

## 一种新型智能化远距光纤预警的算法研究

王放\*, 邢冀川

北京理工大学光电学院信息光子技术工业和信息化部重点实验室, 北京 100081

**摘要** 提出一种新型智能化长距离光纤预警系统,研究了该系统在真实工作环境下的预测准确性。该预警系统主要分为分布式传感和信号识别两个部分,其中相位敏感光时域反射( $\Phi$ -OTDR)技术用于系统的分布式传感部分,而神经网络技术用于信号识别部分,以对入侵事件进行识别和分类。在信号识别部分创新地提出了一种改进型神经网络结构,并使用基于小波包分解的神经网络和具有三个隐藏层的神经网络等其他两种方法进行效果对比。最后,通过三次不同的实验,探究了系统的识别准确性。结果表明,基于改进型神经网络的光纤预警系统在入侵事件识别方面具有优良的分类效果,平均识别率达到 95% 以上。

**关键词** 光纤光学; 分布式光纤传感系统; 信号识别; 神经网络; 深度学习

中图分类号 TN929.1

文献标志码 A

doi: 10.3788/AOS202141.0706002

## Novel Intelligent Long-Distance Optical Fiber Pre-Warning Algorithm

Wang Fang\*, Xing Jichuan

*Key Laboratory of Photonics Information Technology, Ministry of Industry and Information Technology,  
School of Optics and Photonics, Beijing Institute of Technology, Beijing 100081, China*

**Abstract** We proposed a novel intelligent system for long-distance optical fiber pre-warning and investigated its predictive accuracy in real working environment. The system mainly includes two parts: distributed sensing and signal recognition. Specifically, the phase-sensitive optical time domain reflection ( $\Phi$ -OTDR) technology was used for distributed sensing and the neural network technology was used for signal recognition so as to recognize and classify intrusion events. In addition, an improved neural network structure was proposed in the signal recognition and compared with a neural network based on wavelet packet decomposition and that with three hidden layers. Finally, we performed three different experiments to explore the recognition accuracy of the system. The results show that the proposed system can well recognize and classify the intrusion events with an average recognition rate above 95%.

**Key words** fiber optics; distributed optical fiber sensing system; signal recognition; neural network; deep learning

**OCIS codes** 060.2310; 060.2370; 060.4250

## 1 引言

目前为止,全球正式投入运营的石油天然气管道数量已达约 3800 条<sup>[1-3]</sup>。众所周知,管道运输可以显著提高油气产品的输送效率,但是管道破坏也会对国家和社会带来巨大的经济损失。管道安全保护是油气资源输送体系中的关键一环。随着油气管

道建设规模的日益扩大,越来越多的管道会通过道路和村庄在内的稠密地区,因此,在众多的油气管道泄漏事故中,大部分都是源于人为破坏。如何及时地检测管道附近的有害入侵事件,是防止管道泄漏的主要研究目标<sup>[4-6]</sup>。与其他方法相比,基于分布式光纤传感技术的长距离光纤预警系统具有定位精度高和灵敏度好的优势,可以在真实的土壤环境

收稿日期: 2020-09-10; 修回日期: 2020-10-23; 录用日期: 2020-11-17

基金项目: 上海市经济和信息化委员会项目资助(2018-RGZN-02015)

\* E-mail: wolfehappy@163.com

中实现对管道的远程监控<sup>[7-9]</sup>。

本研究应用的光纤预警系统由两个主要部分组成,即分布式传感部分和信号识别部分。其中,分布式传感部分采用相位敏感光时域反射( $\Phi$ -OTDR)技术来检测外界振动产生的光纤动态应变信号,该功能可以实现对外界振动信号的高灵敏度远程监测<sup>[10-12]</sup>。而信号识别部分则用于对不同类型入侵事件(包括人工机械挖掘、车辆驾驶等)的分类和识别。随着系统对识别精度和探测距离要求的提高,分布式传感部分采集的数据量逐渐增大,因此信号识别部分必须通过简单易用的算法来处理采集到的大量数据。在长距离光纤预警系统中,不同的算法在对入侵事件的识别和分类精度方面存在很大的差别<sup>[13-14]</sup>。2016年,国家管道安全工程实验室利用不同事件的能量信息、基音周期、时间信息等设计了分类器,通过阈值实现施工、车辆、敲击等信号的识别分类,但是该方法难以在环境差异较大的区域实现真正的管道安全预警<sup>[15]</sup>。随后,有一些团队开始采用信号的特征提取特征向量,结合机器学习进行识别分类研究<sup>[16-17]</sup>。通过机器学习实现识别和分类的方式主要结合小波分解或小波包分析等方法,但是这些方法会产生大量的小波系数,训练网络的复杂性增加,实时性降低,且信号特征提取过程复杂。而传统的支持向量机等分类方式<sup>[18-19]</sup>难以在大规模的数据中实现信号的识别,且难以对多人入侵事件进行分类。所以与传统技术相比,神经网络算法具有明显的优势。但是近期有关神经网络的研究大部分仅使用一种类型的基础神经网络,这些方法并不能有效地学习分布式传感系统收集的大量数据的信号特

征<sup>[16,20-21]</sup>。文献[17,22-26]中研究的是靠近传感区域数十米或是在干净的背景环境中生成的实验数据,此情况下简单神经网络模型无法准确地识别和分类实际环境中的入侵事件。

