

基于 LSTM-CNN 的  $\varphi$ -OTDR 模式识别王鸣<sup>1</sup>, 沙洲<sup>1</sup>, 封皓<sup>1\*</sup>, 杜立普<sup>2</sup>, 齐敦哲<sup>2</sup><sup>1</sup>天津大学精密仪器与光电子工程学院精密测试技术及仪器国家重点实验室, 天津 300072;<sup>2</sup>宁夏回族自治区水利工程建设中心, 宁夏 银川 750004

**摘要** 提出了以长短期记忆网络(LSTM)与卷积神经网络(CNN)为主要框架的深度学习网络,基于该网络实现模式识别。LSTM-CNN以时域曲线及其短时傅里叶变换(STFT)结果作为网络输入,LSTM提取输入信号的时序特征,CNN提取时域曲线的轮廓特征及能量特征。实验中以相敏光时域反射仪( $\varphi$ -OTDR)为传感系统完成数据采集。将LSTM-CNN与传统的人工神经网络(ANN)及CNN对比,LSTM-CNN在各项评价指标中均处于最优状态,实现了 $\varphi$ -OTDR模式识别的既定目标,为实际的工程产品开发提供了概念证明与演示示例。

**关键词** 光通信; 模式识别; 长短期记忆网络; 卷积神经网络; 光纤预警

中图分类号 TP212 文献标志码 A

DOI: 10.3788/AOS221468

## 1 引言

分布式光纤传感技术凭借分辨率高、监测范围广、抗干扰能力强等优点,成为近年来安全监测领域的研究热点<sup>[1-2]</sup>。其中,相敏光时域反射仪( $\varphi$ -OTDR)被广泛运用于管道安全维护、清管器定位追踪、入侵预警等领域<sup>[3-4]</sup>。 $\varphi$ -OTDR向传感光缆发射光脉冲并接收后向瑞利散射曲线来获知光缆沿线的安全状态<sup>[5]</sup>,时空图则动态呈现入侵事件的时间及地点。当存在入侵信号时,时空图上的特征图块可以迅速实现事件定位,索引相应位置的时域曲线并分析其形态特征与能量特征,能够有效判断事件类别,帮助用户采取更有效的处置措施。

机器学习与深度学习是当前模式识别的主要手段<sup>[6]</sup>。一种是以支持向量机(SVM)<sup>[7-8]</sup>、相关向量机(RVM)<sup>[9]</sup>、K-近邻算法(KNN)<sup>[10]</sup>、K-均值(K-means)聚类算法<sup>[11]</sup>为代表的机器学习算法,将信号的特征向量作为算法输入,其分类准确度对特征提取的依赖程度较高,且由于训练周期短、算法复杂度低、训练样本数较少,模型存在泛化性弱、区分类别有限的缺点<sup>[12]</sup>。相比之下,深度学习面对大批量样本的多分类问题时通常具有更出色的表现,端到端的学习方式无需人为地提取目标特征<sup>[13]</sup>,神经网络通过对大批量训练样本的学习与误差反向传播,实现对模型参数的更新与特征的提取,使模型收敛于最优状态。

本文模拟工程环境搭建了 $\varphi$ -OTDR振动传感系

统,设计了环境噪声、行走、挖掘、电机4类激励信号。以时域曲线为网络输入端,使用一维卷积算子提取输入信号的轮廓特征,使用长短期记忆网络(LSTM)提取输入序列的时序特征<sup>[14-15]</sup>。考虑到不同激励信号的能量分布差异,使用短时傅里叶变换(STFT)及二维卷积算子提取信号的时频域特征。LSTM-CNN融合多种特征,有效提高了模型的准确率与收敛速度,与人工神经网络(ANN)、卷积神经网络(CNN)等比较,LSTM-CNN在各项评价指标中均表现优异,实现了 $\varphi$ -OTDR模式识别的既定目标,为LSTM与CNN在光纤传感领域的应用提供了参考示例。本文将LSTM-CNN与常见的SVM、KNN、决策树<sup>[16]</sup>、随机森林<sup>[17]</sup>等机器学习算法进行比较,证明了深度学习在泛化性与分类精度方面的优势。

## 2 理论与实验

## 2.1 数据呈现形式

分布式光纤传感是近年来广泛研究的入侵预警技术之一,其中 $\varphi$ -OTDR已存在大量工程案例,具备精准的定位功能,因此选取该系统用于数据采集。其基本光路结构如图1所示。

$\varphi$ -OTDR向传感光缆发射测量光脉冲并接收后向瑞利散射曲线,对一定数量的瑞利散射曲线进行拼接得到时空图。当某一时刻的特定地点存在入侵事件时,时空图上呈现出显著区别于背景噪声的特征图块,迅速实现事件的定位,如图2所示。

收稿日期: 2022-07-13; 修回日期: 2022-09-05; 录用日期: 2022-09-26; 网络首发日期: 2022-10-08

基金项目: 国家自然科学基金(62005191,61873183)、广西自动检测技术及仪器重点实验室开放基金(YQ21205)

通信作者: \*fenghao@tju.edu.cn

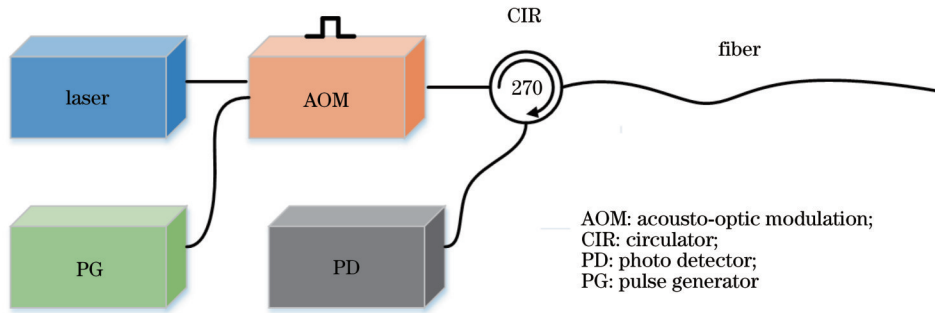
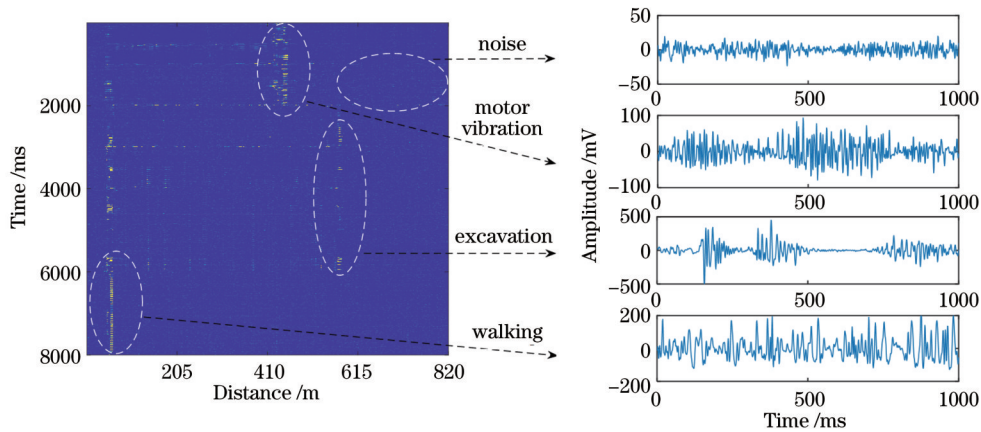
图 1  $\varphi$ -OTDR 结构图Fig. 1 Structure diagram of  $\varphi$ -OTDR

