

光学学报

基于卷积长短期记忆全连接深度神经网络的光纤振动传感事件识别

周子纯^{1,2,3}, 刘琨^{1,2,3*}, 江俊峰^{1,2,3}, 徐天华^{1,2,3}, 王双^{1,2,3}, 孙振世^{1,2,3},
郭海若^{1,2,3}, 刘铁根^{1,2,3}

¹天津大学精密仪器与光电子工程学院, 天津 300072;

²天津大学光电信息技术教育部重点实验室, 天津 300072;

³天津大学光纤传感研究所, 天津 300072

摘要 在光纤周界安防系统的应用中, 准确区分传感事件的类型进而给出针对性的处理方案是实现智能振动传感的核心技术之一。本文提出一种包含多维度时间信息特征的信号特征提取算法, 并结合卷积长短期记忆全连接深度神经网络(CLDNN)对具体振动传感事件进行识别和分类。首先将采集获取到的光纤传感事件信息进行堆叠和截取, 得到包含传感事件多维度时间特征信息图片, 然后将其输入到 CLDNN 结构中, 最后对敲击、轰砸、摇晃、踢和无入侵 5 种信号进行识别和分类实验。实验结果证明, 所提算法可以有效对 5 类信号进行识别与分类, 平均识别率均达到 96% 以上, 识别响应时间可以控制到 0.006 s。

关键词 光纤光学; 光纤传感; 周界安全; 模式识别; 深度学习; 神经网络

中图分类号 V211

文献标志码 A

doi: 10.3788/AOS202141.1306019

Optical Fiber Vibration-Sensing Event Recognition Based on CLDNN

Zhou Zichun^{1,2,3}, Liu Kun^{1,2,3*}, Jing Junfeng^{1,2,3}, Xu Tianhua^{1,2,3}, Wang Shuang^{1,2,3},
Sun Zhenshi^{1,2,3}, Guo Hairuo^{1,2,3}, Liu Tiegeng^{1,2,3}

¹School of Precision Instruments and Optoelectronics Engineering, Tianjin University, Tianjin 300072, China;

²Key Laboratory of Optoelectronic Information Technology of Ministry of Education, Tianjin University,
Tianjin 300072, China;

³Institute of Optical Fiber Sensing, Tianjin University, Tianjin 300072, China

Abstract In the application of fiber optic perimeter security systems, realizing intelligent vibration sensing requires both accurately identifying specific types of sensing events and providing targeted processing solutions for such events. In this paper, we propose a signal feature-extraction algorithm that includes multidimensional time information features, combining these features in a convolutional long short-term deep neural network (CLDNN) that identifies and classifies specific vibration-sensing events. First, we stack and intercept the collected optical fiber sensing event information to obtain a broad picture containing multidimensional time characteristics of the sensing event. Next, we input these collected data into the CLDNN structure. We define five distinct types of events or signals for our identification and classification experiments: knocking, crashing, waggling, kicking, and no intrusion whatsoever. Experimental results show that the proposed algorithm can effectively recognize and classify these five types of signals with an average recognition rate of over 96% and a recognition response time that can be

收稿日期: 2021-03-30; 修回日期: 2021-05-03; 录用日期: 2021-06-02

基金项目: 国家自然科学基金(61922061, 61735011, 61775161)、国家重大科学仪器设备开发专项(2013YQ030915)、天津市自然科学基金杰出青年科学基金(19JCJQC61400)

通信作者: *beiyangkl@tju.edu.cn

limited to 0.006 s.

Key words fiber optics; optical fiber sensing; perimeter security; pattern recognition; deep learning; neural network

OCIS codes 060.2370; 060.2310; 100.4996

1 引言

光纤传感技术作为传感技术的一个新型分支,因其具有抗电磁干扰、耐腐蚀、质量轻、体积小、可复用和可组网等优越特性而被广泛应用在安全检测方面^[1]。分布式光纤振动传感技术作为光纤传感技术的一个重要分支,集传感和传输于一体,能够实现对外光纤传感链路周边压力或振动信号的连续探测,传感距离可以达到数十公里至数百公里^[2]。目前,分布式光纤振动传感技术已经广泛应用于油气管道泄漏监测、输电网安全监测以及周界安全监控等领域^[3-4]。随着传感技术的深入应用,其对具体应用环境中复杂传感事件的识别和分类逐渐成为近年来国内外学者的研究热点之一。