针对上述问题,本研究提出一种智能化的远距光纤预警系统,用于油气输送管道周界入侵信号的识别和分类。本系统的分布式传感部分将采集到的信号送入信号识别部分进行分类识别,而信号识别部分则采用以下三种方法进行识别:第一种是本研究提出的改进型神经网络算法,该算法同时具备长短时记忆网络(LSTM)、卷积神经网络(CNN)等网络算法的优点;第二种是基于小波包分解(WPD)的人工神经网络(ANN)法;第三种是一种更为简单的全连接深度神经网络(DNN)法。后两种方法用于对比验证本文方法的有效性。最后,在上海宝山区一个真实的工作环境下,采集了人工挖掘(MG)、机械挖掘(ME)和非入侵(NI)三种事件的信号,并对上述三种识别方法的准确性进行了对比。研究表明,该三种方法对信号识别均具有一定的准确性,其中改进型神经网络的算法具有最好的适应性,能够准确识别和分类复杂环境中的入侵信号,识别率达95%以上。

## 2 长距离光纤预警系统

本研究使用的光纤预警系统组成结构如图1所示。首先,分布式传感部分用于实现对管道附近土壤振动信号的实时采集,实现入侵事件的实时监控。当地面发生入侵事件时,土壤振动产生的压力会作用于监测光纤上。由于光纤的光弹效应,光纤相应

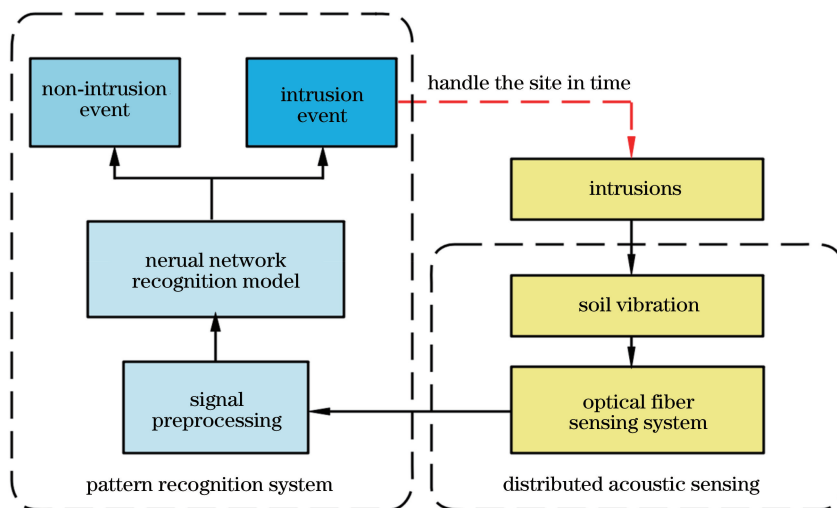


图 1 长距离光纤预警系统的组成

Fig. 1 Structure of long-distance optical fiber pre-warning system

位置的折射率会发生改变,随后该点的光相位也会发生变化。由于干扰,相位变化将会导致背向瑞利散射光的强度产生差异,因此,当某一时刻发生入侵事件时,相应位置的光强将与未发生入侵时的光强不同,而光纤其他位置的光强则保持不变。根据这一原理,可以准确地定位入侵事件发生的位置。随后将这些入侵信号输入到信号识别部分中进行识别,最后利用神经网络算法对入侵事件进行分类,据此判断入侵事件是否存在威胁。

### 2.1 分布式传感部分

管道预警系统分布式传感部分的结构如图 2 所示。具体而言,该部分采用窄线宽激光器作为光源,

该激光器能够输出波长为 1550 nm 的连续光。使用声光调制器对发射光进行调制以获得激光脉冲,然后由掺铒光纤放大器(EDFA)对激光脉冲进行放大,通过 50:50 耦合器耦合到传感光纤中。系统采用双向泵浦拉曼放大技术提高系统性能,以补偿光信号在光纤中的传输损耗,延长光纤传感系统的检测距离。其中,本系统所用的泵浦光源的中心波长为 1450 nm,最大输出功率为 0.5 W。泵浦光源经 3 dB 耦合器和波分复用器(WDM)处理后,进入传感光纤,随后通过光环行器耦合进光纤光栅(FBG)进行噪声滤波,最后光纤中的反向瑞利散射光信号进入到光电探测器,由采集卡进行采集。

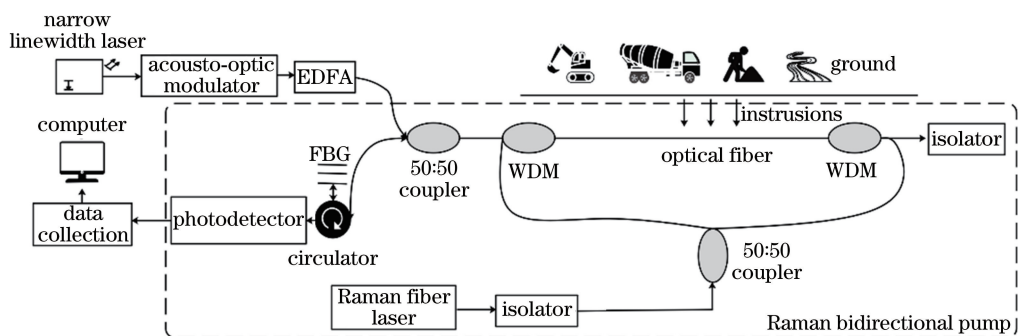


图 2 Φ-OTDR 振动信号采集系统

Fig. 2 Φ-OTDR vibration signal acquisition system

### 2.2 信号识别部分

管道预警系统的信号识别部分主要包括信号归一化和信号分类两个步骤。图 3 显示了入侵振动事件的分类过程。具体而言,首先对系统采集的入侵信号进行归一化处理。数据归一化则是指将数据缩放到较小的特定区间之内。为了保证结果的可靠性,在建立神经网络模型之前,有必要先对数据进行标准化处理,然后利用标准化数据进行分析。本研究采用的标准化方法为绝对值最大标准化法(Max Abs Scaler)<sup>[27]</sup>。该方法是指将数据每个特征调整