图 2 时空图与时域曲线的数据呈现形式对比

Fig. 2 Comparison of the data presentation form between the time-space map and the time-domain curve

实际应用中,车辆、行人、流水等非入侵性行为也会引起光缆的振动,因此需要对事件类别作出准确的判断,以帮助用户采取合理的应对措施。图 2 涵盖了实验中涉及的主要事件类别,这些事件在时空图上并未呈现出清晰的形态学特征,依靠时空图无法准确地对信号类型做出判断。相比之下,图 2 中时域曲线的特征脉冲、曲线轮廓、能量分布均反映了入侵信号的特性,其细节特征更加清晰;同时,相比时空图,时域曲线数据量更小,训练周期更短,存储空间更小,更适合大批量样本的训练,因此本文以时域曲线构建训练样本。

## 2.2 CNN 与 LSTM

CNN 是以卷积计算为主的神经网络,设置不同数目与尺寸的卷积核来提取目标的空间特征<sup>[18-19]</sup>。图 2 中不同类型的时域信号存在不同的轮廓特征与幅值特征,由于时域曲线的采样点幅值在一维方向上按照时间顺序排列,因此使用一维卷积算子即可提取其形态特征,图 3(a)、(b)分别为一维卷积算子与二维卷积算子的运算示意图。

$\varphi$ -OTDR 的输出信号为时间序列,曲线上的特征脉冲与其所处的时间点及前后状态密切相关,因此对信号时序特征的有效提取至关重要。LSTM 通过记忆体实现时间序列的短期记忆,同时依靠细胞态维持长期记忆,当前记忆体的输出不仅取决于网络输入,还

取决于上一个记忆体的输出,通过遗忘门、输入门、输出门 3 个门结构来实现对信息的筛选和记忆<sup>[20]</sup>。如图 3(c)所示,LSTM 将时间窗内的采样点作为网络输入,并得到基于窗内采样点的预测值,以设定步长移动窗口,不断对序列进行预测,实现对信号时序特征的提取。

综上,本文以时域曲线为神经网络的输入,使用卷积算子提取其轮廓特征与能量特征;使用 LSTM 提取其时间特征,经过特征融合,实现入侵预警与模式识别的既定目标。

## 2.3 实验

实验中将传感光缆埋于土层 0.45 m 深度,土壤由沙土和部分黏土组成,整体颗粒度小于 0.02 mm。考虑到灵敏度、光缆强度、传感寿命等因素,工程中通常使用高弹性模量的多芯光缆,因此实验中采用 GYTA53 型光缆,传感光缆长度为 1.5 km。填埋后对土壤做夯实处理,在光缆水平方向 1~6 m 的范围内开展实验。在第一阶段,使用铁锹、小锤、锄头等工具产生挖掘信号,使用一台 20 kW 电动机满功率输出作用于地面,以模拟持续性振动源。在第二阶段,采集行走信号与无入侵状态下的背景噪声。

光信号产生及数据接收由自研  $\varphi$ -OTDR 机箱完成,图 4 为机箱内部光路图。光源功率为 20 mW,光中

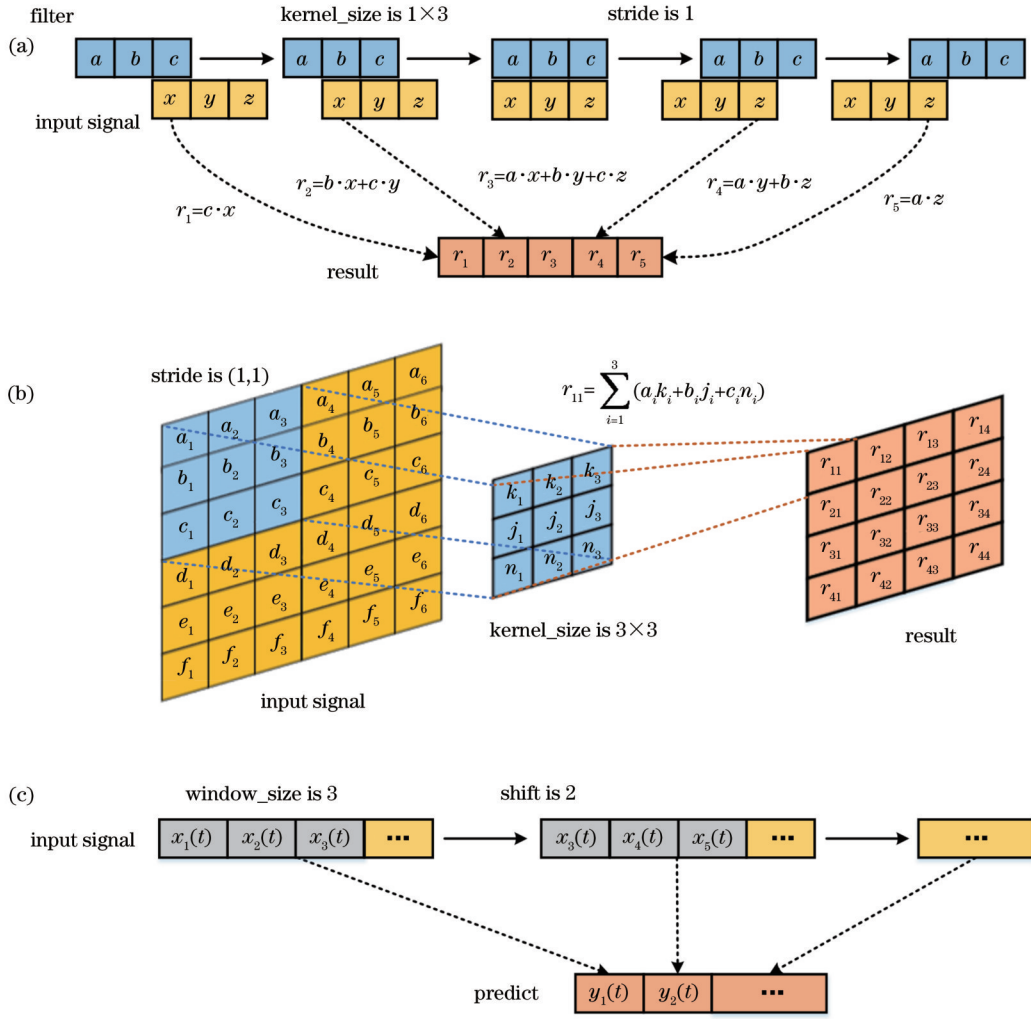


图 3 CNN 与 LSTM 的运算过程。(a)一维卷积;(b)二维卷积;(c) LSTM

Fig. 3 Operation process of CNN and LSTM. (a) 1D convolution; (b) 2D convolution; (c) LSTM

