

盛学文, 杨文辉, 徐亚磊, 等. 基于深度学习的光纤振动信号分类研究[J]. 智能计算机与应用, 2025, 15(1): 59-64. DOI: 10.20169/j. issn. 2095-2163. 250109

## 基于深度学习的光纤振动信号分类研究

盛学文, 杨文辉, 徐亚磊, 宗子轩, 许晨

(国家管网集团 华中分公司, 武汉 430021)

**摘要:** 管道在城市给排水, 油气输送等方面发挥着重要的作用, 管道的实时监测十分的重要。本文提出了一种采用深度学习的残差网络, 对分布式光纤振动传感系统收集到的光纤振动信号进行分类的技术。将光纤铺设在管道上, 将分布式光纤振动传感系统采集到的信号视作一维时间序列, 利用格拉米角场对一维时间序列进行编码得到对应的二维图像, 将二维图像输入深度学习残差网络进行分类, 实现对管道的实时监测。实验结果表明, 该方法比直接将一维数据转换为灰度图再输入到深度学习神经网络中具有更高的分类准确率。

**关键词:** 分布式光纤振动传感; 深度学习; 残差网络; 格拉米角场

中图分类号: TP312 文献标志码: A 文章编号: 2095-2163(2025)01-0059-06

### Design of simulation experiment for buried pipeline damage identification based on fiber optic vibration signal

SHENG Xuewen, YANG Wenhui, XU Yalei, ZONG Zixuan, XU Chen

(Central China Branch of China National Petroleum & Natural Gas Pipeline Network Group Co. Ltd, Wuhan 430021, China)

**Abstract:** Pipeline plays an important role in urban water supply and drainage, oil and gas transmission and so on. Real-time monitoring of pipeline is very important. In this paper, a deep learning residual network is proposed to classify the optical fiber vibration signals collected by distributed optical fiber vibration sensing system. The optical fiber was laid on the pipeline, and the signals collected by the distributed optical fiber vibration sensing system were regarded as one-dimensional time series. The Grami Angle field was used to encode the one-dimensional time series to obtain the corresponding two-dimensional images. The two-dimensional images were input into the deep learning residual network for classification, so as to realize the real-time monitoring of the pipeline. Experimental results show that this method has higher classification accuracy than converting one-dimensional data into gray image and then input it into deep learning neural network.

**Key words:** distributed fiber optic vibration sensing; deep learning; residual network; Grami Angle field

## 0 引言

管道在现代城市建设中起着不可或缺的作用, 在城市给排水系统、油气输送系统中都发挥着重要的作用。随着使用时间的增加, 管道会出现各种各样的损害, 从而发生泄漏。对管道进行实时监测十分重要。目前, 管道泄漏检测方法主要有负压波检测法<sup>[1]</sup>、压力梯度监测法<sup>[2]</sup>、质量平衡监测法<sup>[3]</sup>、声

波检测法<sup>[4]</sup>等。但是, 这些方法均存在产生误报信号、定位精度差、不适用于小范围泄露等问题。分布式光纤检测法作为当今新涌现的管道泄漏检测方法有抗电磁干扰强、绝缘性好、耐腐蚀耐高压、可以实现长距离探测等优点<sup>[5]</sup>, 同时光学传感器也具有许多有用的特性, 其中包括重量轻、成本低、体积小、部署灵活, 以及能够在高压<sup>[6]</sup>、高/低温<sup>[7-8]</sup>和高电磁场<sup>[9]</sup>下工作而不会降低其性能的特性。机器学习

**基金项目:** 国家自然科学基金(62275153, 62005165); 上海产业协同创新项目(HCXBCY-2022-006)。

**作者简介:** 杨文辉(1981—), 男, 学士, 工程师, 主要研究方向: 网络通信; 徐亚磊(1990—), 男, 学士, 工程师, 主要研究方向: 管道保护及光通信管理; 宗子轩(1991—), 男, 硕士, 工程师, 主要研究方向: 管道保护及光通信管理; 许晨(1988—), 男, 学士, 工程师, 主要研究方向: 管道保护及光通信管理。