到[-1,1]的范围,并通过每个特征内的最大绝对值来划分,其主要的数学依据为

$$x' = \frac{x}{x_{\max}}, \quad (1)$$

式中: $x$ 与 $x'$ 分别为标准化前后的信号矩阵; $x_{\max}$ 为信号矩阵某一行或某一列的最大值,其取值主要取决于标准化时为行压缩方式还是列压缩方式。该方法具有不破坏数据结构的特点,不会移动和聚集数据,因此不会破坏任何的稀疏性,适用于光纤系统采集的信号。

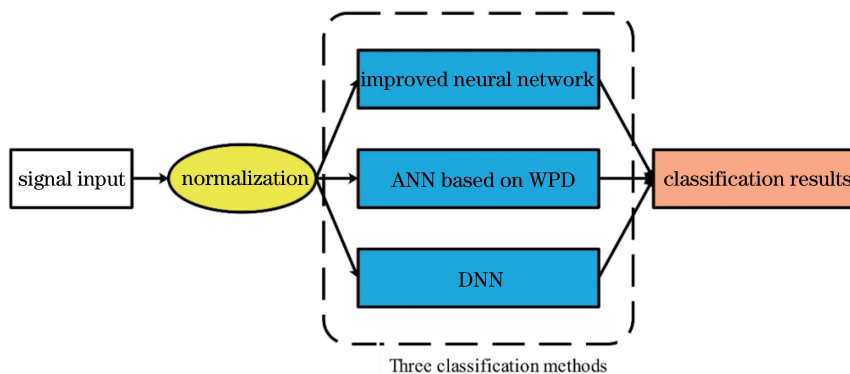


图 3 振动事件的分类步骤

Fig. 3 Vibration event classification process

2.2.1 改进型神经网络算法(方法 1)

改进型神经网络算法是将归一标准化处理后的信号作为神经网络的输入数据进行深度学习。其神经网络在 LSTM 的基础上结合了 CNN 的特点。通过卷积, CNN 有效避免了信号特征提取和分类中复杂的数据重构。通过权值共享的特殊结构大幅度减少了模型的参数量, 降低了复杂程度。CNN 主要包括卷积层和池化层。卷积层通过使用多个滤波器识别输入数据的不同浅层特征。池化层是一个筛选过滤的过程, 利用池化层可以减少卷积层之间的连接, 从而降低运算的复杂程度。CNN 和 LSTM 在建立识别模型方面的优势是互补的。CNN 可以有效地减小频率的变化, LSTM 可以对信号的时间序列特征进行建模。最后, 将 LSTM 的输出结果输入到完

全连接层里进行分析, 特征空间将被映射到更容易分类的输出层, 进而生成更容易分离的特征表示<sup>[28-31]</sup>。

如图 4 所示, 该网络其包含一个 LSTM 层、三个 CNN 层、一个线性层(dim red)以及一个完全连接层。每层的 CNN 层包括  $1 \times 5$  频率-时间滤波器和一个最大池化层; 最大池化层中池的大小为 2, 步幅大小为 2。在 CNN 层之后添加线性层可以有效地减少参数且没有精度损失。在通过 CNN 层之后, 使用具有 256 个输出的线性层来构造 LSTM 层的输入。在执行频率建模之后, 将输出传递给 LSTM 层, 对信号的时间序列进行建模。所使用的 LSTM 层由 64 个单元组成, 每个单元具有 256 个隐藏单元。最后, 使用一个全连接层输出分类的结果。




图 4 改进型神经网络的结构

Fig. 4 Structure of the improved neural network

2.2.2 基于小波包分解的人工神经网络(ANN, 方法 2)

小波包分解是一种能够针对近似特征和细节特征进行分解的方法。图 5 为 WPD 的流程, 在外观上类似一棵从顶部到底部的平衡树。利用  $j$  级分解, WPD 创建了  $2^j$  个表示为  $C_{j,l}$  的各种分解分量, 其中,  $l=0, 1, 2, \dots, 2^j-1$ , 是第  $j$  级的终端节点索引。按照表示为  $[S_0, S_1, \dots, S_m]$  的频带对分解后的信号进行排序,  $m=2^j-1$ 。每个频带的等效能量为