田苗^[5]使用双马赫-曾德干涉仪型(Dual Mach-Zehnder Interferometer, DMZI)分布式光纤振动传感系统^[6],并采用径向基函数(RBF)神经网络结合经验模态分解(EMD)的方法,实现了对剪切、晃动、敲击和攀爬4种事件的识别,平均识别率均达到85.75%;李志辰等^[7]利用短时傅里叶与奇异值分解来提取特征并采用支持向量机(SVM)对其进行识别和分类,但仅实现了对攀爬、敲击和晃动三种入侵事件的识别,识别的正确率均在90%以上;Xu等^[8]基于相敏光学时域反射计(Phase Sensitive Optical Time Domain Reflectometer, Φ -OTDR)分布式光纤传感系统^[9],提出了一种基于SVM分类器与多参量融合特征(短时能量比、短时水平穿越率、振动持续时间和功率谱能量)的提取方案,并采用该方案对踩踏和敲击等4类事件进行识别和分类,平均识别率均达到93%以上;Xu等^[10]采用快速傅里叶变换与卷积神经网络(Convolutional Neural Network, CNN)相结合的分类方法,并采用该方法对4种不同事件(挖掘、行走、车辆通过和损伤)进行识别和分类,平均识别率均达到90%;Che等^[11]基于一种改进的带有弱光纤布拉格光栅(wFBG)阵列的 Φ -OTDR系统,并采用多尺度小波分解和重建方法来提取局部放电信号,通过梅尔频率倒谱系数(MFCC)来获得信号的二维频谱帧,最后使用CNN对内部局部放电、电晕局部放电、表面局部放电和噪声4种不同类型的事件进行识别和分类,平均识别率均达到96.3%。通过对以上几种识别方案的

分析可知,识别和分类过程往往需要复杂的信号处理方法,使得整个信号识别和分类的复杂度较高,而且效率在实际应用中会受到严重制约,此外最终的识别和分类结果严重依赖于特征提取的有效性和分类器设计的合理性。

针对以上光纤传感事件在识别过程中存在的问题,本文提出一种高效的多维度时间信号特征提取算法,该算法结合卷积长短期记忆全连接深度神经网络(CLDNN)可以有效提升光纤传感事件的识别效率和准确率。首先将需要识别的多组传感信号按照时间顺序进行堆叠,用来扩充传感信号在时间上的相关性;然后对堆叠得到的信号矩阵进行随机截取,得到大小为 40×40 且含振动信息的矩阵并将其作为后续分类网络的输入;其次使用CLDNN进行特征提取以及事件识别,其融合了CNN、长短时记忆(Long Short Term Memory, LSTM)网络和深度神经网络(Deep Neural Network, DNN)三种网络,首先使用CNN来提取特征,然后将提取的特征传递到LSTM中以提取长期的时间信息,最后将其输出到DNN中并对特征进行加权分类;最后在DMZI分布式光纤传感系统中,使用敲击、轰砸、摇晃、踢和无入侵5种事件信号进行实验验证。实验结果表明,所提算法可以有效地识别和分类5种光纤传感事件,并且可以在降低信号处理复杂度的同时大幅度提升处理效率。

2 基本原理

2.1 DMZI 分布式光纤传感系统

DMZI 分布式光纤振动传感系统在较大的空间范围内具有能够连续传感、定位精度高、结构简单以及对硬件要求低等诸多优点,已成为安全检测领域的重要手段和方法之一^[12-13],结构如图1所示。系统中光源的中心波长为1550.12 nm,最大输出功率为5 mW。系统所输出的连续激光信号通过光纤衰减器(VOA)后,由3 dB耦合器C1(分光比为50:50)分成两束光并分别进入环形器C4和C5中,接着沿顺时针(CW)和逆时针(CCW)方向将光束传进由耦合器C2和C3组成的光纤DMZI中并在对应的耦合器处进行干涉,干涉的传感光信号再次通过环形器C4和C5后进入到光电探测器PD1和

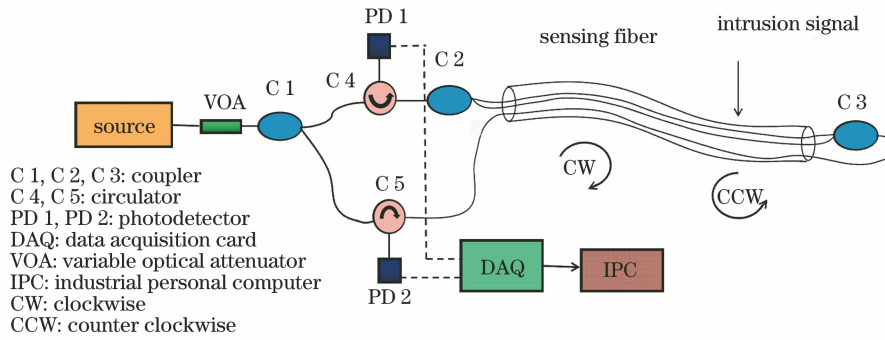


图 1 DMZI 分布式光纤振动传感系统的原理示意图

Fig. 1 Schematic of DMZI distributed optical fiber vibration sensing system

PD 2 中,经光电转换后传感电信号由采样速率为 100 kHz 的数据采集卡进行采集,最终送入工控机 (IPC) 中进行处理和分析。

当入侵信号引起光缆振动时,DMZI 分布式光纤振动传感器的等效光路如图 2 所示。光源所发出的光经过耦合器 C 1 后分成两路并分别进入耦合器 C 2 和 C 3 中的一端。进入 C 2 的光又被分为两路,

