

## 激光与光电子学进展

基于 GAF-HorNet 的  $\Phi$ -OTDR 周界安防监测研究胡胜<sup>1</sup>, 胡歆敏<sup>1</sup>, 李莎莎<sup>1</sup>, 吕朴初<sup>1</sup>, 秦海鑫<sup>1</sup>, 赵灿<sup>2</sup>, 武明虎<sup>1</sup>, 刘聪<sup>1\*</sup><sup>1</sup>湖北工业大学电气与电子工程学院, 湖北 武汉 430068;<sup>2</sup>华中科技大学光学与电子信息学院, 湖北 武汉 430074

**摘要** 相位敏感型光时域反射( $\Phi$ -OTDR)技术是一种具有高精度振动监测优点的分布式光纤传感技术,能够检测周界安防领域中的扰动事件。针对传统识别方法中需要人工提取振动信号特征,无法保留时间的相关性导致信息丢失的问题,提出一种基于 GAF-HorNet 的扰动事件识别方法,该方法无需特征提取步骤,能将一维振动信号通过格拉姆角场(GAF)转为二维图像,采用 HorNet 训练模型并进行识别分类。为了验证该算法的性能,选择 4 种经典算法训练模型进行对比实验。实验结果表明,该算法对背景噪声、石头敲击、石头划、树枝划、拉拽、攀爬等 6 类信号的平均识别准确率为 93.56%,比现有的方法在识别率、误报率上有更好的表现。

**关键词** 光纤传感; 相位敏感光时域反射计; 格拉姆角场; 分类识别

中图分类号 TN929

文献标志码 A

DOI: 10.3788/LOP231499

## Research on $\Phi$ -OTDR Perimeter Security Monitoring Based on GAF-HorNet

Hu Sheng<sup>1</sup>, Hu Xinmin<sup>1</sup>, Li Shasha<sup>1</sup>, Lü Puchu<sup>1</sup>, Qin Haixin<sup>1</sup>, Zhao Can<sup>2</sup>,  
Wu Minghu<sup>1</sup>, Liu Cong<sup>1\*</sup><sup>1</sup>School of Electrical and Electronic Engineering, Hubei University of Technology, Wuhan 430068, Hubei, China;<sup>2</sup>School of Optical and Electronic Information, Huazhong University of Science and Technology,  
Wuhan 430074, Hubei, China

**Abstract** Phase-sensitive optical time-domain reflection ( $\Phi$ -OTDR) technology is a distributed fiber-optic sensing technique with the advantage of high-precision vibration monitoring. It can be used to detect disturbance events in the field of perimeter security. Traditional recognition methods require the manual extraction of vibration signal features and cannot retain a time correlation, leading to information loss. To solve this problem, a disturbance event recognition method based on GAF-HorNet, which does not require a feature extraction step, is developed. A one-dimensional vibration signal is converted into a two-dimensional image through a Gramian angular field (GAF), and HorNet is used to train the model and perform recognition and classification. To verify the performance of the algorithm, four classical algorithms are selected to train the model for comparative experiments. The experimental results demonstrate that the average accuracy of the proposed algorithm is 93.56% for six types of signal: background noise, stone knocking, stone stroking, branch stroking, pulling, and climbing. Compared with previous methods, the method proposed has better recognition rate and false alarm rate performances.

**Key words** optical fiber sensing; phase-sensitive optical time-domain reflectometer; gramian angular fields; classification recognition

## 1 引言

分布式光纤传感技术由于具有灵敏度高、精度高、成本低、监测范围长等优点,在工程领域及生活中得到了广泛的应用<sup>[1]</sup>。相位敏感型光时域反射( $\Phi$ -OTDR)

技术是一种能实现高精度振动监测的长距离分布式光纤传感技术,在道路监测<sup>[2]</sup>、管道检测<sup>[3]</sup>、周界安防<sup>[4]</sup>等领域有着广阔的应用前景,并且取得了显著的研究进展<sup>[5]</sup>。 $\Phi$ -OTDR 技术通过测量光纤中的后向瑞利散射来提取相位,得到的振动信号可反映外界的干扰行为。

收稿日期: 2023-06-12; 修回日期: 2023-07-05; 录用日期: 2023-07-24; 网络首发日期: 2023-08-07

通信作者: \*20141109@hbut.edu.cn

在实际监测环境中,由于背景噪声复杂多变,甚至存在噪声引起的假振动,因此难以准确识别不同的信号干扰。自从机器学习得到快速发展,研究人员提出多种基于机器学习的 $\Phi$ -OTDR模式识别方法。目前,针对光纤振动信号的检测方法可以根据特征提取方式分为两类:一类是对振动信号进行时域、频域和时频域的特征提取,将提取到的特征传送到分类器中进行识别<sup>[6]</sup>;另一类是将二维图像作为分类特征进行研究。

传统的特征提取方法需要人工提取特征,如通过快速傅里叶变换<sup>[7]</sup>、短时傅里叶变换<sup>[8]</sup>、经验模态分解<sup>[9]</sup>、小波变换等方法提取能量特征,然后送入分类器中,如极限学习机(ELM)<sup>[10]</sup>、支持向量机(SVM)<sup>[11]</sup>、长短时记忆神经网络(LSTM)<sup>[12]</sup>等。文献<sup>[13]</sup>提出了一种基于极限梯度提升算法(XGBoost)的模型,对铁路领域中频繁的人工挖掘、机器挖掘、行走、开车等4种外部入侵事件和噪声的平均识别准确率高达98.5%。随着人工智能的快速发展,以卷积神经网络(CNN)为代表的深度学习网络由于具有能够自动提取特征并进行大规模并行运算的能力,成为目前的研究热点。文献<sup>[14]</sup>采用CNN对背景噪声、行走、跳跃、敲击和机械挖掘等5种事件类型进行分类检测,平均分类准确率为96.67%。文献<sup>[15]</sup>提出了一种基于迁移训练的深度卷积神经网络(AlexNet)事件识别方法,该方法能够快速建立高精度的事件识别网络,并对晴天背景、雨天背景、行走、跳跃、水洗、敲打、挖掘、骑自行车等8种信号进行识别训练,分类准确率可以达到96.16%。文献<sup>[16]</sup>提出卷积长短期记忆神经网络(LSTM-CNN)模型,针对背景噪声、挖掘、电机振动、行走等4类信号,识别准确率为94.6%。

传统特征提取方法基于复杂的人工特征提取步骤,不仅过程繁杂,还无法完整准确地获取干扰信号的全部特征,导致信息丢失从而造成误报,不适用于复杂环境。近年来,研究人员提出了用二维图像作为分类特征的研究思路,将一维信号转换为二维图像进行分

析。文献<sup>[17]</sup>以图像目标检测思想为基础,使用3种预处理方法,同时实现对入侵事件的定位和识别,对地表插打、地表挖掘和人为跳跃等3种事件的识别精确率达到70.4%。文献<sup>[18]</sup>将振动信号重构成时空域脉冲扫描图像,提出了一种基于CNN的输水管道泄漏识别系统,对车辆经过、破坏、行人经过、挖掘等4种事件的综合识别率为98.2%。文献<sup>[19]</sup>提出了一种基于马尔可夫转换场(MTF)和CNN的方法,对5种振动事件进行分类,识别准确率达到97%。

