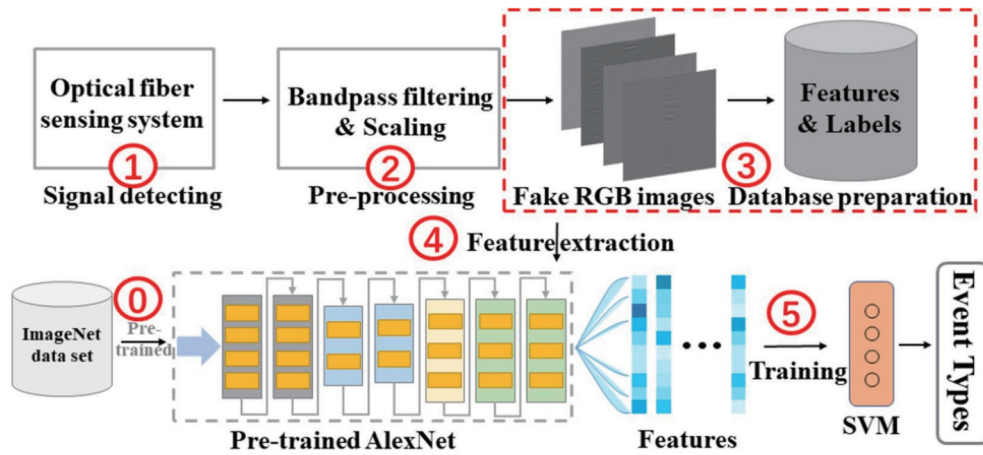


图 19 基于 AlexNet+SVM 的 DAS 迁移学习网络^[89]

Fig. 19 DAS transfer learning network based on AlexNet+SVM^[89]

3.3 识别模型的性能评价指标

3.3.1 识别性能

以上识别模型的准确性和可靠性可以通过多种评价指标来衡量,如准确率、精确率、召回值、F1-score、虚警率/误警率、漏警率、ROC (Receiver Operating Characteristic) 曲线和 AUC (Area under Curve) 等,其中 6 个指标的计算均用到了混淆矩阵。混淆矩阵按照实际类别与预测类别的所有可能组合,分为 4 种情况:

真阳性 (TP)、真阴性 (TN)、假阳性 (FP) 和假阴性 (FN),如表 1 所示。若假设正(异常)类为 1,负(正常)类为 0; TP 指实际为 1、预测为 1,可用 N_{TP} 表示; TN 指实际为 0、预测为 0,可用 N_{TN} 表示; FP 指实际为 0、预测为 1,可用 N_{FP} 表示; FN 指实际为 1、预测为 0,可用 N_{FN} 表示。

准确率 (A) 反映模型正确判断样本正确与否的能力,它表示预测正确的样本占所有样本的比例,可表

表 1 二分类问题的混淆矩阵

Table 1 Confusion matrix of binary classification

Item	Positive (true label, abnormal)	Negative (true label, normal)
Positive (predicted label)	TP	FP
Negative (predicted label)	FN	TN

示为

$$A = \frac{N_{TP} + N_{TN}}{N_{TP} + N_{FN} + N_{FP} + N_{TN}} \quad (2)$$

精确率(P)反映模型正确预测正样本精度的能力,它表示预测为正类的样本中有多少是真正的正类样本,可表示为

$$P = \frac{N_{TP}}{N_{TP} + N_{FP}} \quad (3)$$

召回值(R),也称为真阳率、命中率,反映模型正确预测正样本全度的能力,即正样本被预测为正样本占总正样本的比例,可表示为

$$R = \frac{N_{TP}}{N_{TP} + N_{FN}} \quad (4)$$

F1-Score 是一种衡量最终预测结果的指标,它将精确率和召回值结合,以体现总体预测结果。精确率越高,召回值就越低;而召回值越高,精确率也就越低。因此,F1-Score 是二者的调和平均数,可以用来衡量这两者的综合效果,以更好地评估预测的整体表现,可表示为

$$F_1 = \frac{2PR}{P + R} \quad (5)$$

式(5)中 F_1 的取值范围是 0 到 1,1 代表最好,0 代表最差。

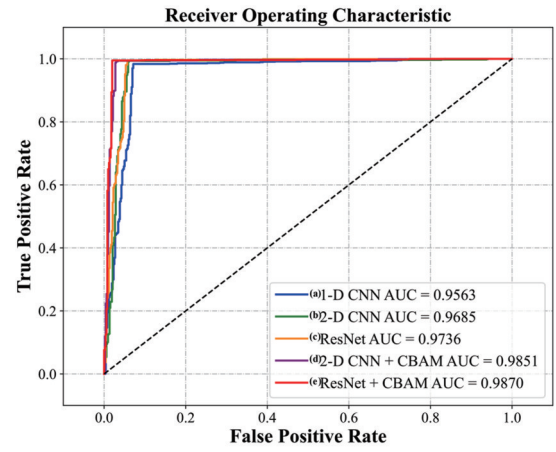
AUC 是指 ROC 曲线下的面积,ROC 曲线是指受试者工作特征曲线,它的横轴为假阳率(N_{FP}),纵轴为真阳率(N_{TP}),如图 20 所示。AUC 实际上是沿 ROC 横轴的积分结果。通常情况下,ROC 曲线处于 $y=x$ 的上方,所以 AUC 的值总是在 0.5~1 之间。AUC 值越大,代表模型的性能越好。

此外,在模型的实际应用中,虚警率/误警率(F_{AR})和漏警率(M_{AR})也是评价算法性能好坏的常用指标。虚警率/误警率指的是本来正常的样本被判定为异常的概率,计算公式为

$$F_{AR} = \frac{N_{FP}}{N_{FP} + N_{TN}} \quad (6)$$

漏警率指的是本来异常的样本被判定为正常的概率,计算公式为

$$M_{AR} = 1 - R = \frac{N_{FN}}{N_{TP} + N_{FN}} \quad (7)$$

图 20 不同模型的 ROC 曲线^[72]Fig. 20 ROC curves for different models^[72]

