

文章编号: 2095-2163(2021)09-0048-07

中图分类号: TN274

文献标志码: A

分布定位式光纤振动传感系统的事件识别

吴世海, 任梓豪, 何抒航, 贾建华, 孟雨盈, 孔 勇

(上海工程技术大学 电子电气工程学院, 上海 201620)

摘要: 本文提出了一种对分布式光纤声传感器的入侵事件分类方法。该方式采用小波包去噪方式对原始信号进行去噪;将去噪后的原始信号进行小波变换,得到原始信号的小波时频图;构建双输入型的卷积神经网络,将滤波后的原始一维信号直接输入到一个三层的1-D CNN中,滤波后得到的二维小波时频图直接输入到一个两层的2-D CNN中;将两种CNN输出的特征输入到支持向量机(SVM),使用SVM对事件进行分类。本文中主要识别3种振动事件:汽车通过、挖掘机挖掘和破路机工作。实验结果表明,所提方式对实际环境中3种振动事件的识别准确率平均可以达到96%,并且识别时间仅为0.61 s。

关键词: 分布式光纤传感;相敏光时域反射计(φ -OTDR);一维卷积神经网络;二维卷积神经网络;支持向量机

Event recognition based on the distributed located fiber sensor

WU Shihai, REN Zihao, HE Shuhang, JIA Jianhua, MENG Yuying, KONG Yong

(School of Electrical and Electronic Engineering, Shanghai University of Engineering Science, Shanghai, 201620, China)

[Abstract] In this paper, a novel approach to classify intrusion events from distributed fiber optic acoustic sensors is proposed. The approach consists of four main steps. At the first step, the original signal is denoised using wavelet packet denoising. At the second step, the denoised original signal is transformed with wavelet to obtain the wavelet time-frequency map of the original signal. At the third step, a two-input convolutional neural network is constructed. The filtered original 1-D signal is directly fed into a three-layer 1-D CNN, and the filtered 2-D wavelet time-frequency map is directly fed into a two-layer 2-D CNN. At the fourth step, the features output from the two CNNs are fed to a support vector machine (SVM), which is used to classify the events. A phase-sensitive optical time-domain reflectometer (φ -OTDR) sensing system is also used. In this paper three main vibration events are identified; car passing, excavator digging, and road breaker working. The experimental results show that the recognition accuracy of the three vibration events in the real environment using the proposed approach can reach 96% on average, and the recognition time is 0.61 s.

[Key words] distributed fiber optic sensing; phase-sensitive optical time domain reflectometer (φ -OTDR); 1D convolutional neural network; 2D convolutional neural network; support vector machine

0 引言

由于相位敏感光时域反射计(φ -OTDR)^[1-2]具有高灵敏度、高空间分辨率、监控距离长的优势,可以准确的定位振动事件位置。所以, φ -OTDR分布式声传感器已被广泛应用于油气管道安全检测^[3]、高速轨道的入侵检测^[4]、周界安防^[5]等领域。但是,在这些领域对于识别实际环境下的振动事件还是非常具有挑战性的任务。

对振动信号的识别主要分为3个步骤:振动信号的预处理、振动信号的特征提取、对振动信号进行分类。振动信号的预处理主要是对信号进行去噪,划分数据集;特征提取需要通过不同方式来获取不同类型的振动信号特征。提取到的特征应能很好的

表达振动信号具有的性质,不同特征之间的搭配也会形成不同的分类效果。提取的典型特征有短时过零率、短时能量、梅尔频率倒频系数(MFCC)^[6-8]。除了直接提取特征外,还可以使用EMD、VMD分解算法将信号分解后再提取信号的相关特征^[9-10]。根据提取的振动信号的特征使用分类器进行分类。典型的分类器有支持向量机(SVM)^[11]、相关向量机(RVM)^[12]、高斯混合模型^[13]和随机森林树^[14]。然而在使用分布式光纤传感系统进行长距离监测时,数据量会随监测长度的增加而增加,但上述方式在处理大量数据时会非常耗费时间。对于振动信号特征的选择也是一件很困难的事情,对于不同类型的振动事件使用相同的特征可能会出现识别效果不理想的情况。