在当前用二维图像作为分类特征的研究中,大多以时频域图像为主,在分类过程中需要选取一段信号作为一帧数据,而且每帧数据长度的选择不当会导致频率信息不准确或者出现时域分辨率低的问题。基于此,本文提出了一种基于格拉姆角场(GAF)与HorNet模型的识别方法,对采集到的6类原始信号进行预处理和窗口划分后,通过GAF直接将一维时间信号转换为二维图像,采用HorNet模型识别扰动信号。所提方法以图像的方式有效地保留原时间序列信号的信息,避免了复杂的特征提取步骤,减少了计算量,采用的HorNet模型有效地提高了识别准确率。

## 2 信号采集与预处理

### 2.1 $\Phi$ -OTDR 系统搭建

搭建 $\Phi$ -OTDR分布式光纤传感系统,系统结构如图1所示。光源采用频率为0.1 kHz的超窄线宽激光器(NLL)。利用声光调制器(AOM)将光中心波长为1550 nm的连续光调制成重复频率为5 kHz、脉冲持续时间为200 ns的脉冲序列。光脉冲由掺铒光纤放大器(EDFA)放大,经过环形器注入总长为20 km的标准G652单模传感光纤。当光纤沿线有振动产生时,相应位置的光纤会发生变化并导致该位置背向瑞利散射光的相位发生改变,经环形器被光电探测器(PD)接收,经过滤波放大将光信号转换为电信号,输出信号由数据采集(DAQ)卡以100 MSa/s的采样速率进行采样并传递到计算机进行识别及分析。

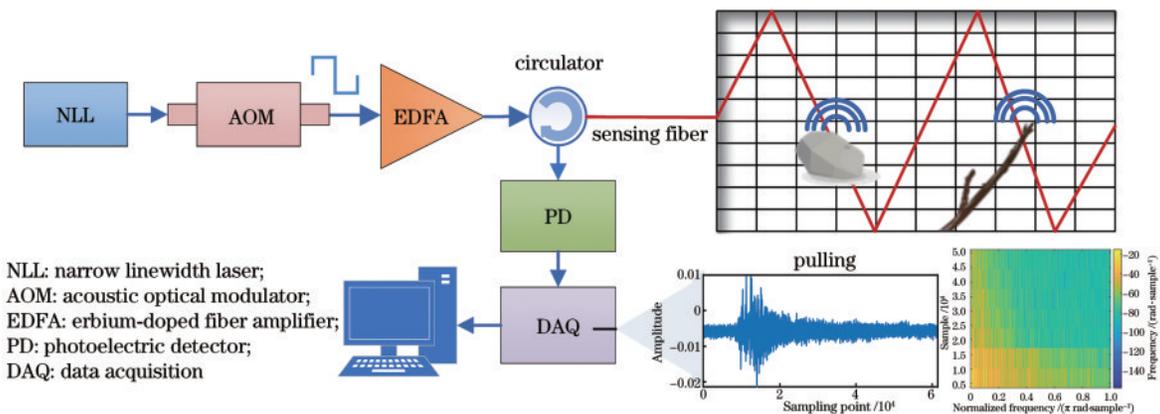


图1  $\Phi$ -OTDR系统原理图

Fig. 1 Schematic diagram of  $\Phi$ -OTDR system

为了更真实、准确地测试  $\Phi$ -OTDR 分布式光纤扰动传感系统的识别性能,采用标准通信单模光纤作为传感光纤。根据周界安防中可能出现的扰动,设置了 6 类信号,并将总长为 20 km 的室内传感光纤缠绕在实验室内放置的防护网上,通过人为模拟动作采集了 5 种不同类型扰动事件和背景噪声数据。

1) 背景噪声:无扰动时的信号,用来模拟无任何扰动发生时由背景噪声带来的误报警。

2) 石头敲击:实验者用半径为 5 cm 的石头敲击传感光纤,用来模拟实际环境中对围栏的大规模应力破坏行为。

3) 石头划:实验者用半径为 5 cm 的石头均匀划动传感光纤,用来模拟实际环境中对围栏的连续破坏

行为。

4) 树枝划:实验者手持树枝均匀划动传感光纤,树枝的半径大约为 2 cm,用来模拟实际环境中连续轻微的划动破坏动作。

5) 纵向拉拽:实验者用力拉拽传感光纤,使传感光纤发生扰动。

6) 攀爬:实验者对放置有传感光纤防护网施加晃动,用来模拟实际环境中攀爬、翻越围栏的行为。

采集的背景噪声样本数量为 140 个,石头敲击、石头划、树枝划均为 160 个,纵向拉拽和攀爬为 245 个。实验采集 6 种原始信号波形如图 2 所示,将 6 类事件打上标签,编码为 0、1、2、3、4、5,生成原始一维数据集。

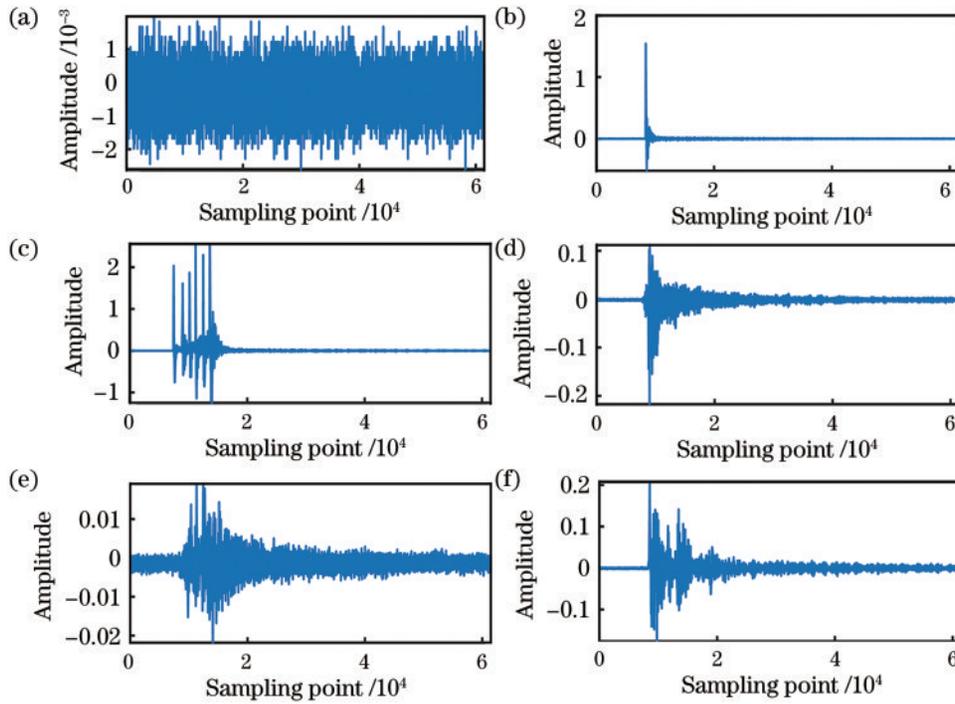


图 2 6 类一维时间信号图。(a) 背景噪声; (b) 石头敲击; (c) 石头划; (d) 树枝划; (e) 纵向拉拽; (f) 攀爬

Fig. 2 Six types of one-dimensional time signals. (a) Background noise; (b) stone knocking; (c) stone stroking; (d) branch stroking; (e) longitudinal pulling; (f) climbing