$$E_l = \sum_{n=1}^N |C_{j,l}(n)|^2, \quad (2)$$

其中,  $n$  表示索引,  $N$  表示序列的长度。通过归一化处理, 可以将(2)式中的小波包能量(WPE)向量表示为

$$\mathbf{T}_{wp} = \frac{1}{E_{wp\_sum}} [E_0, E_1, \dots, E_m], \quad (3)$$

式中:  $E_{wp\_sum}$  表示  $E_l$  中所有成员的总和。

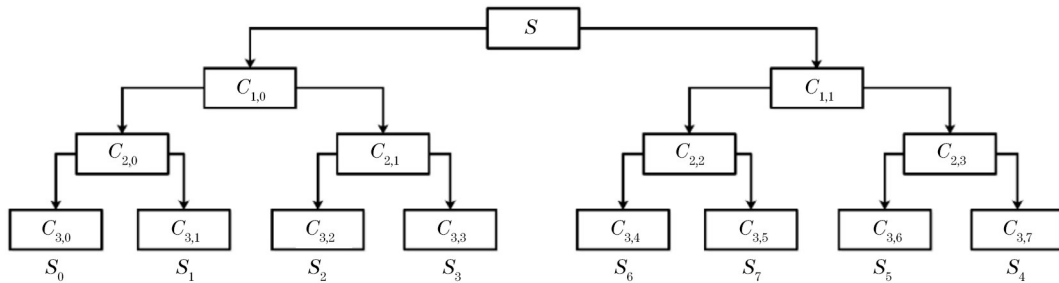


图 5 小波包分解的多尺度分解树

Fig. 5 Multi-scale decomposition tree of wavelet packet decomposition

完成多尺度分析后可以得到关于各类事件信号的能量分布信息。为了对事件进行进一步的分类和识别, 本文方法构建了一个 4 层的人工神经网络(如图 6 所示), 其中识别网络包含一个输出层、一个输入层和两个隐藏层。输入层以 WPE 作为基本输入特征, 网络的输入节点数由特征向量的维数  $2^j$  决

定。对于两个隐藏层, 通常选择双曲正切 Sigmoid 函数作为激活函数, 其中: 第一个隐藏层包含 5 个节点, 并根据一系列的实验参数进行测试; 调整第二个隐藏层中的三个节点。具有线性激活函数的输出层包含三个基于目标数的节点。




图 6 第二种分类方法的神经网络

Fig. 6 ANN network used for classification

2.2.3 具有三个隐藏层的全连接深度神经网络 (DNN, 方法 3)

全连接深度神经网络采用一种更为简单的神经网络, 主要由一个输入层、三个隐藏层和一个输出层组成(如图 7 所示)。对于三个隐藏层, 选择双曲正切 Sigmoid 函数作为其激活函数; 基于实验参数进行测试, 在第一隐藏层中设置 5 个节点, 在第二个隐藏层中设置 4 个节点, 在三个隐藏层中设置三个节点。最后的输出层由三个节点组成。

通过 3 种方法的对比, 可知本研究提出的方法 1 有别于方法 2 和方法 3, 方法 1 是一种新型的多级联神经网络, 它在 LSTM 的基础上结合了 CNN 网络的特点, 最后通过一个全连接层进行输出, 相比方法 2 和方法 3 更加复杂和稳定, 能够将信号的时域作为振动信号的特征输入神经网络进行深度学习, 有效避免了提取信号特征、构建特征向量等复杂的信号预处理方式, 可以实时对采集到的振动信号进行处理和分析。




图 7 第三种分类方法的神经网络

Fig. 7 DNN network used for classification

3 信号采集与标准化处理

不同类型的入侵事件对管道造成的破坏程度不同。本研究采集的数据类型主要有手工挖掘、机械挖掘以及非入侵事件三种。针对上海宝山地区管道周界实际铺设的光纤场地进行信号采集, 实验过程中使用的分布式光纤传感系统全长 20 km, 掩埋深度为 1.2 m, 采样频率为 750 Hz, 响应时间 ≤ 60 s。

传感系统可实现的距离分辨率为 5 m, 对振动信号的定位精度可以达到 ± 20 m。

为了保证采集数据具有多样性和复杂性, 本研究在不同位置、不同时间以及远离测试起点的位置对上述三种典型事件的振动信号样本进行采集, 采集到具有时域特征的信号后, 以 4 s 为间隔进行分段, 获取样本数据。图 8 给出在上海宝山地区采集的三种事件类型样本的时域信号图例。

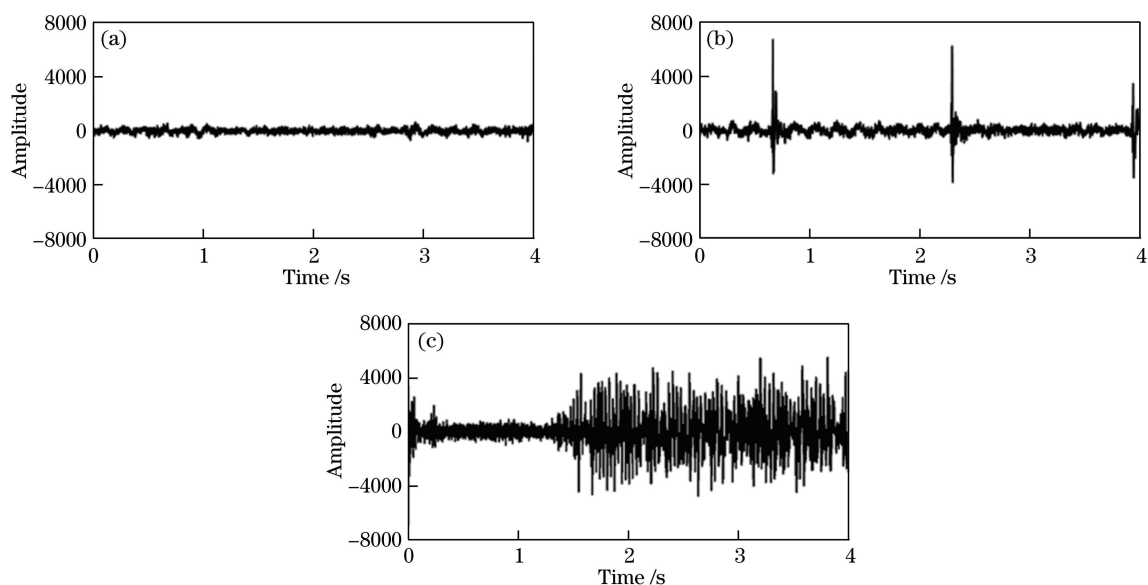


图 8 上海宝山地区 3 种类型的信号样本。(a)非入侵事件;(b)人工挖掘事件;(c)机械挖掘事件

Fig. 8 Three signal samples in Baoshan area of Shanghai. (a) NI event; (b) MG event; (c) ME event

