




DOI: 10.12086/oe.2019.180493

## 基于多尺度一维卷积神经网络的光纤振动事件识别

吴俊<sup>1,2</sup>, 管鲁阳<sup>2\*</sup>, 鲍明<sup>2</sup>, 许耀华<sup>1</sup>, 叶炜<sup>3</sup><sup>1</sup>安徽大学计算智能与信号处理教育部重点实验室,安徽合肥 230039;<sup>2</sup>中国科学院声学研究所,北京 100190;<sup>3</sup>浙江大学控制科学与工程学院,浙江杭州 310058

**摘要:** 针对相位敏感光时域反射( $\Phi$ -OTDR)分布式光纤振动传感系统如何对振动事件进行高效准确识别的问题,本文提出了一种基于多尺度一维卷积神经网络(MS 1-D CNN)的振动事件识别方法。该方法将原始振动信号经过预加重、归一化和谱减降噪的预处理操作后得到的一维信号,直接通过 MS 1-D CNN 实现端到端的振动信号特征的提取和识别。MS 1-D CNN 在提取入侵振动信号特征时可兼顾信号时间和频率尺度,利用全连接层(FC layer)和 Softmax 层完成最终的识别过程,与二维卷积神经网络(2-D CNN)和一维卷积神经网络(1-D CNN)相比减少了待定参数数量。对破坏、敲击和干扰三类目标振动事件的光纤振动传感信号识别结果表明,MS 1-D CNN 的识别正确率与 2-D CNN 相近,达到了 96% 以上,而处理速度提升一倍,在保持识别性能的前提下,有利于提高振动事件识别的实时性。

**关键词:** 分布式光纤振动传感; 多尺度一维卷积神经网络; 相位敏感光时域反射; 振动事件识别; 模式识别

**中图分类号:** TB872; TN253

**文献标志码:** A

**引用格式:** 吴俊,管鲁阳,鲍明,等. 基于多尺度一维卷积神经网络的光纤振动事件识别[J]. 光电工程, 2019, 46(5): 180493

## Vibration events recognition of optical fiber based on multi-scale 1-D CNN

Wu Jun<sup>1,2</sup>, Guan Luyang<sup>2\*</sup>, Bao Ming<sup>2</sup>, Xu Yaohua<sup>1</sup>, Ye Wei<sup>3</sup><sup>1</sup>Key Laboratory of Intelligent Computing and Signal Processing, Ministry of Education, Anhui University, Hefei, Anhui 230039, China;<sup>2</sup>Institute of Acoustics, Chinese Academy of Sciences, Beijing 100190, China;<sup>3</sup>College of Control Science and Engineering, Zhejiang University, Hangzhou, Zhejiang 310058, China

**Abstract:** A new CNN-based deep neural network, multi-scale one-dimensional convolutional neural network (MS 1-D CNN) was proposed to improve the efficiency and accuracy of vibration event recognition for a phase-sensitive optical time-domain reflectometry ( $\Phi$ -OTDR) distributed optical fiber vibration sensing system. The raw vibration signals are pre-processed first to remove noise as far as possible. The pre-processing operations include pre-emphasis filtering, normalization and spectral subtraction. The pre-processed signals are used as the inputs of MS 1-D CNN directly. MS 1-D CNN realizes the end-to-end feature extraction of vibration signals and finally recognizes the vibration events by using a fully-connected layer (FC layer) and a Softmax layer. In comparison with

收稿日期: 2018-09-21; 收到修改稿日期: 2019-03-22

基金项目: 中国科学院战略性先导科技专项(XDC02040600)

作者简介: 吴俊(1994-),男,硕士研究生,主要从事光纤振动检测及模式识别方面的研究。E-mail: wujunahuyj@gmail.com

通信作者: 管鲁阳(1979-),男,博士,副研究员,主要从事信号处理与模式识别的研究。E-mail: guanluyang@mail.ioa.ac.cn

two-dimensional convolutional neural network (2-D CNN) and one-dimensional convolutional neural network (1-D CNN), the proposed method balances the time and frequency scales better during feature extraction and reduces the pending parameters of the whole neural network. A vibration recognition experiment was designed to classify the three types of the vibration events including damaging, knocking and interference. The recognition results show that MS 1-D CNN achieves similar recognition performance, over 96 percent, at twice processing speed compared to 2-D CNN. Therefore, it is beneficial to improve the real-timing of vibration monitoring while maintaining the recognition performance.