## 2.2 GAF 图像编码

GAF 可在保留数据时间依赖性的前提下,将一维时间序列编码为唯一的二维图像<sup>[20]</sup>。GAF 图像编码方式包括格拉姆角和场 (GASF) 和格拉姆角差场 (GADF) 两种。将样本转为极坐标形式,数值看作夹角余弦值,时间戳看作半径,编码具体过程如下。

假设一个一维扰动信号  $X = \{x_1, x_2, \dots, x_n\}$ , 首先对于每一个包含  $n=300$  的时间序列样本进行归一化,将时间序列缩放到  $[-1, 1]$  范围内,计算公式为

$$\tilde{x}_i = \frac{x_i - \max(X) + x_i - \min(X)}{\max(X) - \min(X)}, \quad (1)$$

式中:  $\tilde{x}_i$  为缩放后时间序列  $\tilde{X}$  中的元素,为时间序列样本中的第  $i$  个样本点对应的数值,  $i \in [1, 300]$ ;  $\max(X)$

为时间序列样本中若干样本点对应的最大值;  $\min(X)$  为时间序列样本中若干样本点对应的最小值。

然后将其编码为角余弦  $\cos \varphi$ , 时间戳编码为半径  $r$ , 缩放后的时间序列  $\tilde{X}$  即可表示为极坐标形式, 极坐标可以保留绝对的时间关系, 计算式为

$$\begin{cases} \varphi_i = \arccos(\tilde{x}_i), -1 \leq \tilde{x}_i \leq 1, \tilde{x}_i \in \tilde{X} \\ r_i = \frac{t_i}{N}, t_i \in N_0 \end{cases}, \quad (2)$$

式中:  $\varphi_i$  是第  $i$  个样本点在极坐标系下的极角;  $t_i$  是第  $i$  个样本点对应的的时间戳;  $r_i$  是第  $i$  个样本点在极坐标系下的极半径;  $N_0$  是正则化极坐标系统跨度的常数因子 (也表示时序数据中包含的所有时间点的个数)。这种基于极坐标的表示方法是一种理解时间序列的新方

法,可以有效保留时间相关性<sup>[21]</sup>。

计算每个点之间的三角和或三角差,通过两种不同的方式来识别数据点在不同时间间隔内的时间相关性,两种计算方法为

$$G_{ASF} = \begin{pmatrix} \cos(\varphi_1 + \varphi_1) & \cos(\varphi_1 + \varphi_2) & \cdots & \cos(\varphi_1 + \varphi_j) \\ \cos(\varphi_2 + \varphi_1) & \cos(\varphi_2 + \varphi_2) & \cdots & \cos(\varphi_2 + \varphi_j) \\ \vdots & \vdots & \ddots & \vdots \\ \cos(\varphi_i + \varphi_1) & \cos(\varphi_i + \varphi_2) & \cdots & \cos(\varphi_i + \varphi_j) \end{pmatrix}, \quad (3)$$

$$G_{ADF} = \begin{pmatrix} \sin(\varphi_1 + \varphi_1) & \sin(\varphi_1 + \varphi_2) & \cdots & \sin(\varphi_1 + \varphi_j) \\ \sin(\varphi_2 + \varphi_1) & \sin(\varphi_2 + \varphi_2) & \cdots & \sin(\varphi_2 + \varphi_j) \\ \vdots & \vdots & \ddots & \vdots \\ \sin(\varphi_i + \varphi_1) & \sin(\varphi_i + \varphi_2) & \cdots & \sin(\varphi_i + \varphi_j) \end{pmatrix}, \quad (4)$$

式中: $i, j$ 为行、列索引, $i, j \in N_0$ 且 $1 \leq (i, j) \leq n$ 。某样本的 GASF 和 GADF 编码效果如图 3 所示。

### 2.3 数据预处理

由于采集到的扰动事件信号包含了事件发生前后的背景噪声,因此需要将不同类型的扰动信号进行裁

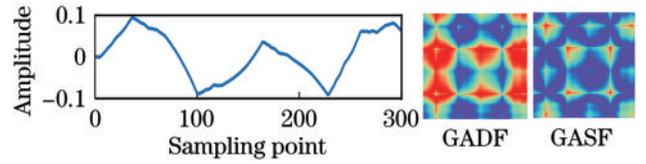


图 3 GASF 和 GADF 编码示意图  
Fig. 3 Schematic of GASF and GADF encoding

剪,仅保留扰动发生的信号部分。信号的有效长度为 3000,针对每一类信号,设定一个阈值  $M$ ,当检测到  $a$  点信号数值大于  $M$  时,对  $(a, a+3000)$  的部分进行裁剪,即可保留所有的有效扰动信号。

为了抑制现场复杂环境对于振动信号的干扰,采用小波去噪的方法对振动信号进行降噪处理,提取出真实有效的现场数据,再进行后续的分析处理。如图 4 所示,小波去噪主要分为 3 个步骤:1)对信号进行小波分解,选择一个小波函数并确定一个小波分解的层次  $N$ ,然后对信号进行  $N$  层小波分解,图 4 中  $S$  表示低频信息, $d$  表示高频信息;2)将小波分解高频系数的阈值量化,对第 1 层到第  $N$  层的每一层高频系数(3 个方向),选择一个阈值进行阈值量化处理;3)根据小波分解的第  $N$  层的低频系数和经过量化处理后的第 1 层到第  $N$  层的高频系数,进行信号的小波重构。

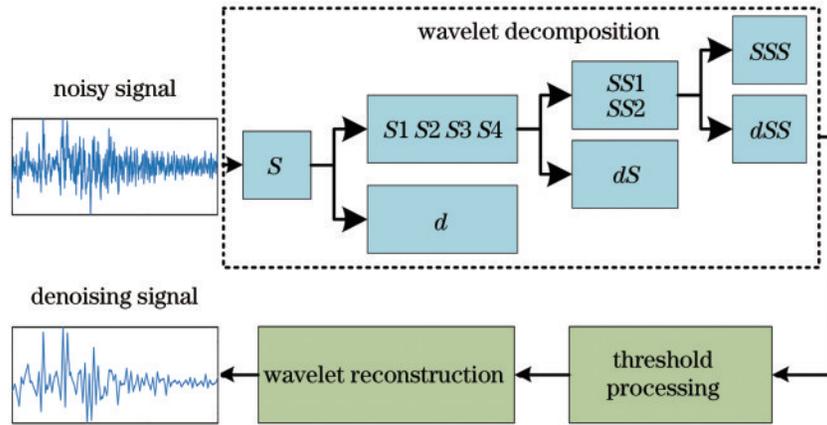


图 4 小波去噪过程  
Fig. 4 Wavelet denoising process

本文选择通用阈值“sqrtwolog”,根据第一层系数进行噪声层估计来调整阈值,进行  $N=50$  层的小波去噪,其中背景噪声不进行处理。去噪前后的波形如图 5 所示。

