

基于格拉姆角场的分布式光纤振动信号识别技术

李俊^{1,2}, 姚瑞煦^{1,2*}, 任美莹¹, 张家瑞^{1,2}, 张新炜^{1,2}, 马天^{1,2}¹西安科技大学安全科学与工程学院, 陕西 西安 710054;²陕西省煤火灾防治重点实验室, 陕西 西安 710054

摘要 针对天然气管道沿线威胁事件的实时识别问题, 笔者提出了一种基于瑞利光时域反射分布式光纤振动监测系统 and 深度学习网络的方法。首先, 利用分布式光纤振动监测系统采集 28.9 km 长管道沿线 6 类事件的波形信号, 并通过格拉姆角场(GAF)将其转化为二维图像信息, 然后利用 GoogLeNet、VGG、AlexNet 三种深度学习网络对图像信息进行分类对比, 并分析了不同信噪比条件下 GoogLeNet 的分类效果。结果表明: GoogLeNet 对 6 类事件的分类准确率最高, 优于其他两种网络; 当信噪比为 8 dB 时, GoogLeNet 对人工挖掘和机械破坏事件数据进行滤波、GAF 等处理之后没有出现误报。本文所提方法适合在实际现场使用, 为管道安全监测提供了一种新的技术手段。

关键词 光纤光学; 管道监测; 格拉姆角场; 分布式光纤振动; 特征识别

中图分类号 X937

文献标志码 A

DOI: 10.3788/CJL230822

1 引言

长输油气管道是我国重要的能源命脉, 对于保障国家能源安全和经济发展具有重要意义。然而, 在复杂多变的管道周边环境中, 长输油气管道容易遭受人为破坏和第三方施工等事件的威胁^[1]。一旦发生管道泄漏事故, 将会造成油气资源的浪费和环境污染, 甚至会引发火灾、爆炸等灾难, 危及人民生命财产安全^[2]。因此, 实现对管道沿线第三方破坏事件的有效监测和准确识别是长输油气管道安全运行的关键。

分布式光纤振动监测技术是一种有效的管道沿线第三方破坏事件安全预警技术。该技术利用光纤作为传感器^[3], 在管道沿线布置传感光纤, 通过采集传感光纤产生的一维时间波形信号来监测管道沿线发生的各种事件, 并通过特征提取和分类算法来识别威胁管道安全的第三方破坏事件^[4]。

目前, 该领域常用的一维时间信号特征主要有时域特征^[5]、频域特征^[6]和时频域特征^[7]等, 常用的技术包括短时过零率^[8]、快速傅里叶变换(FFT)^[9]、梅尔频率倒谱系数(MFCC)^[10]、经验模态分解(EMD)^[11]、小波变换能量谱以及信息熵^[12]等技术。常用的分类算法主要为机器学习和深度学习算法^[13], 如支持向量机(SVM)^[14]、人工神经网络(ANN)^[15]、卷积神经网络(CNN)^[16]等。其中, 机器学习算法对已知的特征信息进行分类识别, 而深度学习算法对自主提取的图片特征信息进行分类识别。例如: 吴俊等^[17]提出了基于

CNN 的振动事件识别方法, 该方法通过端到端的方式对一维振动信号进行不同尺度的特征提取和识别, 识别率可达到 96% 以上; 吴虎等^[18]提出了 EMD 与 CNN 相结合的光纤振动信号的识别方法, 该方法的训练时间少于 3 min, 识别准确率可达 98.3%。这些方法虽然取得了一定效果, 但仍存在一些问题, 如特征提取方法没有充分利用信号的时频域信息, 分类算法参数数量多, 计算复杂度高。

基于此, 本文提出了一种基于格拉姆角场(GAF)和 GoogLeNet 的管道沿线第三方破坏事件识别方法。GAF^[19]是一种将时频域特征转换为图像特征的方法, 可以与 CNN 等深度学习模型结合, 提高对一维时间序列信号的分类性能。GoogLeNet^[20]是一种优化的 CNN 模型, 具有多层次、多尺度、多分支的特点, 可以有效地提取图像中的局部和全局特征, 同时可以减少参数量和降低计算复杂度。笔者通过 GAF 将分布式光纤振动监测系统采集获取的一维时间信号转换为二维图像信息, 保留了信号的完整信息和时间依赖性^[21]。笔者针对长输气管道实际运行过程中管道沿线 6 类典型事件(人工挖掘、机械破坏、噪声、人行走、车辆振动、流水振动)的波形信号进行采集, 采集时间为一周, 然后采用 GAF 算法对采集的信号进行处理, 接着采用 GoogLeNet 网络进行分类识别^[22]。结果显示, 所提方法相比同类方法具有更高的计算效率和识别能力。最后, 通过实验验证了所提方法的有效性。

收稿日期: 2023-05-10; 修回日期: 2023-05-25; 录用日期: 2023-08-07; 网络首发日期: 2023-08-15

基金项目: 国家自然科学基金青年科学基金(51904231)、榆林市科技局项目(CXY-2020-029)

通信作者: *437370716@qq.com

2 分布式光纤振动监测系统的硬件结构

采用本课题组自研的分布式光纤振动监测系统^[23]进行实验,如图 1 所示,该系统由超窄激光器(NLL)、隔离器(IO)、声光调制器(AOM)、掺铒光纤放大器(EDFA)、环形器、数据采集卡(DAQ)、光电探测器(PIN)、下位机(PC)和传感光纤等组成。

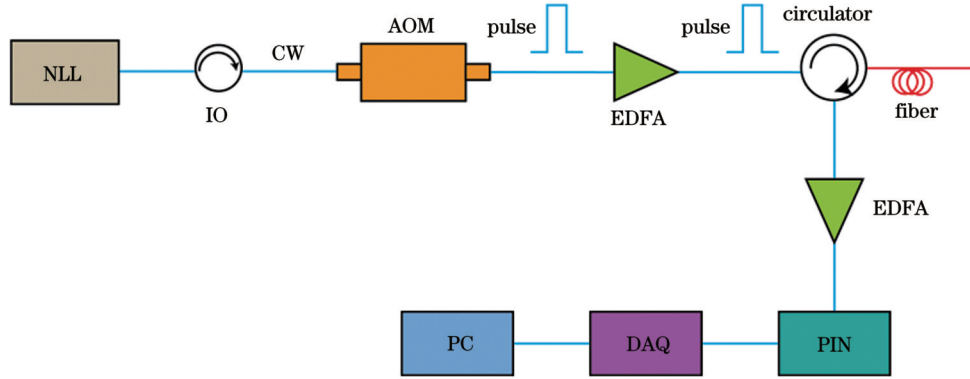


图 1 基于相位敏感光时域反射(φ -OTDR)的分布式光纤振动监测系统结构图

Fig.1 Schematic diagram of distributed optical fiber vibration monitoring system based on phase-sensitive optical time-domain reflection (φ -OTDR)

该系统采用线宽为 3 kHz 的窄线宽激光器,激光器的中心波长为 1550.12 nm,功率为 20 mW,脉宽设置为 100 ns,重复频率为 1 kHz。窄线宽激光器发出的光通过隔离器,以避免光纤中后向反射光对激光器的影响。系统中光纤放大器的增益均为 15 dB;数据采集卡采用上海简仪科技有限公司生产的 PCIe-

成。对于该系统,当窄线宽超短激光脉冲注入传感光纤后,光纤中沿传播方向返回的不同位置处的瑞利散射波会发生干涉。当有外界扰动发生时,扰动处的光纤长度和折射率均会发生改变,进而导致该处的光相位发生改变,从而进一步引起背向瑞利散射光强的变化。通过与未扰动时的背向瑞利散射曲线进行比较,可以进一步确定扰动点对应的位置^[24]。