3.3.2 处理时间

DAS 识别模型的处理时间及其实时性通过以下 4 个指标进行衡量评估:1) 模型大小;2) 以乘加累积操作(MACs)为评价指标的模型计算复杂度;3) 模型的离线训练时间;4) 单空间点样本信号的在线测试时间。模型大小通常指的是模型参数数量的多少,它与模型占用空间有一定差异,通常模型占用空间=模型参数数量×每个参数的字节数。MACs 是模型参与卷积等运算过程中的乘加计算量,可以通过程序统计得到。模型的离线训练时间通常指从模型初始化到模型调整收敛所用的时间或参与迭代的周期数。模型在线处理时间则可以统计单空间点样本的测试时间。模型的离线训练时间和在线测试时间需要在相同的计算平台上进行测试。

本文对 3.1 和 3.2 节提及的关键 DAS 识别算法进行以上相关性性能指标的统计比较,如表 2 所示。值得注意的是,表 2 内容是基于相关发表文章提及的数据进行统计,基于数据训练的算法模型在不同数据集上测试性能差异较大,因此,比较不同模型的识别性能和处理时间时,建议在相同数据集、相同测试平台等条件下进行公平比较。

4 DAS 智能感知新挑战

4.1 从单源检测到多源混叠检测

在大范围城市安全监测应用中,地面交通(地铁、高铁、公路车辆等)、工厂生产、生活噪声及地下施工、地震等多种振动源共同存在,近百米范围内两三个振动源同时作用光纤的概率大,如图 21 所示,DAS 传感信号中多源混叠现象频繁发生,适用于单源处理的信号检测识别算法性能将急剧下降甚至失效,这制约其在复杂城市环境中的应用。

表 2 关键 DAS 信号识别算法及其性能比较

Table 2 Comparison of key DAS signal recognition algorithms and their performance

Institution	Information extraction	Model/method	$A / \%$	$P / \%$	$R / \%$	F_1	$F_{AR} / \%$	$M_{AR} / \%$	IDT	Application scenario	Ref. No
University of Electronic Science and Technology of China	Time	1-D CNN	98.19	97.95	97.16	0.9753	—	—	27.0 ms	Pipeline	[58]
Huazhong University of Science and Technology	Time	1-D CNN + DenseNet	98.40	—	—	—	—	—	2.00 ms	Cable	[62]
Beijing Jiaotong University	Time	DBN-GRU	96.72	—	—	—	—	1.83	79.0 ms	Cable	[63]
Jinan University	Time	DRSN-NTF	92.82	—	—	0.9167	—	—	—	Perimeter security	[64]
Anhui University	Time (multi-scale)	MS 1-D CNN	96.59	—	—	—	—	—	—	Perimeter security	[65]
Tianjin University	Time (multi-scale)	MSCNN + CPL	84.67	—	—	—	—	—	17.0 ms	Perimeter security	[66]
University of Electronic Science and Technology of China	Time (multi-scale, long-short-term)	mCNN + HMM	98.10	98.08	98.08	0.9805	—	—	67.0 ms	Cable	[67]
Tianjin University	Time (multi-scale, long-short-time)	LSTM + CNN	94.60	—	—	—	—	—	—	Perimeter security	[68]
University of Shanghai for Science and Technology	Time	SSGAN	88.94	—	—	—	—	—	—	Perimeter security	[84]
Beijing Jiaotong University	Time	Semi-supervised FixMatch	97.91	97.93	97.96	—	—	2.04	—	Railway	[86]
UGES of Türkiye	T-F	2D CNN	93.00	98.10	—	—	—	—	—	Cable	[70]
Beijing Institute of Technology	T-F	2D CNN	97.18	98.02	97.99	0.9798	—	—	—	Cable	[69]
Hubei University of Technology	T-F	2D CNN	97.22	93.66	91.90	0.9267	—	8.10	—	Perimeter security	[71]
Zhejiang University	T-F	2D CNN + SVM	93.30	—	—	—	—	—	—	Cable	[59]
University of Electronic Science and Technology of China	T-F	ResNet + CBAM	98.89	98.58	98.68	0.9863	—	—	3.30 ms	Cable	[72]
University of Cologne	T-F	ALSTM	94.30	—	—	—	—	—	0.910 s	Cable	[81]
University of Electronic Science and Technology of China	T-F	Unsupervised SNN	96.52	—	—	—	—	—	0.364 s	Cable	[87]

续表

Institution	Information extraction	Model/ method	A / %	P / %	R / %	F_1	$F_{AR} / %$	$M_{AR} / %$	IDT	Application scenario	Ref. No
Russian Academy of Sciencesul	T-S	2D CNN	91.20	92.06	—	0.9138	—	—	—	Perimeter security	[60]
University of Applied Sciences, Austria	T-S	2D CNN	99.91	—	—	—	—	—	34.3 μ s	Pipeline	[61]
Tongji University	T-S	2D CNN	98.00	—	—	—	—	—	—	Pipeline	[73]
Tianjin University	T-S	2D CNN+ YOLO	—	70.40	82.90	—	—	17.1	—	Pipeline	[74]
University of Electronic Science and Technology of China	T-S	1D CNNs- BiLSTM	97.00	97.06	96.90	0.9706	—	3.10	49.0 ms	Cable	[75]
North China Electric Power University	T-S	MATCN	98.50	—	—	—	—	—	0.530 s	Perimeter security	[79]
Sichuan University	T-S	2D CNN + LSTM	85.60	—	—	0.8870	8	—	1.24 s	Railway	[82]
Qilu University of Technology	T-S	100G-Net	99.60	—	—	—	—	—	20.0 ms	Perimeter security	[76]
Southern University of Science and Technology	T-S	Faster RCNN	96.32	—	—	—	—	—	0.160 s	Cable	[77]
	T-S	YOLO	96.14	—	—	—	—	—	43.8 ms	Perimeter security	[78]
Shantou University	T-S	Transfer learning	96.16	—	—	—	—	—	—	Cable	[88]
			94.67	—	—	—	—	—	3.05 ms	Cable	[89]
Tsinghua University	T-S	SSAE	97.90	—	97.38	—	—	2.62	1.73 ms	Pipeline	[85]
Shanghai Institute of Optics and Fine Mechanics, Chinese Academy of Sciences	S-F	DPN	99.28	99.28	99.28	0.9700	—	0.72	—	Railway	[80]

Notes: T-F represents time-frequency; T-S represents time-space; S-F represents space-frequency; IDT represents identification time.