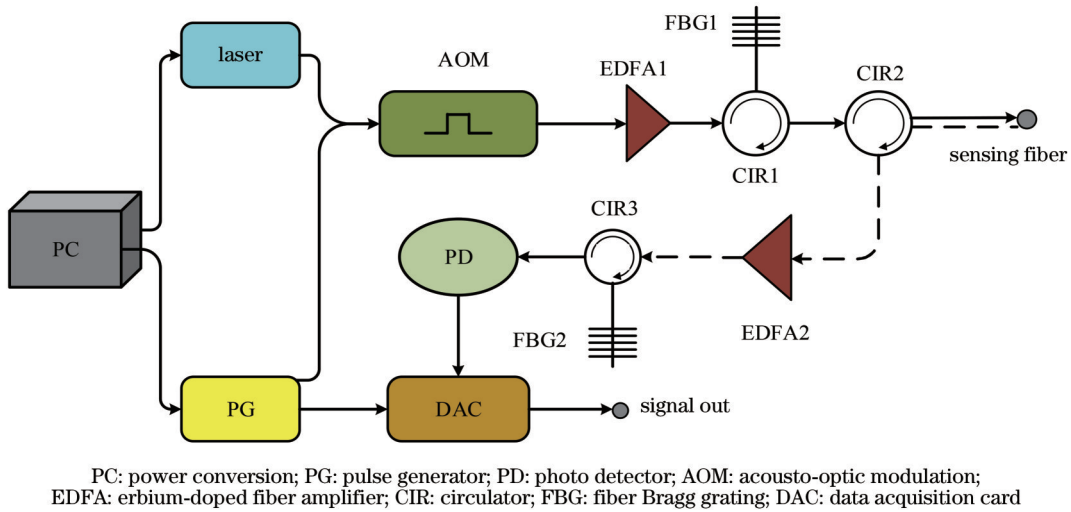


图 4  $\varphi$ -OTDR 机箱内部结构示意图

Fig. 4 Schematic of the internal structure of  $\varphi$ -OTDR integrated system

心波长为 1550 nm,连续测量光经 AOM 调制为 100 ns 的光脉冲。EDFA 对光脉冲进行 23 dB 功率放大,再

经环形器 1 与 FBG1 以滤除光源自发噪声,FBG 的中心波长为 1550.05 nm,反射率为 99%,3 dB 带宽为

0.13 nm。DAC 的带宽为 250 MHz。图 4 中相同元器件的参数均保持一致。

上述实验采集了挖掘、电机振动、行走、背景噪声 4 类信号,设计 LSTM-CNN 网络提取其形态特征、时序特征及能量特征以识别事件类型,并测试训练后的模型以验证其可靠性。

### 3 网络构建及训练

#### 3.1 训练 LSTM

在时序信号中,当前时间点的幅值不仅与上一时刻相关,同时还影响下一时刻的输出。为了更好地提

取信号的时序特征,基于 TensorFlow2.4GPU 与 Python 3.8 搭建了双向循环神经网络(BRNN),每层由 60 个 LSTM 循环核组成,如图 5 所示。

图 5 中 L1 和 L2 均为 LSTM 循环核,对于输入的时序序列  $x$ ,其正向隐藏状态  $\vec{f}_i$  与反向隐藏状态  $\overleftarrow{f}_i$  [21-23] 可分别表示为

$$\vec{f}_i = g(x_i W_{hx1} + f_{i-1} W_{hh1} + b_{h1}), \quad (1)$$

$$\overleftarrow{f}_i = g(x_i W_{hx2} + f_{i+1} W_{hh2} + b_{h2}), \quad (2)$$

式中:  $W_{hx1}$ 、 $W_{hh1}$  为正向权值矩阵;  $b_{h1}$  为正向偏置矩阵;  $W_{hx2}$ 、 $W_{hh2}$  为反向权值矩阵;  $b_{h2}$  为反向偏置矩阵;  $g$  为隐含层激活函数。




图 5 BRNN(LSTM)结构图

Fig. 5 Structure diagram of BRNN (LSTM)

$\vec{f}_i$  与  $\overleftarrow{f}_i$  共同得到隐藏状态  $f_i$ 。输入向量  $x_i$  的输出值为

$$y_i = f_i W_{hy} + b, \quad (3)$$

式中:  $W_{hy}$  为输出层权值矩阵;  $b$  为输出层偏置矩阵。

通常 LSTM 的训练周期较长,因此需要单独对 LSTM 进行训练以确定最佳模型参数。训练集为一段 720 s 的连续信号,包含 2.3 节中所有场景,可以充分反映训练样本的一般特性。设置窗函数长度为 20 个采样点的长度,训练小批量样本数为 64,训练轮次为 120,时间窗移动长度为 1 个采样点的长度,验证集划分比例为 0.2。优化器选择“SGDM”,一阶动量为 0.8。使用指数法更新学习率,学习率更新公式为

$$l_r = l_{r0} \cdot \alpha^{n/20}, \quad (4)$$

式中:学习率  $l_{r0}$  的初始值设置为  $10^{-8}$ ;学习率增长系数  $\alpha$  设置为 10;  $n$  为 epoch 的数量。

损失函数选择“Huber”,评价指标选择“mae”。训练集共包含 720000 个采样点,训练共耗时 1.2 h。图 6(a)所示为损失函数随学习率的动态变化曲线,随着学习率的增大,损失函数逐渐减小并趋于稳定;在学习率超过  $10^{-3}$  之后,损失函数出现了轻微振荡,因此最佳学习率选择  $10^{-3}$ 。设置固定学习率为  $10^{-3}$ ,再次对模型进行训练,损失函数的变化曲线如图 6(b)所示。显然,在设置最佳学习率之后,模型迅速收敛并且预测误

差也显著降低。

使用 epoch 为 100 时的模型参数分别对 4 类信号提取时序特征,结果如图 6(c)~(f)所示。LSTM 对 4 类信号都实现了有效的时序特征提取,在保留目标特征的同时也降低了噪声的干扰(由于 LSTM 需要使用当前时间窗内的采样点预测下一个时间节点的幅值,因此在预测结果与原信号的对比呈现中,预测结果领先原信号一个时间窗的长度)。