9802DC,数据采集卡的最大采样率为 250 MSa/s;传感光纤采用单模光纤,纤芯的光折射率为 1.47。

分布式光纤振动监测系统的扰动图如图 2 所示。当外界发生扰动时,由于干涉的作用, φ -OTDR 系统的强度就会发生变化,从而可以获取扰动事件的类型和所处位置。




图 2 基于 φ -OTDR 的分布式光纤振动监测系统的扰动迹线图

Fig. 2 Disturbance trace diagram of distributed optical fiber vibration monitoring system based on φ -OTDR

3 信号分析

3.1 GAF 原理

分布式光纤振动监测系统采集的原始数据是含有

各种特征的时间序列信号,管道现场威胁安全的事件发生的时间是连续的,因此采集数据的特征与时间序列的前后信息有关。GAF 能够将时间序列数据转换为图像数据,从而既能保留信号的完整信息,也能保持

信号对时间的依赖性。将现场采集的原始信号数据转换为图像数据后就可以充分利用深度学习网络在图像分类识别上的优势,进行分类预警处理。主要的处理流程如下:

先把人工挖掘、机械破坏、噪声、人行走、车辆振动、流水振动等 6 类事件的振动信号规范化到区间 $[-1, 1]$ 。假设时间信号序列为 $\mathbf{X}=(x_1, x_2, \dots, x_n)$, 规范化后的值记为 \bar{x}_i , 其表达式为

$$\bar{x}_i = \frac{[x_i - \max(\mathbf{X})] + [x_i - \min(\mathbf{X})]}{\max(\mathbf{X}) - \min(\mathbf{X})}, i = 1, 2, \dots, n. \quad (1)$$

然后通过将时间戳作为半径和缩放值的反余弦来生成极坐标,将 \mathbf{X} 转化为极坐标下的时间序列 $\bar{\mathbf{X}}$ 。其中极坐标为

$$\begin{cases} \theta = \arccos(x_i), -1 \leq x_i \leq 1, x_i \in \mathbf{X} \\ r = \frac{t_i}{N} \end{cases}, \quad (2)$$

式中: t_i 为时间步; N 为极坐标下的正则化常数因子。最后根据编码过程生成格拉姆角和场(GASF)和格拉姆角差场(GADF),其中使用两角和的余弦函数得到 GASF,使用两角差的正弦函数得到 GADF。将每对值相加(相减),然后取余弦值后进行求和汇总,生成 2 种特征图像。

$$\mathbf{G}_{\text{GASF}} = \begin{bmatrix} \cos(\varphi_1 + \varphi_1) & \dots & \cos(\varphi_1 + \varphi_n) \\ \cos(\varphi_2 + \varphi_1) & \dots & \cos(\varphi_2 + \varphi_n) \\ \vdots & & \vdots \\ \cos(\varphi_n + \varphi_1) & \dots & \cos(\varphi_n + \varphi_n) \end{bmatrix} = \bar{\mathbf{X}}' \cdot \bar{\mathbf{X}} - \sqrt{\mathbf{I} - \bar{\mathbf{X}}'^2} \sqrt{\mathbf{I} - \bar{\mathbf{X}}^2}, \quad (3)$$

$$\mathbf{G}_{\text{GADF}} = \begin{bmatrix} \sin(\varphi_1 - \varphi_1) & \dots & \sin(\varphi_1 - \varphi_n) \\ \sin(\varphi_2 - \varphi_1) & \dots & \sin(\varphi_2 - \varphi_n) \\ \vdots & & \vdots \\ \sin(\varphi_n - \varphi_1) & \dots & \sin(\varphi_n - \varphi_n) \end{bmatrix} = \sqrt{\mathbf{I} - \bar{\mathbf{X}}'^2} \cdot \bar{\mathbf{X}} - \bar{\mathbf{X}}' \sqrt{\mathbf{I} - \bar{\mathbf{X}}^2}, \quad (4)$$

式中: \mathbf{I} 为单位行向量; $\bar{\mathbf{X}}'$ 是 $\bar{\mathbf{X}}$ 的转置向量。在最后生成的 GAF 特征图像中,从左上角到右下角,时间和像素点增加,从而保留了原始数据的相关性。

振动信号的 GAF 图像编码过程如图 3 所示。图 3(c) 横纵坐标表示时间,从左上角到右下角时间是递增的,颜色代表计算出来的 GAF 值:黄色表示 GAF 值为 1,蓝色表示 GAF 值为 -1。 $[-1, 1]$ 表示两两数据之间的

相关性, -1 表示联系最不紧密, 1 表示联系最紧密。GAF 通过极坐标中的半径表示时间戳,通过角度表示时间序列数值,通过半径 r 保持序列的时间依赖性。

3.2 单频信号的 GAF 数值仿真

对 50、80、100 Hz 正弦信号的 GAF 变换进行仿真。由图 4(a)~(f) 可以看出:随着频率增加, GAF 图像中黄蓝相间的点数增加。这说明 GAF 具有表征信号不同频率信息的能力。

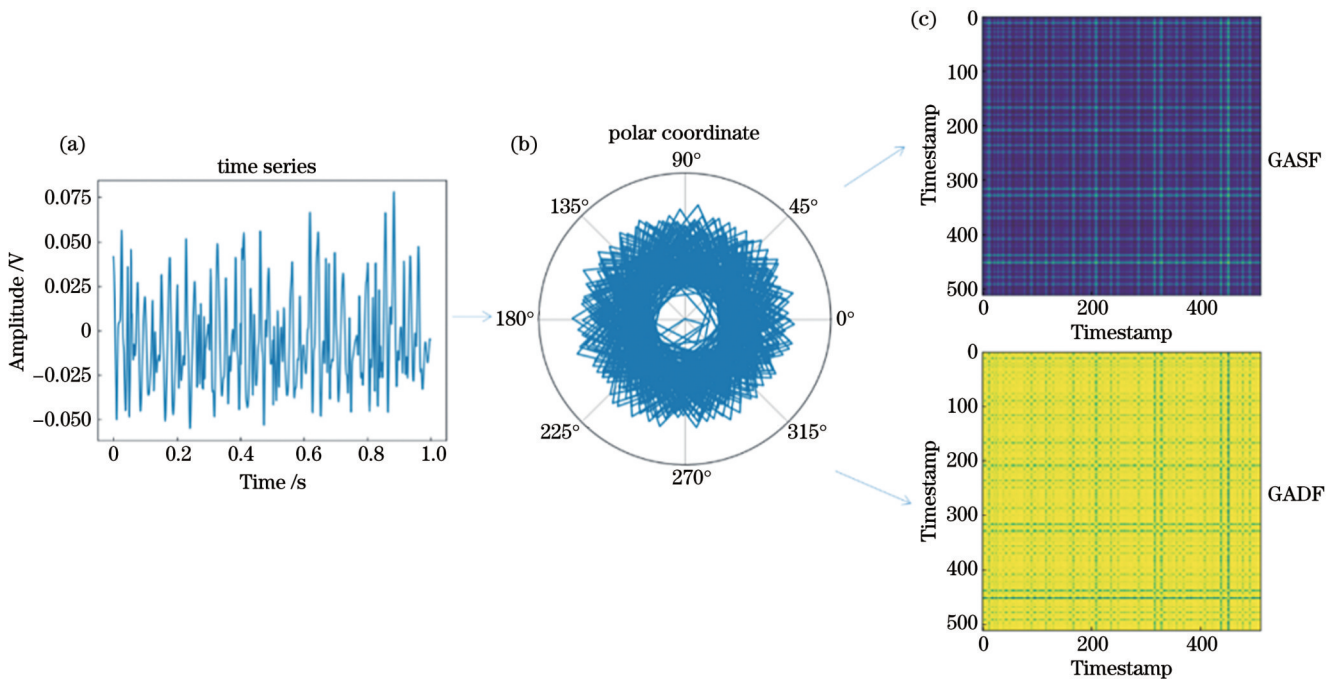


图 3 人工挖掘振动信号 GAF 图像的编码过程图

Fig. 3 Diagram of GAF image encoding process for manual excavation vibration signal