**通信作者:** 盛学文(1994—), 男, 学士, 工程师, 主要研究方向: 光传输系统, 安防。Email: 13701867620@163.com。

收稿日期: 2023-07-19

的重要组成部分是信号特征的选择和表示,但是这些特征需要根据工作经验来设计,可能会丢失信号的一些重要局部特征。深度学习算法以自动化的方式进行特征提取,这样可以节省大量的时间与人力成本,就能提取出具有辨别力的特征。因此在光纤振动信号识别领域,深度学习是目前最热门的方法之一<sup>[10-11]</sup>。

目前,基于深度学习的光纤振动信号识别有仅通过一维卷积神经网络(One-Dimensional Convolutional Neural Network, 1D-CNN)算法,以及 LSTM 算法实现光纤振动信号的模式识别。孔勇等<sup>[12]</sup>通过经验模态分解与带有 3 个卷积层的 1D-CNN,对汽车通过、挖掘机挖掘、破路机工作的光纤振动信号实现了分类和识别。管鲁阳等<sup>[13]</sup>设计了一种多尺度 1D-CNN(有 3 个并行的 4 层多尺度卷积层),并行的 3 个 4 层多尺度卷积层,采用不同尺度的卷积核提取信号中,从高到低的频率特征成分以及从短到长的时域特征成分,对汽车通过、挖掘机挖掘、破路机工作的光纤振动信号实现了分类和识别。通过二维卷积神经网络(Two-Dimensional Convolutional Neural Network, 2D-CNN)和时频图实现光纤振动信号的模式识别,Wen 等<sup>[14]</sup>通过快速傅里叶变换,将每一段中的时域信号变换到频域后,将幅频旋转 90°,将谱幅度映射到灰度(0~255)值。振幅越高,对应区域越暗。信号的时频表示称为频谱图,通过一个 2D-CNN(多分类 SVM 替代 Softmax)对频谱图进行分类,再结合 1D-CNN 和二维卷积神经网络 2D-CNN 进行特征提取实现光纤振动信号识别。吴世海等<sup>[15]</sup>构造了一种新的双输入卷积神经网络,将滤波后的原始一维信号输入到三层一维 CNN 中,将滤波后的二维小波时频图输入两层二维 CNN。将两个特征输入到两个完全连接层,然后使用 Softmax 逻辑回归模型进行分类识别,

实现了对汽车通过、挖掘机挖掘、破路机工作的光纤振动信号的分类和识别。

虽然将分布式光纤振动信号转换为二维图像,再运用现有的深度学习神经网络进行分类,但在转换过程中忽略了数据之间的关联性,往往不能取得很好的效果。因此,本文将分布式光纤振动信号视为一维时间序列,然后采用格拉米角场对一维时间序列进行编码,得到对应的二维图像,将得到的二维图像输入到残差网络中实现对光纤振动信号的分类。

## 1 实验原理与方法

### 1.1 分布式光纤传感系统的基本原理

光在光纤中发生散射产生各种类型的散射光,光的偏振、强度、相位、波长特性受到外界环境温度、压力、振动等物理量的调制<sup>[16-19]</sup>,因此可以通过检测散射光的光学特性来实现对这些物理量的传感。

分布式光纤传感系统如图 1 所示,激光调制模块主要由声光调制器、掺铒光纤放大器和环形器等三部分完成。激光作为整个系统的光源,在发射端发射出连续的激光,为系统提供超窄带线宽光信号使系统正常工作。激光经过声光调制器后被调制为光脉冲信号,光脉冲信号再经过掺铒光纤放大器放大之后,再通过环形器进入传感和传导模式。传感和传导模式是由单模光纤组成,完成这个模块的所有功能。传感光纤在感知到扰动事件发生的时候,产生的后向瑞利散射信号经过环形器传输到信号接收与处理模块。信号接收与处理模块如图 1 中的数据收集卡部分,一般由光电二极管、模数转换器以及计算机等组合。经过分布式光纤后向瑞利散射的信号首先经过光电二极管接受,再经过放大器对信号进行放大,信号经过模数转换器可以实现光信号到电信号的转变,最后信号再经过计算机进行储存。