#### 3.2 LSTM-CNN

除了提取时域信号的轮廓特征、数值特征与时序特征,还需要提取信号的能量特征。事实上,不同事件响应信号的能量分布存在显著差异,这种差异不仅表现为绝对能量的增减,还体现在各频段的相对变化。分别使用 STFT 分析 4 种激励信号,窗函数选择汉宁窗,窗长度设置为 64,窗重叠长度为 8,FFT 点数为 512,采样率为 1000 Hz,结果如图 7 所示。

图 7(a)中背景噪声在时域和频域上的能量分布较为均匀,且整体能量值偏低,主要集中在 20~70 Hz 的低频段。相比之下,入侵信号各频段的绝对能量显著高于静态信号,其分布则呈现出不同的特点。挖掘信号的能量主要集中在 100 Hz 附近的频段,且在时间维度上较为集中;电机振动信号整体的能量分布在频率和时间维度上较为均匀;行走信号的能量则主要

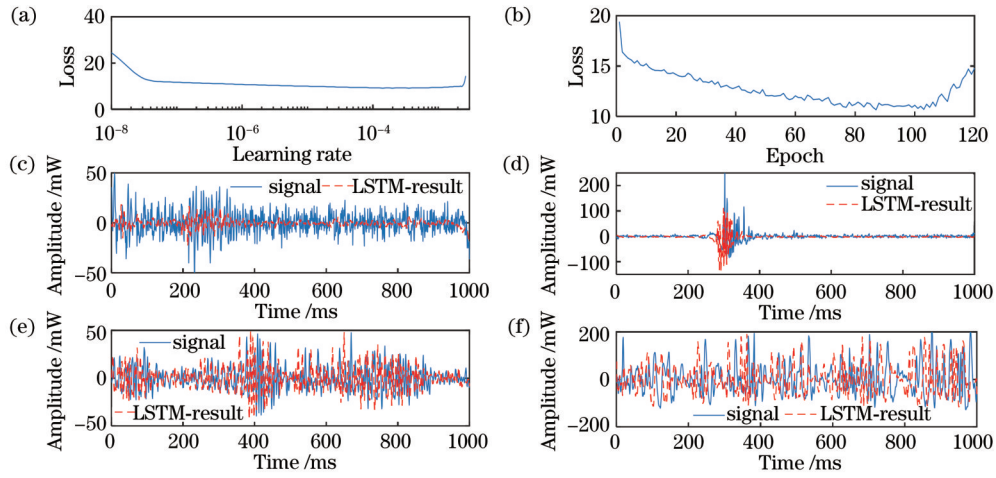


图 6 LSTM 的训练情况与测试结果。(a) 损失函数随动态学习率的变化曲线；(b) 损失函数随固定学习率的变化曲线；(c) 背景噪声；(d) 挖掘信号；(e) 电机振动信号；(f) 行走信号  
 Fig. 6 Training situation and test results of LSTM. (a) Curve of loss function with dynamic learning rate; (b) curve of loss function with fixed learning rate; (c) background noise; (d) excavation signal; (e) motor vibration signal; (f) walking signal

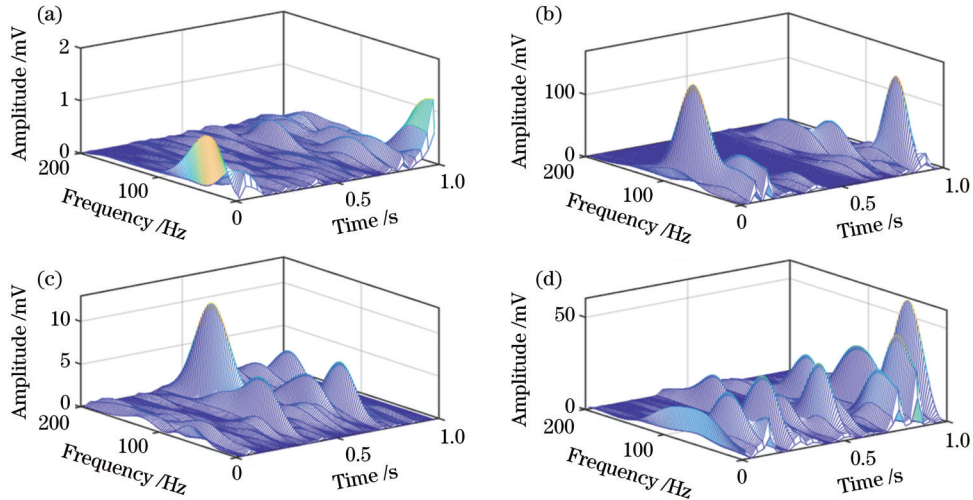


图 7 目标信号的 STFT 结果。(a) 背景噪声；(b) 挖掘信号；(c) 电机振动信号；(d) 行走信号  
 Fig. 7 STFT results of target signals. (a) Background noise; (b) excavation signal; (c) motor vibration signal; (d) walking signal

集中在 100 Hz 以下的频段,且在时间维度上分布均匀。因此可以通过 STFT 提取信号的时频域特征,从而提升事件分类的准确率。

基于上述分析,设计了以 LSTM 和 CNN 为主要框架、以时域信号及其 STFT 为输入的神经网络,如图 8 所示。

为比较 LSTM 与 CNN 对神经网络性能的提升效

果,实验中搭建了多种不同结构的网络,各网络主要参数如表 1 所示。

分别对上述网络展开训练并比较训练效果。其中,训练集与测试集分别包括 3658 组与 1200 组样本,每组样本包含 1000 个采样点,STFT 的相关参数与前文一致。针对不同的网络结构与网络输入,卷积核、卷积层、隐含层以及学习率的调整情况如图 8 与表 1 所

表 1 不同神经网络结构的重要参数

Table 1 Important parameters of different neural network structures

Net number	Net structure	Input	Number of CNN layers	Layer node	Learning rate
1	ANN	Time-domain sequence	0	36	0.01
2	ANN	STFT	2	80	0.05
3	ANN	Time-domain sequence + STFT	2	88	0.03
4	CNN	Time-domain sequence + STFT	4	90	0.001
5	LSTM-CNN	Time-domain sequence + STFT	4	90	0.001