**Keywords:** distributed optical fiber vibration sensing; multi-scale 1-D CNN;  $\Phi$ -OTDR; vibration events recognition; pattern recognition

**Citation:** Wu J, Guan L Y, Bao M, *et al.* Vibration events recognition of optical fiber based on multi-scale 1-D CNN[J]. *Opto-Electronic Engineering*, 2019, 46(5): 180493

## 1 引言

分布式光纤振动传感系统由于具备灵敏度高、抗电磁干扰性能强、重量轻、易铺设和定位精度高等优点,近年来在区域防护、管线保护等应用中得到了迅速发展<sup>[1-3]</sup>。不同的应用场景下振动事件的识别性能和实时性,是限制分布式光纤传感技术广泛应用的瓶颈问题。因此对引起振动的事件的识别逐渐成为了分布式光纤传感系统信号处理的核心任务。

由于  $\Phi$ -OTDR(phase-sensitive optical time-domain reflectometry, 相敏光时域反射仪)技术可提供足够高的灵敏度,能较好地反映振动的特性,针对  $\Phi$ -OTDR 分布式光纤振动传感系统的振动事件识别成为近年来的研究热点。传统方法是首先从振动信号中提取特征,然后进行识别。振动信号典型特征包括短时能量、短时过电平率、奇异谱、短时傅里叶频谱和小波能量谱等。识别方法主要分为两种:第一种是根据提取的特征设计分类判别规则<sup>[4-5]</sup>。第二种是目前的主流方法,利用 BP 神经网络和支持向量机(SVM)等分类器进行识别<sup>[6-7]</sup>。但以上方法的识别率和鲁棒性都不够理想,并且对人工特征设计依赖较强。近年来,深度学习方法因具备更强的非线性学习能力而得到广泛应用。在光纤振动事件识别相关研究中,Xu 等<sup>[8]</sup>将振动信号的时频图作为输入特征,通过 2-D CNN 提取时频图中的特征进行识别。它相对于前述两种方法提升了识别效

果,减少特征提取的影响,但是其依然需要人工初步提取时频图特征的过程,并且时频图特征数据量大,处理速度较慢。

对于振动和声音等一维信号,1-D CNN 无需设计特定特征即可实现特征提取与识别,目前已取得较为广泛的应用。Ince 等<sup>[9]</sup>将电机振动信号作为 1-D CNN 的输入,实现了实时准确的电机状态监控。Kiranyazd 等<sup>[10]</sup>利用自适应 1-D CNN,融合了心电信号的特征提取和识别过程,提高了异常心脏搏动识别速度并获得良好的识别效果。Hu 等<sup>[11]</sup>通过 1-D CNN 提取水下声信号特征然后利用极限学习机(extreme learning machine, ELM)进行识别,提高了对三种船舶的识别正确率。这些信号与本文待识别的信号均由物体的振动产生,故具有较强的相似性以及较高的参考价值。

因此,本文针对振动事件识别中 2-D CNN 仍依赖人工特征提取以及处理速度有待提升的问题,结合 1-D CNN 在一维信号中较好地兼顾识别速度和识别效果的特点,提出了一种基于 MS 1-D CNN 的振动事件识别方法,将预处理后的振动信号作为输入,通过端到端地对一维振动信号进行不同尺度的特征提取和识别,以实现更加高效准确的识别。