分别进入传感臂 1 与参考臂 1 后到达 C 3,此时构成顺时针的马赫曾德干涉仪。同理,进入 C 3 的光分别进入传感臂 2 与参考臂 3 后到达 C 2,此时构成逆时针的马赫曾德干涉仪。当外界扰动行为发生在距离耦合器 C 2 为 x 的点 P 处时,两传感臂能够同时受到外界的相位调制,则由耦合器 C 3 输出到探测器 PD 2 的两路光振幅分别为

$$E_{cw1} = \frac{\sqrt{2}}{4} E_{in} \exp \left\{ j \left[\frac{2\pi n(L + \Delta L)}{\lambda} + b_1 f \left[t - \frac{n(L-x)}{c} - \frac{n\Delta L}{c} \right] \right] \right\}, \quad (1)$$

$$E_{cw2} = \frac{\sqrt{2}}{4} E_{in} \exp \left\{ j \left[\frac{2\pi nL}{\lambda} + \pi + b_2 f \left[t - \frac{n(L-x)}{c} \right] \right] \right\}, \quad (2)$$

式中: E_{in} 为光源的振幅; L 为光波的传输距离; ΔL 为传感光纤与参考光纤的长度差; n 为光纤的有效折射率; λ 为激光光源的波长; b_1 和 b_2 为常数; x 为从扰动点到耦合器 C 2 的距离; c 为真空中的光速; t 为时间变量; $f(\cdot)$ 为外界扰动所产生的对光纤的作用力。 $2\pi nL/\lambda$ 为光波传输 L 所对应的相位延迟, π 为跨接耦合方式所引入的附加相位, $b_1 f(t)$ 和 $b_2 f(t)$ 分别为入侵所引起的两臂输出光波附加相位。假设光缆中两个相反方向的光纤长度近似相等,实验中两路传感光纤的长度相差很小,则(1)式和 (2) 式中 $f \left[t - \frac{n(L-x)}{c} - \frac{n\Delta L}{c} \right]$ 与 $f \left[t - \frac{n(L-x)}{c} \right]$ 近似相等,由干涉理论可知探测器 PD 2 接收到的光强为

$$I_{PD2} = \frac{I_0}{4} \cos[\Delta\varphi_L + \varphi(t - \tau_1)], \quad (3)$$

其中

$$\tau_1 = [n(L-x)]/c, \quad (4)$$

$$\varphi(t) = (b_1 - b_2) \cdot f(t), \quad (5)$$

$$\Delta\varphi_L = 2\pi n \Delta L / \lambda, \quad (6)$$

式中: I_0 为光源的光强; τ_1 为光从距离 C 2 为 x 的点 P 处沿顺时针方向传到探测器 PD 2 所需的时间; $\varphi(t)$ 为外界扰动造成传感臂和参考臂之间的相位差; $\Delta\varphi_L$ 为由两臂长度不等产生的相位延迟。同理可得探测器 PD 1 接收到的光强为

$$I_{PD1} = \frac{I_0}{4} \cos[\Delta\varphi_L + \varphi(t - \tau_2)], \quad (7)$$

其中

$$\tau_2 = nx/c, \quad (8)$$

式中: τ_2 为光从距离 C 2 为 x 的点 P 处沿逆时针方向传输到探测器 PD 1 所需的时间。系统中两路干涉信号都受到外界振动信号的调制,对于链路周边不同振动事件的模式识别,利用其中一路干涉信号进行特征提取并根据特征进行识别与分类。

2.2 卷积长短期记忆全连接深度神经网络

深度学习^[14-15]作为一种新型的智能识别和分类技术,在图像^[16-17]和语音^[18-19]领域获得了广泛的应用,其核心思想在于使用新的算法和网络结构来提升神经网络的泛化能力。相比于传统的手动特征提取方案,基于深度学习的神经网络模型能够自动且

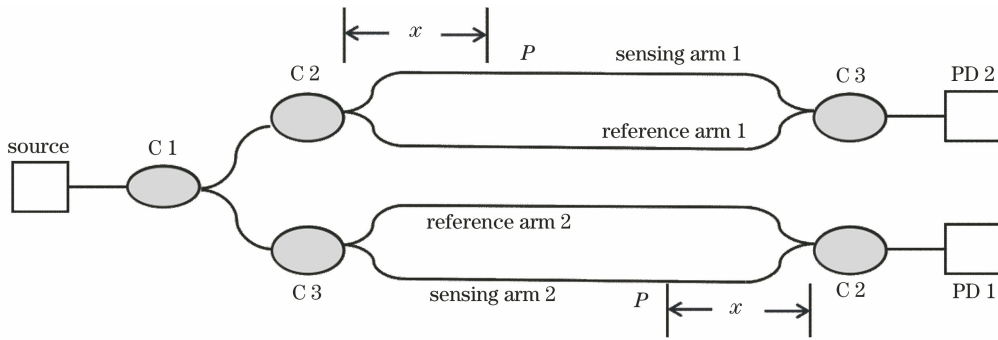


图 2 DMZI 分布式光纤振动传感器的等效光路

Fig. 2 Equivalent optical path of DMZI distributed optical fiber vibration sensor