设置大小为 300 的滑动窗口,步长为 210,对样本点进行滑动窗口划分,每个样本具有 120 个独立样本点。对于每一个包含  $n=300$  的时间序列样本,首先进行归一化,将得到的时间序列缩放至  $[-1, 1]$  范围内,然后将归一化后的样本进行 GAF 图像编码,设置图像分辨率为  $224 \text{ pixel} \times 224 \text{ pixel}$ ,能够较好地保留原始信号特征信息。图 6 为对划分后的样本进行 GAF 编码的效果图,包括 GASF 和 GADF 两种方式,情景从

上到下依次为背景噪音、石头敲击、石头划、树枝划、纵向拉拽、攀爬。

从图 6 可以看出:噪声信号是杂乱无章的,归一化后信号幅值之间的变化较为频繁,因此在 GAF 图上存在交叠的垂直线与水平线最多,颜色也最为丰富;石头划动作引发的波形具有明显突起,从对应生成的 GAF 图中可以观察到图像中存在大面积颜色相似的连通区域。针对其他事件,从波形上可以看到明显的波动,存在较多交叠的垂直线与水平线。

为探究不同的编码方式对模型训练效果的影响,选用 GASF 和 GADF 两种编码方式对预处理后的数据分别进行编码,通过 HorNet 进行训练,测试集准确

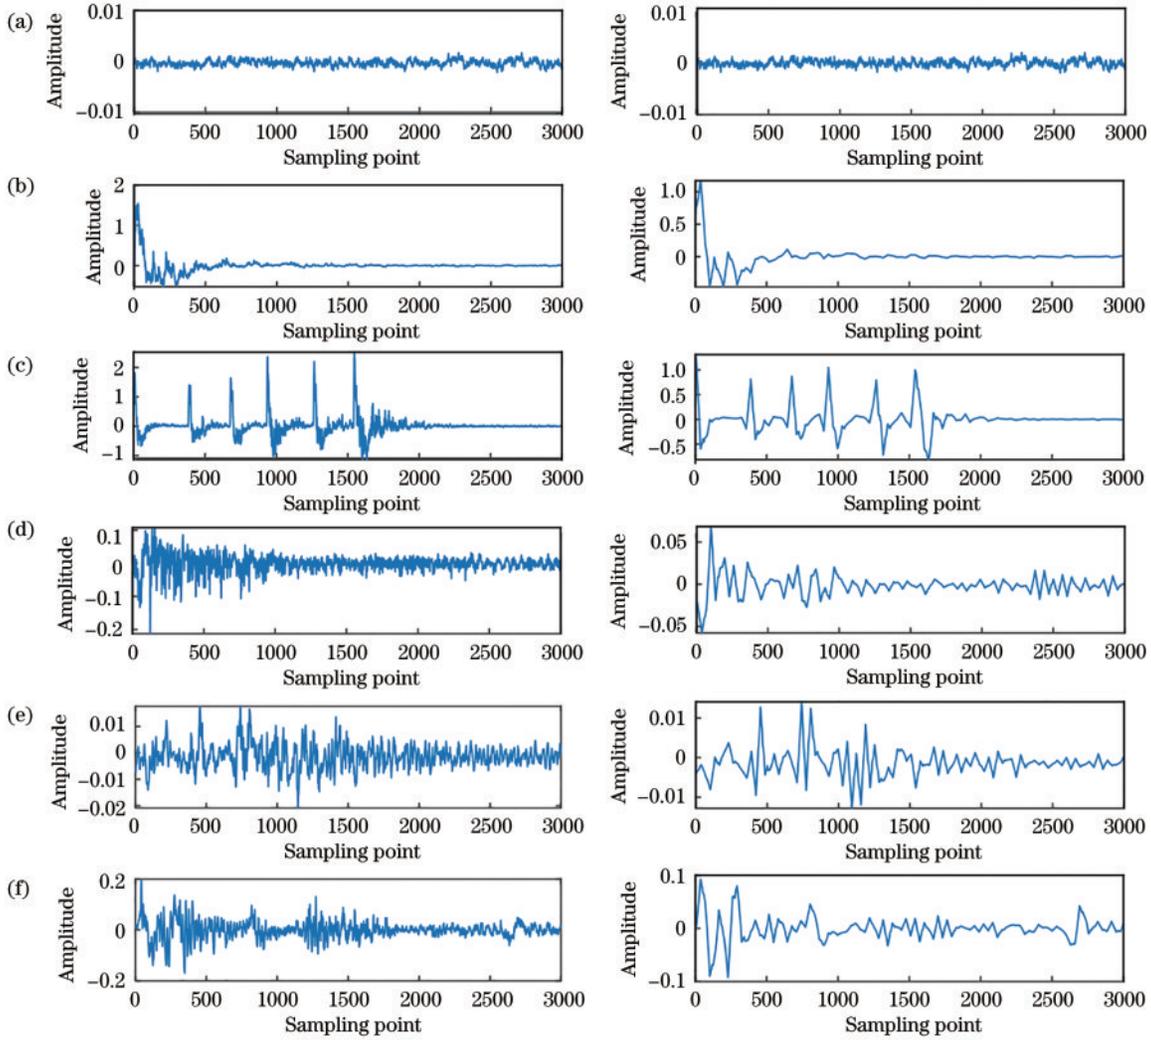


图 5 小波去噪效果图。(a)背景噪声;(b)石头敲击;(c)石头划;(d)树枝划;(e)纵向拉拽;(f)攀爬

Fig. 5 Effect picture of wavelet denoising. (a) Background noise; (b) stone knocking; (c) stone stroking; (d) branch stroking; (e) longitudinal pulling; (f) climbing

率变化曲线如图 7 所示。

从图 7 中可以看出, GADF 在训练过程中的变化更稳定且准确率优于 GASF, 因此本文采用了 GADF 的编码方式。实验中采用 80% 的 GADF 图像数据集作为训练样本, 20% 的 GAF 图像数据集作为测试样本。图片样本总量为 14425, 训练集共 11540 个样本, 测试集共 2885 个样本。数据集中每类样本训练集与测试集的个数如表 1 所示。

表 1 训练集与测试集个数

Table 1 Number of training set and test set

Event type	Training set	Test set	Total
Background noise	2548	637	3185
Stone knocking	1668	417	2085
Stone stroking	1664	416	2080
Manual beating	1656	414	2070
Mechanical breaking	2548	637	3185
Manual digging	1456	364	1820
Total	11540	2885	14425

### 3 模型训练分析与讨论

#### 3.1 模型搭建

搭建 HorNet 模型<sup>[22]</sup>, 采用 HorNet-Tiny 结构, 通道数  $C=64$ , 主要包括输入层、特征提取层、全连接层、输出层, 网络结构如图 7 所示。输入层为  $224 \text{ pixel} \times 224 \text{ pixel}$  的 GAF 图像, 特征提取层采用递归门控卷积 ( $g^r\text{Conv}$ ) 层, 经过多层感知机 (MLP) 得到融合了图像和信号信息的特征图。HorNet 模型的  $g^r\text{Conv}$  层由两个子模块组成: 全局滤波器和局部滤波器。全局滤波器负责提取全局上下文信息, 局部滤波器负责提取局部细节信息。两个滤波器之间通过一个门控机制进行动态权重分配, 从而实现自适应的特征融合。HorNet 可以通过堆叠多个  $g^r\text{Conv}$  层来构建不同的模型结构。