## 2 系统原理

$\Phi$ -OTDR 分布式光纤振动传感系统的工作原理如图 1 所示。利用窄线宽激光器作为光源输出连续激光,




图 1  $\Phi$ -OTDR 分布式光纤振动传感系统原理图

Fig. 1 Schematic of  $\Phi$ -OTDR distributed optical vibration fiber sensing systems

通过声光调制器将激光器发射出的激光调制成具有一定脉冲宽度和频率的光脉冲。调制后的光脉冲经由掺铒光纤放大器放大，通过环形器注入到单模传感光纤中。光脉冲在传感光纤中传播时产生的背向瑞利散射光在光纤内产生干涉，干涉光的光强信号再次通过环形器，由掺铒光纤放大器进行放大。光电转换器再将放大后的光强信号转化为电信号，由数据采集卡完成该电信号的采集，最后进行信号的检测和识别。

$\Phi$ -OTDR 光纤系统通过背向瑞利散射光干涉进行光纤振动探测，可以用一个离散模型<sup>[12]</sup>来描述，如图 2 所示。




图 2  $\Phi$ -OTDR 背向瑞利散射离散模型

Fig. 2  $\Phi$ -OTDR backward discrete model of Rayleigh scattering

在该离散模型中，假定光纤被分为  $N$  段，每段的长度均为  $\Delta L = L / N$ ，背向瑞利散射过程可以视为由一组在长度为  $\Delta L$  的光纤内随机分布的  $M$  个瑞利散射元背向散射的矢量和构成。则第  $m$  段背向瑞利散射光的电场可以表示为

$$E_{bs}^m = E_0 e^{-2\alpha L_m} \sum_{i=1}^M r_i^m e^{j\varphi_i} \quad (1)$$

其中： $\alpha$  为光纤的衰减系数， $L_m$  为光纤前  $m$  段的长度  $m\Delta L$ 。 $r_i$  和  $\varphi_i$  分别为  $\Delta L$  长度光纤内第  $i$  个背向散射的散射系数和相位。在  $\Phi$ -OTDR 中，脉冲宽度内产生的背向瑞利散射光会干涉形成干涉谱。若将每个散射段的散射系数视为相同，统一用  $r$  表示，则探测到的光信号强度可以表示为

$$I_{bs}^m = |E_{bs}^m|^2 = \sum_{i=1}^{M-1} \sum_{i'+1}^M E_0^2 r^2 e^{-4\alpha L_m} + 2E_0^2 r^2 \sum_{i=1}^{M-1} \sum_{i'+1}^M \cos(\varphi_{i'} - \varphi_i) \quad (2)$$

其中：式(2)的第一部分为直流分量，第二部分为多个干涉信号的和，其强度取决于在脉冲宽度内的相位差的集合。由于在这段长度为  $\Delta L$  的光纤上的散射元的背向散射光具有随机的相位和幅度，因此这些散射的矢

量将会随机落在一个复平面上。当某个位置有振动事件发生时，背向瑞利散射光相对相位的改变就会引起光强度的变化。通过将不同光强度转化为相应的电信号，从而得到待处理的振动信号。

### 3 多尺度一维卷积神经网络

在信号处理中，选取固定长度的窗函数会出现时间分辨率和频率分辨率无法较好均衡的问题。而从学习局部感受野中特征信息的角度考虑则有：若卷积核尺度和跨度过小，信号的时间分辨率较好，对于高频特征变化较为敏感，但无法较好地学习信号中存在的低频特征。相反，尺度较大的卷积核对应使用较大的跨度，可以学习更长时间范围的信息，即信号中存在的低频特征，却无法较好地反映其中的高频率特性。本文为了将不同尺度的优点结合起来，提出了一种 MS 1-D CNN 算法模型。