分层次提取特征,可以反映数据本身的结构,从而大幅度提升识别和分类的有效性和可靠性。

CNN^[20-21]是一种带有卷积结构的深度神经网络,主要由输入层、卷积层、池化层、全连接层与输出层 5 部分组成。卷积层能够对输入图像进行特征提取,可以反映输入信息的特征信息;池化层能够减少全连接层中的网络参数,从而降低整个网络的复杂度,达到轻量化网络的目的。卷积神经网络的输出结果可以保留邻域之间的联系和空间上的局部特点。LSTM^[22]是一种改进的循环时间递归神经网络,该神经网络可以有效保留信息,能够解决一般循环神经网络对信息长期依赖的问题。LSTM 网络由三个门(输入门、遗忘门和输出门)和一个细胞单元来实现历史信息的更新和保留,适用于处理和预测时间序列中间隔和延迟相对较长的部分。DNN^[23]是一种判别模型,也是一种具备至少一个隐藏层的神经网络。与浅层神经网络类似,DNN 也能够为复杂非线性系统进行建模,而多出的层次为模

型提供了更高的抽象层次,因此提高了模型的泛化能力。

文献[24]已经表明,CNN 层可以提取图像特征,因此在 LSTM 层前加上 CNN 层可以优化网络。由文献[25]可知,LSTM 中未包含中间的非线性隐藏层,因此在 LSTM 层之后加上 DNN 层可以模拟减少隐藏状态的变化情况,同时使隐藏单元和输出之间的映射更深以改善输出预测。文献[26]将 CNN、LSTM 和 DNN 合并到一个可以联合训练的统一框架中,鉴于此提出了一种 CLDNN 模型,网络结构如图 3 所示。首先将输入馈入 CNN 层以提取特征信息,为了减少参数,CNN 层后加上线性层^[24];其次使用 LSTM 层来接收 CNN 层提取后的特征信息并对其进行处理;最后使用完全连接的 DNN 层来接收 LSTM 层的信息,并根据特征进行分类。文献[26]利用语音训练集来测试 CLDNN,相比于 CNN + LSTM 或 LSTM + DNN,CLDNN 的训练效果更为优秀。




图 3 CLDNN 的网络结构

Fig. 3 Network structure of CLDNN

CLDNN 融合了 CNN、LSTM 和 DNN 的优点,首先使用 CNN 层来提取特征,然后将特征传递到 LSTM 层中以提取长期的时间信息,最后将提取的信息输出到 DNN 层中并对特征进行加权分类,用来识别传感系统中的多种事件信号。本文将该神经

网络加以改进,用于识别来自基于 DMZI 的光纤周界安防系统的传感信号。

2.3 CLDNN 模型的设计及训练

针对参考光纤振动传感信号的随机非平稳特征以及深度学习网络在文献[26]的经典设计,本文对

CLDNN 的结构进行设计。其中 CNN 结构采用 4 组交替的卷积层和池化层来提取更为准确的传感特征,然后采用线性层将提取的二维特征进行一维化,并送入到含有 128 个隐藏神经元节点的 LSTM 网络中进行进一步的时间维度特征提取,最后将含有时间维度的传感特征由全连接层进行权重运算并送入输出层中进行分类输出。详细的参数设计如表 1 所示,其中 line 为线性层,FC 为全连接层。

表 1 CLDNN 的结构设计参数

Table 1 Structural design parameters of CLDNN

Layer	Kernel size	Stride	Output dimension	Function
Conv	5×5	1	(100,40,40,64)	Relu
Pooling	2×2	2	(100,20,20,64)	Max Pooling
Conv	5×5	1	(100,20,20,64)	Relu
Pooling	2×2	2	(100,10,10,64)	Max Pooling
Conv	5×5	1	(100,10,10,64)	Relu
Pooling	2×2	2	(100,5,5,64)	Max Pooling
Conv	5×5	1	(100,5,5,64)	Relu
Line	—	—	(100,256)	Line
LSTM	128	—	—	Tanh
FC	128	—	(100,5)	—
Output	—	—	(100,5)	Softmax

为了进一步提升训练过程的效率和稳定性,使 CLDNN 模型能够快速且有效收敛,实验对训练模

型的参数进行优化。具体优化过程如下:1)采用异步随机梯度下降(ASGD)算法^[27]作为优化算法;2)CLDNN 中的损失函数全部采用交叉熵函数^[28];3)采用 Glorot-Bengio 方法^[29]来初始化 CNN 层和 DNN 层的权重,采用高斯方法来随机初始化 LSTM 层;4)在训练过程中对学习率进行调节,使用损失值进行评估,损失量大则学习率大,此时能够加快网络的收敛速度并且保证网络有最优解,网络训练的初始学习率设为 0.0001。

3 实验结果与分析

3.1 数据处理

图 4 为 DMZI 分布式光纤振动传感系统的实物,将长为 2.25 km 的传感光缆以正弦的形式铺设在高为 2 m 的周界围栏上,用来采集无入侵、敲击、轰砸、摇晃和踢 5 种传感事件的数据以验证提出方案的有效性。每帧采集的信号长度设为 0.3 s,由采集速率为 100 kHz 的采集卡对数据进行采集,每帧信号所包含的数据点数为 3×10^4 。由三名同学分别来模拟振动事件,每类事件均采集 900 组信号,共 4500 组。值得注意的是,当采集敲击信号时,使用不同的工具进行敲击模拟以避免结果的特殊性。