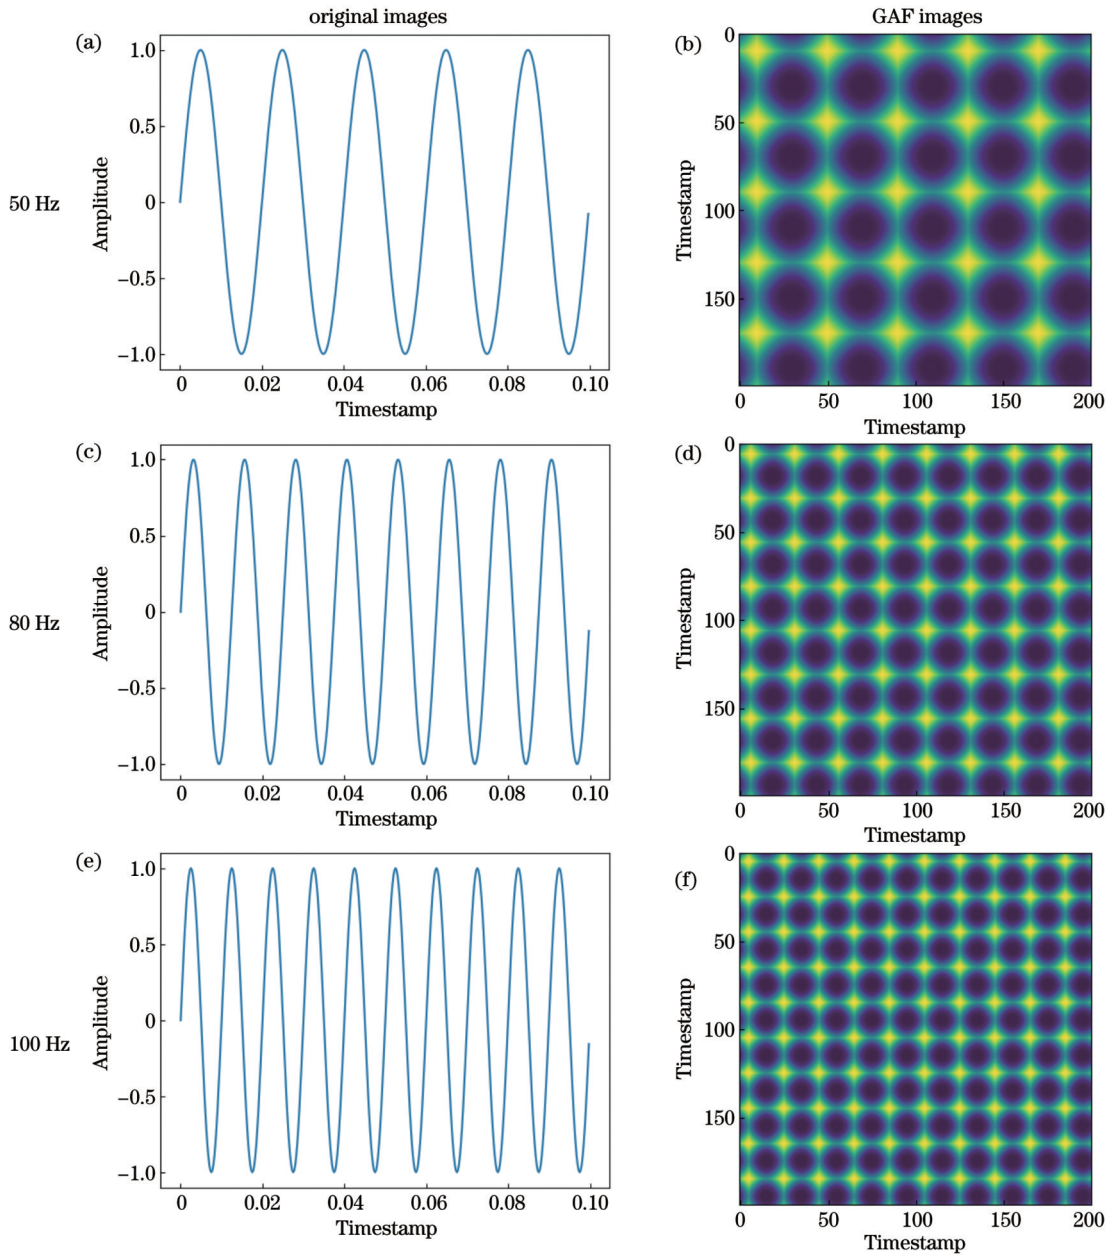


图 4 不同频率正弦信号的 GAF 仿真

Fig. 4 GAF simulation of sinusoidal signal with different frequencies

3.3 事件识别方法流程

首先,为了增强有效信号的特征,采用基于“wname”的正交小波函数对原始数据进行小波阈值滤波,实现数据的平滑处理;其次,利用 GAF 变换将滤波后的 1 s 信号转换为图像数据,并划分训练集和测试集;然后,构建 GoogLeNet 深度学习模型并采用该模型对图像数据进行分类训练,该模型由 5×5 卷积核、9 个 Inception 模块、2 个辅助分类器、1 个平均池化层和 1 个全连接层组成;最后,选择分类效果最优的模型输出分类结果。该方法的基本流程如图 5 所示。笔者选取在实际管道现场采集一周的人工挖掘、机械破坏、噪声、人行走、车辆振动、流水振动等 6 类数据作为实验对象,分别在管道前端、中部和末端附近采集数据,数据经过滤波平滑波形后,生成 GAF 时间序列图像,然

后采用分类算法进行识别。

图 6 展示了 6 类事件的时间信号波形和对应的 GAF 图像,不同事件的信号强度有明显差异。人工挖掘信号幅值基本上在 $-0.05 \sim 0.05$ V 之间,且持续不断;人行走信号的最大幅值约为 0.23 V,其特点是突然出现;机械破坏信号的最大幅值约为 0.075 V,呈振荡衰减趋势;流水振动信号幅值基本上在 $0.125 \sim 0.150$ V 之间,持续稳定;车辆振动信号幅值在 $0.015 \sim 0.040$ V 之间,其特点是持续增加;噪声信号幅值在 0 V 左右,其特点是持续且微弱。

图 6 还展示了 6 类事件的 GAF 变换图,它们各有特征。人工挖掘事件的 GAF 变换图呈现均匀交叉的小方格状,方格线颜色相近,反映了原始图像波峰的连续性;人行走事件的 GAF 变换图呈现一个明显的十字