Wu等^[90]提出的基于多尺度小波分解的 Φ -OTDR信噪分离方法,在非线性混合信号中有效提取入侵信号并分离波动的噪声背景,但不适用于主要频率分量重叠的多目标振动源分离。Wang等^[91]利用空间阵列信号合成的定向相干增强技术,提出DAS多源混叠目标声源信号增强及干扰抑制方法,从强宽带噪声中提取被淹没的弱目标信号。Tu等^[92]在传播速度恒定的假设条件下,利用不同位置振动源到达同一光纤接收点的时间差引起的振动相位差异,提出DAS双源混叠信号的分离方法。Wu等^[93]基于线性瞬时混叠模型假设,提出了基于快速独立成分分析(Fast ICA)盲源分离的地理DAS多源分离方法,如图22所示,仿真和实际现场混叠实验验证了其分离可行性。此外,Lü等^[94]针对MZI多源信号混叠现象提出基于时频注意的深度递归神经网络(TFA-DRNN),利用TFA和DRNN学习的信息构建时频掩码,将其作用于输入信号以获

取分离信号的STFT时频谱,这为基于深度学习的多源信号分离提供了初步的借鉴思路,但复杂场景下未知源数的多源非线性混叠及其实际有效的信号分离方法实现仍需要研究人员对多种信号处理技术的交叉应用进行深入的研究。

4.2 从单任务到多任务处理

4.2.1 从目标识别到定位估计

在各种安全监测应用中,DAS系统既要实现自然灾害、人为入侵等振动/声源的准确识别,也需要对该类目标事件进行精确定位,以实现精准预警。目前基于DAS的振动及声源定位研究方法主要借鉴传统的雷达天线定位或麦克风阵列的声学信号处理方法,针对不同目标的声学特征以及使用场景设计改进方案。2019年,Liang等^[95]将DAS视为分布式传感阵列,利用阵列信号处理——经典多信号分类(MUSIC)方法,实现空气中远场DAS声源的二/三维定位,初步验证了

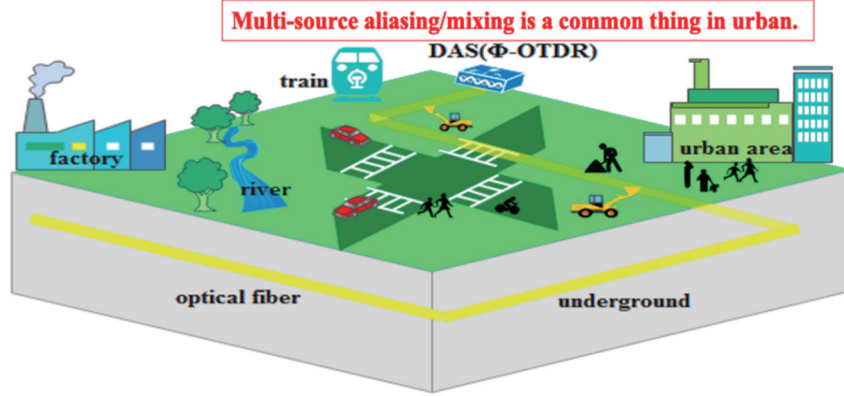


图 21 城市复杂监测环境中的多源混叠现象^[93]

Fig. 21 Multi-source aliasing phenomenon in complex urban environment^[93]




图 22 基于 Fast ICA 的 DAS 多源分离方法^[93]

Fig. 22 DAS multi-source separation method based on Fast ICA^[93]

二维空间同时定位多个频率相同的声源和三维空间定位一个移动的窄带声源的可行性, 这为 DAS 在静/动态目标、多目标的定位和识别领域的应用开辟新思路。2021 年, Lu 等^[96]将 MUSIC 阵列信号处理应用于水下, 准确实现了基于 Φ -OTDR 的分布式光纤水听器 (DOFH) 对水声信号源的定位和运动轨迹跟踪。MUSIC 法更适合在均匀介质中传播的远场窄带信号, 而对于复杂环境中传播的宽带信号定位仍是一个挑战。

此外, 基于到达时间差 (TDOA) 的 DAS 目标声源定位方法也备受关注。2021 年, Liu 等^[97]利用多个传感单元检测信号间的时间延迟, 实现了基于 TDOA 的 DAS 水声定位系统。DAS 光纤中以光速传播的信号保证了沿光纤分布的多个传感器之间的同步, 降低了 TDOA 法多个传感器同步问题对定位精度的影响。Muñoz 等^[98]进一步考虑了 DAS 各通道响应不均匀的影响, 认为声灵敏度较低或包含失真信号的信道会影响 TDOA 估计, 根据通道间相位互相关函数的峰值-均方根之比对每个 DAS 通道的测量可靠性进行评估和排序, 并提出一种基于近场阵列信号处理的 DAS 响应增强技术, 以对宽带声源的二维空间坐标进行全盲估计。