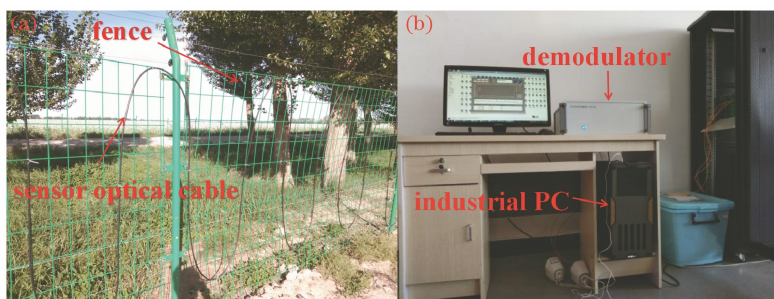


图 4 DMZI 分布式光纤振动传感系统。(a)传感部分;(b)解调部分

Fig. 4 DMZI distributed optical fiber vibration sensing system. (a) Sensing part; (b) demodulation part

在信号的预处理过程中,首先将 N 帧的原始信号按照时间顺序进行叠加,得到每种事件 $900/N$ 个 $N \times 30000$ 尺寸的灰度图,然后对这些灰度图进行错位裁剪,则每种信号可以得到 $\left(\frac{30000}{N} \times 2 - 1\right) \times \frac{900}{N}$ 个 $N \times N$ 尺寸的小灰度图,以此作为实验的数据集。鉴于此,以 N 帧敲击信号的预处理过程为示例。当 N 为 5 时,将 5 帧的敲击信号按照时间顺序进行叠加,则每点的幅度值可以组成一个 5×30000 大小的灰度图,如图 5(a)所示;然后对该灰度图进行错位裁剪以得到 2159820 个 5×5 的小灰度图,并

将其作为敲击事件的数据集,如图 5(b)所示。

原始信号及其对应的叠加结果如图 6(a)~6(e)所示。从图 6 可以看到,经过叠加处理后的信号间差距明显增大,特征明显且易于区分。

使用 NVIDIA GTX 2080 Ti GPU 在 TensorFlow 中实现实验。将 N 值分别设为 20、30、40 和 50,可以得到 4 个不同尺度的数据集,将得到的数据集以 7:1:1 的比例随机划分为训练集、验证集和测试集并输入到网络中,每轮训练随机选取 100 张图作为 CLDNN 的输入,为每个数据集设定三次 1×10^4 轮训练,测试结果如表 2 所示。从表 2

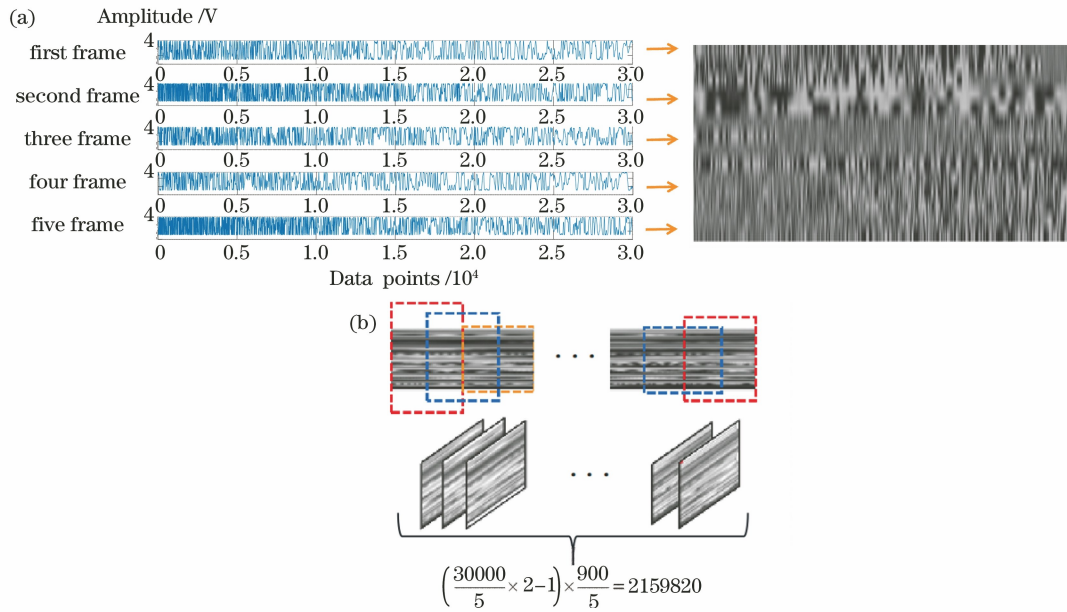


图 5 敲击信号的预处理过程。(a) 5 帧信号的叠加过程示意图；(b) 叠加后的信号错位剪裁示意图
 Fig. 5 Preprocessing of knocking. (a) Schematic of superposition process of 5 frames of signals; (b) schematic of signal misalignment clipping after superposition