交叉线,交叉线重合处颜色更亮,反映了原始图像波峰的突然性;机械破坏事件的 GAF 变换图呈现多个十字

交叉,反映了原始图像波形的振荡衰减特性;噪声事件的 GAF 变换图呈不均匀的方格状,反映了原始图像的

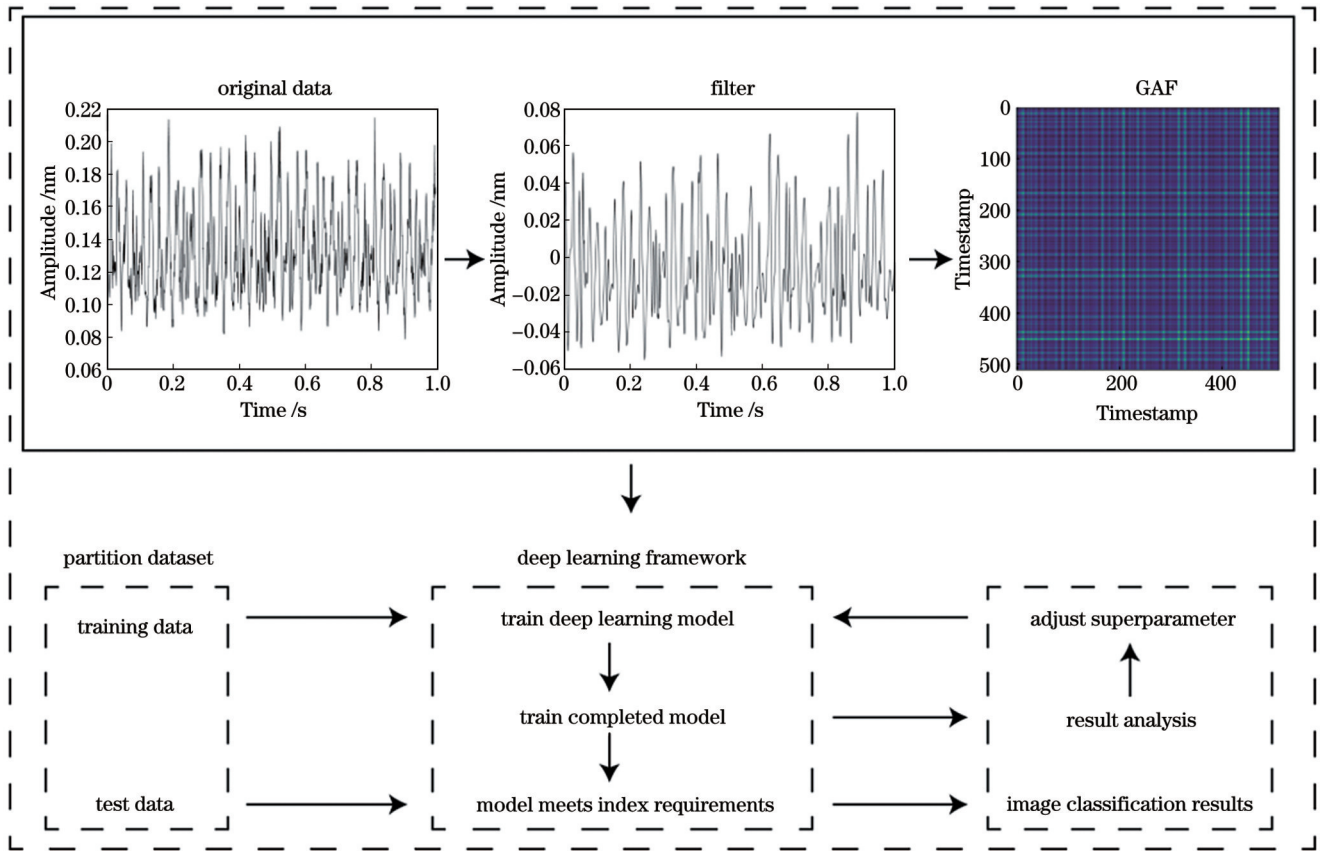
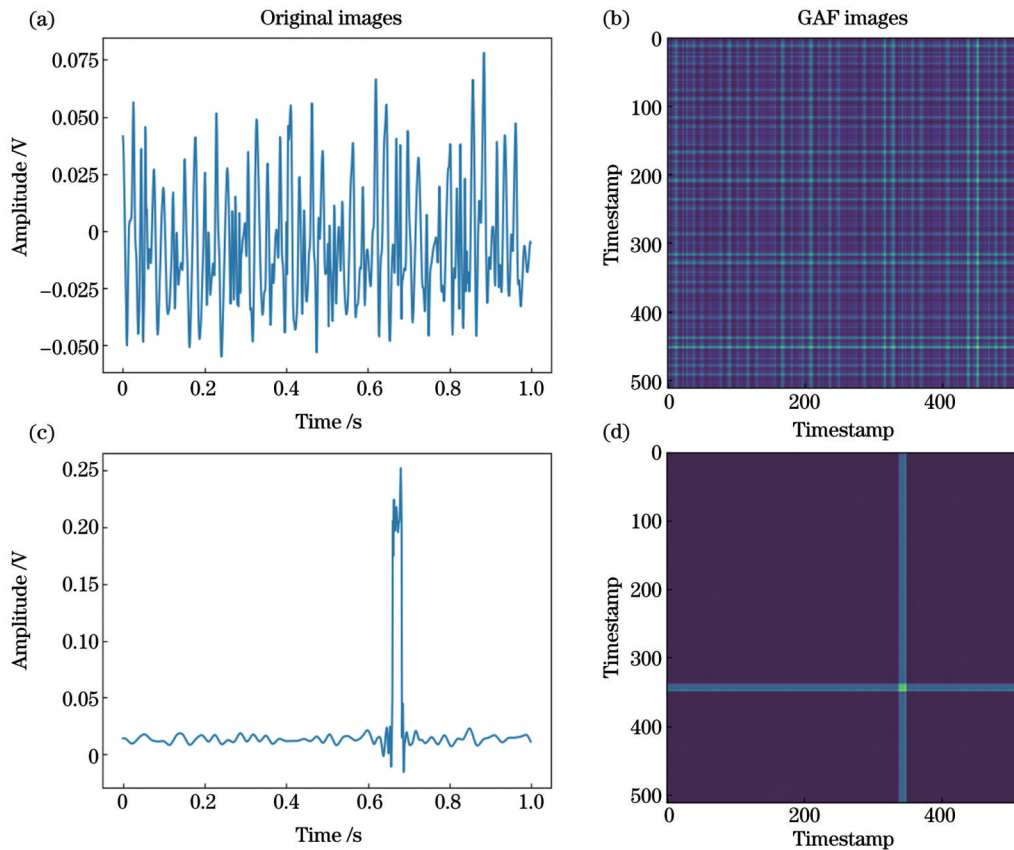