基金项目: 上海市自然科学面上基金项目(19ZR1421700)。

作者简介: 吴世海(1999-),男,本科生,主要研究方向:光纤传感技术;孔 勇(1977-),男,博士,副教授,高级工程师,主要研究方向:光纤传感技术、数字全息技术等。

通讯作者: 孔 勇 Email:kky7757@163.com

收稿日期: 2021-02-01

随着深度学习算法在图像识别^[15]、情绪识别^[16]、故障诊断^[17]中的应用,深度学习算法也开始被应用到对分布式声传感器振动信号的识别中。文献[18]中提出,将卷积神经网络应用到分布式光纤声传感系统中,去识别电缆的放电现象。使用的方式为:使用梅尔频率倒谱算法,将采集到的电缆一维振动信号转为二维的MFCC后,根据得到的MFCC画出二维图像;将该MFCC图像作为深度神经网络的输入,使识别平均准确率达到97.1%。文献[19]提出使用一维卷积神经网络代替二维卷积神经网络,在降低识别时间的同时提高了识别准确率。文献[20]提出使用两种不同类型的卷积神经网络,对高速轨道的入侵事件进行检测,克服了大量噪声的影响,将误报率减小到10%,准确率到达了91%。虽然这些方法提供了很好的结果,但为了提高在实际环境下的识别准确率,仍然需要开辟新的方式。

因此,本文尝试使用双输入多层卷积神经网络(TI-CNN)对振动事件进行分类。首先将经过小波包去噪的原始信号输入1-D CNN,把通过小波变换得到的小波时频图输入2-D CNN中;将1-D CNN和2-D CNN提取的特征使用SVM来进行分类。由于TI-CNN融合了两种不同类型CNN输出的特征,所以相比于传统1-D CNN、2-D CNN能获得更多的特征。TI-CNN相比于CNN+LSTN^[21],具有更浅的网络层次。所以在输入数据量小的时候不容易出现过拟合的现象,并且识别时间更短。通过对比LeNet-5型1-D CNN与TI-CNN的性能差异证实:本文所提模型能更好的对振动信号进行分类,并且由于采用了SVM进行最后的识别分类,可以将全连接层的数量减小且识别时间也满足了实时识别的要求。

1 使用 TI-CNN 分类的方法

在对路面振动事件的长距离监测中,所使用的分布式光纤声传感器系统,如图1所示。所采用的分布式光纤声传感器系统主要分为3大部分: ϕ -OTDR 传感系统、传感光纤、信号识别单元。分布式光纤声传感系统的主要工作步骤如下:

(1)激光经过声光调制器(AOM)后被调制为光脉冲。该光脉冲被掺铒光纤放大器(EDFA)放大后通过一个带通滤波器(BPF),滤除由EDFA产生的放大自发辐射(ASE)噪声。