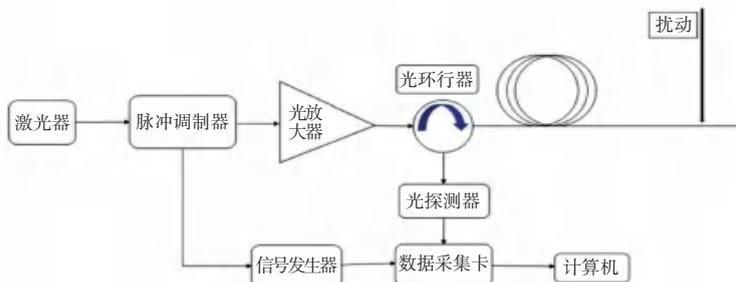


图 1 分布式光纤传感系统

Fig. 1 Distributed optical fiber sensor system

### 1.2 基于格拉米角场的数据编码

当将一维序列转换为对应的二维图像时,使用深度学习可以获得更好的效果。本文提出了一种基于格拉米角场的编码方式,将分布式光纤振动信号转换为二维图像。本文中的分布式光纤振动信号,可以当作一种特殊的时间序列去处理。转换过程如图 2 所示。

格拉姆角场(Gramian Angular Field, GAF)方法的原理,是将得到的一维时间序列数据从直角坐标

系转换为极点坐标系,并通过考虑不同点之间的角度和角度差异,来识别不同时间点的时间相关性。在 GAF 方法中,图像被认为是 **Gram** 矩阵,每个 **Gram** 矩阵是不同时间间隔之间的三角形。两种实现方法:格拉米求和角场 Gramian Angular Summation Fields, GASF) 和格拉米差分角场(Gramian Angular Difference Fields, GADF)。

**Gram** 矩阵可以由下式表示:

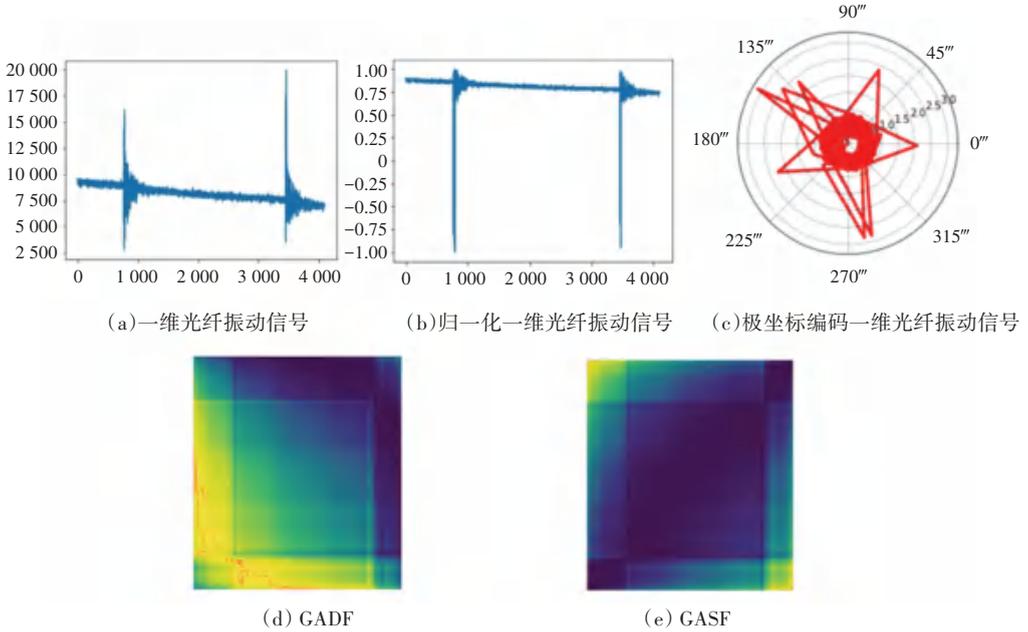


图 2 数据编码过程

Fig. 2 Data encoding process

$$G1 = \begin{pmatrix} \cos(\phi_{1,1}) & \cdots & \cos\phi_{1,n} \\ \vdots & \ddots & \vdots \\ \cos(\phi_{n,1}) & \cdots & \cos(\phi_{n,n}) \end{pmatrix} \quad (1)$$

其中,  $\phi_{n,n}$  是两个向量的角度。

单变量时间序列只能在一定程度上解释数据特征和潜在状态,因此应用了具有更丰富表示的 **Gram** 矩阵,其保留了时间依赖性。在实现后获得的 **Gram** 矩阵中,对角元素提供关于每个特征的信息,而其余元素提供关于这些特征彼此关系的信息。因此, **Gram** 矩阵不仅可以显示数据的特征,还可以反映不同特征之间的紧密联系。