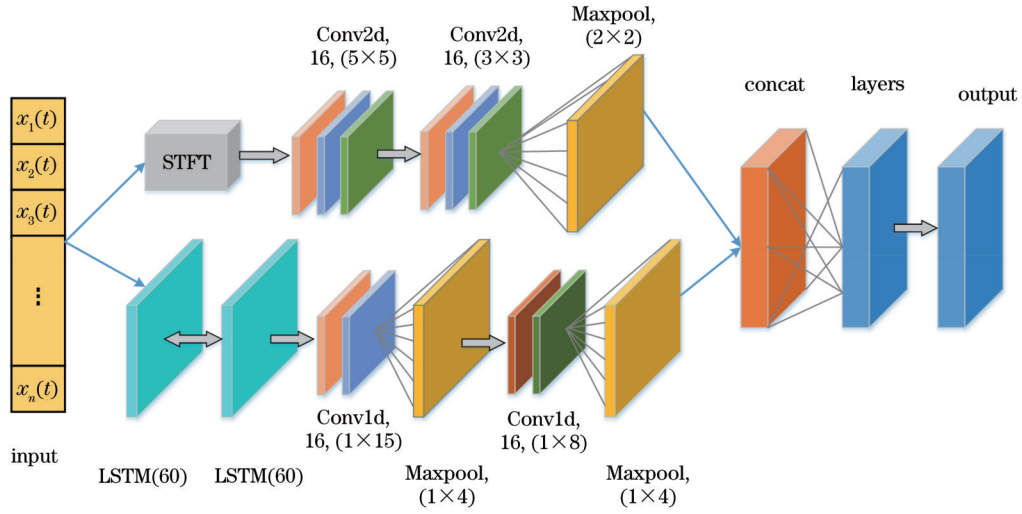


图 8 LSTM-CNN 网络结构

Fig. 8 Network structure of LSTM-CNN

示,网络 4 与网络 5 的卷积层参数一致。训练过程中小批量样本数为 20,训练轮次为 1000,优化器选择“Adam”。输入层激活函数选择“ReLU”,输出层激活函数选择“Softmax”,损失函数选择“Categorical\_crossentropy”。

评价指标包括训练集的损失函数  $f_{train}$ 、准确率  $A_{train}$ 、精确率  $P_{train}$ 、召回率  $R_{train}$  和测试集的损失函数  $f_{test}$ 、准确率  $A_{test}$ 、精确率  $P_{test}$ 、召回率  $R_{test}$ 。准确率、精确率与召回率的计算公式分别为

$$A = \frac{\sum_{i=1}^k N_{TPi}}{N}, \quad (5)$$

$$P = \frac{N_{TP}}{N_{TP} + N_{FP}}, \quad (6)$$

$$R = \frac{N_{TP}}{N_{TP} + N_{FN}}, \quad (7)$$

式中:  $N_{TP}$  表示正确识别事件 L 的数量;  $N_{FP}$  表示将其他事件识别为 L 的数量;  $N_{FN}$  表示将 L 识别为其他事件的

数量;  $k$  表示事件分类数;  $N$  为总样本数。

图 9 所示为总体评价指标比较结果。比较网络 1 与网络 2,当训练网络为 ANN 时,以 STFT 为输入的准确率远高于时域信号;网络 2 与网络 3 的比较则表明,在未有有效提取时域信号的特征时,将时域信号作为网络输入没有提升网络性能。相比之下,网络 4 在网络 3 的基础上增加了一维卷积算子作用于时域序列,其性能得到显著的提升,总体评价指标超过了网络 2,此时时域序列对网络性能的提升起到正向促进作用。网络 5 在网络 4 的基础上补充了 LSTM 提取时间序列的时序特征,进一步强化了网络性能,各项指标及收敛速度都优于其他网络,其训练集准确率与测试集准确率分别为 97.8% 和 94.6%。

准确率与损失函数都是综合性评价指标,衡量网络对于全体样本的综合表现,当网络用于模式识别时,对具体事件的识别准确程度也是网络可靠性的衡量指标。样本中共包含 4 种标签,分别对测试集中各类事件的精确率、召回率进行比较,结果见图 10、图 11。




图 9 总体评价指标比较。(a) 训练集准确率; (b) 测试集准确率; (c) 训练集损失函数; (d) 测试集损失函数

Fig. 9 Comparison of overall evaluation indicators. (a) Train accuracy; (b) test accuracy; (c) train loss; (d) test loss

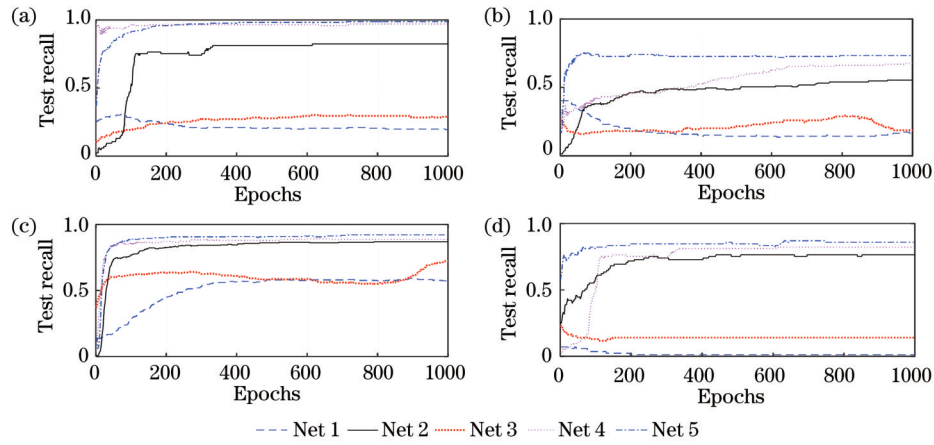


图 10 测试集召回率比较。(a)背景噪声;(b)挖掘信号;(c)电机振动信号;(d)行走信号

Fig. 10 Recall comparison of test set. (a) Background noise; (b) excavation signal; (c) motor vibration signal; (d) walking signal

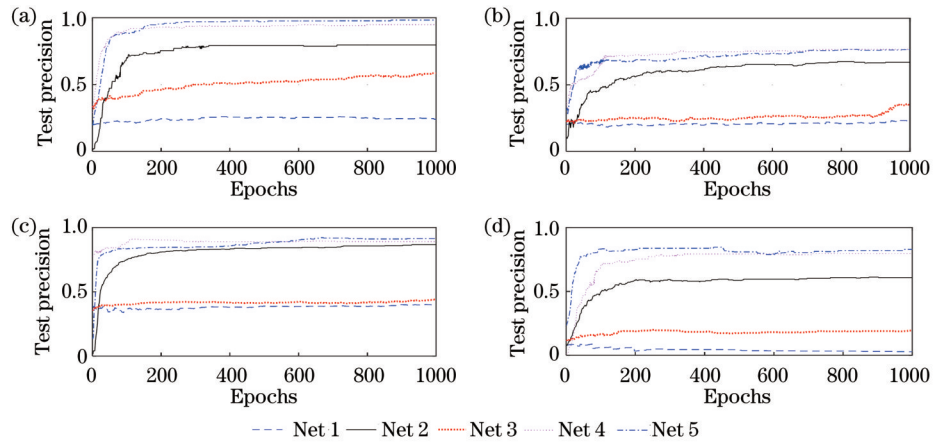


图 11 测试集精确率比较。(a)背景噪声;(b)挖掘信号;(c)电机振动信号;(d)行走信号

Fig. 11 Precision comparison of test set. (a) Background noise; (b) excavation signal; (c) motor vibration signal; (d) walking signal