(2)得到的滤波光脉冲从环形器的1号端口进入环形器,再从环形器的2号端口射入传感光纤。

由传感光纤返回的后向瑞利散射光经环形器的3号端口输出到EDFA,经过EDFA放大后,再使用BPF滤除ASE噪声。

(3)光电探测器将滤波后的后向瑞利散射光转换为电信号,在通过信号采集卡后将采集到的信号输入到信号处理单元进行识别。

在本次应用中,主要的识别任务是区分通过路面的汽车、路面挖掘机的挖掘工作和路面破路机的工作事件。

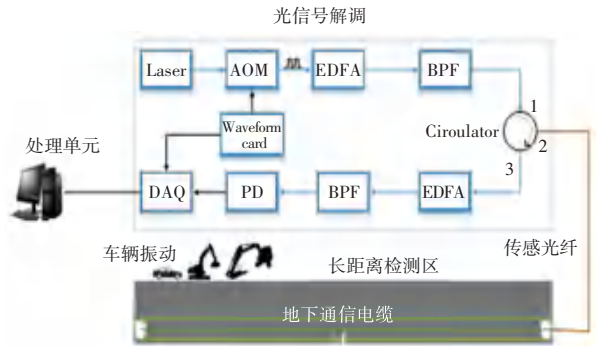


图1 phi-OTDR 系统实验设置

Fig. 1 Phi-OTDR system experimental setting

图中,AOM为声光调制器;EDFA为掺铒光纤放大器;PD为光电探测器;DAQ为数据采样器。

本文所提出的TI-CNN的识别方式如图2所示,主要步骤为:数据的预处理、数据集的准备、数据集转为小波时频图、使用TI-CNN进行训练、对训练结果分类。

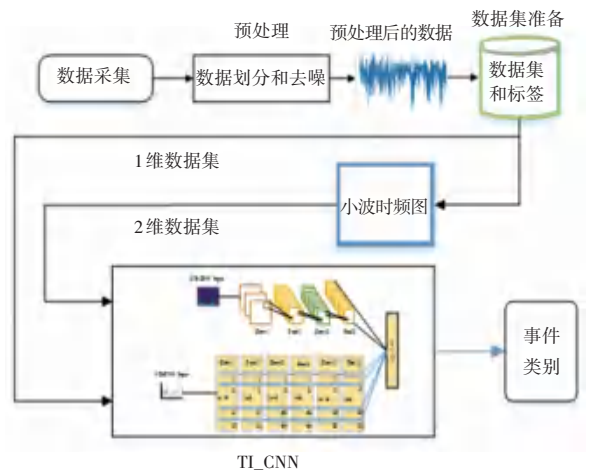


图2 系统操作过程

Fig. 2 System operating process

1.1 数据去噪

振动数据是通过采集传感光纤上每个点的空间响应以及积累沿时间轴的空间响应得到的。获得的在每个点空间的一维时间序列被轮流作为识别目标。由于在实际环境中存在有许多的噪声,导致信

号被淹没在各种噪声中,严重影响最后的识别结果。因此,在对数据进行分析之前,需对数据进行去噪处理。本文使用文献[22]中提到的基于小波分解的信噪分离方式,并使其更好的应用到分布式光纤振动传感信号上。WD的处理过程如图3所示。




图3 多尺度分解树

Fig. 3 Multi-scale decomposition tree

小波包分解与小波分解相比,小波包分解能将前一步分解结果中的高频部分继续分解,会将原始信号分解到 2^i (i 为分解尺度)小波包子空间中。因此,小波包分解能得到比小波分解更详细的信息。小波包分解公式为:

$$L_i^{2j-1} = \sum_m H(m-2x)L_{i-1}^j(x) \quad (1)$$

$$L_i^{2j} = \sum_m G(m-2x)L_{i-1}^j(x) \quad (2)$$

式中: $L_i^j(x)$ 表示第 i 层上第 j 个小波包, H 、 G 表示共轭滤波器系数。

小波包重构的公式为:

$$L_i^j = 2 \left[\sum_m H_{(m-2k)} L_{i+1}^{2j-1}(x) + \sum_m G_{(m-2k)} L_{i+1}^{2j}(x) \right] \quad (3)$$

因此,在本文中使用的3层,母波为‘sym8’的小波包分解,对振动信号进行去噪。小波包分解的层数和母波类型是通过实验选择的最优设置。

1.2 数据集准备

在图1所示的对地面振动事件的监测中存在着很多的振动源,而本文主要研究小汽车通过,挖掘机挖掘,破路机工作这3种振动源,将这3种事件依次命名为类型1、类型2、类型3。