基于 HorNet 的具体流程如下。首先, HorNet 的输入是一张  $224 \text{ pixel} \times 224 \text{ pixel} \times 3 \text{ pixel}$  的图像, 将输入图像分为两个通道, 一个是时空图像特征提取层, 另

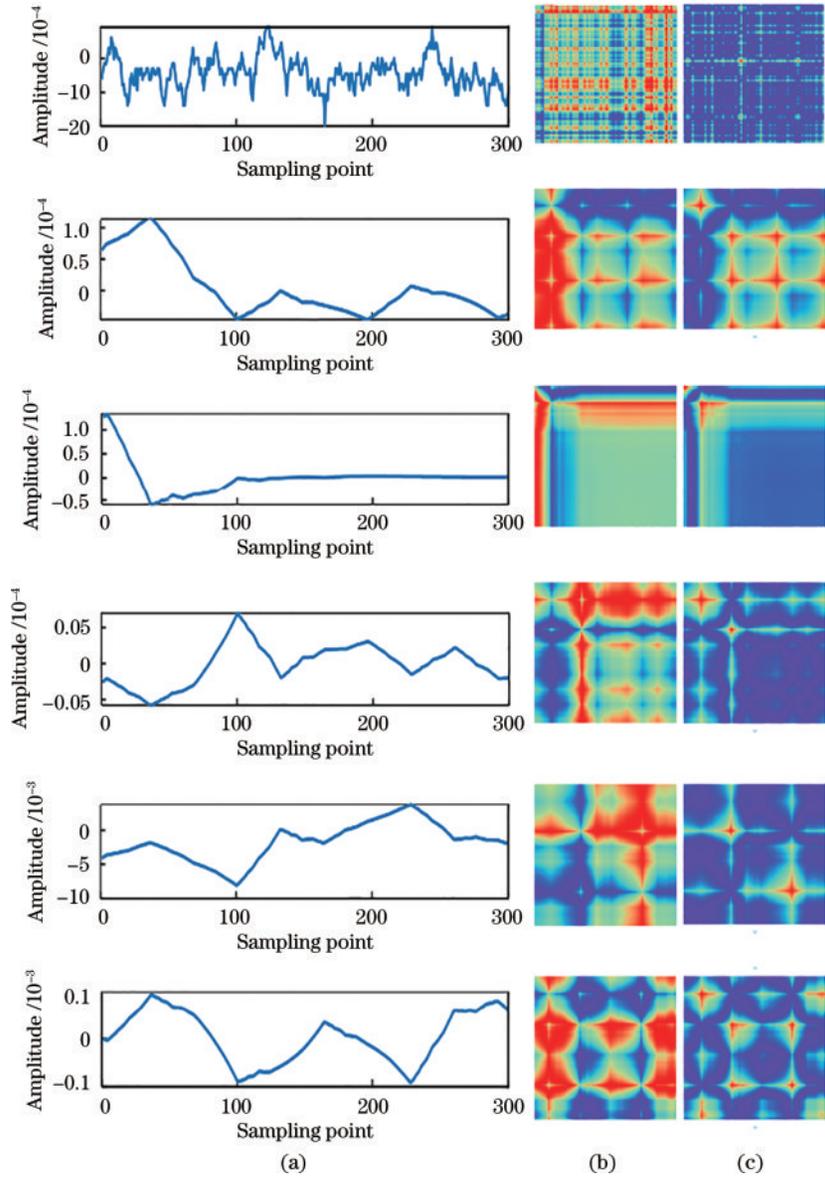


图 6 6 类信号 GAF 编码示意图。(a)窗口划分信号;(b)GADF 编码示意图;(c)GASF 编码示意图

Fig. 6 Schematic diagram of GAF coding for 6 types of signals. (a) Window partition signal; (b) schematic diagram of GADF coding; (c) schematic diagram of GASF coding

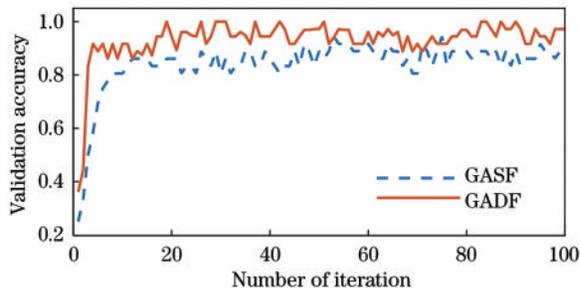


图 7 不同编码方式测试集准确率曲线

Fig. 7 Test set accuracy of different encoding methods

一个是信号振动波纹特征提取层。时空图像特征提取层使用 3 个二维卷积块来提取图像的空间信息,信号振动波纹特征提取层使用 2 个一维卷积块和 1 个长短期记忆网络来提取图像的时间信息。其次,将两个通

道的输出分别进行平坦化操作,得到两个特征向量。然后,将两个特征向量进行拼接,得到一个融合特征向量。将融合特征向量作为  $g^n\text{Conv}$  的输入,对其进行高阶空间交互。 $g^n\text{Conv}$  由一个全局滤波器和一个局部滤波器组成,全局滤波器使用一个视觉 Transformer 来提取全局上下文信息,局部滤波器使用一个 CNN 来提取局部细节信息。两个滤波器之间通过一个门控机制进行动态权重分配,从而实现自适应的特征融合。最后,将  $g^n\text{Conv}$  的输出经过全连接层、dropout 层和分类层,得到最终的分类结果。

一阶空间交互公式如下所示,设  $x \in \mathbf{R}^{H \times W \times C}$  是门控卷积的输入特征,则输出  $y = g^n\text{Conv}(x)$  可表示为

$$[p_0^{H \times W \times C}, q_0^{H \times W \times C}] = \phi(x) \in \mathbf{R}^{H \times W \times 2C}, \quad (5)$$