图 9 中,尽管网络 2 的损失函数和准确度与网络 4 和网络 5 不存在明显的差距,但是具体到每一种标签,网络 2 在静态信号、挖掘信号、行走信号的召回率与精确率上则存在劣势。网络 5 在各项指标中都优于其他网络,其收敛速度与稳定性都优于网络 2 与网络 4,对静态信号与电机振动信号的识别精确率与召回率均接近 100%,对挖掘信号与行走信号的识别精确率与召回率分别接近 85% 与 90%,均优于表 1 中其他网络。

### 3.3 模型验证

本小节验证网络 5 对非训练样本模式识别的准确率与可靠性。实验中连续对光缆施加不同类型的激励,并记录激励作用时间。重复 5 次数据采集流程,采集得到的时域信号时长分别为 361 s、324 s、338 s、347 s、363 s。以 1 s 为间隔划分数据,共得到 1733 个样本,每个样本包含 1000 个采样点。样本标签值依据实验记录标记,其中静态噪声、挖掘信号、电机振动信号、行走信号分别有 327、218、478、710 个样本。使用 TensorFlow2.4GPU 与 CUDA11.1 提升网络的数据

处理速度,单个样本的平均处理时长小于 1 s,避免了网络预测的滞后性。

分别使用训练后的表 1 中网络对上述验证样本集进行识别,统计其准确率、精确率及召回率。识别结果及准确率统计如表 2 所示。

面对非训练样本数据,网络 3 与网络 1 的泛化性显著弱于其他网络,表明对时域信号实现有效的特征提

表 2 验证样本的识别结果分布及准确率

Table 2 Distribution of identification results and accuracy of the verification samples

Sample type	Number of sample points				Accuracy / %
	Noise	Excavation	Motor vibration	Walking	
Original	327	218	478	710	
Net 1	252	167	720	468	35.77
Net 2	340	180	550	663	82.28
Net 3	136	140	815	373	47.39
Net 4	328	193	493	695	89.47
Net 5	315	224	493	695	94.43

取是十分必要的。网络 5 的验证样本准确率为 94.43%，其准确率与泛化性均处于最优状态。分别统

计每种事件的精确率与召回率,结果如图 12 和图 13 所示。




图 12 验证样本的精确率。(a)背景噪声;(b)挖掘信号;(c)电机振动信号;(d)行走信号

Fig. 12 Precision of validation sample. (a) Background noise; (b) excavation signal; (c) motor vibration signal; (d) walking signal




图 13 验证样本的召回率。(a)背景噪声;(b)挖掘信号;(c)电机振动信号;(d)行走信号

Fig. 13 Recall of validation sample. (a) Background noise; (b) excavation signal; (c) motor vibration signal; (d) walking signal

图 12 中,网络 5、网络 2、网络 4 对静态噪声的识别精确率均接近 100%,而对其他 3 种信号,网络 5 的识别

精确率均表现出不同程度的优势。图 13 中,召回率的统计结果与精确率一致,尤其对挖掘信号和行走信号



的识别,网络 5 相比网络 2 和网络 4 高出 10%~15%。

结合训练样本的训练效果与验证数据的测试结果,LSTM 有效提取了时域信号的时序特征,CNN 提取了时域信号的轮廓特征,同时将 STFT 作为网络输入,提取了网络的时频域能量特征,LSTM-CNN 实现了对噪声信号、挖掘信号、电机振动信号、行走信号的模式识别,相比传统的 ANN、CNN,LSTM-CNN 在各项评价指标中均处于最优状态。

### 3.4 对比机器学习

前文提到,当面对大批量样本的多分类问题时,传统的机器学习算法通常面临着泛化性较弱、可识别类别数有限的缺陷,本小节将训练后的 LSTM-CNN 与 SVM、KNN、决策树、随机森林这 4 种常见的分类器进行对比。利用神经网络提取信号的时序特征、能量特

征、轮廓特征等;类似地,使用经验模态分解(EMD)提取时域特征,使用离散小波变换(DWT)提取信号频域能量特征,分别将 EMD 与 DWT 每层分解曲线的能量求和并归一化构建特征向量,其中 EMD 与 DWT 均分解为 6 层,特征向量共包含 12 个维度。式(8)为特征向量  $V$  的归一化公式:

$$V = \frac{V - \min(V)}{\max(V) - \min(V)} \quad (8)$$

分类器基于 Python 3.8 及第三方库 sklearn 实现。其中,SVM 的核函数选择高斯核函数,使用网格搜索及交叉验证确定惩罚因子为 1.5,核函数系数为 0.15。其余模型参数均为函数默认值。分类器的训练集、测试集与验证集与 LSTM-CNN 一致。表 3 为各模型对测试集与验证集的平均准确率。

表 3 LSTM-CNN 及常见机器学习模型的对比  
Table 3 Comparison of LSTM-CNN and common machine-learning models

Model type	Model 1	Model 2	Model 3	Model 4	Model 5
Structure	LSTM-CNN	SVM	KNN	Decision-tree	Random-forest
Test accuracy / %	94.60	83.65	83.71	78.17	87.38
Validation accuracy / %	94.43	81.98	65.66	75.24	83.26

面对训练样本以外的验证数据,只有 LSTM-CNN 依旧保持了较高的准确率,模型 2~5 的验证集准

准确率均呈现出不同程度的下降,在具体事件的评价中,这种差异更加明显,如图 14 和图 15 所示。




图 14 表 3 中模型的验证样本精确率。(a)背景噪声;(b)挖掘信号;(c)电机振动信号;(d)行走信号

Fig. 14 Precision of validation sample of models in Table 3. (a) Background noise; (b) excavation signal; (c) motor vibration signal; (d) walking signal