1.3 数据集转为小波时频图

对时序信号的分析主要有两种方式:连续小波变换(CWT)、短时傅里叶变换(STFT)。STFT的窗口是固定的,在实际使用中很难寻找到一个合适的窗口大小。一方面,如果窗口尺寸太窄,则窗口所截取的信号将太短,从而导致频率分析不精准。另一方面,如果窗口尺寸太宽,则导致截取的信号长度太长,从而导致较低的时间分辨率。所以短时傅里叶变换不能满足非稳态信号变化的频率要求。

连续小波变换很好的解决了短时傅里叶变换(STFT)固定窗口的问题。其通过采用一个有限长

衰减小波基函数来代替STFT中的无限长三角基函数,更适合用于非稳态的时序信号的处理。通过使用CWT,可以将一维时序信号转变为二维的时频图像。二维时频图像包含了一维时序信号的时间和频率的信息,相比于原始信号,时频图能全面、更准确的反应出原始信号的特征。

分布式光纤传感系统返回的振动信号属于非稳态信号,所以采用CWT对其进行分析。对任意 $L^2(r)$ 空间的函数 $f(t)$,其CWT的变换方程如下:

$$WT(a,b) = \frac{1}{\sqrt{a}} \int f(t) \psi \left(\frac{t-b}{a} \right) dt \quad (4)$$


其中:

$$\psi_{a,b}(t) = \frac{1}{\sqrt{a}} \psi \left(\frac{t-b}{a} \right) \quad (5)$$


在公式(4)中, a 是一个尺度分解因子, $a > 0$ 代表频率相关拓展; b 是平移量,代表时间相关的拓展; $\psi_{a,b}(t)$ 是小波基函数。

给出尺度分解因子和小波基函数后,就可以根据公式(1)得到各振动信号的小波系数,并将小波系数序列转变为实际的频率序列。结合点序列,画出各振动信号的小波时频图。

对分布式光纤声传感系统采集的振动信号进行小波时频分析中,根据实验得出最优小波基函数参数选择‘Cgau1’,尺度分解因子为30。小汽车通过、破路机工作、挖掘机挖掘所生成的小波时频图像如图4所示。



(a) 汽车通过的情况 (b) 挖掘机工作的情况



(c) 破路机工作的情况

图4 小波时频图

Fig. 4 Wavelet time-frequency chart

1.4 基于TI_CNN训练

采用TI_CNN(3层1-D CNN,2层2-D CNN)比

采用单独网络结构的 LSTM、1-D CNN、2-D CNN 得到更好的性能,如图 5 所示。

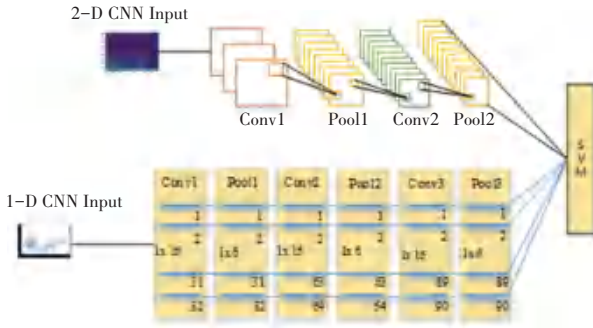


图 5 TI_CNN 网络

Fig. 5 TI_CNN Web

图 5 显示出该识别网络具有两种不同输入类型卷积神经网络。下臂使用的神经网络结构为 3 层 1-D CNN,其网络结构参数见表 1;由于 2-D CNN 输入的参数较多运算量较大,所以在本文中提出仅采用 2 层 2-D CNN 对小波时频图进行识别,大大减小了 2-D CNN 对图像特征提取的时间,双层 2-D CNN 的网络结构参数见表 2;使用两个全连接层 (FC) 将上下臂卷积神经网络输出的特征映射到样本标记空间,从而将所有特征整合到一起,最后使用一个 SOFTMAX 分类层输出各标记事件的概率值。其网络结构参数见表 3。