在信号输入神经网络训练之前,首先对数据进行统一的标准化处理,这里以图 8 中在上海宝山地

区采集的三类事件为例,将三类信号进行标准化处理后的信号波形如图 9 所示。通过对比可见,Max

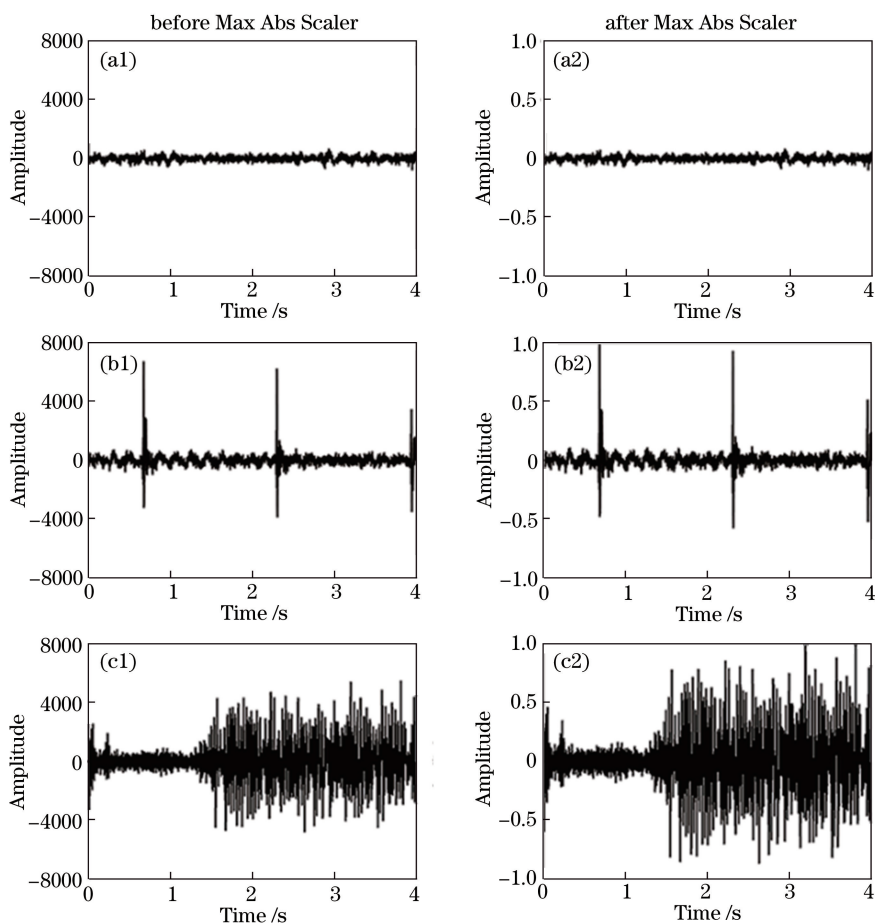


图 9 标准化前后信号样本的比较。(a1)(a2)非入侵事件;(b1)(b2)人工挖掘事件;(c1)(c2)机械挖掘事件

Fig. 9 Comparison of signal samples before and after Max Abs Scaler. (a1)(a2) NI event;

(b1)(b2) MG event; (c1)(c2) ME event

Abs Scaler 法并不会移动和聚集数据,只是将信号的范围缩放到 $[-1, 1]$ 的固定区间,便于随后利用神经网络进行深度学习建模。这里要特别指出的是,图 9(a1)(a2)为非入侵事件的信号样本,该事件的振幅比较小,在 $[-500, 500]$ 的区间内,所以这里选取最大值为 8000 进行归一化处理,以防将信号扩大,改变信号的时域特点。