$$p_1 = f(q_0) \odot p_0 \in \mathbf{R}^{H \times W \times C}, \quad (6)$$

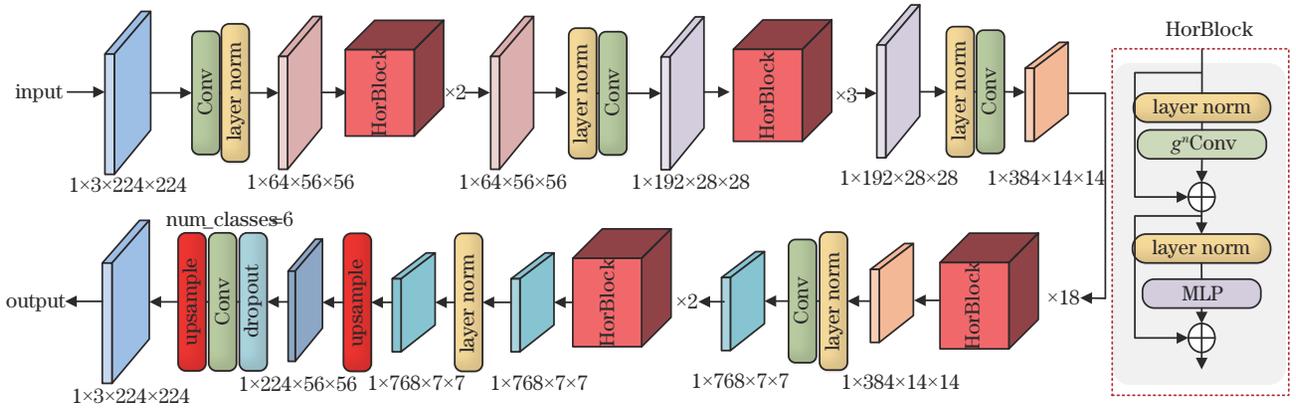


图 8 HorNet 结构图

Fig. 8 Architecture of the HorNet

$$y = \phi(p_1) \in \mathbf{R}^{HW \times C}, \quad (7)$$

式中:  $H$  为特征高度;  $W$  为特征宽度;  $\phi$  为进行通道混合的线性投影层;  $f$  为深度卷积层;  $\odot$  为哈达玛积, 表示对应位置元素相乘;  $p_i^j$  和  $q_i^j$  为相邻特征;  $C$  表示特征通道数。

高阶空间交互与一阶空间交互原理相同, 首先使用线性投影函数  $\phi$  得到一组投影特征  $p_0$  和  $\{q_k\}_{k=0}^{n-1}$ ,

$$[p_0^{HW \times C_0}, q_0^{HW \times C_0}, \dots, q_{n-1}^{HW \times C_{n-1}}] = \phi_m(x) \in \mathbf{R}^{HW \times (C_0 + \sum_{k=0}^{n-1} C_k)}, \quad (8)$$

得到切分特征后, 将其依次输入到门控卷积中进行递归运算,

$$p_{k+1} = f_k(q_k) \odot g_k(p_k) / \alpha, \quad (9)$$

式中:  $k=0, 1, \dots, n-1$ , 将输出缩放  $1/\alpha$  以稳定训练;  $f_k$  是一个深度卷积层;  $g_k$  是根据不同阶匹配维度数, 其表达式为

$$g_k = \begin{cases} \text{Identity} & k=0 \\ \text{Linear}(C_{k-1}, C_k) & 1 \leq k \leq n-1 \end{cases}. \quad (10)$$

最后, 将得到的递归输出  $q_n$  输入到映射层, 得到最终  $g^n \text{Conv}$  输出结果。从式(9)中可以看出,  $p_k$  在每次交互后阶数加 1, 即为递归门控卷积实现交互的方式, 该方式中使用一个  $f_k$  函数将  $\{q_k\}_{k=0}^{n-1}$  的特征串联在一起为组合特征进行深度卷积, 简化了计算步骤。其中每一阶的通道数为指数递减的形式

$$C_k = \frac{C}{2^{n-k-1}}, 1 \leq k \leq n-1. \quad (11)$$

### 3.2 评价指标

混淆矩阵在测试样本集上的预测结果有 4 种可能: 将正样本预测为正样本 (TP;  $T_p$ ), 将正样本预测为负样本 (FN;  $F_N$ ), 将负样本预测为正样本 (FP;  $F_p$ ), 将负样本预测为负样本 (TN;  $T_N$ )。精确率  $P$ 、召回率  $R$  和  $F_1$  分数值 3 个分类效果指标的计算方法为

$$P = \frac{T_p}{T_p + F_p}, \quad (12)$$

$$R = \frac{T_p}{F_p + F_N}, \quad (13)$$

$$F_1 = \frac{2 \times P \times R}{P + R}. \quad (14)$$

误报率 (NAR;  $N_{AR}$ ) 是指识别错误的样本数量占总样本数量的比例, 其计算可以利用召回率公式, 用 1 减去召回率计算得到

$$N_{AR} = 1 - R. \quad (15)$$

### 3.3 模型训练

设置初始学习率为  $1 \times 10^{-3}$ , 每个训练批次大小为 64, 选择 Adam 优化器和交叉熵损失函数, 将训练样本特征送入所提模型进行前向传播, 得到预测样本标签, 并随机打乱顺序。采集样本按照标签种类随机分成训练集和验证集, 划分比例为 8:2。训练集包含约 11540 个样本, 验证集包含 2885 个样本。训练框架为 PyTorch, 总共训练 100 轮。对每个批次进行以下操作: 将图片输入 HorNet 模型, 得到输出的分类结果; 计算输出的分类结果和真实标签之间的交叉熵损失; 根据损失进行反向传播, 更新网络参数; 记录当前批次的损失和准确率; 所有批次完成后, 计算当前周期的平均损失和准确率, 并将结果打印出来。

模型的训练过程如图 9、图 10 所示, 损失曲线和精度曲线经过多轮迭代后迅速收敛, 得到最终的识别模型, 利用训练得到的模型进行扰动信号识别, 监测背景噪声、石头敲击、石头划、树枝划、纵向拉拽、攀爬等 6 类事件, 从图 9、图 10 可以看出, 在训练迭代 20 次之后, 损失趋于平稳并保持在 0.03 上下, 迭代 100 次时, 测试集准确率达到 97.22%。

实验统计了每类事件的识别平均值与 4 个指标, 绘制了混淆矩阵, 如图 11 所示。混淆矩阵的坐标轴上的数字 0、1、2、3、4、5 代表不同事件的标签: 背景噪声、石头敲击、石头划、树枝划、纵向拉拽和攀爬, 主对角线为正确识别的样本数与识别精确率。