在给定的时间序列  $X = \{x_1, x_2, \dots, x_n\}$  中,为了确保内部点不会偏向最大观测值,将  $X$  归一化使其分布到  $[-1, 1]$ , 归一化公式如下:

$$\tilde{x}_i = \frac{(x_i - \max(X)) + (x_i - \min(X))}{\max(X) - \min(X)} \quad (2)$$

其中,  $\max(X)$  和  $\min(X)$  分别表示序列中的最大值和最小值。

将缩放后的序列数据转换到极坐标系,即将数值看作夹角余弦值,时间戳看作半径,转换公式如下:

$$\begin{cases} \phi = \arccos(\tilde{x}_i), & -1 \leq \tilde{x}_i \leq 1, \tilde{x}_i \in \tilde{X} \\ r = \frac{t_i}{N}, & t_i \in N \end{cases} \quad (3)$$

式中:  $t_i$  是时间戳,  $N$  是标准化极坐标跨度的常数因子,  $\tilde{x}_i$  是时间序列归一化到  $[-1, 1]$  后的元素值,  $\phi$  是极坐标下的角度,  $r$  是极坐标下的半径。

这种转换有两个优点:整个编码是双射的,通过  $r$  坐标保持时间依赖性。

在将时间序列转换为极坐标形式后,可以考虑用角度表示与每个点之间的差异,以便从角度上确定不同时间间隔的时间依赖性。GASF 和 GADF 定义如下:

$$\begin{aligned} \text{GASF} &= [\cos(\phi_i + \phi_j)] = \tilde{X}' \cdot \tilde{X} - \sqrt{\mathbf{I} - \tilde{X}^2} \cdot \\ &\quad \sqrt{\mathbf{I} - \tilde{X}^2} \\ \text{GADF} &= [\sin(\phi_i - \phi_j)] = \sqrt{\mathbf{I} - \tilde{X}^2} \cdot \\ &\quad \tilde{X} - \tilde{X}' \cdot \sqrt{\mathbf{I} - \tilde{X}^2} \end{aligned} \quad (4)$$

其中,  $\tilde{X}$  是归一化后的时间序列,  $\mathbf{I}$  是单位向量。

变换后的极坐标可以表示为新的格拉米矩阵:

$$\mathbf{G2} = \begin{pmatrix} \cos(\phi_1 + \phi_1) & \cdots & \cos(\phi_1 + \phi_n) \\ \vdots & \ddots & \vdots \\ \cos(\phi_n + \phi_1) & \cdots & \cos(\phi_n + \phi_n) \end{pmatrix} \quad (5)$$

$$\mathbf{G3} = \begin{pmatrix} \sin(\phi_1 - \phi_1) & \cdots & \sin(\phi_1 - \phi_n) \\ \vdots & \ddots & \vdots \\ \sin(\phi_n - \phi_1) & \cdots & \sin(\phi_n - \phi_n) \end{pmatrix} \quad (6)$$

其中,  $\mathbf{G2}$  是 GASF 方法获得的 *Gram* 矩阵, 而  $\mathbf{G3}$  是 GADF 方法获得的 *Gram* 矩阵。因为分布式光纤振动信号的频率为 4 096 Hz, 所以这里的  $n$  取 64。