图 5 算法流程图

Fig. 5 Flow chart of the algorithm



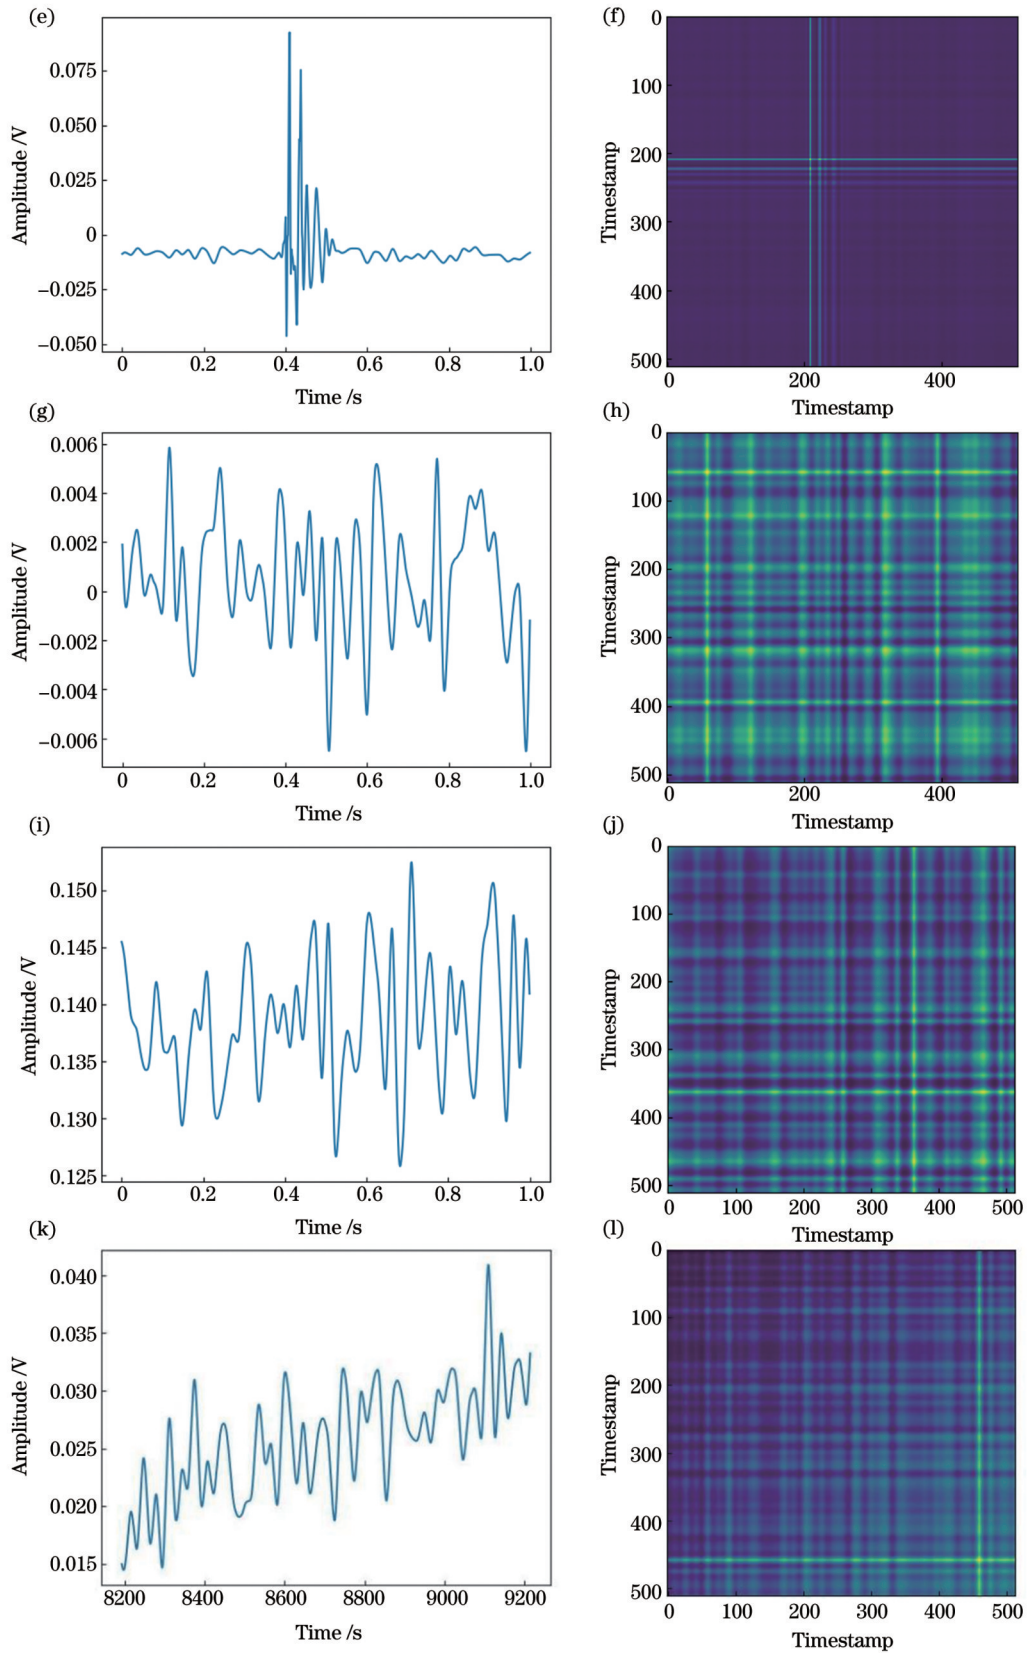


图6 6类事件的时域信号波形和对应的GAF图。(a)~(b)人工挖掘事件;(c)~(d)人行走事件;(e)~(f)机械破坏事件;(g)~(h)噪声事件;(i)~(j)流水振动事件;(k)~(l)车辆振动事件

Fig. 6 Time-domain signal waveforms and corresponding GAF images of the six types of events. (a)~(b) Manual excavation event; (c)~(d) walking event; (e)~(f) machine damage event; (g)~(h) noise event; (i)~(j) water flow vibration event; (k)~(l) vehicle vibration event

无规则连续性;流水振动事件的 GAF 变换图呈现不规则方格状,且右下角颜色较亮,反映了原始图像幅值的逐渐增大特性;车辆振动事件的 GAF 变换图在右下角呈现一个交叉十字状,反映了原始图像幅值的逐渐增大特性。由此可见,GAF 图能将一维振动信号映射为二维时序图像,从而可以利用图像特征区分不同的

事件。

3.4 多种分类方法的对比测试

现场 GAF 图形化的 6 类典型事件数据集如表 1 所示,包含各类事件信号训练集和测试集的信号样本数及标签。数据集通过镜像、调节亮度、旋转、翻转等操作进行数据增强。

表 1 分布式光纤振动信号事件数据集

Table 1 Distributed optical fiber vibration signal event dataset

Event type	Original sample quantity		Enhanced sample quantity		Label
	Training set	Test set	Training set	Test set	
Machine damage	58	14	1044	252	0
Manual excavation	24	6	432	108	1
Noise	69	17	1242	306	2
Vehicle vibration	48	12	864	216	3
Walking	118	29	2124	522	4
Water flow vibration	62	15	1116	270	5

表 2 列出了 AlexNet、VGG 和 GoogLeNet 三种模型在增强数据集下的识别准确率和召回率。其中:GoogLeNet 模型的识别准确率和召回率(分别为

97.79% 和 97.46%)均最高,表现最佳;AlexNet 模型次之,识别准确率为 95.28%,召回率为 94.95%;VGG 模型最差,识别准确率为 94.44%,召回率为 93.75%。

表 2 三种模型在增强数据集上的测试结果对比

Table 2 Test results comparison of the three models in enhanced dataset

Model	Event	Accuracy rate / %	Recall rate / %	Overall accuracy / %
GoogLeNet	Manual excavation	100	97.46	97.79
	Machine damage	97.22		
AlexNet	Manual excavation	99.07	94.95	95.28
	Machine damage	97.62		
VGG	Manual excavation	97.22	93.75	94.44
	Machine damage	97.22		

在分类问题中,混淆矩阵是一种评价模型性能的工具。 T_p 表示实际为 1 且预测为 1 的样本数, F_p 表示实际为 0 但预测为 1 的样本数, F_N 表示实际为 1 但预测为 0 的样本数, T_N 表示实际为 0 且预测为 0 的样本数。准确率 A 是指预测正确的样本数占总样本数的比例,计算公式为 $A = (T_p + T_N) / (T_p + T_N + F_p + F_N)$ 。准确率虽然能反映模型的总体正确性,但在样本不平衡的情况下,不能很好地衡量模型的区分能力。召回率 r 是指在实际为 1 的样本中被预测为 1 的样本的占比,计算公式为 $r = T_p / (T_p + F_N)$ 。召回率反映了模型对正样本的识别精度,它随着 T_p 的增大和 F_N 的减小而增大。

图 7 展示了三种模型在训练集和测试集上的准确率和损失函数随着 Epoch 的变化情况。从图中可以看出,GoogLeNet 模型在准确率表现最佳,训练准确率达到 98.6%,测试准确率为 97.8%。这说明 GoogLeNet 模型具有较强的拟合能力和泛化能力。AlexNet 模型

的准确率次之,虽然其训练准确率也达到了 98.3%,但测试准确率只有 95.3%,说明该模型存在一定程度的过拟合问题。准确率最差的是 VGG 模型,其训练准确率仅为 97.6%,测试准确率更是低至 94.4%,说明该模型的拟合能力和泛化能力都较弱。综上所述,GoogLeNet 模型优于其他两种模型。