近年来, 随着新技术的不断发展, 也有新的基于机器学习模型的定位方案利用网络来学习 DAS 感知目

4.3 提升 DAS 智能感知能力的其他方法

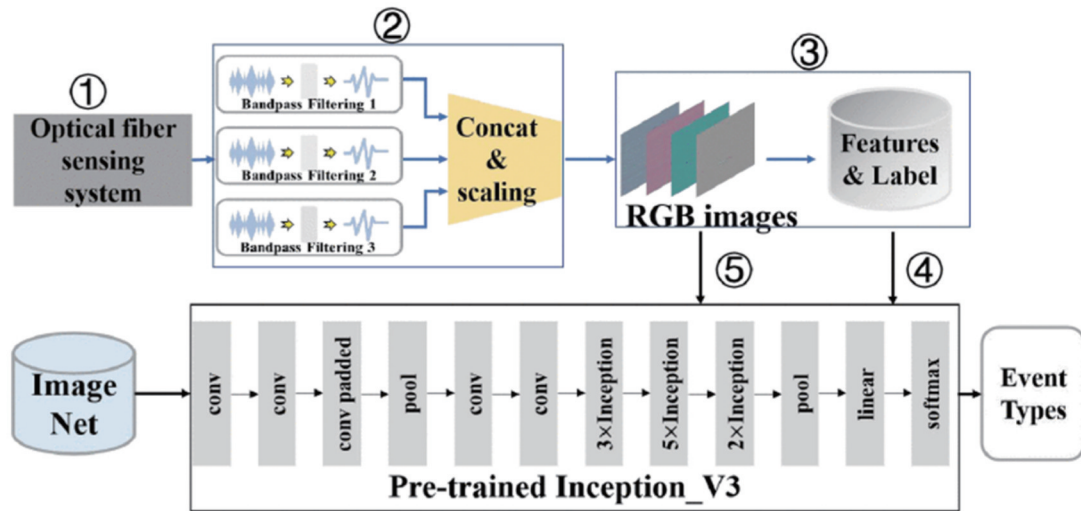
目前, 提升 DAS 智能感知能力的方法总的来说包

标信号的特征分布与位置之间的非线性映射关系。例如, Wu 等^[99]发现 DAS 振动源的空间能量分布特征与其在不同垂直偏移距离处的衰减规律有关, 提出一种基于协同能量特性的振动源定位方法。经过快速傅里叶变换和窄带滤波后, 计算某一垂距下不同光纤接收点上滤波后的信号功率, 利用 SVM 和 RF 构建的两阶段堆栈模型自动学习不同垂距目标的特征差异, 估计特定振动源的垂直偏移距离, 分级量化其对地理光纤的威胁程度。

4.2.2 识别与定位的多任务处理

当前大部分 DAS 后处理方法都还是只聚焦于振动或声源的识别或定位, 当面向实际应用中同时实现目标识别与定位的多任务需求时, 需要叠加不同处理算法, 这导致计算冗余, 时效性差。Shi 等^[100]提出一种基于深度学习的多径向距离事件分类方法, 采用 3 个带通滤波器增强时空样本的有效特征, 将其转换为 RGB 图像并输入 ImageNet 数据集预训练的多分类器模型即 Inception_V3 网络, 在 4 个径向距离上识别 5 种类型的振动事件, 最终达到 86.82% 的准确率。图 23 为基于深度学习的多径向距离事件分类方法, 图中①代表信号检测, ②代表数据预处理, ③代表数据库准备, ④代表离线训练, ⑤代表在线测试。在实际应用需求的驱动下, 需要在不增加算法冗余或计算开销的情况下对 DAS 多任务高效学习模型进行探索研究。

括增强识别模型的泛化能力和减少模型的处理时间两类。除了以上通过半监督、无监督、跨场景迁移学习方

图 23 基于深度学习的多径向距离事件分类方法^[100]Fig. 23 Multi-radial-distance event classification method based on deep learning^[100]

法来增强模型的鲁棒性和泛化能力的方法外,在监督学习网络中,通过 GAN^[101-102]对训练数据集进行数据增广,解决训练样本不够或不充分的问题,也是提升模型泛化能力的一类方法。随着研究人员对 DAS 深度学习网络广泛深入的研究,在实现精准识别模型设计、优化的同时,通过轻量化的网络结构设计提升模型的实时处理能力^[103]也是一个重要的研究方向。

5 结 论

DAS 信号处理及其感知能力的进一步提升仍面临新的挑战和机遇,也将开启全智能化 DAS 的新篇章。以深度学习为主线总结了当前全智能化 DAS 的信号处理研究现状,包括基于多维信息提取的监督学习到小样本(无样本)的半/无监督学习和快速高效的跨场景迁移学习,单源检测到多源混叠检测,单任务到多任务实现等的信号处理方法。新的复杂应用场景下稳定准确且实时高效的全智能化 DAS 信号处理仍然是未来分布式光纤传感领域的热点研究方向,具体包括:

1) 跨场景模型泛化能力的提升。提升 DAS 多维多域信息提取能力及全方位特征的利用率,并提升 DAS 采集的大量无标签数据的利用率,融合专家经验与深度学习知识,构建端对端性能更加优越的新模型或组合模型及具有增强泛化能力的域适应模型等,都是进一步提升跨场景模型泛化能力的有效解决途径。

2) DAS 实时处理能力的大幅提升。面向 DAS 目标识别及定位等多种功能的应用需求,在保证检测、识别及定位准确性的基础上,进行轻量级 DAS 识别及定位估计模型的设计与优化以提高 DAS 海量阵列数据的计算效率和实时处理能力,是 DAS 急需解决的一大问题。

3) DAS 多任务处理能力的提升。在 DAS 振动及

声源目标的识别、定位、跟踪等单任务精准实现的基础上,多种感知功能的同步高效实现也是 DAS 的一大发展方向。

4) 高性能片上 DAS 的实现。目前 DAS 的不同任务实现均是以上位机 GPU/CPU 的高强度计算为代价,而基于可编程逻辑阵列(FPGA)、数字信号处理器(DSP)等有限计算资源的嵌入式设备实现低功耗、低成本、小型化、智能型 DAS 也是未来值得研究的方向之一。