另外,本系统累积时间信号的采样率为 750 Hz,

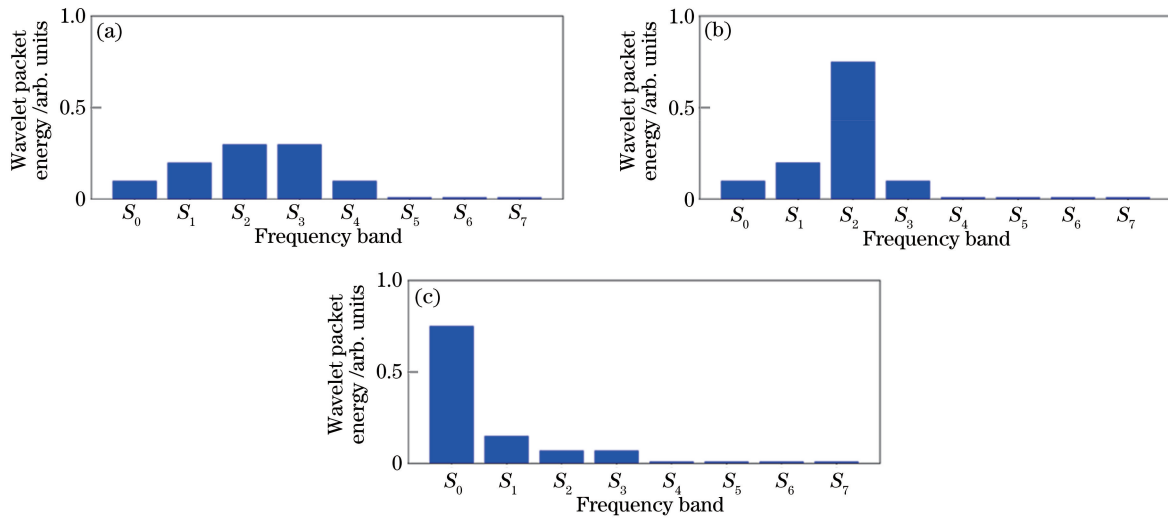


图 10 三类信号的 WPE 分布。(a)非入侵事件;(b)人工挖掘事件;(c)机械挖掘事件  
Fig. 10 Signal and its WPE distributions. (a)NI event; (b)MG event; (c) ME event

#### 4 模型构建及识别测试分析

使用在上海宝山地区采集的数据对神经网络模型进行训练。首先,实验准备识别模型的训练集和测试集。其中,神经网络的输入训练集和测试集的

所以根据小波包分解的基本原理,分解后的频带宽度为 46.875 Hz。图 10 为上述三种典型事件的 WPE 分布情况,从图中可以看出三种类型事件的信号在各频段的分布存在差异,非入侵事件的能量在低频和中频段都有一定的分布且相对均衡,人工挖掘事件的能量主要集中在 S<sub>2</sub> 分量,而机械挖掘事件的能量绝大部分存在于低频的 S<sub>0</sub> 分量。根据这些信号的能量分布特征,可进行信号的识别和分类。

具体信息如表 1 所示,一般训练集和测试集的分割比例约为 7:3,总共包含 16500 组训练数据,其中非入侵事件数据 5500 组,人工挖掘事件数据 5500 组,机械挖掘事件数据 5500 组。

表 1 第一次实验的数据信息  
Table 1 The first experiment data

Type of event	Number of training sets	Collection location of training sets /km	Number of test sets	Collection location of test sets /km
NI	5500	2.99	2000	2.99
MG	5500	6.21	2000	6.21
ME	5500	5.68	2000	5.68

训练时,所有训练数据集都训练过一次为 1 个 epoch。Epoch 的多少决定该神经网络对于数据的拟合程度,epoch 次数过大,则可能会造成数据的过拟合,反之则会造成欠拟合。神经网络训练过程中的 epoch 次数由神经网络本身的自测准确率 V 自测准确率决定,这里设置神经网络的自测准确率到达 99% 以上时停止训练,以防止 epoch 过大造成过拟合。图 11 为神经网络训练所用的 epoch 与自测准确率的关系,由此可见当 epoch 达到 1185 次时,

自测准确率已到达要求,此时训练模型的训练损耗也接近于 0。在完成模型训练后,选择与训练集不同的测试集作为测试集来测试模型的识别效果。由表 1 可见,总共 6000 组新数据作为测试集,用于检验模型的识别效果,其中包括非入侵事件数据 2000 组,人工挖掘事件数据 2000 组,机械挖掘事件数据 2000 组。

该系统对上述三种类型信号的识别准确率如表 2 所示,方法 1 中信号识别平均准确率为




图 11 训练中 Epoch 大小与自测准确率和训练损耗的变化关系。(a)自测准确率;(b)训练损耗

Fig. 11 Relationship between number of epoch and validation accuracy, training loss during training.

(a) Validation accuracy; (b) training loss

97.2%，方法 2 中信号识别平均准确率为 95.2%，方法 3 中信号识别平均准确率为 93.5%。通过比较发现，三种方法的测试准确率均在 90% 以上，其中方法 1 的测试效果最好。

表 2 第一次实验的信号识别准确率

Table 2 Signal recognition accuracy of the first experiment

Type of event	Method 1	Method 2	Method 3
NI	98.2	95.9	95.0
MG	97.5	95.5	93.1
ME	96.1	94.2	92.5
Average accuracy	97.2	95.2	93.5

unit: %

## 5 识别系统的准确性研究

光纤预警系统的准确性表征该系统对不同地点采集数据的识别分类能力。根据实际的需求，

表 3 第二次实验的数据信息

Table 3 The second experiment data

Type of event	Number of training sets	Collection location of training sets /km	Number of test sets	Collection location of test sets /km
NI	5500	2.99	2000	14.96
MG	5500	6.21	2000	16.86
ME	5500	5.68	2000	6.24

表 4 第二次实验的信号识别准确率

Table 4 Signal recognition accuracy of the second experiment

Type of event	Method 1	Method 2	Method 3
NI	98.0	95.2	94.0
MG	96.3	94.0	92.1
ME	95.4	92.7	90.5
Average accuracy	96.5	93.8	92.2

unit: %

根据表 2、表 4 的数据分析结果，可以看出，在真实环境的光纤系统上，由上述三种方法得到的系统平均识别准确率均在 90% 以上。不过，随着训练和测试数据复杂度增加，系统的识别精度随之降低。其中，方法 2 和方法 3 获得的平均准确率与方法 1