MS 1-D CNN 算法模型框架如图 3 所示，含有三个并行的四层多尺度卷积层，其中每层卷积层都是由卷积和最大池化操作构成。预处理后的一维振动信号通过多尺度卷积层提取信号中隐藏在不同尺度上时间和频率的特征，再将这些特征信息融合为一个特征信息矩阵，经过全连接层和 Softmax 层处理，得到相应的识别类型，从而进行端到端的训练和识别。

本文利用多个一维卷积核与输入的信号进行不同尺度的卷积，以实现对不同时间尺度信号特征的提取，用  $L$  表示信号长度。多尺度一维卷积定义如下：

$$y_i^{K,s} = \delta(\text{Conv}_{k \in K, s \in S}(X_{(i-1)s+k}, W_k) + b_i) \quad (3)$$

其中： $k$  表示当前的卷积核尺度，这里选取三种卷积核尺度  $K = [k_1, k_2, k_3]$ ，对应三种卷积核尺度分别选取三个卷积核的跨度  $s = [s_1, s_2, s_3]$ 。从  $k_1, s_1$  到  $k_3, s_3$  分别提取信号中从高到低的频率特征成分以及从短到长的时域特征成分。 $X$  表示输入的振动信号， $\delta$  为激活函数， $y_i^{K,s}$  表示以卷积核尺度  $K$  和跨度  $s$  的第  $i$  个输出元素。

由于多尺度卷积得到一维特征长度不一致，对并行的卷积层使用相应尺度和跨度的池化以实现特征融合。此池化过程定义如下：

$$z_j^{R,c} = P_{r \in R, c \in C}(y_{(j-1)c+r}) \quad (4)$$

其中： $y_{(j-1)c+r}$  分别表示在池化尺度  $R = [r_1, r_2, r_3]$  内以及跨度  $c = [c_1, c_2, c_3]$  下的输入， $z_j^{R,c}$  则为得到的以  $R$  为池化尺度、 $c$  为跨度的第  $j$  个池化结果。