使用 TI_CNN 进行分类前需要先将 CNN 模型训练好,但由于 SVM 不能进行反向梯度传播,故先使用 softmax 层来输出 TI_CNN 的准确率,当准确率达到要求时便认为 TI_CNN 的模型已经训练好,再将训练好的 TI_CNN 模型用来提取特征,使用 SVM 来进行最后的分类。SVM 的核函数设置为高斯核函数,超参数 C 设置为 0.09, $degree$ 设置为 3。

表 1 1-D CNN 的参数

Tab. 1 Parameters of 1-D CNN

Layers	Kernal size/Fliters	Input Shape
Conv1	1×32/16	1×4 096×1
Pool1	1×6	1×4 081×32
Conv2	1×64/16	1×680×32
Pool2	1×6	1×665×64
Conv3	1×90/16	1×110×64
Pool3	1×6	1×95×90
FC	neurons:6 400	1×1 350
Batch_size = 300		

表 2 2-D CNN 的参数

Tab. 2 Parameters of 2-D CNN

Layers	Kernal size/Fliters	Input Shape
Conv1	1×64×64/9	1×64×64×3
Pool1	1×3×3	1×56×56×64
Conv2	1×128×128/9	1×18×18×64
Pool2	1×3×3	1×10×10×128
FC	neurons: 8 500	1×1 152
Batch_size = 300		

表 3 全连接层的参数

Tab. 3 Parameters of the full connection layer

Layers	Neurons _ num	Input Shape
FC1	neurons:3 000	1×14 900
FC2	neurons:1 000	1×3 000
SOFTMAX	neurons:3	1×1 000
Batch_size = 300		

下臂的 1-D CNN 网络输入的是经过滤波的原始一维振动信号,上臂的 2-D CNN 网络输入的是使用滤波信号经过 CWT 得到的小波时频图。卷积层和全连接层使用的激活函数都是线性整流函数 ($ReLU$)。 $ReLU$ 是一个非线性函数,其定义如下:

$$\varphi(x) = \text{Max}(x, 0) \quad (6)$$

$ReLU$ 激活函数可以有效避免梯度消失的问题,并且运算简单,可以提高计算速度且能让网络很快收敛。

TI_CNN 采用的损失函数为:

$$L = - \sum_{j=1}^M y^{(j)} \log \hat{y}^{(j)} + (1 - y^{(j)}) \log(1 - \hat{y}^{(j)}) \quad (7)$$

式中, G 代表具有 G 个样本数, $y^{(j)}$ 和 $\hat{y}^{(j)}$ 分别代表第 j 个信号样本的真实值和预测值。

采用随机梯度下降 (SGD) 去更新 TI_CNN 的网络参数。在本文中 SGD 损失函数的学习率设置为 0.01,该参数是经过实验得出的最优参数。在训练结束后,使用 $Accuracy$ 、 $Recall$ 、 $Precision$ 、 $F1$ 来评估模型的有效性。具体公式如下:

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (8)$$

$$Recall = \frac{TP}{TP + FN} \quad (9)$$

$$Precision = \frac{TP}{TP + FP} \quad (10)$$

$$F1 = \frac{2 \times Recall \times Precision}{Recall + Precision} \quad (11)$$

式中, TP 代表在判断正类中判断正确的个数; TN 代

表在判断负类中判断正确的个数;FP 代表在判断正类中判断错误的个数;FN 代表在判断负类中判断错误的个数。

2 实验

实验设置如图 1 所示。一个线宽为 3 kHz, 能源为 10 mW 的分布式反馈激光器 (DFB-LD) 产生连续激光。这个光源被 AOM (100 M) 调制为光脉冲。然后通过一个 EDFA (插入损耗为 4 dB, 增益为 27 dB) 被放大, 并使用 BPF 滤除 ASE 噪声。这个光被注入一段 20 km 长的传感光纤中通过一个光学环形器。后向瑞利散射光往回传播通过传感光纤, 由 EDFA 放大和 BPF 滤波后被 PD (100 M) 检测, 然后由采样率为 200 MS/s, 位数为 12 bit 的 DAQ 采样。实验数据在上海沪松路和文翔东路工地上采集。其中, 20 km 长的传感光纤被深埋在地下大约 1~2 m 处。