通过混淆矩阵可以计算 6 类不同类型事件的召回率、精确率  $F_1$  分数值和误报率, 如表 2 所示。对 6 类事

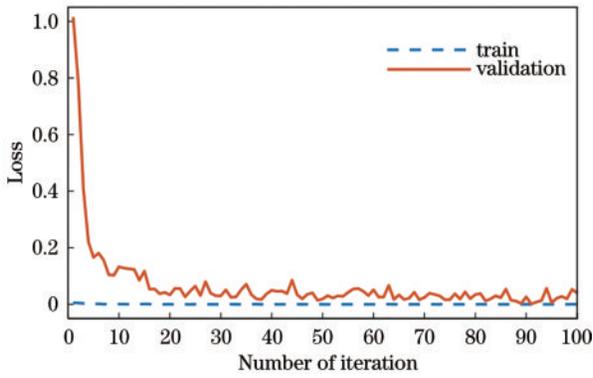


图 9 训练损失曲线

Fig. 9 Loss curves of training

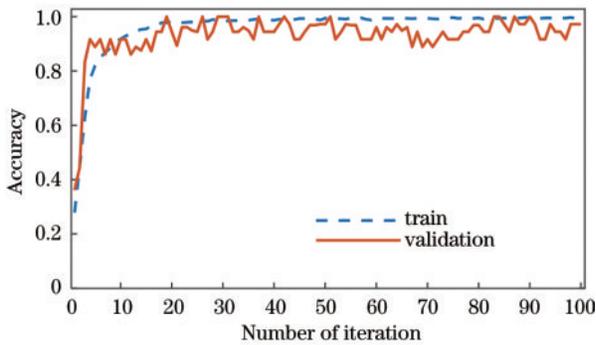


图 10 训练精确率曲线

Fig. 10 Precision curves of training

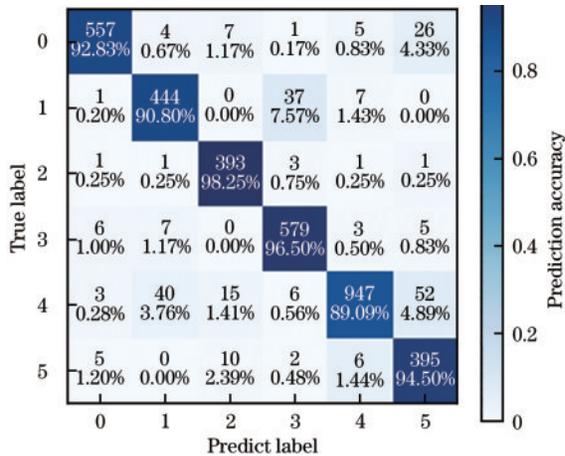


图 11 混淆矩阵

Fig. 11 Confusion matrix

件的识别准确率分别为 92.83%、90.80%、98.25%、96.50%、89.09% 和 94.50%，这一结果表明，HorNet 模型中的递归门控卷积实现了高阶空间交互作用，能够适应 GAF 图像的密集性与复杂性，可以有效提取不同类型图片中的特征。从表 2 中可以看出，在石头划事件的识别上，所提模型表现最为突出，分类精度高达 98.25%。石头划事件与其他 5 种扰动事件在振动幅度和频率上存在明显差异，因此能够被有效地识别出来，从而可有效识别围栏划动等破坏行为。然而，该模型在纵向拉拽事件的识别方面表现最差，其分类精度

仅为 89.09%。此外，模型对背景噪声的识别精度为 92.83%，有 5.17% 的概率识别为攀爬事件，召回率为 97.20%。在对攀爬事件的识别方面，召回率最低，有 5.17% 的概率被识别为噪声，7% 的概率识别为纵向拉拽，对纵向拉拽事件识别的过程中也有 5% 的概率被识别为攀爬事件，这表明，攀爬和纵向拉拽引起的异常响应与背景噪声较为相似，存在一定的干扰。

表 2 6 类不同类型事件的识别效果

Table 2 Recall and accuracy of different types of six events

Event type	Recall / %	Precision / %	$F_1$	NAR
Background noise	97.20	92.83	0.9497	0.0280
Stone knocking	89.55	90.80	0.9017	0.1045
Stone stroking	92.47	98.25	0.9527	0.0753
Branch stroking	92.20	96.50	0.9430	0.0780
Longitudinal pulling	96.74	89.09	0.9276	0.0326
Climbing	83.26	94.50	0.8852	0.1674

为了验证本模型的综合性能，选取几种现有的 CNN 算法架构进行对比，包括 CNN<sup>[23]</sup>、VGG16<sup>[24]</sup>、ResNet34<sup>[25]</sup> 和 ResNet101<sup>[25]</sup>，设置相同的训练参数和迭代次数，将经过训练得到的结果进行对比分析，5 种神经网络的验证准确率如图 12 所示，可以看出所提模型的训练准确率高于其他模型，迭代速度更快，在迭代到 20 次时，准确率最高且保持在 90% 以上。

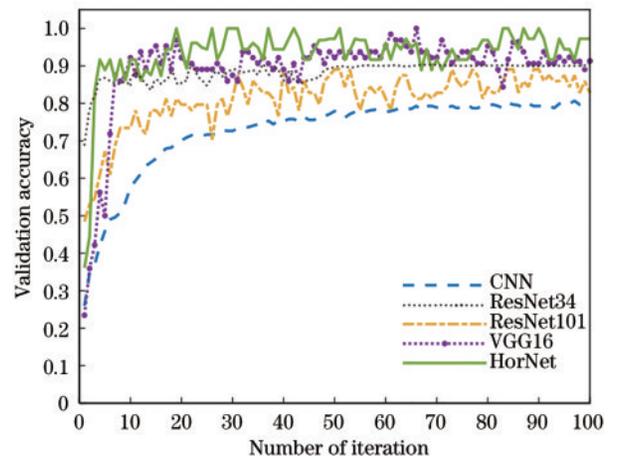


图 12 不同神经网络模型训练准确率

Fig. 12 Training accuracy of different neural networks

基于训练结果，分别计算了不同模型对于 6 类事件的识别精确率，对比结果如图 13 所示。可以看出，所提模型与其他模型在对每一类事件的识别精度上基本一致，对石头敲、石头划和树枝划这 3 类的识别率整体较高，对纵向拉拽和攀爬的识别率较低。在石头划事件中，所提模型识别率提升最高，表明该模型对于规律性的波动识别能力最强，但是所提模型对波动性较小的背景噪声的识别精度低于 ResNet101，对波动性较大但持续时间短的石头敲击识别精度低于 VGG16 网络，分别为 91.17% 和 90.80%。

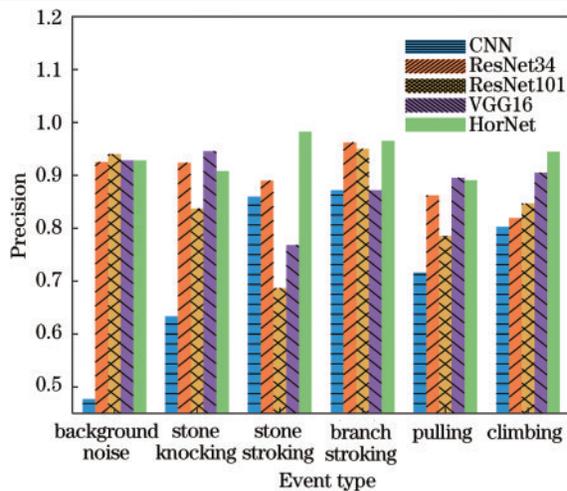


图 13 不同神经网络模型精确率

Fig. 13 Precision of different neural networks

统计的测试结果如表 3 所示,分析可知,HorNet 网络模型的识别准确率达到 93.56%,误报率 8.10%,优于其他网络模型,相较于 CNN、VGG16、ResNet34 和 ResNet101 准确率分别提高了 20.83 百分点、4.25 百分点、6.63 百分点和 12.25 百分点。由于 HorNet 网络具有高阶递归门控卷积,因此与其他方法相比具有一定的优势。

表 3 不同识别算法与本文算法的对比

Table 3 Comparison between different methods and proposed algorithm

Method	Accuracy / %	NAR / %
CNN	72.73	25.38
VGG16	89.31	10.64
ResNet34	86.93	10.13
ResNet101	81.31	16.32
<b>HorNet</b>	<b>93.56</b>	<b>8.10</b>