参 考 文 献

- [1] Williams E F, Fernández-Ruiz M R, Magalhaes R, et al. Distributed sensing of microseisms and teleseisms with submarine dark fibers[J]. *Nature Communications*, 2019, 10: 5778.
- [2] Jousset P, Currenti G, Schwarz B, et al. Fibre optic distributed acoustic sensing of volcanic events[J]. *Nature Communications*, 2022, 13: 1753.
- [3] Marra G, Clivati C, Luckett R, et al. Ultrastable laser interferometry for earthquake detection with terrestrial and submarine cables[J]. *Science*, 2018, 361(6401): 486-490.
- [4] Rao Y J, Wang Z N, Wu H J, et al. Recent advances in phase-sensitive optical time domain reflectometry (Φ -OTDR) [J]. *Photonic Sensors*, 2021, 11(1): 1-30.
- [5] Han B, Guan H J, Yao J Z, et al. Distributed acoustic sensing with sensitivity-enhanced optical cable[J]. *IEEE Sensors Journal*, 2021, 21(4): 4644-4651.
- [6] Sladen A, Rivet D, Ampuero J P, et al. Distributed sensing of earthquakes and ocean-solid Earth interactions on seafloor telecom cables[J]. *Nature Communications*, 2019, 10: 5777.
- [7] Lindsey N J, Dawe T C, Ajo-Franklin J B. Illuminating seafloor faults and ocean dynamics with dark fiber distributed acoustic sensing[J]. *Science*, 2019, 366(6469): 1103-1107.
- [8] 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.
- [9] Fernández-Ruiz M R, Garcia-Ruiz A, Martins H F, et al. Protecting fiber-optic links from third party intrusion using distributed acoustic sensors[C]//2017 19th International