一维的时间序列经过上述步骤被编码成了二维图像。三类管道的分布式光纤振动信号转换成如图 3 所示的二维图像。

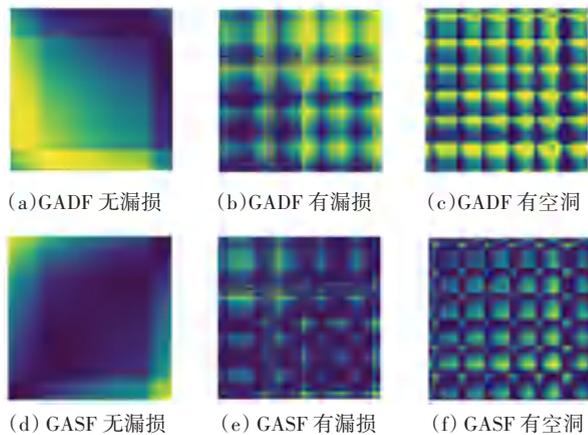


图 3 编码后 3 种信号类别示意

Fig. 3 Schematic representation of the three signal categories after encoding

### 1.3 ResNet

ResNet50 网络<sup>[20]</sup>的整体模型如图 4 所示, 在图 4 中将卷积块 CONV BLOCK (Convolution Block) 和残差块 ID BLOCK (Identity Block) 单独提取出来。网络输入模块由卷积层 CONV (Convolution) 和最大池化层 MAX POOL (Max Pooling) 组成, 中间使用激活函数 ReLU (Rectified Linear Unit, ReLU) 和批归一化层 Batch Norm 提升网络拟合能力; 4 个残差模块包含 CONV BLOC 和 ID BLOCK 两种残差结构。CONV BLOCK 输出的维度与输入的维度不同, 可用于网络维度的改变; ID BLOCK 输出的维度与输入的维度相同, 通过串联加深网络。在输出模块中, 特征经过池化层会将其转化为一个特征向量, 最后分类器会对这个特征向量进行计算并输出类别概率。

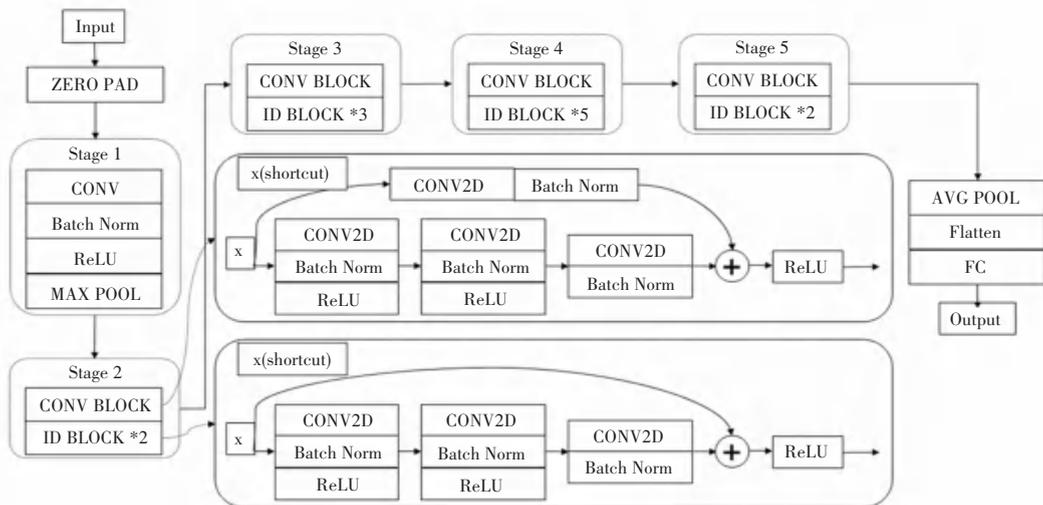


图 4 模型结构图

Fig. 4 Model structure diagram

## 2 实验结果分析

本文的数据集来自实际实验所得, 采用的光纤铺设方式如图 5 所示, 均采用缠绕的方式将光纤铺设在管道外壁并且将管道埋在地下。实验分别在有外界噪声干扰和无外界噪声干扰情况下, 采集了 3 种管道的情况。其中包括: 正常无漏损的管道、有漏损的管道、管道下方存在空洞。

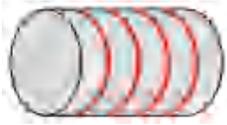


图 5 光纤铺设方式示例

Fig. 5 Example of fiber laying mode

如图 6 所示, 分别为正常无漏损的管道、有漏损的管道、管道下方存在空洞 3 种情况下, 分布式光纤振动信号经过格拉米角场 GADF、GASF 编码得到的二维图像, 灰度图则是将一维光纤振动信号归一化后再映射到  $[0, 255]$  上转换而来。其中, 无漏损的数据样本为 6 690 个, 有漏损的数据样本为 6 800 个, 管道下方存在空洞的数据样本有 6 880 个。实验中的训练集、测试集和验证集按照对应图像数量 8 : 1 : 1 的比例进行划分。