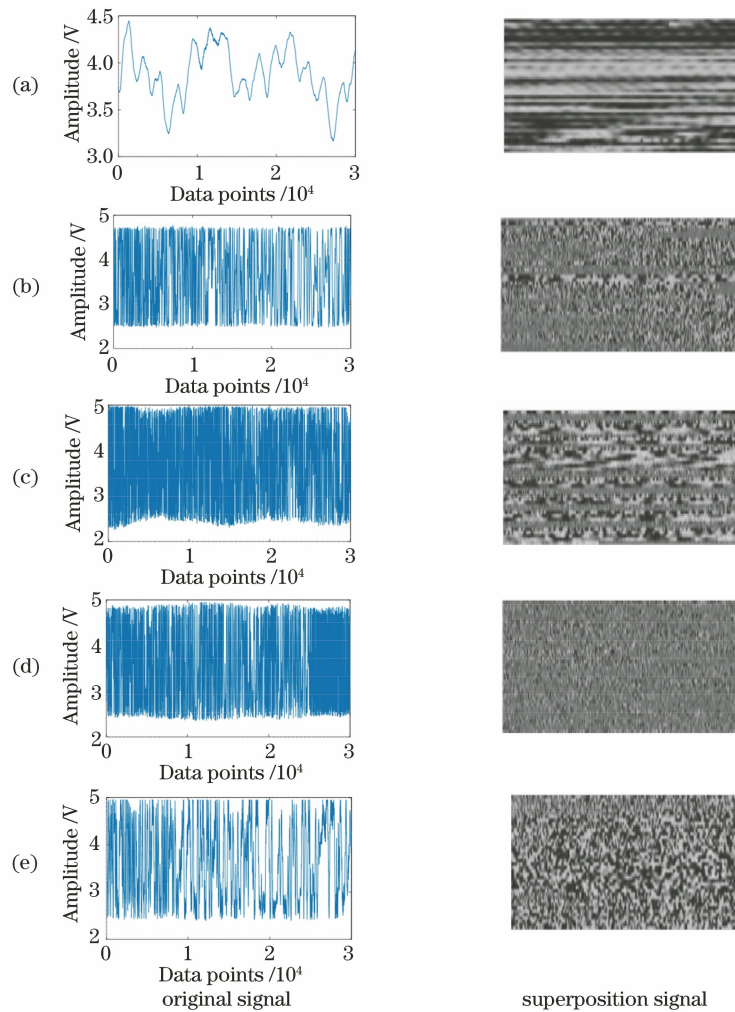


图 6 5 类入侵事件信号的特征图。(a) 无人入侵；(b) 敲击；(c) 轰砸；(d) 摇晃；(e) 踢

Fig. 6 Characteristic maps of 5 types of intrusion event signals. (a) No intrusion; (b) knocking; (c) crashing; (d) wagging; (e) kicking

表 2 三次测试中不同剪裁情况下的平均识别率及平均训练时间

Table 2 Average recognition rate and average training time under different clipping conditions in three tests

Parameter	N=20	N=30	N=40	N=50
Accuracy 1 / %	78.3	88.0	96.6	95.9
Accuracy 2 / %	75.0	87.4	96.2	94.7
Accuracy 3 / %	72.9	89.3	96.1	95.1
Time / s	2034	3004	5420	8982

可以看到,对于识别和分类的准确率,随着 N 值的增大,5 种信号的平均准确率不断提升,达到 40 后趋于稳定;对于训练时间,随着 N 值的增大,训练时间在不断增加。综上可知,当 N 值设为 40 时,能够达到高效率和高准确率的目的。基于此结论,利用采集的数据进行处理及结果分析。

3.2 实验结果分析

利用网络的损失以及训练的准确率来检测网络的性能,图 7 为 CLDNN 中 CNN 部分在三种卷积层次下的误差函数值变化情况。从图 7 可以看到,

表 3 三种算法的识别结果对比

Table 3 Comparison of recognition results of three algorithms

Algorithm	Average accuracy / %	Number of events	Preprocessing time / s	Identification time / s
CLDNN	96.24	5	5×10^{-5}	0.006
RBF-EMD	85.75	4	1.14	0.510
SVM	93.82	4	0.30	0.300

表 4 所提算法对 5 类事件的识别率

Table 4 Recognition rate of proposed algorithm for five kinds of events

unit: %

Algorithm	No intrusion	Knocking	Crashing	Wagging	Kicking
CLDNN	100.0	99.8	95.2	87.5	98.7

从表 3 可以看到,所提算法大大缩短了信号预处理的时间,达到几乎可以忽略的数量级,利用 CLDNN 对事件特征进行提取与识别融合,降低了算法的复杂度,其事件识别时间较其他两种算法均降低了两个数量级,识别时间达到 0.006 s,同时所提算法在增加识别事件数量的前提下,平均识别率达到了 96.24%,结合表 4 中 5 种事件各自的识别准确率,各事件的识别正确率均在 87% 以上,对于无入侵、敲击、轰砸和踢 4 种事件而言,识别率都达到了 95% 以上,说明事件的识别可信度极高。