图 8~13 分别给出了三种模型的 ROC(receiver operating characteristic)曲线和混淆矩阵。三种模型的 ROC 曲线都表现出较高的曲线下面积(AUC)值,而且三种模型对机械破坏和人工挖掘事件的 AUC 值都为 1,说明三种模型都具有较好的分类能力。混淆矩阵显示:GoogLeNet 模型能够完全准确地识别人工挖掘事件,并且对机械破坏事件有较低的误报率(2.78%),该模型的准确率、召回率、精确率和 F1 值均达到了 0.97 以上;AlexNet 模型对机械破坏事件有最低的误报率(0.93%),对人工挖掘事件也有较低的误报率(2.38%),其各项评价指标均在 94% 以上;VGG

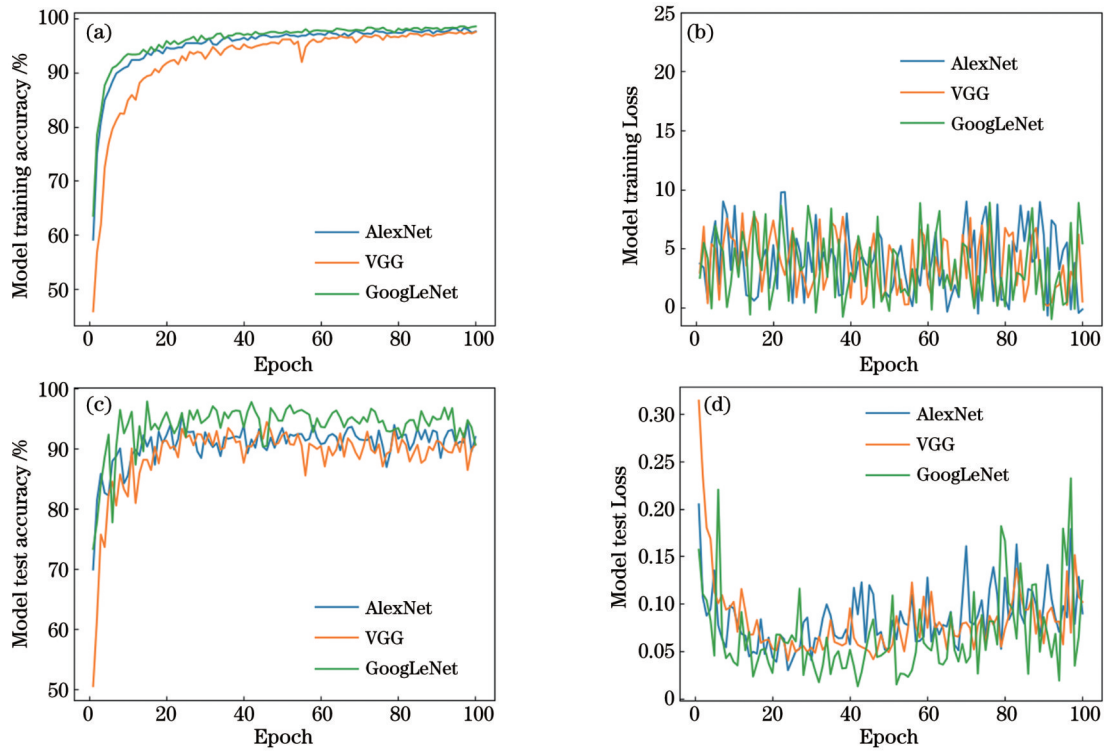


图 7 GoogLeNet、VGG、AlexNet 三种模型在训练集和测试集上的准确率曲线及损失(Loss)函数。(a)模型训练准确率;(b)模型训练损失函数;(c)模型测试准确率;(d)模型测试损失函数

Fig. 7 Accuracy curves and Loss function of GoogLeNet, VGG, and AlexNet models in training and test datasets. (a) Training accuracy of the models; (b) training Loss function of the models; (c) test accuracy of the models; (d) test Loss function of the models




图 8 VGG ROC 曲线
Fig. 8 VGG ROC curve




图 10 AlexNet ROC 曲线
Fig. 10 AlexNet ROC curve

	machine damage	manual excavation	noise	vehicle vibration	walking	water flow vibration
machine damage	105	3	0	0	0	0
manual excavation	0	245	0	1	0	6
noise	0	2	296	0	0	8
vehicle vibration	0	0	0	198	0	18
walking	0	0	0	0	522	0
water flow vibration	0	0	51	4	0	215

图 9 VGG 混淆矩阵
Fig. 9 VGG confusion matrix

	machine damage	manual excavation	noise	vehicle vibration	walking	water flow vibration
machine damage	107	1	0	0	0	0
manual excavation	0	246	1	2	0	3
noise	0	0	284	0	0	22
vehicle vibration	0	0	0	202	0	14
walking	0	0	0	0	522	0
water flow vibration	0	1	25	10	0	234

图 11 AlexNet 混淆矩阵
Fig. 11 AlexNet confusion matrix

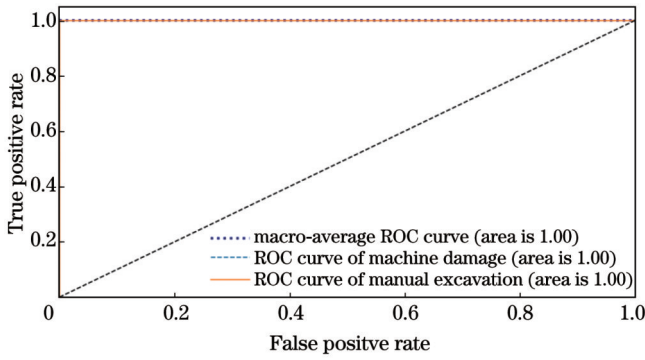


图 12 GoogLeNet ROC 曲线
Fig. 12 GoogLeNet ROC curve

模型对机械破坏事件和人工挖掘事件都有较低的误报率(2.78%),其各项评价指标均在 93% 以上。综合比较后认为 GoogLeNet 模型在识别管道沿线第三方破坏事件方面表现最优,其次是 AlexNet 模型,最后是 VGG 模型。

3.5 对现场数据加噪声进行 GoogLeNet 分析

为了测试基于 GAF 和 GoogLeNet 的管道沿线第三方破坏事件识别方法在低信噪比条件下是否能够准

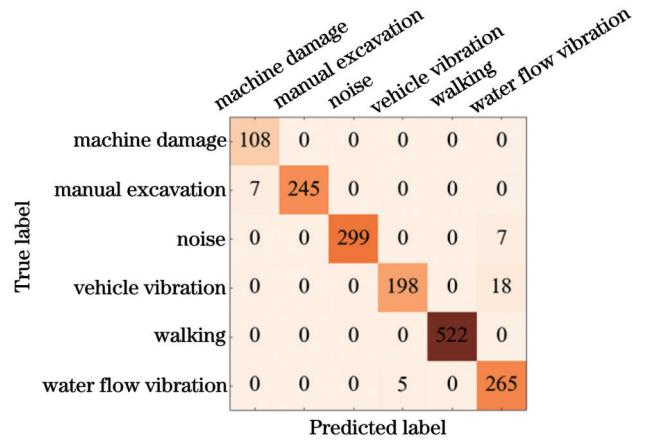


图 13 GoogLeNet 混淆矩阵
Fig. 13 GoogLeNet confusion matrix

确识别管道威胁事件,对数据集在不同信噪比条件下的 6 类数据进行了测试分类。图 14 展示了测试结果,其中图 14(a)~(d)分别对应信噪比为 2 dB、4 dB、6 dB 和 8 dB 时的混淆矩阵。随着信噪比逐渐增大,测试效果逐渐变好,当信噪比增大到 8 dB 以后,机械破坏和人工挖掘事件的误报率为 0%,即能够完全准确地进行分类。