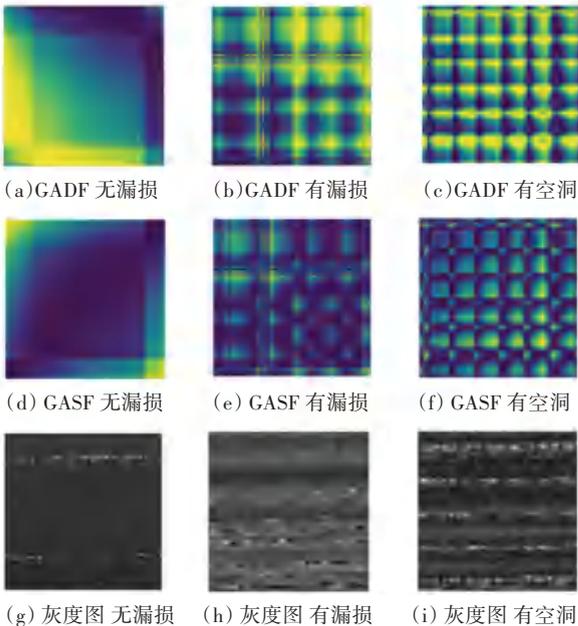


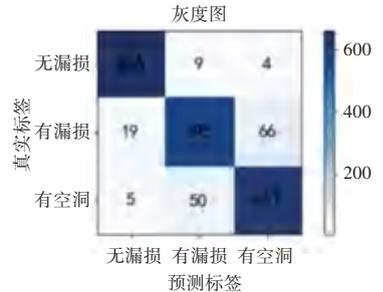
图 6 3 种不同管道情况下分布式光纤振动数据的 3 种不同编码方式  
 Fig. 6 Three different encoding methods of distributed optical fiber vibration data for three different pipeline cases

对图 6 中这 3 种编码方式分别进行训练, 然后进行对应的测试。得到的准确率见表 1, 混淆矩阵如图 7 所示。

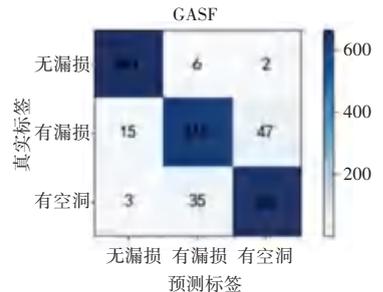
表 1 3 种不同编码方式识别准确率表

Table 1 Table of recognition accuracy for three different coding methods

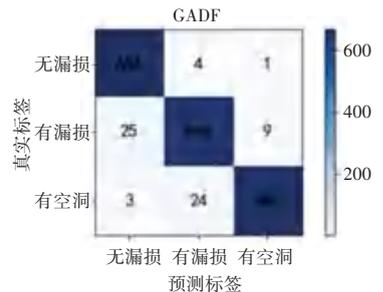
编码方式	准确率/%
灰度图	92.48
GASF	94.69
GADF	96.76



(a) 灰度图混淆矩阵



(b) GASF 混淆矩阵



(c) GADF 混淆矩阵

图 7 3 种编码方式的混淆矩阵

Fig. 7 Confusion matrix for the three encoding modalities

从表 1 可以看出, 深度学习神经网络对格拉米角场编码后时间序列图像的分类识别率均高于直接将一维序列转换为灰度图。相比灰度图, 将准确率平均提高了 3.51%, 而格拉米差分角场编码后的二维图像的分类准确率最高, 相比灰度图提升了 4.63%。从混淆矩阵中可以看出, 深度学习神经网络对于识别无漏损的管道准确率最高, 无论是哪种编码方式, 分类准确率都在 98% 以上。

## 3 结束语

本文提出了一种将分布式光纤振动信号作为一

维时间序列数据进行分析的方法,将一维时间序列经过格拉米角场编码为二维图像,并应用 Resnet-50 深度学习神经网络模型对无漏损管道,有漏损管道以及管道下有空洞这 3 种常见的管道情况进行分类和检测。通过格拉米角场的编码后,充分发挥 CNN 网络对二维图像的优异性能,大大提高了检测精度。实验表明,将分布式光纤振动数据视作一维时间序列并编码为二维时间序列图像并结合深度神经网络的优点进行分布式光纤振动信号分类的方法是非常有效的,经过格拉米差分角场编码后分类准确率能达到 96.76%。