在对除噪声以外的 3 种事件的识别中,模型 2~5 的表现均弱于 LSTM-CNN,表明其在泛化性与大批量样本应用中均有缺陷。需要指出的是,在噪声的识

别中,SVM、决策树、随机森林分类器均达到了 100% 的精确率与召回率。因此,可以将机器学习算法作为神经网络的前端预处理机制,利用其响应时间短、数据

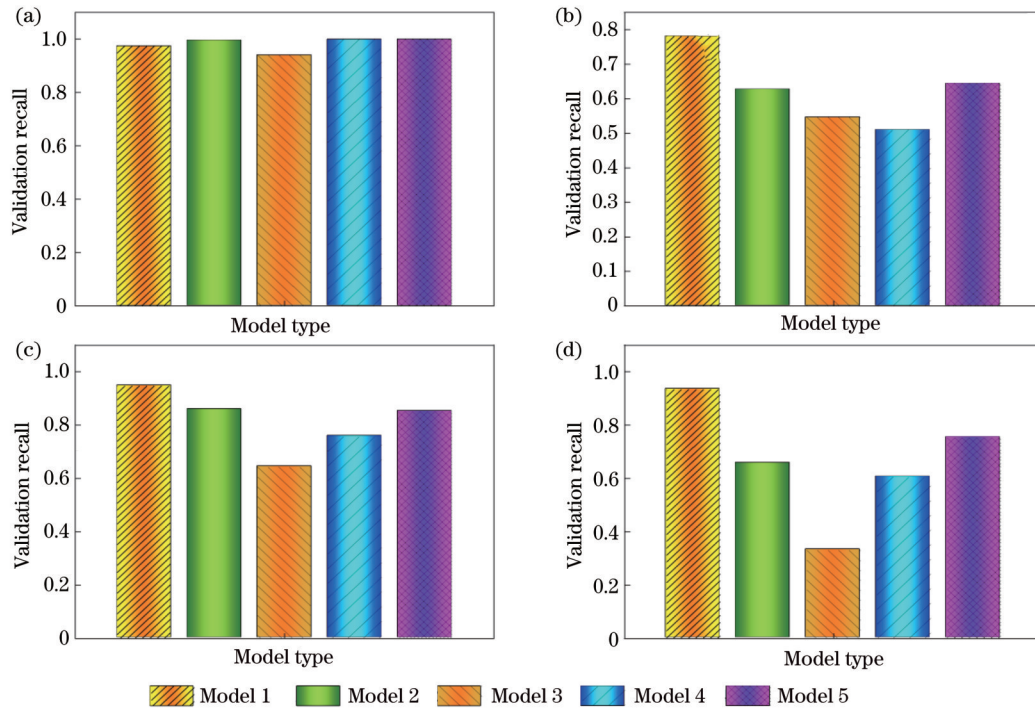


图 15 表 3 中模型的验证样本召回率。(a)背景噪声;(b)挖掘信号;(c)电机振动信号;(d)行走信号

Fig. 15 Recall of validation sample of models in Table 3. (a) Background noise; (b) excavation signal; (c) motor vibration signal; (d) walking signal

处理量小的优点剔除非威胁性信号,从而提升模式识别的效率。

## 4 结 论

针对  $\varphi$ -OTDR 模式识别问题,提出了以 LSTM 与 CNN 为主要框架的神经网络,以时域曲线为网络输入,经 LSTM 提取其时序特征,再经过 CNN 与 STFT 提取其轮廓特征、能量特征,相比于 ANN 与传统 CNN, LSTM-CNN 均表现出不同程度的优越性。针对背景噪声、挖掘、电机振动、行走 4 类信号, LSTM-CNN 对训练集与测试集的准确率分别为 97.8% 和 94.6%, 其各项指标均优于 CNN 与 ANN。在 LSTM-CNN 的性能测试中,验证样本集的准确率为 94.43%, 完成了模式识别的既定目标。

将 LSTM 与 CNN 结合,有效实现了对时域信号多种特征的提取与融合,弥补了传统 ANN 与 CNN 的不足。使用 TensorFlow2.4 GPU 调用 CUDA11.1 提高了 LSTM-CNN 的数据处理能力,弥补了 RNN 网络在数据处理速度上的缺陷,具有良好的应用前景。

### 参 考 文 献

- [1] Lü J D, Fang N, Wang C H, et al. Location method of Sagnac distributed optical fiber sensing system based on CNNs ensemble learning[J]. Optics & Laser Technology, 2021, 138: 106841.
- [2] Wang J, Wang L, Su X Q, et al. Temperature, stress, refractive index and humidity multi parameter highly integrated optical fiber sensor[J]. Optics & Laser Technology, 2022, 152: 108086.
- [3] 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.
- [4] Sha Z, Feng H, Rui X B, et al. PIG tracking utilizing fiber optic distributed vibration sensor and YOLO[J]. Journal of Lightwave Technology, 2021, 39(13): 4535-4541.
- [5] Yang Y, Fan T, Li Q, et al. Digitalized phase demodulation scheme of  $\varphi$ -OTDR based on cross-coherence between Rayleigh back-scattering beat signals[J]. Optical Fiber Technology, 2022, 71: 102896.
- [6] Kandamali D F, Cao X M, Tian M L, et al. Machine learning methods for identification and classification of events in  $\phi$ -OTDR systems: a review[J]. Applied Optics, 2022, 61(11): 2975-2997.
- [7] Yang C, Oh S K, Yang B, et al. Hybrid fuzzy multiple SVM classifier through feature fusion based on convolution neural networks and its practical applications[J]. Expert Systems With Applications, 2022, 202: 117392.
- [8] Ali J, Aldhaifallah M, Nisar K S, et al. Regularized least squares twin SVM for multiclass classification[J]. Big Data Research, 2022, 27: 100295.
- [9] Chang X Y, Wang H, Zhang Y M, et al. Bayesian prediction of tunnel convergence combining empirical model and relevance vector machine[J]. Measurement, 2022, 188: 110621.
- [10] Wang H Y, Xu P D, Zhao J H. Improved KNN algorithms of spherical regions based on clustering and region division[J]. Alexandria Engineering Journal, 2022, 61(5): 3571-3585.
- [11] Dadgar M. Developing new measuring and ANN prediction method for the longitudinal diameter of intermingled untwisted heat set bulk continues filament yarns[J]. Measurement, 2021, 171: 108727.
- [12] Khan T, Tian W H, Zhou G Y, et al. Machine learning (ML)-centric resource management in cloud computing: a review and