实验中, 3 种主要的振动事件被选择作为振动信号识别的对象, 总共设置 1 200 个一维数据样本和 1 200 个小波时频图样本, 按照 7:3 的划分比例, 随机将数据划分为训练集和测试集, 每个样本的帧长为 2 s。在施工现场的左方大约 5 m 处有一条大约 4.8m 宽的公路, 当有汽车通过时便记录下此时的振动波形; 挖掘机挖掘是挖掘机在施工现场进行挖掘工作时采集到的波形; 破路机工作是指将挖掘机原有的铲斗更换为破碎锤时进行工作的振动信号。振动识别实验在一台配备了 NVIDIA Quadro P5000 GPU 的图形工作站上进行。

本文中, CNN 结构是在基于 keras 框架上使用 python 编程语言实现的。LeNet-5 1-D CNN 结构如图 6 所示。




图 6 1-D CNN 结构

Fig. 6 1-D CNN construction

网络详细信息见表 4。表 4 中主要展示了 1-D CNN 网络的输入值大小、卷积层中卷积核的大小以及卷积核的数量。

上述两个网络每次迭代输入的数据量 (Batch_size) 设置为 300。LeNet-5 型 1-D CNN 网络输入的是数据集中的经过滤波后的一维原始信号样本。TI_CNN (输入的是经过滤波的一维原始信号和使用滤


波后的一维信号通过 CWT 得到的小波时频图。

表 4 LeNet-5 1D_CNN 参数

Tab. 4 Parameters of LeNet-5 1D_CNN

Layers	Kernal size/Fliter	Input Shape
Conv1	1×32/16	1×4096×1
Pool1	1×6	1×4081×32
Conv2	1×64/16	1×680×32
Pool2	1×6	1×665×64
Conv3	1×90/16	1×110×64
Pool3	1×6	1×95×90
FC1	neurons: 6 400	1×1 350
FC2	neurons: 1 000	1×6 400
SOFTMAX	neurons: 3	1×1 000
Batch_size = 300		

两种方法在测试集上的混淆矩阵如图 7 所示。在图 7 中, 使用 TI_CNN 对小汽车通过、挖掘机挖掘、破路机工作的识别准确率分别为 95%、94%、100%, 平均识别率为 96.3%; LeNet-5 型 1-D CNN 对小汽车通过、挖掘机挖掘、破路机工作的识别率分别为 94%、93%、86%, 平均识别为 91%。



(a) 1-D CNN (LeNet-5) 方法 (b) TI_CNN 方法

图 7 混淆矩阵

Fig. 7 Confusion matrix

由此可见, 由于 TI_CNN 采用两种卷积神经网络对振动信号进行特征的提取, 能提取到更加丰富的特征, 再加上使用 SVM 进行分类, 使其准确率和识别时间都有所提升, 其平均准确率高于 LeNet-5 型 1-D CNN。TI_CNN 和 LeNet-5 型 1-D CNN 的验证集损失函数下降曲线如图 8 所示、验证集准确率上升曲线如图 9 所示。

在图 8 中, LeNet-5 型 1-D CNN 损失函数的下降速度优于 TI_CNN, 但在图 9 中, LeNet-5 1-D CNN 出现过拟合 (准确率曲线振荡过大) 的程度比 TI_CNN 严重。其主要原因是: TI_CNN 不仅从原始一维信号中提取出信号的时域特征, 还从小波时频图中获得了时频域特征, 而 LeNet-5 1-D CNN 只能从一维信号中获得信号的时域特征。TI_CNN 由于