从 3 个方面进行探究：1) 研究分析光纤系统同一位置上的数据；2) 研究分析光纤系统不同位置上的数据；3) 研究改进神经网络应用前后的系统识别率。

本文在第 4 章已完成对上述第一种情况的研究，最终结果显示改进型神经网络的识别效果优秀。本章将研究该系统光纤不同位置上数据的识别准确性，此时使用的测试集与第一次实验不同，是由在系统其他位置点采集的振动数据构成，具体的数据信息如表 3 所示。同样地，用三种方法进行实验，实验的结果如表 4，方法 1 中信号识别平均准确率为 96.5%，方法 2 中信号识别平均准确率为 93.8%，方法 3 中信号识别平均准确率为 92.2%。通过比较发现，三种方法的测试准确率均有所下降，但方法 1 的测试效果最稳定。

相比下降的幅度更为显著。综合比较可知，方法 1 的识别效果最好，在两次实验中的最终识别准确率均在 95% 以上。而且方法 1 训练后的识别模型可以直接输入时域信号，更简单有效。除此以外，实验在测试过程中记录了三种方法识别 2000 组数据的平均识别时间，具体信息如表 5 所示。

表 5 三种方法的识别时间的比较

Table 5 Comparison of the recognition time of the three methods

Number of test sets	Method 1	Method 2	Method 3
2000	1.74 s	5.43 s	1.88 s



为了保证分析的完整性,最后进行了第三次实验,比较了应用方法 1 即改进型神经网络前后两种情况下系统对于干扰事件发生的预测能力。这里未使用改进型神经网络的方法是指方法 3 即第三种全连接神经网络,由于第二种方法产生大量的小波系数,训练网络的复杂性增加,实时性较差,这里不作讨论。图 12 给出人工挖掘事件发生时,整个光纤长度上各点的识别概率(PR)。实验数据为在 6.81 km 处进行人工挖掘时采集的整个光纤长度上的数据。此时光纤上的其他位置处没有其他的入侵

事件。图 12(a)中可见,未使用改进型神经网络前,系统对于 6.81 km 处发生的人工挖掘事件可以进行预测,但是识别率还不到 80%,其他位置还有一定程度的误报虚警,这是因为该算法中没有经过复杂网络,也没有进行归一化运算,所以由该网络生成的模型,在实时的采集环境中不具备较好的应变能力,对于新发生事件的预测能力较差;然而利用改进型神经网络后,由图 12(b)可见 6.81 km 处的识别率超过 95%,其他位置处也没有误报虚警的情况发生,系统模型整体的识别率得到改善。




图 12 模型识别人工挖掘事件的发生概率对比。(a)未使用改进型神经网络;(b)使用改进型神经网络  
Fig. 12 Comparison of occurrence probability of MD event in model recognition. (a) Before using the improved neural network; (b) after using the improved neural network

## 6 结 论

为了实现对真实环境中入侵事件的精准分类和识别,本研究提出一种新型高智能化光纤预警系统,并对其识别分类的准确性进行了研究。

本研究应用的长距离预警系统由分布式传感和信号识别两部分组成。其中,分布式传感部分采用 $\Phi$ -OTDR技术来检测由外界入侵事件产生的光纤动态应变,采集数据,并将数据输入信号识别部分进行分类。在信号识别部分中采用了三种神经网络的方法,其中基于CNN的改进型神经网络的识别准确率最高,达到95%以上。通过三次真实环境实验,证明该改进型神经网络技术具有较高的准确性。因此,该技术可以在世界范围内的光纤监测领域进行推广。本研究成功解决了油气传输管道入侵事件监测的现场部署及性能评估等相关问题,上述研究成果对油气管道安全监测具有较高的实用价值。

### 参 考 文 献

- [1] Cramer R, Shaw D, Tulalian R, et al. Detecting and correcting pipeline leaks before they become a big problem [J]. *Marine Technology Society Journal*, 2015, 49(1): 31-46.
- [2] Lu B, Wang Z Y, Zheng H R, et al. The achievement of high spatial resolution and long haul distributed fiber vibration sensing system [J]. *Chinese Journal of Lasers*, 2017, 44(10): 1015001. 卢斌, 王照勇, 郑汉荣, 等. 高空间分辨率长距离分布式光纤振动传感系统 [J]. *中国激光*, 2017, 44(10): 1015001.
- [3] Lin W T, Lou S Q, Liang S. Fiber-optic distributed vibration sensor for pipeline pre-alarm [J]. *Applied Mechanics and Materials*, 2014, 684: 235-239.
- [4] López-Higuera J M, Cobo L R, Incera A Q, et al. Fiber optic sensors in structural health monitoring [J]. *Journal of Lightwave Technology*, 2011, 29(4): 587-608.
- [5] Juarez J C, Maier E W, Choi K N, et al. Distributed fiber-optic intrusion sensor system [J]. *Journal of Lightwave Technology*, 2005, 23(6): 2081-2087.
- [6] Ren L, Jiang T, Jia Z G, et al. Pipeline corrosion and leakage monitoring based on the distributed optical fiber sensing technology [J]. *Measurement*, 2018, 122: 57-65.
- [7] Chai Q, Luo Y, Ren J, et al. Review on fiber-optic sensing in health monitoring of power grids [J]. *Optical Engineering*, 2019, 58(7): 072007.
- [8] Zhang X, Guo Z, Shan Y, et al. Enhanced  $\Phi$ -OTDR system for quantitative strain measurement based on