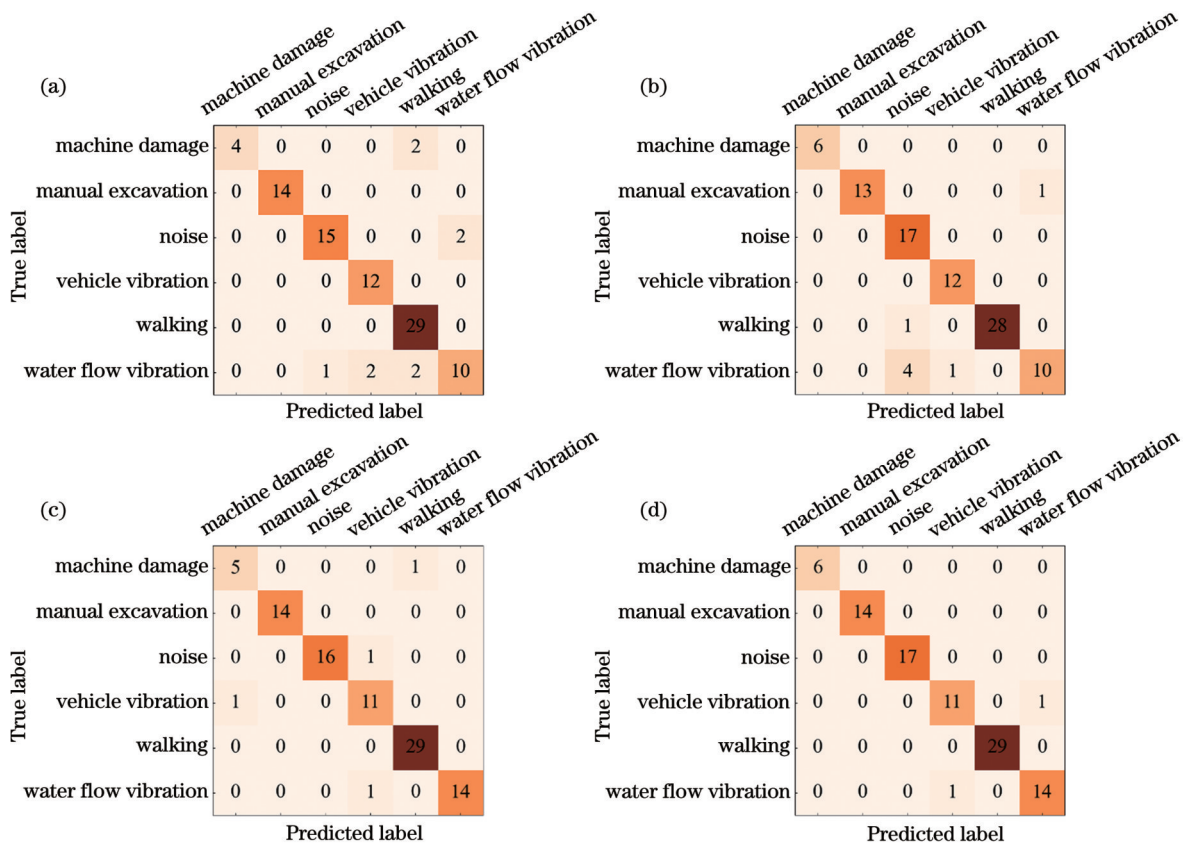


图 14 不同信噪比条件下的混淆矩阵。(a)信噪比为 2 dB;(b)信噪比为 4 dB;(c)信噪比为 6 dB;(d)信噪比为 8 dB

Fig. 14 Confusion matrices under different signal-noise ratio values. (a) Signal-noise ratio is 2 dB; (b) signal-noise ratio is 4 dB; (c) signal-noise ratio is 6 dB; (d) signal-noise ratio is 8 dB

4 结 论

本文利用分布式光纤振动监测系统采集了 28.9 km

长天然气管道沿线 6 类事件的波形信号,通过 GAF 变换将其转化为二维图像信息,然后采用 GoogLeNet、VGG、AlexNet 三种深度学习模型对图像信息进行分

类识别,并对比了各模型的识别精度和误报率。结果表明,GoogLeNet模型在分类精度和误报率方面均优于其他两种模型,分类精度达到了97.79%,而且在系统信噪比大于8 dB时能够有效区分人工挖掘和机械破坏事件,适用于管道沿线威胁事件的实时识别。本文所提方法为长输管道的安全监测提供了一种新的思路和技术手段。

参 考 文 献

- [1] 彭宽. 分布式光纤振动传感系统模式识别方法研究[D]. 武汉: 华中科技大学, 2017: 1-6.
Peng K. Research on pattern recognition method of distributed optical fiber vibration sensing system[D]. Wuhan: Huazhong University of Science and Technology, 2017: 1-6.
- [2] 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): 19-36.
Zhang Y K, Shang Y, Wang C, et al. Detection and recognition of distributed optical fiber intrusion signal[J]. Opto-Electronic Engineering, 2021, 48(3): 19-36.
- [3] 孙琪真, 李豪, 范存政, 等. 基于散射增强光纤的分布式声波传感研究进展[J]. 激光与光电子学进展, 2022, 59(21): 2100001.
Sun Q Z, Li H, Fan C Z, et al. Research progress of distributed acoustic wave sensing based on scattering enhanced fiber[J]. Laser & Optoelectronics Progress, 2022, 59(21): 2100001.
- [4] 陈晨. 基于COTDR技术在长输油气管道光纤预警系统中的设计与应用[J]. 石油化工自动化, 2022, 58(6): 63-66, 80.
Chen C. Design and application of optical fiber early warning system based on COTDR technology in long-distance oil and gas pipeline[J]. Automation in Petro-Chemical Industry, 2022, 58(6): 63-66, 80.
- [5] 张延琛. 基于时域特征的风机轴承 PSO-RBF 故障诊断[J]. 现代制造技术与装备, 2022, 58(10): 13-16, 20.
Zhang Y C. Fault diagnosis of fan bearing based on PSO-RBF in time domain[J]. Modern Manufacturing Technology and Equipment, 2022, 58(10): 13-16, 20.
- [6] 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.
- [7] 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.
Chen P C, You C T, Ding P F. Pattern recognition of intrusion events in perimeter defense areas of optical fiber[J]. Chinese Journal of Lasers, 2019, 46(10): 1006001.
- [8] 吴红艳, 贾波, 卞庞. 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.
Wu H Y, Jia B, Bian P. Study on endpoint detection technology based on fiber perimeter security system[J]. Chinese Journal of Scientific Instrument, 2013, 34(4): 743-748.
- [9] Cao C, Fan X Y, Liu Q W, et al. Practical pattern recognition system for distributed optical fiber intrusion monitoring based on Φ -COTDR[J]. ZTE Communications, 2019, 15: 52-55.
- [10] 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.
Zou D B, Liu H, Zhao L, et al. Research of signal recognition of distributed optical fiber vibration sensors[J]. Laser Technology, 2016, 40(1): 86-89.
- [11] Liu K, Tian M, Liu T G, et al. A high-efficiency multiple events discrimination method in optical fiber perimeter security system[J]. Journal of Lightwave Technology, 2015, 33(23): 4885-4890.
- [12] 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, 236.
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]. Journal of Vibration and Shock, 2010, 29(5): 1-4, 236.
- [13] 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.
- [14] 曲洪权, 吉祥, 盛智勇, 等. 基于AdaBoost集成学习的光纤振动信号识别分类方法[J]. 激光与光电子学进展, 2022, 59(13): 1307004.
Qu H Q, Ji X, Sheng Z Y, et al. Optical fiber vibration signal identification and classification method based on AdaBoost ensemble learning[J]. Laser & Optoelectronics Progress, 2022, 59(13): 1307004.
- [15] 王雨墨, 李彦博, 李晓平, 等. 神经网络预测管道冲蚀速率研究进展[J]. 石油科学通报, 2020, 5(1): 114-121.
Wang Y M, Li Y B, Li X P, et al. Research progress on prediction of pipeline erosion rate by artificial neural network[J]. Petroleum Science Bulletin, 2020, 5(1): 114-121.
- [16] 肖璞, 黄海霞. 基于CNN算法的深度学习研究及应用[J]. 现代计算机, 2019(35): 27-32.
Xiao P, Huang H X. Research and application of deep learning based on CNN algorithm[J]. Modern Computer, 2019(35): 27-32.
- [17] 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.
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.
- [18] 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.
Wu H, Kong Y, Wang Z W, et al. Recognition of optical fiber vibration signals based on VMD_CNN algorithm[J]. Laser & Infrared, 2021, 51(8): 1043-1049.
- [19] 骆家杭, 张旭, 汪靖翔. 基于格拉姆角场和多尺度CNN的轴承故障诊断[J]. 轴承, 2022(6): 73-78.
Luo J H, Zhang X, Wang J X. Fault diagnosis for bearings based on Gram angle field and MSCNN[J]. Bearing, 2022(6): 73-78.
- [20] 魏超. 基于改进GoogLeNet模型的电气设备红外图像分割与识别[J]. 机械设计与制造工程, 2022, 51(6): 126-130.
Wei C. Infrared image segmentation and recognition of electrical equipment based on improved GoogLeNet model[J]. Machine Design and Manufacturing Engineering, 2022, 51(6): 126-130.
- [21] 李斌, 阎君宇. 基于GAF-CNN的弓网电弧识别方法研究[J]. 电子测量与仪器学报, 2022, 36(1): 188-195.
Li B, Yan J Y. Research on recognition method of pantograph arc based on GAF-CNN[J]. Journal of Electronic Measurement and Instrumentation, 2022, 36(1): 188-195.
- [22] 王国伟, 刘嘉欣. 基于卷积神经网络的玉米病害识别方法研究[J]. 中国农机化学报, 2021, 42(2): 139-145.
Wang G W, Liu J X. Research on corn disease recognition method based on convolutional neural network[J]. Journal of Chinese Agricultural Mechanization, 2021, 42(2): 139-145.
- [23] Li J, Lu X, Wang W F. Leak monitoring and localization in baghouse filtration system using a distributed optical fiber dynamic air pressure sensor[J]. Optical Fiber Technology, 2020, 57(C): 102218.
- [24] 高岗, 李俊, 刘旭安, 等. 基于相位敏感型光时域反射仪的除尘器破袋检漏及定位技术[J]. 光学学报, 2018, 38(7): 0706001.
Gao G, Li J, Liu X A, et al. Bag filter leak detection and location based on phase-sensitive optical time domain reflectometry[J]. Acta Optica Sinica, 2018, 38(7): 0706001.