在未来的研究工作中,计划在现有研究的基础上,尝试将一维和二维特征的跨模态融合,以进一步提高识别准确率。

## 参考文献

- [1] LI J, ZHENG Q, QIAN Z H, et al. A novel location algorithm for pipeline leakage based on the attenuation of negative pressure wave[J]. *Process Safety and Environmental Protection*, 2019, 123: 309-316.
- [2] XIE S J, DUAN Z R, LI J, et al. A novel magnetic force transmission eddy current array probe and its application for nondestructive testing of defects in pipeline structures[J]. *Sensors and Actuators A Physical*, 2020, 309(1): 112030.
- [3] MARTINS J C, SELEGHIM P. Assessment of the performance of acoustic and mass balance methods for leak detection in pipelines for transporting liquids[J]. *Journal of Fluids Engineering*, 2010, 132(1): 011401.
- [4] 崔勋杰. 天然气管道泄漏声波检测原理及定位方法[J]. *辽宁化工*, 2017, 46(2): 3.
- [5] WANG Z, ZHANG L, WANG S, et al. Coherent  $\phi$ -otdr based on I/Q demodulation and homodyne detection [J]. *Optics Express*, 2016, 24(2): 853.
- [6] KUMARI C U, SAMIAPPAN D, KUMAR R, et al. Fiber optic sensors in ocean observation; A comprehensive review[J]. *Optik*, 2019, 179: 351-360.
- [7] RORIZ P, FRAZÃO O, LOBO-RIBEIRO A B, et al. Review of fiber-optic pressure sensors for biomedical and biomechanical applications[J]. *Journal of Biomedical Optics*, 2013, 18(5): 50903.
- [8] GUPTA S, MIZUNAMI T, YAMAOT, et al. Fiber Bragg grating cryogenic temperature sensors [J]. *Applied Optics*, 1996, 35(25): 5202-5205.
- [9] TAFFONI F, FORMICA D, SACCOMANDI P, et al. Optical fiber-based MR-compatible sensors for medical applications; An overview[J]. *Sensors*, 2013, 13(10): 14105-14120.
- [10] LI J, WANG Y, WANG P, et al. Pattern recognition for distributed optical 291 fiber vibration sensing; A review[J]. *IEEE Sensors Journal*, 2021(10): 11983-11998.
- [11] KANDAMALI D F, CAO X M, TIAN M L, et al. Machine learning methods for identification and classification of events in  $\phi$ -OTDR systems; A review[J]. *Applied Optics*, 2022, 61(11): 2975-2997.
- [12] 吴虎,孔勇,王振伟,等. 基于 EMD 分解与 1-D CNN 算法的光纤振动信号的识别[J]. *激光与红外*, 2021, 51(8): 1043-1049.
- [13] 吴俊,管鲁阳,鲍明,等. 基于多尺度一维卷积神经网络的光纤振动事件识别[J]. *光电工程*, 2019, 46(5): 79-86.
- [14] WEN Tingkun, ZHU Pengyang, YE Wei, et al. Application of graphics processing unit parallel computing in pattern recognition for vibration events based on a phase-sensitive optical time domain reflectometer[J]. *Applied Optics*, 2019, 58(26): 7127-7133.
- [15] 吴世海,任梓豪,何抒航,等. 分布定位式光纤振动传感系统的事件识别[J]. *智能计算机与应用*, 2021, 11(9): 48-53.
- [16] DONG Y. High-performance distributed Brillouin optical fiber sensing[J]. *Photonic Sensors*, 2021, 11(1): 69-90. DOI: 10.1007/s13320-021-0616-7
- [17] PALMIERI L, SCHENATO L, SANTAGIUSTINA M, et al. Rayleigh-based distributed optical fiber sensing [J]. *Sensors*, 2022; 22(18): 6811. DIO: 10.3390/s22186811
- [18] ZHANG J, FENG C, ZHANG M, et al. Brillouin optical correlation domain analysis based on chaotic laser with suppressed time delay signature[J]. *Optics Express*, 2018, 26(6): 6962-6972.
- [19] KARAPANAGIOTIS C, KREBBER K. Machine learning approaches in Brillouin distributed fiber optic sensors[J]. *Sensors (Basel Switzerland)*, 2023, 23(13): 6187.
- [20] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition; A survey [C]//Proceedings of 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway, NJ: IEEE, 2016: 770-778. Doi: 10.1109/CVPR.2016.90