合并了两种卷积神经网络的特征, 加大了识别的数据量, 所以在输入数据量较小时也不易出现过拟合。




图 8 损失函数下降曲线

Fig. 8 Loss value of 1-D CNN and TI_CNN

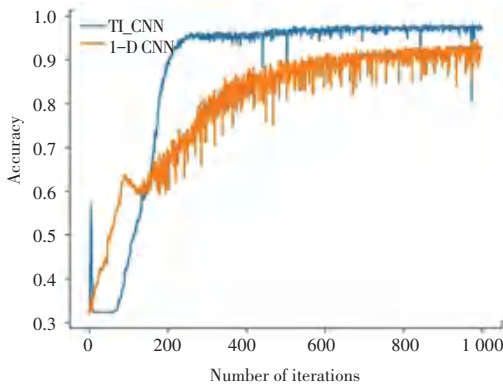


图 9 准确率上升曲线

Fig. 9 Accuracy rate of LeNet-5 1-D CNN and TI_CNN

表 5 为 LeNet-5 型 1-D CNN 和 TI_CNN 识别结果计算指标的对比。从表中可以看出: TI_CNN 的各项计算指标都优于 LeNet-5 型 1-D CNN, 这说明 TI_CNN 模型能很好的识别各种振动数据。

表 5 TI_CNN 和 LeNet-5 1-D CNN 识别结果对比

Tab. 5 Comparison of identification results of TI_CNN and LeNet-5 1-D CNN

CNN	Event Types	Precision	Recall	F1
LeNet-5 1-D CNN	1	0.92	0.93	0.92
	2	0.92	0.92	0.92
	3	0.87	0.85	0.86
TI_CNN	1	0.96	0.95	0.95
	2	0.96	0.94	0.95
	3	0.96	1	0.98

3 结束语

本文提出了一种新颖的方式, 去识别分布式光纤声传感器采集的振动事件, 提高了检测精度。为了验证所提方法的有效性, 将该方法与文献[19]中

所提出的多层 1-D CNN 识别模型进行了对比, 实验证明 TI_CNN 可以在使用较小数据集时, 达到较好的效果并且降低过拟合现象的出现。该方法通过同时提取一维信号的时域特征和小波时频图的时频域特征增加了最后识别的特征数量, 但网络层次并没有加深, 减小了模型的过拟合和识别时间, 提高了识别的准确率。

基于本研究采集的数据构成的数据集, 采用 TI_CNN 对小汽车通过、挖掘机挖掘、破路机工作的识别准确率分别可以达到 95%、94%、100%, 平均识别率为 96.3%, 并且识别时间为 0.61 s。

参考文献

- [1] WANG Z, 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.
- [2] LI H, SUN Q, LIU T, et al. Ultra-high sensitive quasi-distributed acoustic sensor based on coherent OTDR and cylindrical transducer[J]. Journal of Lightwave Technology, 2019, 38(4): 929-938.
- [3] LI S, PENG R, LIU Z. 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.
- [4] LI Z, ZHANG J, WANG M, 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.
- [5] WANG N, FANG N, WANG L. Intrusion recognition method based on echo state network for optical fiber perimeter security systems[J]. Optics Communications, 2019, 451: 301-306.
- [6] TABI FOUDA B M, HAN D, AN B, et al. Events detection and recognition by the fiber vibration system based on power spectrum estimation[J]. Advances in Mechanical Engineering, 2018, 10(11): 1-9.
- [7] WU X, HOU J, LIU K, et al. Research on fully distributed optical fiber sensing security system localization algorithm [C]//2013 International Conference on Optical Instruments and Technology: Optical Sensors and Applications. International Society for Optics and Photonics, 2013, 9044: 90441K1-90441K7.
- [8] WU H, ZHAO D, XU H. The research on pattern recognition in distributed fiber vibrant sensor system[C]//Mathematics of Data/Image Pattern Coding, Compression, and Encryption with Applications XIII. International Society for Optics and Photonics, 2011, 8136: 81360K1-81360K6.
- [9] ZHAO H, WU D, ZENG M, et al. A vibration-based vehicle classification system using distributed optical sensing technology [J]. Transportation Research Record, 2018, 2672(43): 12-23.
- [10] 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.