- ultra-weak fiber Bragg grating array [J]. *Optical Engineering*, 2016, 55(5): 054103.
- [9] Cai H W, Ye Q, Wang Z Y, et al. Distributed optical fiber acoustic sensing technology based on coherent Rayleigh scattering [J]. *Laser & Optoelectronics Progress*, 2020, 57(5): 050001.  
蔡海文, 叶青, 王照勇, 等. 基于相干瑞利散射的分布式光纤声波传感技术[J]. *激光与光电子学进展*, 2020, 57(5): 050001.
- [10] Yang Y, Sha Z, Feng H, et al. Signal processing method of  $\Phi$ -OTDR technology in early warning and leakage positioning of water pipelines [J]. *Laser & Optoelectronics Progress*, 2018, 55(4): 040607.  
杨洋, 沙洲, 封皓, 等. 输水管道预警与泄漏定位中  $\Phi$ -OTDR 技术信号处理法[J]. *激光与光电子学进展*, 2018, 55(4): 040607.
- [11] 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.
- [12] Ma H Y, Wang X X, Ma F, et al. Research progress of  $\Phi$ -OTDR distributed optical fiber acoustic sensor [J]. *Laser & Optoelectronics Progress*, 2020, 57(13): 130005.  
马皓钰, 王夏霄, 马福, 等.  $\Phi$ -OTDR 型分布式光纤声波传感器研究进展[J]. *激光与光电子学进展*, 2020, 57(13): 130005.
- [13] 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.
- [14] Wang Y, Jin B Q, Wang Y C, et al. Real-time distributed vibration monitoring system using  $\varphi$ -OTDR [J]. *IEEE Sensors Journal*, 2017, 17(5): 1333-1341.
- [15] Liu S J, Zhang J Q, Wan J F, et al. The research of recognition algorithm of vibration source based on the optical fiber vibration safety warning system [J]. *Optical Technique*, 2016, 42(1): 89-96.  
刘素杰, 张金权, 万江飞, 等. 基于光纤振动安全预警系统的振源识别算法研究[J]. *光学技术*, 2016, 42(1): 89-96.
- [16] 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.
- [17] Wang Y P, Gong D J, Pang L P, et al. RVFL-based optical fiber intrusion signal recognition with multi-level wavelet decomposition as feature [J]. *Photonic Sensors*, 2018, 8(3): 234-241.
- [18] Qu Z G, Feng H, Zeng Z M, et al. A SVM-based pipeline leakage detection and pre-warning system [J]. *Measurement*, 2010, 43(4): 513-519.
- [19] Papp A, Wiesmeyr C, Litzemberger M, et al. A real-time algorithm for train position monitoring using optical time-domain reflectometry [C] // 2016 IEEE International Conference on Intelligent Rail Transportation (ICIRT), August 23-25, 2016, Birmingham, UK. New York: IEEE Press, 2016: 89-93.
- [20] Zhan Y, Yu Q, Wang K, et al. A high performance distributed sensor system with multi-intrusions simultaneous detection capability based on phase sensitive OTDR [J]. *Opto-Electronics Review*, 2015, 23(3): 187-194.
- [21] Tejedor J, Macias-Guarasa J, Martins H, et al. Machine learning methods for pipeline surveillance systems based on distributed acoustic sensing: a review [J]. *Applied Sciences*, 2017, 7(8): 841.
- [22] Sidelnikov O, Redyuk A, Sygletos S. Equalization performance and complexity analysis of dynamic deep neural networks in long haul transmission systems [J]. *Optics Express*, 2018, 26(25): 32765-32776.
- [23] Wang G L, Li X L, Li Y. The application of wavelet transform in the fiber pipeline safety pre-warning system [C] // The 27th Chinese Control and Decision Conference (2015 CCDC), May 23-25, 2015, Qingdao, China. New York: IEEE Press, 2015: 3605-3608.
- [24] Tian Q, Yang D, Zhang Y, et al. Detection and recognition of mechanical, digging and vehicle signals in the optical fiber pre-warning system [J]. *Optics Communications*, 2018, 412: 191-200.
- [25] Tejedor J, Macias-Guarasa J, Martins H F, et al. Real field deployment of a smart fiber-optic surveillance system for pipeline integrity threat detection: architectural issues and blind field test results [J]. *Journal of Lightwave Technology*, 2018, 36(4): 1052-1062.
- [26] Tian Q, Zhao C, Zhang Y, et al. Intrusion signal recognition in OFPS under multi-level wavelet decomposition based on RVFL neural network [J]. *Optik*, 2017, 146: 38-50.
- [27] Mistry J, Inden B. An approach to sign language translation using the intel real sense camera [C] // 2018 10th Computer Science and Electronic Engineering (CEECS), September 19-21, 2018, Colchester, United Kingdom. New York: IEEE Press, 2018: 219-224.
- [28] Sak H, Senior A, Beaufays F. Long short-term memory based recurrent neural network architectures for large vocabulary speech recognition [EB/OL].

- (2014-02-05) [2020-09-01]. <https://arxiv.org/abs/1402.1128>.
- [29] Greff K, Srivastava R K, Koutnik J, et al. LSTM: a search space odyssey [J]. IEEE Transactions on Neural Networks and Learning Systems, 2017, 28 (10): 2222-2232.
- [30] Sainath T N, Vinyals O, Senior A, et al. Convolutional, long short-term memory, fully connected deep neural networks [C] // 2015 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP), April 19-24, 2015, South Brisbane, QLD, Australia. New York: IEEE Press, 2015: 4580-4584.
- [31] Jiang F, Li H L, Zhang Z H, 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.