- Conference on Transparent Optical Networks (ICTON), July 2-6, 2017, Girona, Spain. New York: IEEE Press, 2017.
- [10] Peng F, Duan N, Rao Y J, et al. Real-time position and speed monitoring of trains using phase-sensitive OTDR[J]. IEEE Photonics Technology Letters, 2014, 26(20): 2055-2057.
- [11] Wang Z Y, Lu B, Zheng H R, et al. Novel railway-subgrade vibration monitoring technology using phase-sensitive OTDR[J]. Proceedings of SPIE, 2017, 10323: 103237G.
- [12] 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与实现[J]. 光学仪器, 2012, 34(2): 61-66. 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.
- [13] 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.
- [14] 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.
- [15] 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.
- [16] Masoudi A, Belal M, Newson T P. A distributed optical fibre dynamic strain sensor based on phase-OTDR[J]. Measurement Science and Technology, 2013, 24(8): 085204.
- [17] Wang Z N, Zhang L, Wang S, et al. Coherent Φ -OTDR based on I/Q demodulation and homodyne detection[J]. Optics Express, 2016, 24(2): 853-858.
- [18] Dong Y K, Chen X, Liu E H, et al. Quantitative measurement of dynamic nanostrain based on a phase-sensitive optical time domain reflectometer[J]. Applied Optics, 2016, 55(28): 7810-7815.
- [19] Sha Z, Feng H, Zeng Z M. Phase demodulation method in phase-sensitive OTDR without coherent detection[J]. Optics Express, 2017, 25(5): 4831-4844.
- [20] 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.
- [21] Wu M S, Fan X Y, Zhang X P, et al. Frequency response enhancement of phase-sensitive OTDR for interrogating weak reflector array by using OFDM and vernier effect[J]. Journal of Lightwave Technology, 2020, 38(17): 4874-4882.
- [22] Zhang J D, Zheng H, Zhu T, et al. Distributed fiber sparse-wideband vibration sensing by sub-Nyquist additive random sampling[J]. Optics Letters, 2018, 43(9): 2022-2025.
- [23] Wang Z N, Zhang B, Xiong J, et al. Distributed acoustic sensing based on pulse-coding phase-sensitive OTDR[J]. IEEE Internet of Things Journal, 2019, 6(4): 6117-6124.
- [24] Gu J F, Lu B, Yang J Q, et al. High SNR Φ -OTDR based on frequency and wavelength diversity with differential vector aggregation method[J]. IEEE Photonics Journal, 2020, 12(6): 7103612.
- [25] Wu M S, Fan X Y, He Z Y. Phase noise compensation for ultra-highly sensitive fiber-optic quasi-distributed acoustic sensing system[C]//Conference on Lasers and Electro-Optics, May 5-10, 2019, San Jose, California. Washington, DC: OSA, 2019: SF3L.4.
- [26] Shao L Y, Liu S Q, Bandyopadhyay S, et al. Data-driven distributed optical vibration sensing: a review[J]. IEEE Sensors Journal, 2019, 20(12): 6224-6239.
- [27] Liehr S. Artificial neural networks for distributed optical fiber sensing[C]//Optical Fiber Communications Conference and Exhibition (OFC), June 6-10, 2021, San Francisco, California, United States. New York: IEEE Press, 2021.
- [28] Li J C, Wang Y, Wang P F, et al. Pattern recognition for distributed optical fiber vibration sensing: a review[J]. IEEE Sensors Journal, 2021, 21(10): 11983-11998.
- [29] Kandamali D F, Cao X M, Tian M L, et al. Machine learning methods for identification and classification of events in Φ -OTDR systems: a review[J]. Applied Optics, 2022, 61(11): 2975-2997.
- [30] Butter C D, Hocker G B. Fiber optics strain gauge[J]. Applied Optics, 1978, 17(18): 2867-2869.
- [31] 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.
- [32] Ölçer İ, Öncü A. Adaptive temporal matched filtering for noise suppression in fiber optic distributed acoustic sensing[J]. Sensors, 2017, 17(6): 1288.
- [33] Adeel M, Shang C, Zhu K, et al. Nuisance alarm reduction: using a correlation based algorithm above differential signals in direct detected phase-OTDR systems[J]. Optics Express, 2019, 27(5): 7685-7698.
- [34] van den Ende M, Lior I, Ampuero J P, et al. A self-supervised deep learning approach for blind denoising and waveform coherence enhancement in distributed acoustic sensing data[J]. IEEE Transactions on Neural Networks and Learning Systems, 2023, 34(7): 3371-3384.
- [35] 吴慧娟, 刘欣雨, 饶云江. 基于 Φ -OTDR 的光纤分布式传感信号处理及应用[J]. 激光与光电子学进展, 2021, 58(13): 1306003. Wu H J, Liu X Y, Rao Y J. Processing and application of fiber optic distributed sensing signal based on Φ -OTDR[J]. Laser & Optoelectronics Progress, 2021, 58(13): 1306003.
- [36] 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.
- [37] Fang N, Wang L T, Jia D J, et al. Walking intrusion signal recognition method for fiber fence system[C]//Asia Communications and Photonics Conference and Exhibition, November 2-6, 2009, Shanghai, China. Washington, DC: OSA, 2009: WL96.
- [38] 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. 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.
- [39] 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. 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.
- [40] 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. 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.
- [41] 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.
- [42] 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.
- [43] 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.
- [44] 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.
- [45] Tejedor J, Macias-Guarasa J, Martins H, et al. A novel fiber optic based surveillance system for prevention of pipeline integrity threats[J]. *Sensors*, 2017, 17(2): 355.
- [46] 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.
- [47] 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.
- 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.
- [48] Jia H Z, Liang S, Lou S Q, et al. A k -nearest neighbor algorithm-based near category support vector machine method for event identification of φ -OTDR[J]. *IEEE Sensors Journal*, 2019, 19(10): 3683-3689.
- [49] Abufana S A, Dalveren Y, Aghnaiya A, et al. Variational mode decomposition-based threat classification for fiber optic distributed acoustic sensing[J]. *IEEE Access*, 2020, 8: 100152-100158.
- [50] Wang Y, Wang P F, Ding K, et al. Pattern recognition using relevant vector machine in optical fiber vibration sensing system[J]. *IEEE Access*, 2019, 7: 5886-5895.
- [51] 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.
- [52] Wang X, Liu Y, Liang S, et al. Event identification based on random forest classifier for Φ -OTDR fiber-optic distributed disturbance sensor[J]. *Infrared Physics & Technology*, 2019, 97: 319-325.
- [53] Wang J, Hu Y Z, Shao Y C. The digging signal identification by the random forest algorithm in the phase-OTDR technology[J]. *IOP Conference Series: Materials Science and Engineering*, 2018, 394: 032005.
- [54] Timofeev A V, Groznov D I. Classification of seismoacoustic emission sources in fiber optic systems for monitoring extended objects[J]. *Optoelectronics, Instrumentation and Data Processing*, 2020, 56(1): 50-60.
- [55] 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.
- [56] 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.
- [57] 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.
- [58] 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.
- [59] 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.
- [60] Makarenko A V. Deep learning algorithms for signal recognition in long perimeter monitoring distributed fiber optic sensors[C]// 2016 IEEE 26th International Workshop on Machine Learning for Signal Processing (MLSP), September 13-16, 2016, Vietri Sul Mare, Italy. New York: IEEE Press, 2016.