## 4 结 论

通过搭建  $\Phi$ -OTDR 分布式光纤传感系统,对实验室内环境下模拟的背景噪声信号和 5 类扰动信号进行了采集,提出了一种基于 GAF-HorNet 的扰动事件检测方法。该方法基于 GAF 的原理,将预处理后的一维时间序列信号转换成二维图像,获得更深层次的特征,并省去了复杂的特征提取步骤,有效保留了原序列时间维度的信息。基于 GAF 图像编码方式,HorNet 识别效果更优,准确率达到 93.56%,平均误报率为 8.10%,相较于 CNN、VGG16、ResNet34、ResNet101 网络模型,准确率有明显提升。

本文方法有利于实现对周界安防中的石头敲击、石头划、树枝划、纵向拉拽和攀爬等 5 种入侵和背景噪声的 6 类信号实时精准检测,减少了人力物力等维护成本,保护人民的生命财产安全。该方法适用于实际

应用,并在其他应用场景中具有很大的利用价值,对实际工程安全监测具有重要意义。

## 参 考 文 献

- [1] Fan C Z, Li H, He T, et al. Large dynamic range optical fiber distributed acoustic sensing (DAS) with differential-unwrapping-integral algorithm[J]. Journal of Lightwave Technology, 2021, 39(22): 7274-7280.
- [2] 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.
- [3] 孙琪真, 范存政, 李豪, 等. 光纤分布式声波传感技术在石油行业的研究进展[J]. 石油物探, 2022, 61(1): 50-59, 77.  
Sun Q Z, Fan C Z, Li H, et al. Progress of research on optical fiber distributed acoustic sensing technology in petroleum industry[J]. Geophysical Prospecting for Petroleum, 2022, 61(1): 50-59, 77.
- [4] Wen T K, Zhu P Y, Ye W, 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.
- [5] 苑立波, 童维军, 江山, 等. 我国光纤传感技术发展路线图[J]. 光学学报, 2022, 42(1): 0100001.  
Yuan L B, Tong W J, Jiang S, et al. Road map of fiber optic sensor technology in China[J]. Acta Optica Sinica, 2022, 42(1): 0100001.
- [6] 吴慧娟, 刘欣雨, 饶云江. 基于  $\Phi$ -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  $\Phi$ -OTDR [J]. Laser & Optoelectronics Progress, 2021, 58(13): 1306003.
- [7] Wen H Q, Peng Z Q, Jian J N, et al. Artificial intelligent pattern recognition for optical fiber distributed acoustic sensing systems based on phase-OTDR[C]// Asia Communications and Photonics Conference 2018, October 26-29, 2018, Hangzhou, China. Washington, DC: Optica Publishing Group, 2018: Su4B.1.
- [8] 丁宝俊, 白翼虎. 基于短时傅里叶变换的舰船辐射噪声特征提取[J]. 水雷战与舰船防护, 2015, 23(1): 22-24.  
Ding B J, Bai Y H. Feature extraction of ship radiated noise based on short-time Fourier transform[J]. Mine Warfare & Ship Self-Defence, 2015, 23(1): 22-24.
- [9] Delechelle E, Lemoine J, Niang O. Empirical mode decomposition: an analytical approach for sifting process [J]. IEEE Signal Processing Letters, 2005, 12(11): 764-767.
- [10] Jia H Z, Lou S Q, Liang S, et al. Event identification by F-ELM model for  $\Phi$ -OTDR fiber-optic distributed disturbance sensor[J]. IEEE Sensors Journal, 2020, 20(3): 1297-1305.
- [11] Zhang J N, Lou S Q, Sheng L. Study of pattern

- recognition based on SVM algorithm for  $\varphi$ -OTDR distributed optical fiber disturbance sensing system[J]. *Infrared and Laser Engineering*, 2017, 46(4): 422003.
- [12] Chen X, Xu C J. Disturbance pattern recognition based on an ALSTM in a long-distance  $\varphi$ -OTDR sensing system[J]. *Microwave and Optical Technology Letters*, 2020, 62(1): 168-175.
- [13] Meng H, Wang S L, Gao C X, et al. Research on recognition method of railway perimeter intrusions based on  $\Phi$ -OTDR optical fiber sensing technology[J]. *IEEE Sensors Journal*, 2021, 21(8): 9852-9859.
- [14] Shi Y, Wang Y Y, Zhao L, et al. An event recognition method for  $\Phi$ -OTDR sensing system based on deep learning[J]. *Sensors*, 2019, 19(15): 3421.
- [15] Shi Y, Li Y H, Zhang Y C, et al. An easy access method for event recognition of  $\Phi$ -OTDR sensing system based on transfer learning[J]. *Journal of Lightwave Technology*, 2021, 39(13): 4548-4555.
- [16] 王鸣, 沙洲, 封皓, 等. 基于 LSTM-CNN 的  $\varphi$ -OTDR 模式识别[J]. *光学学报*, 2023, 43(5): 0506001.  
Wang M, Sha Z, Feng H, et al.  $\varphi$ -OTDR pattern recognition based on LSTM-CNN[J]. *Acta Optica Sinica*, 2023, 43(5): 0506001.
- [17] 杨震, 封皓. 基于深度学习的  $\Phi$ -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  $\Phi$ -OTDR[J]. *Laser & Optoelectronics Progress*, 2022, 59(8): 0806001.
- [18] 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  $\varphi$ -OTDR[J]. *Optical Engineering*, 2018, 57(1): 016103.
- [19] Zhao X T, Sun H B, Lin B, et al. Markov transition fields and deep learning-based event-classification and vibration-frequency measurement for  $\varphi$ -OTDR[J]. *IEEE Sensors Journal*, 2022, 22(4): 3348-3357.
- [20] Wang Z G, Yan W Z, Oates T. Time series classification from scratch with deep neural networks: a strong baseline[C]//2017 International Joint Conference on Neural Networks (IJCNN), May 14-19, 2017. Anchorage, AK, USA. New York: IEEE Press, 2017: 1578-1585.
- [21] 郑炜, 林瑞全, 王俊, 等. 基于 GAF 与卷积神经网络的电能质量扰动分类[J]. *电力系统保护与控制*, 2021, 49(11): 97-104.  
Zheng W, Lin R Q, Wang J, et al. Power quality disturbance classification based on GAF and a convolutional neural network[J]. *Power System Protection and Control*, 2021, 49(11): 97-104.
- [22] Rao Y M, Zhao W L, Tang Y S, et al. HorNet: efficient high-order spatial interactions with recursive gated convolutions[EB/OL]. (2022-07-28) [2023-03-05]. <https://arxiv.org/abs/2207.14284>.
- [23] Krizhevsky A, Sutskever I, Hinton G. ImageNet classification with deep convolutional neural networks[J]. *Advances in Neural Information Processing Systems*, 2012, 25(2): 1097-1105.
- [24] Simonyan K, Zisserman A. Very deep convolutional networks for large-scale image recognition[EB/OL]. (2014-09-04) [2023-03-02]. <https://arxiv.org/abs/1409.1556>.
- [25] He K M, Zhang X Y, Ren S Q, et al. Deep residual learning for image recognition[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), June 27-30, 2016, Las Vegas, NV, USA. New York: IEEE Press, 2016: 770-778.