4 结 论

本文提出一种含有多维度时间信息特征的信号特征提取算法,并结合 CLDNN 对具体振动传感事件进行识别和分类。信号堆叠再截取的方式充分利用事件在时间尺度上的信息来增强信号特征,并保

随着网络训练迭代次数的增加,三种网络的误差函数曲线都是趋于收敛,但是在卷积层数为 4 的情况下,损失函数以最快的速度趋于收敛,因此在 CNN 结构中选择 4 层卷积网络较为合理。

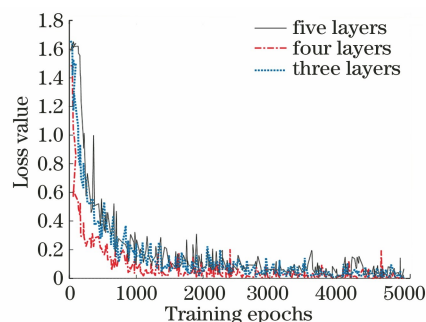


图 7 CLDNN 中 CNN 部分在三种卷积层次情况下的误差函数值变化情况

Fig. 7 Variation of error function values of CNN in CLDNN under three convolution levels

表 3 为所提算法与 RBF-EMD 算法^[5]和 SVM 算法^[7]在事件识别方面的对比结果。所提算法在 5 类事件下的识别率如表 4 所示。

留了精简的数据;对应用于该方向的 CLDNN 进行网络层次与参数的改进,使其更适合对传感振动信号进行特征提取与事件识别。数据采集方面采用了较为低速的 100 kHz 采集卡,利用所提算法能够在低速采集的基础上实现 96% 以上的准确率,一定程度上摆脱了实际应用对高速采集卡的依赖,为低价高效的系统提供了一种可行且稳定的替代方案。

参 考 文 献

- [1] Xie S R, Zou Q L, Wang L W, et al. Positioning error prediction theory for dual Mach-Zehnder interferometric vibration sensor [J]. Journal of Lightwave Technology, 2011, 29(3): 362-368.
- [2] Hou J F, Pei L, Li Z X, et al. Development and application of optical fiber sensing technology [J]. Electro-Optic Technology Application, 2012, 27(1): 49-53.

- 侯俊芳, 裴丽, 李卓轩, 等. 光纤传感技术的研究进展及应用[J]. 光电技术应用, 2012, 27(1): 49-53.
- [3] Hu Z S, Yang Q H, Qiao B. Design of interference distributed fiber-optic underwater long gas pipeline leakage detection system [J]. Laser & Optoelectronics Progress, 2012, 49(7): 070602.
胡正松, 杨其华, 乔波. 干涉分布式光纤水下长输气管道泄漏检测系统设计[J]. 激光与光电子学进展, 2012, 49(7): 070602.
- [4] Chen Q N. Research on several key technologies of double Mach-Zehnder distributed optical fiber vibration sensing [D]. Tianjin: Tianjin University, 2015.
陈沁楠. 双马赫-曾德型分布式光纤振动传感若干关键技术研究[D]. 天津: 天津大学, 2015.
- [5] Tian M. Research and implement of algorithms for the fiber perimeter security system based on dual Mach-Zehnder [D]. Tianjin: Tianjin University, 2017.
田苗. 双马赫-曾德型光纤周界安防系统的算法研究及其实现[D]. 天津: 天津大学, 2017.
- [6] Chen W M, Wu J, Tan J, et al. Locating technology for twin Mach-Zehnder distributed optical fiber sensing system [J]. Acta Optica Sinica, 2007, 27(12): 2128-2132.
陈伟民, 吴俊, 谭靖, 等. 双马赫-曾德型分布式光纤传感系统定位技术[J]. 光学学报, 2007, 27(12): 2128-2132.
- [7] Li Z C, Liu K, Jiang J F, et al. A high-accuracy event discrimination method in optical fiber perimeter security system [J]. Infrared and Laser Engineering, 2018, 47(9): 0922002.
李志辰, 刘琨, 江俊峰, 等. 光纤周界安防系统的高准确度事件识别方法[J]. 红外与激光工程, 2018, 47(9): 0922002.
- [8] Xu C J, Guan J J, Bao M, et al. Pattern recognition based on enhanced multifeature parameters for vibration events in Φ -OTDR distributed optical fiber sensing system [J]. Microwave and Optical Technology Letters, 2017, 59(12): 3134-3141.
- [9] Zhang X P, Ding Z W, Hong R, et al. Phase sensitive optical time-domain reflective distributed optical fiber sensing technology [J]. Acta Optica Sinica, 2021, 41(1): 0106004.
张旭苹, 丁哲文, 洪瑞, 等. 相位敏感光时域反射分布式光纤传感技术[J]. 光学学报, 2021, 41(1): 0106004.
- [10] 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 φ -OTDR [J]. Optical Engineering, 2018, 57(1): 016103.
- [11] Che Q, Wen H Q, Li X Y, et al. Partial discharge recognition based on optical fiber distributed acoustic sensing and a convolutional neural network [J]. IEEE Access, 2019, 7: 101758-101764.
- [12] Sun Q Z, Liu D M, Liu H R, et al. Distributed fiber-optic sensor with a ring Mach-Zehnder interferometer [J]. Proceedings of SPIE, 2007, 6781: 67814D.
- [13] Li P C. Research and modularization of polarization control method for dual Mach-Zehnder fiber disturbance system [D]. Tianjin: Tianjin University, 2018.
李鹏程. 双马赫-曾德型光纤扰动系统的偏振控制方法研究及其模块化实现[D]. 天津: 天津大学, 2018.
- [14] Sun Z J, Xue L, Xu Y M, et al. Overview of deep learning [J]. Application Research of Computers, 2012, 29(8): 2806-2810.
孙志军, 薛磊, 许阳明, 等. 深度学习研究综述[J]. 计算机应用研究, 2012, 29(8): 2806-2810.
- [15] Bengio Y, Delalleau O. On the expressive power of deep architectures [C] // Proceedings of the 14th International Conference on Discovery Science, October 5-7, 2011, Espoo, Finland. Berlin: Springer, 2011: 18-36.
- [16] Liu J M, Yang S, Huang H. Hyperspectral remote sensing image classification based on local reconstruction Fisher analysis [J]. Chinese Journal of Lasers, 2020, 47(7): 0710001.
刘嘉敏, 杨松, 黄鸿. 基于局部重构 Fisher 分析的高光谱遥感影像分类[J]. 中国激光, 2020, 47(7): 0710001.
- [17] Kong F Q, Zhou Y B, Shen Q, et al. End-to-end multispectral image compression using convolutional neural network [J]. Chinese Journal of Lasers, 2019, 46(10): 1009001.
孔繁锵, 周永波, 沈秋, 等. 基于卷积神经网络的端到端多光谱图像压缩方法[J]. 中国激光, 2019, 46(10): 1009001.
- [18] Chen H K, Chen Y. Speaker identification based on multimodal long short-term memory with depth-gate [J]. Laser & Optoelectronics Progress, 2019, 56(3): 031007.
陈湟康, 陈莹. 基于具有深度门的多模态长短期记忆网络的说话人识别[J]. 激光与光电子学进展, 2019, 56(3): 031007.
- [19] Ren K L, Wang Y, Chen X D, et al. Speaker-dependent speech recognition algorithm for laparoscopic supporter control [J]. Laser & Optoelectronics Progress, 2020, 57(18): 181702.
任凯龙, 汪毅, 陈晓冬, 等. 用于腹腔镜扶持器控制的特定人语音识别算法[J]. 激光与光电子学进展, 2020, 57(18): 181702.