- [61] Bublin M. Event detection for distributed acoustic sensing: combining knowledge-based, classical machine learning, and deep learning approaches[J]. *Sensors*, 2021, 21(22): 7527.
- [62] Zhang S X, He T, Fan C Z, et al. An intrusion recognition method based on the combination of one-dimensional CNN and DenseNet with DAS system[C]// Asia Communications and Photonics Conference 2021, October 24-27, 2021, Shanghai, China. Washington, DC: Optica Publishing Group, 2021: T1A. 3.
- [63] Liu M X, Wang X, Liang S, et al. Single and composite disturbance event recognition based on the DBN-GRU network in φ -OTDR[J]. *Applied Optics*, 2023, 62(1): 133-141.
- [64] 梁惠康, 谢浩桑, 黄红斌, 等. 基于改进深度残差收缩网络的分布式光纤声传感信号识别[J]. *激光与光电子学进展*, 2024, 61(5): 0506002.
- Liang H K, Xie H S, Huang H B, et al. Distributed optical fiber acoustic sensing signal recognition based on improved depth residual shrinkage network[J]. *Laser & Optoelectronics Progress*, 2024, 61(5): 0506002.
- [65] 吴俊, 管鲁阳, 鲍明, 等. 基于多尺度一维卷积神经网络的光纤扰动事件识别[J]. *光电工程*, 2019, 46(5): 79-86.
- 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.
- [66] Lü C G, Huo Z Q, Liu Y G, et al. Robust intrusion events recognition methodology for distributed optical fiber sensing perimeter security system[J]. *IEEE Transactions on Instrumentation and Measurement*, 2021, 70: 9505109.
- [67] Wu H J, Yang S Q, Liu X Y, et al. Simultaneous extraction of multi-scale structural features and the sequential information with an end-to-end mCNN-HMM combined model for fiber distributed acoustic sensor[J]. *Journal of Lightwave Technology*, 2021, 39(20): 6606-6616.
- [68] 王鸣, 沙洲, 封皓, 等. 基于 LSTM-CNN 的 φ -OTDR 模式识别[J]. *光学学报*, 2023, 43(5): 0506001.
- Wang M, Sha Z, Feng H, et al. φ -OTDR pattern recognition based on LSTM-CNN[J]. *Acta Optica Sinica*, 2023, 43(5): 0506001.
- [69] Li H L, Zhang Z H, Jiang F, 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.
- [70] 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.
- [71] 胡胜, 胡歆敏, 李莎莎, 等. 基于 GAF-HorNet 的 Φ -OTDR 周界安防监测研究[J]. *激光与光电子学进展*, 2024, 61(11): 1106005.
- Hu S, Hu X M, Li S S, et al. Research on Φ -OTDR perimeter security monitoring based on GAF-HorNet[J]. *Laser & Optoelectronics Progress*, 2024, 61(11): 1106005.
- [72] Liu X Y, Wu H J, Wang Y F, et al. A fast accurate attention-enhanced ResNet model for fiber-optic distributed acoustic sensor (DAS) signal recognition in complicated urban environments[J]. *Photonics*, 2022, 9(10): 677.
- [73] 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*, 2021, 20(4): 1704-1715.
- [74] 杨震, 封皓. 基于深度学习的 Φ -OTDR 输油管道入侵监测研究[J]. *激光与光电子学进展*, 2022, 59(8): 0806001.
- Yang Z, Feng H. Oil pipeline intrusion monitoring based on deep learning of Φ -OTDR[J]. *Laser & Optoelectronics Progress*, 2022, 59(8): 0806001.
- [75] 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.
- [76] Yan S, Shang Y, Wang C, et al. Mixed intrusion events recognition based on group convolutional neural networks in DAS system[J]. IEEE Sensors Journal, 2022, 22(1): 678-684.
- [77] Xu W J, Liu S Q, Yu F H, et al. Disturbance recognition for φ -OTDR based on Faster-RCNN[J]. Proceedings of SPIE, 2022, 12169: 121694U.
- [78] Xu W J, Yu F H, Liu S Q, et al. Real-time multi-class disturbance detection for Φ -OTDR based on YOLO algorithm [J]. Sensors, 2022, 22(5): 1994.
- [79] 尚秋峰, 黄达. 基于 MATCN 的光纤周界入侵信号识别方法 [J]. 光学学报, 2023, 43(20): 2006006.
Shang Q F, Huang D. Identification method of optical fiber perimeter intrusion signal based on MATCN[J]. Acta Optica Sinica, 2023, 43(20): 2006006.
- [80] Wang Z Y, Zheng H R, Li L C, et al. Practical multi-class event classification approach for distributed vibration sensing using deep dual path network[J]. Optics Express, 2019, 27(17): 23682-23692.
- [81] 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.
- [82] 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.
- [83] Wu H J, Wang C Q, Liu X Y, et al. Intelligent target recognition for distributed acoustic sensors by using both manual and deep features[J]. Applied Optics, 2021, 60(23): 6878-6887.
- [84] He J, Hu X, Zhang D W, et al. Semi-supervised learning for optical fiber sensor road intrusion signal detection[J]. Applied Optics, 2021, 61(6): C65-C72.
- [85] Yang Y Y, Zhang H F, Li Y. Long-distance pipeline safety early warning: a distributed optical fiber sensing semi-supervised learning method[J]. IEEE Sensors Journal, 2021, 21(17): 19453-19461.
- [86] Wang S L, Liu F, Liu B. Semi-supervised deep learning in high-speed railway track detection based on distributed fiber acoustic sensing[J]. Sensors, 2022, 22(2): 413.
- [87] Wu H J, Gan D K, Xu C R, et al. Improved generalization in signal identification with unsupervised spiking neuron networks for fiber-optic distributed acoustic sensor[J]. Journal of Lightwave Technology, 2022, 40(9): 3072-3083.
- [88] Shi Y, Li Y H, Zhang Y C, et al. An easy access method for event recognition of Φ -OTDR sensing system based on transfer learning[J]. Journal of Lightwave Technology, 2021, 39(13): 4548-4555.
- [89] Li Y H, Zeng X P, Shi Y. Quickly build a high-precision classifier for Φ -OTDR sensing system based on transfer learning and support vector machine[J]. Optical Fiber Technology, 2022, 70: 102868.
- [90] Wu H J, Zhang L Q, Qian Y, et al. Multi-scale wavelet decomposition and its application in distributed optical fiber fences[J]. Proceedings of SPIE, 2015, 9655: 96553U.
- [91] Wang Z Y, Yang J Q, Gu J F, et al. Multi-source aliasing suppression for distributed fiber acoustic sensing with directionally coherent enhancement technology[J]. Optics Letters, 2020, 45(20): 5672-5675.
- [92] Tu G J, Yu B L, Zhen S L, et al. Enhancement of signal identification and extraction in a Φ -OTDR vibration sensor[J]. IEEE Photonics Journal, 2017, 9(1): 7100710.
- [93] Wu H J, Liu Y M, Tu Y L, et al. Multi-source separation under two "blind" conditions for fiber-optic distributed acoustic sensor[J]. Journal of Lightwave Technology, 2022, 40(8): 2601-2611.
- [94] Lü C G, Niu Z H, Tian J C, et al. Identification of intrusion events based on distributed optical fiber sensing in complex environment[J]. IEEE Internet of Things Journal, 2022, 9(23): 24212-24220.
- [95] 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.
- [96] Lu B, Wu B Y, Gu J F, et al. Distributed optical fiber hydrophone based on Φ -OTDR and its field test[J]. Optics Express, 2021, 29(3): 3147-3162.
- [97] Liu Z C, Zhang L, Wei H M, et al. Underwater acoustic source localization based on phase-sensitive optical time domain reflectometry[J]. Optics Express, 2021, 29(9): 12880-12892.
- [98] Muñoz F, Soto M A. Enhancing fibre-optic distributed acoustic sensing capabilities with blind near-field array signal processing [J]. Nature Communications, 2022, 13: 4019.
- [99] 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.
- [100] Shi Y, Dai S W, Jiang T, et al. A recognition method for multi-radial-distance event of Φ -OTDR system based on CNN[J]. IEEE Access, 2021, 9: 143473-143480.
- [101] Shiloh L, Eyal A, Giryas R. Efficient processing of distributed acoustic sensing data using a deep learning approach[J]. Journal of Lightwave Technology, 2019, 37(18): 4755-4762.
- [102] Shi Y, Dai S W, Liu X Y, et al. Event recognition method based on dual-augmentation for a Φ -OTDR system with a few training samples[J]. Optics Express, 2022, 30(17): 31232-31243.
- [103] Yang Y Y, Li Y, Zhang T J, et al. Early safety warnings for long-distance pipelines: a distributed optical fiber sensor machine learning approach[J]. Proceedings of the AAAI Conference on Artificial Intelligence, 2021, 35(17): 14991-14999.