在经过各自初步特征提取的第一层后，将下个多尺度卷积过程得到的三个并行的卷积层分别应用以上

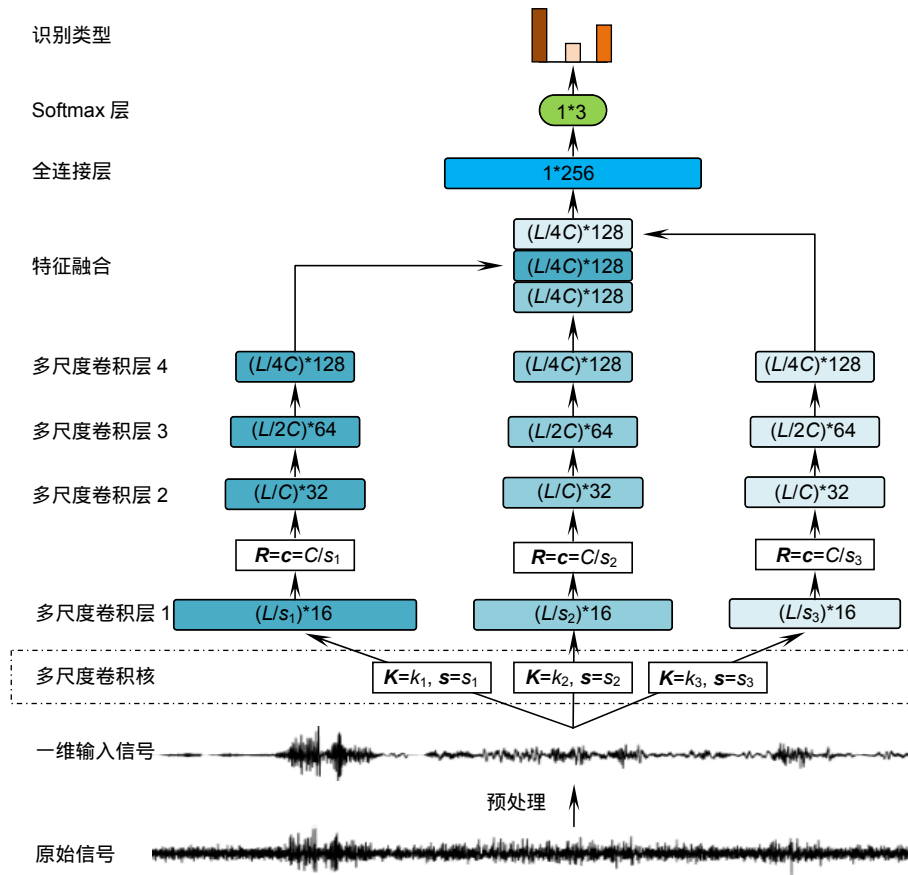


图3 多尺度一维卷积神经网络框架

Fig. 3 The structure of MS 1-D CNN

的池化尺度  $R$  以及跨度  $c$  的池化操作，它们与卷积尺度满足以下关系：

$$s \circ R = s \circ c = [C_1, C_2, C_3], \quad (5)$$

其中：“ $\circ$ ”是哈达马积。为了使池化后的结果尺度相同， $C_1, C_2, C_3$  均取值为常数  $C$ 。之后的卷积层均采用相同尺寸的卷积核和池化核，以进一步提取不同尺度中的高维特征。在最后一层多尺度卷积层后，融合不同尺度提取的特征信号，使不同尺度特征之间信息相互补充，以便更好地识别。

全连接层将特征融合得到的特征信息矩阵的每一个元素作为输入，将学习到的分布式特征表示映射到最终的样本标记空间中作为输出，并且作为特征提取和最终分类识别的过渡层，其输出维数等于目标类别数量。

Softmax 层是将全连接层的输出进行 Softmax 操作，将数值转化为其对应类别的概率。因此 Softmax 层输出矢量的最大值对应的目标类别即为最终的识别结果：

$$P_n = \frac{e^{x_m}}{\sum_n e^{x_n}}, \quad (6)$$

其中： $x_m$  为 Softmax 输入  $x$  的第  $m$  个元素， $P_n$  则为这个元素对应每个类别的 Softmax 结果，也就是预测结果为第  $n$  类的概率。

为了对 Softmax 的结果  $P_n$  不断优化其识别过程，将损失函数定义为

$$L_{\text{loss}} = -\sum_n y_n \cdot \log P_n, \quad (7)$$

其中  $y_n$  表示第  $n$  类的实际类别。

## 4 实验验证

### 4.1 实验准备及数据

本文使用的数据是利用  $\Phi$ -OTDR 分布式光纤振动传感系统在户外实验采集的典型振动事件信号，包括破坏、敲击和干扰三种事件。为了保证信号特征的有效性，同时尽量降低采样率以提高目标识别定位的实时性，本文选定振动信号采样率为 1 kHz。 $\Phi$ -OTDR 分布式光纤振动传感系统的仪器型号和主要参数如表 1 所示。系统有效监控距离 40 km，定位精度约 8 m。

从试验系统中引出一段传感光纤挂于防护网上，搭建户外实验平台如图 4 所示。

表 1  $\Phi$ -OTDR 分布式光纤振动传感系统仪器型号和主要参数

Table 1 Instrument model and key parameters of  $\Phi$ -OTDR distributed optical vibration sensing system

	窄线宽激光器	声光调制器	脉冲放大器	光电转换器	信号采集卡	传感光纤
仪器型号	Koheras AdjustiK E15	T-M080-0.4C2J-3-F2P	PEFA-LP-CPM	APD1D100ATBM	FCFR-PCIe9826	黄色松套管光纤
参数配置	波长: 1550 nm 输出功率: 34.5 mW	脉冲频率: 1 kHz 脉冲宽度: 200 ns	平均输出功率: 200 mW	最大数据传输率: 2.5 Gb/s	采集速度: 13 M samples/s	标准单模光纤 折射率: 1.46