- [20] Zhou J Y, Zhao Y M. Application of convolution neural network in image classification and object detection [J]. Computer Engineering and Applications, 2017, 53(13): 34-41.
周俊宇, 赵艳明. 卷积神经网络在图像分类和目标检测应用综述[J]. 计算机工程与应用, 2017, 53(13): 34-41.
- [21] Masci, J, Meier U, Ciresan D, et al. Stacked convolutional auto-encoders for hierarchical feature extraction[C]//International Conference on Artificial Neural Networks ICANN 2011: Artificial Neural Networks and Machine Learning ICANN 2011, June 14-17, 2011, Espoo, Finland. Heidelberg: Springer, 2011: 52-59.
- [22] Hochreiter S, Schmidhuber J. Long short-term memory [J]. Neural Computation, 1997, 9 (8): 1735-1780.
- [23] Hou Y M, Zhou H Q, Wang Z Y. Overview of speech recognition based on deep learning [J]. Application Research of Computers, 2017, 34 (8): 2241-2246.
侯一民, 周慧琼, 王政一. 深度学习在语音识别中的研究进展综述[J]. 计算机应用研究, 2017, 34(8): 2241-2246.
- [24] Sainath T N, Peddinti V, Kingsbury B, et al. Deep scattering spectra with deep neural networks for LVCSR tasks[C]//INTER_SPEECH 2014 15th Annual Conference of the International Speech Communication Association, September 14-18, 2014, Singapore. Sydney: International Speech and Communication Association, 2014: 900-904.
- [25] Schwarz P, Matejka P, Cernocky J. Hierarchical structures of neural networks for phoneme recognition[C]//2006 IEEE International Conference on Acoustics Speech and Signal Processing Proceedings, May 14-19, 2006, Toulouse, France. New York: IEEE Press, 2006: 9209251.
- [26] 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.
- [27] Dean J, Corrado G, Monga R, et al. Large scale distributed deep networks [C]//Advances in Neural Information Processing Systems 25 (NIPS 2012), December 3-6, 2012, Lake Tahoe, Nevada, USA. New York: Curran Associates, 2012: 1223-1231.
- [28] Sahraeian R, van Compernelle D. Cross-entropy training of DNN ensemble acoustic models for low-resource ASR [J]. IEEE/ACM Transactions on Audio, Speech, and Language Processing, 2018, 26 (11): 1991-2001.
- [29] Glorot X, Bengio Y. Understanding the difficulty of training deep feedforward neural networks [J]. Proceedings of Machine Learning Research, 2010, 9: 249-256.