Signal Processing in Smart Fiber-Optic Distributed Acoustic Sensor

Wu Huijuan^{1*}, Wang Xinlei¹, Liao Haibei¹, Jiao Xiben¹, Liu Yiyu¹, Shu Xinjian¹,
Wang Jinglun¹, Rao Yunjiang^{1,2**}

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

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

Abstract

Significance Optical fiber sensors play an increasingly important role in safety monitoring areas in the smart Internet of Things (IoT). Particularly, a fiber-optic distributed acoustic sensor (fiber-optic DAS) based on the phase-sensitive optical time-domain reflectometry (Φ -OTDR) technology provides a highly dense, cost-effective, and continuous environment measurement way over a wide range. All kinds of vibration sources can be sensed and located with high sensitivity and precision utilizing the widely laid ordinary telecommunication cables, and thus fiber-optic DAS has been applied in various ground listening applications, such as natural disaster prediction of ocean-floor seismic activity, volcanic events, and earthquake, energy exploration in oil and gas industry, and civil infrastructure monitoring in the pipelines, railways, and perimeters. It leads to a new generation of large-scale fiber-optic IoT for ground and underwater listening technology. From the current research status in China and abroad, DAS is becoming mature in its hardware performance, such as the demodulation fidelity, sensing distance, detection bandwidth, and sensitivity, which are all approaching their perfection. However, with the rapid advance of DAS applications, the complicated and ever-changing environments for large-scale monitoring have brought about challenges of high false alarm rates due to its advantages of high sensitivity. It is difficult to achieve high-precision detection, recognition, and positioning of perceived vibration and acoustic targets, which has become the biggest technical bottleneck restricting the large-scale application of DAS technology. In recent years, driven by the development of advanced signal processing and artificial intelligence (AI) technology, the signal processing methods of fully intelligent DAS with high accuracy and real-time performance in practical complex environments have become a research hotspot and focus in the field of fiber-optic sensing. The signal processing method in DAS plays a crucial and decisive role in improving the intelligent perception ability of the entire system.

Progress We review the current research status of signal processing methods in smart fiber-optic DAS entering the deep learning stage, from mainstream supervised learning to unsupervised, semi-supervised, and transfer learning, from single-source detection to multi-source aliasing detection, and from single-task recognition or localization to simultaneous implementation of recognition and localization tasks, and we predict possible research directions for further improving the intelligent processing performance and perception ability of DAS in the future. Firstly, the typical fiber-optic DAS system structure and its vibration/sound sensing mechanism (Fig. 2), and the smart DAS and its signal processing architecture in smart city monitoring applications (Fig. 3) are introduced. Then, the signal processing methods based on deep learning are explained in detail, which includes the main stream of supervised learning methods based on multi-dimensional information extraction, and semi-supervised, unsupervised learning, and cross-scene transfer learning methods in DAS. For the supervised learning method, it includes DAS signal recognition models based on temporal information extraction, such as one-dimensional convolutional neural networks (1D-CNNs) (Fig. 4), multi-scale convolutional neural networks (MS-CNNs) (Fig. 5), multi-scale and contextual temporal relationship mining methods (Figs. 6–7), and the two-dimensional recognition models based on time-frequency (Figs. 8–11), time-space (Figs. 12–14), and space-frequency (Fig. 15) information extraction technologies. Besides, some other supervised methods are also included, for example, recognition models based on attention-based long short-term memory (Fig. 16) and the fusion of manual features and deep features. It proves that the combination of traditional empirical rules and deep learning networks can further reduce the false alarm rate of the system. In response to the problem of insufficient labeled samples in new scenarios in practical applications, several semi-supervised recognition methods based on the 1D-SSGAN (one-dimensional semi-supervised generative adversarial network), SSAE (sparse stacked autoencoder), and FixMatch models have been involved to achieve accurate recognition of DAS signals with a small amount of labeled data and a large amount of unlabeled data. Furthermore, the SNN-based DAS unsupervised learning network (Fig. 17) and the cross-scene transfer learning network based on AlexNet+SVM (Fig. 18) also appear to improve the generalization ability of DAS signal recognition methods. In order to evaluate the performance of these recognition models, we introduce seven indicators for evaluating the recognition accuracy and four indicators for the processing time of the algorithms. The above key DAS recognition methods and their performance are

statistically compared in Table 2. At last, the new challenges of smart DAS sensing, from single-source detection to multi-source aliasing detection, from target recognition to localization, and from a single task to multi-task processing, as well as other methods to enhance its intelligent perception capabilities, have also been introduced.

Conclusions and Prospects Further improvement of signal processing and its sensing capabilities still faces new challenges and opportunities and will open a new chapter in fully intelligent DAS. Stable, accurate, real-time, and efficient signal recognition in DAS in new complicated application scenarios remains a research hotspot in the field of distributed fiber-optic sensing in the future, including: 1) improving the generalization ability of DAS recognition models in cross scenarios; 2) significant improvement in real-time processing capabilities in DAS; 3) improvement of multi-task processing ability in DAS; 4) implementation of high-performance on-chip DAS.

Key words fiber-optic Internet of Things; phase-sensitive optical time domain reflectometry; fiber-optic distributed acoustic sensor; smart sensing; signal processing