- future directions[J]. Journal of Network and Computer Applications, 2022, 204: 103405.
- [13] Ghasemi Y, Jeong H, Choi S H, et al. Deep learning-based object detection in augmented reality: a systematic review[J]. Computers in Industry, 2022, 139: 103661.
- [14] Vankdothu R, Hameed M A, Fatima H. A brain tumor identification and classification using deep learning based on CNN-LSTM method[J]. Computers and Electrical Engineering, 2022, 101: 107960.
- [15] Wang Z D, Lou S Q, Wang X, et al. Multi-branch long short-time memory convolution neural network for event identification in fiber-optic distributed disturbance sensor based on  $\varphi$ -OTDR[J]. Infrared Physics & Technology, 2020, 109: 103414.
- [16] 陈颖, 段玮靓, 杨英, 等. 基于三维荧光光谱和 GBDT-LR 的褐潮藻辨识[J]. 光学学报, 2022, 42(12): 1230001.  
Chen Y, Duan W L, Yang Y, et al. Identification of brown tide algae based on three-dimensional fluorescence spectra and GBDT-LR[J]. Acta Optica Sinica, 2022, 42(12): 1230001.
- [17] 李丹, 孔繁镛, 朱德燕. 基于局部高斯混合特征提取的高光谱图像分类[J]. 光学学报, 2021, 41(6): 0610001.  
Li D, Kong F Q, Zhu D Y. Hyperspectral image classification based on local Gaussian mixture feature extraction[J]. Acta Optica Sinica, 2021, 41(6): 0610001.
- [18] Ding Y, Zhang Z L, Zhao X F, et al. Multi-feature fusion: graph neural network and CNN combining for hyperspectral image classification[J]. Neurocomputing, 2022, 501: 246-257.
- [19] 王洪斌, 肖嵩, 曲家慧, 等. 基于多分支 CNN 的高光谱与全色影像融合处理[J]. 光学学报, 2021, 41(7): 0710001.  
Wang H B, Xiao S, Qu J H, et al. Pansharpening based on multi-branch CNN[J]. Acta Optica Sinica, 2021, 41(7): 0710001.
- [20] 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.  
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.
- [21] Bian C, Yang S K, Liu J, et al. Robust state-of-charge estimation of Li-ion batteries based on multichannel convolutional and bidirectional recurrent neural networks[J]. Applied Soft Computing, 2022, 116: 108401.
- [22] Nammous M K, Saeed K, Kobjek P. Using a small amount of text-independent speech data for a BiLSTM large-scale speaker identification approach[J]. Journal of King Saud University-Computer and Information Sciences, 2022, 34(3): 764-770.
- [23] Zeng C, Ma C X, Wang K, et al. Predicting vacant parking space availability: a DWT-Bi-LSTM model[J]. Physica A: Statistical Mechanics and Its Applications, 2022, 599: 127498.

## $\varphi$ -OTDR Pattern Recognition Based on LSTM-CNN

Wang Ming<sup>1</sup>, Sha Zhou<sup>1</sup>, Feng Hao<sup>1\*</sup>, Du Lipu<sup>2</sup>, Qi Dunzhe<sup>2</sup>

<sup>1</sup>State Key Laboratory of Precision Measuring Technology and Instruments, School of Precision Instrument and Opto-Electronics Engineering, Tianjin University, Tianjin 300072, China;

<sup>2</sup>Ningxia Hui Autonomous Region Water Conservancy Engineering Construction Center, Yinchuan 750004, Ningxia, China

### Abstract

**Objective** With the advantages of long monitoring range, excellent anti-interference ability, accurate event location, and mature measurement principle, phase sensitive optical time domain reflectometer ( $\varphi$ -OTDR) has become a non-destructive detection method that has emerged in recent years and is widely used in pipeline safety maintenance, pig positioning and tracking, intrusion warning, and other fields. Threat warning and pattern recognition are the two main tasks of optical fiber sensing. On the one hand, it needs to quickly respond to possible threat events. On the other hand, countermeasures for different types of threats should be different. Therefore, it is necessary to identify event types. To simulate common threat events in engineering, we apply a self-developed  $\varphi$ -OTDR integrated chassis to collect four types of excitation signals including background noise, excavation, motor vibration, and walking. The established goal of pattern recognition is accomplished by using neural networks and machine learning classifiers, respectively. In addition, deep learning and machine learning have different characteristics in pattern recognition. Deep learning requires multiple rounds of iterative learning on a large batch of samples and converges to an optimal state through error back-propagation and parameter update. In contrast, machine learning has the advantages of fewer training samples, fast response time, and short training period, but it is highly dependent on the effectiveness of feature extraction. Therefore, the performance difference between the two kinds of classifiers is also one of the focuses for comparison in this paper.

**Methods** We employed a short-time Fourier transform (STFT) to extract the time-frequency domain features of the signal while utilizing the long short-term memory network (LSTM) to extract the time-series features. On this basis, a one-dimensional convolution operator was employed to extract contour features, and a two-dimensional convolution operator was used to extract spatial features. Usually, the training period of a recurrent neural network (RNN) is long, so the LSTM needed to be trained separately to determine the optimal model parameters, and thus the LSTM parameters were directly called in the subsequent classifier training. With the comparison of the accuracy, precision, recall, and other

evaluation indicators among an artificial neural network (ANN), traditional convolutional neural network (CNN), and LSTM-CNN (Table 1), the positive improvement of LSTM and CNN for classification performance was illustrated. The same training set and validation set were used to compare LSTM-CNN with four machine learning algorithms (Table 3), including support vector machine (SVM), K-nearest neighbor (KNN), decision tree, and random forest, and the superiority of deep learning compared with machine learning was analyzed in terms of generalization and classification accuracy. The time domain features were extracted by empirical mode decomposition (EMD), and the frequency domain energy features of the signal were extracted by discrete wavelet transform (DWT). The energy of decomposition curves of each layer of EMD and DWT was summed and normalized to construct eigenvectors, in which EMD and DWT were decomposed into six layers, respectively, and thus the eigenvectors contained 12 dimensions in total.

**Results and Discussions** By comparing accuracy, precision, recall, and other parameters of test set (Figs. 9–11), it is found that the convolution operator and LSTM have significantly improved the performance of ANN. In specific event recognition, LSTM-CNN is always in the best state. According to the comparison of the validation set (Table 2, Fig. 12, and Fig. 13), the generalization and classification accuracy of LSTM-CNN are proved. For instance, in the recognition of excavation and walking signals, LSTM-CNN shows significant advantages, and the precision and recall rates exceed CNN by 10% to 15%. By comparing LSTM-CNN with four machine learning algorithms including SVM, KNN, decision tree, and random forest (Table 3, Fig. 14, and Fig. 15), it is proved that deep learning is effective in multi-classification problems with large batches of samples and with great superiority in generalization and classification accuracy. However, in the recognition of noise, SVM, decision tree, and random forest all achieve precision and recall of 100%. Therefore, the machine learning algorithms can be designed as a front-end procession mechanism of the neural network, and the non-threatening signals can be eliminated by taking advantage of its short response time and small data processing volume, so as to improve the efficiency of pattern recognition.

**Conclusions** Aiming at the problem of  $\varphi$ -OTDR pattern recognition, we propose a neural network with LSTM and CNN as the main framework in this paper. With the time domain curve as the network input, we extract its time-series features through LSTM and then its contour and energy features via CNN and STFT, respectively. LSTM-CNN shows different degrees of superiority compared with ANN and traditional CNN. The accuracy of LSTM-CNN on the training set and validation set is 97.8% and 94.6%, respectively, and the accuracy of the validation sample set is 94.43%, which accomplishes the established goal of  $\varphi$ -OTDR pattern recognition. To make up for the drawback of the RNN in data processing speed, we utilize TensorFlow2.4GPU and CUDA11.1 to improve the data processing capability of LSTM-CNN, which provides a proof of concept and demonstration examples for actual engineering product development.

**Key words** optical communications; pattern recognition; long short-term memory network; convolutional neural network; optical fiber early warning