Distributed Optical Fiber Vibration Signal Recognition Technology Based on Gramian Angular Field

Li Jun^{1,2}, Yao Ruixu^{1,2*}, Ren Meiyang¹, Zhang Jiarui^{1,2}, Zhang Xinwei^{1,2}, Ma Tian^{1,2}

¹*School of Safety Science and Engineering, Xi'an University of Science and Technology, Xi'an 710054, Shaanxi, China;*

²*Shaanxi Provincial Key Laboratory of Coal Fire Disaster Prevention, Xi'an 710054, Shaanxi, China*

Abstract

Objective Ensuring the integrity and reliability of oil and gas pipelines is of paramount importance in safeguarding energy security and protecting the environment. However, these pipelines are often exposed to various threats, such as human sabotage and third-party construction excavations, which may cause severe fires and explosion accidents. Therefore, it is necessary to develop an effective method to detect and identify different types of events occurring along pipelines. In this study, distributed optical fiber vibration monitoring technology is used to collect the waveform signals of six types of events that occur along a 28.9-kilometer-long pipeline. Subsequently, the Gramian angular field (GAF) transform is used to convert the one-dimensional time-series signals into two-dimensional image information, enabling the capture of characteristic patterns for each event. Next, the GoogLeNet deep learning model is used to classify and identify image information and evaluate the recognition accuracy and false alarm rate of the model. This study proposes an efficient and accurate method for oil and gas pipeline threat identification based on the GAF transform and deep learning.

Methods This study proposes a novel method for oil and gas pipeline threat identification based on distributed optical fiber vibration monitoring technology and deep learning. The waveform signals of six types of events (manual excavation, machine damage, noise, walking, vehicle damage, and water flow vibration) were collected along a 28.9-kilometer-long pipeline, which have the potential to jeopardize pipeline safety. To enhance the feature representation of the signals, a filter was employed to remove noise, and then the GAF algorithm was used to convert the one-dimensional time-series signals into two-dimensional images, enabling the capture of the characteristic patterns of each event. Subsequently, three different deep learning networks, GoogLeNet, VGG, and AlexNet, were employed to classify and identify the images and compare their recognition accuracies and false alarm rates. Experiments were conducted to evaluate the performance of our method, demonstrating that GoogLeNet outperformed the other two networks in terms of recognition accuracy and detecting false alarm rates. The effect of the signal-to-noise ratio (SNR) on the classification performance was analyzed. The GoogLeNet network was determined to achieve optimal classification performance when the SNR was 8 dB.

Results and Discussions The main contribution of this study is the proposal of a novel method for oil and gas pipeline threat identification based on the GAF algorithm and deep learning. The GAF algorithm was used to transform the waveform signals of six types of field-collected events (manual excavation, machine damage, noise, walking, vehicle vibration, and water flow vibration) into two-dimensional images that captured the characteristic patterns of each event. Subsequently, three different deep-learning networks, GoogLeNet, VGG, and AlexNet, were used to classify and identify the images. Experiments were conducted to evaluate the performance of our method and compare it with existing methods. The experimental results demonstrate that our method has several advantages over existing methods. First, as shown in Table 2, GoogLeNet can achieve a high classification accuracy and recall rate on both the training and test datasets, indicating that our method generalizes well to new data. Second, as shown in Fig. 7, GoogLeNet performs best in terms of accuracy and loss in the training process, indicating that the GoogLeNet model has strong fitting and generalization abilities. Third, as shown in Figs. 8–13, GoogLeNet can obtain high AUC values for machine damage and manual excavation events, can completely and accurately identify manual excavation events, and has a low false-positive rate (2.78%) for machine damage events, which are considered the most critical threats to pipeline safety. This indicates that the proposed method can effectively distinguish between different types of events. Fourth, as shown in Fig. 14, GoogLeNet can achieve optimal classification performance when the SNR is 8 dB, indicating that our method can handle noisy signals well.

Conclusions In conclusion, this study uses a distributed optical fiber vibration sensing system to collect six types of event signals along a 28.9-kilometer-long natural gas pipeline and transforms them into two-dimensional image information through the GAF transform. It then uses three deep learning models, GoogLeNet, VGG, and AlexNet, to classify and identify the image information and compare the recognition accuracy and false alarm rate of each model. The results show that the GoogLeNet model outperforms the other two models in terms of recognition accuracy and false alarm rate, achieving a recognition accuracy of 97.79% and effectively differentiating between manual excavation and machine excavation events when the system signal-to-noise ratio is greater than 8 dB. It is suitable for the real-time identification of threat events along the pipeline. The method proposed in this paper provides a novel conceptual framework and technical approach for the safety monitoring of long-distance pipelines.

Key words optical fiber; pipeline monitoring; Gramian angular field; distributed optical fiber vibration; feature recognition