图 4 户外实验平台

Fig. 4 Outdoor experiment platform

利用以上实验平台在不同位置模拟破坏、敲击和干扰三类振动事件，数据处理后得到三类振动事件的信号作为样本总集，其中破坏事件信号样本 482 个，敲击事件信号样本 399 个，干扰事件信号样本 479 个，每个事件样本信号时长为 2 s。光纤振动传感系统采集的原始信号首先通过预处理尽量去除干扰。本文预处理包括信号预加重、归一化和噪声抑制。根据采集数据时的环境以及自身系统的干扰情况，采取进一步的降噪处理，在本试验数据中使用谱减法抑制宽带加性噪声。图 5 为预处理后三类振动事件的典型信号波形。

破坏事件信号图 5(a)为利用工具模拟破坏光纤产

生的信号，该过程中工具多次接触光纤，因此振动信号有间隔时间不等的多个短时冲击。敲击事件信号为敲击防护网产生的振动信号，由于防护网本身的振动衰减较慢，因此单个敲击振动持续时间较长，如图 5(b)所示，能看到较为明显的衰减过程。干扰信号图 5(c)包括人员走动和大风等环境因素引起的振动，由于来源复杂，振动信号的幅度及波形变化没有明显规律。

#### 4.2 MS 1-D CNN 参数配置

MS 1-D CNN 的卷积核尺度参数  $K$  取 3, 19, 40，以获取信号中从低到高的三种不同尺度的特征。为了使信号前后信息连续且相关，参考信号处理中帧的移动长度与帧长成比例且小于帧长的规则，卷积核跨度  $s$  分别取 1, 4, 8。将  $C$  的取值设置为 16，使最后得到的特征向量长度不会过大或者过小从而影响对特征的表征或执行速度，那么第二层中相应的池化核尺度  $R$  和池化核跨度  $c$  分别为 16、4 和 2。其余层均参照已经在图像识别领域取得成功的 VGG(visual geometry group)模型<sup>[13]</sup>配置：卷积核尺度均为 3，卷积跨度均为 1，池化核尺度均为 2，池化跨度均为 2。卷积核个数分别为 16、32、64 和 128，目的是一开始提取较少的低维特征，再逐渐增加提取更多、更丰富的高维特征。

为了提升网络的收敛速度以及缓解过拟合的现象，文中采用了批归一化(batch normalization, BN)<sup>[14]</sup>




图 5 预处理后三类振动事件典型信号波形。(a) 破坏信号；(b) 敲击信号；(c) 干扰信号

Fig. 5 Preprocessed typical signal waveforms of three vibration events. (a) Damaging; (b) Knocking; (c) Interference

和 Dropout 的优化方法<sup>[15]</sup>。选用的反向传播算法为 Nesterov Momentum 算法<sup>[16]</sup>，其中动量因子为 0.9。本文采用了退化学习率的方法，以避免训练后期因为学习率过大而震荡，初始学习率为 0.001，前 8 次学习率不变，而后每次学习率降至前一次的 90%，迭代训练 30 次。

#### 4.3 实验结果及分析

为了评估本文提出的 MS 1-D CNN 算法的性能，本文将其与文献[8]提出的利用时频图中的特征进行识别的 2-D CNN 以及不使用多尺度识别原始振动信号的 1-D CNN 两种算法进行比较。

对于 2-D CNN<sup>[8]</sup>算法，按照文献给出的方法，将每段振动事件信号经预处理后使用快速傅里叶变换 (fast Fourier transform, FFT) 计算时频图并保存为 224×224 的图像，FFT 的长度为 128，重叠为 50%。再利用 2-D CNN 对所保存的时频图进行识别，得到 2-D CNN 的识别结果。对于 1-D CNN<sup>[9]</sup>和本文提出的 MS 1-D CNN 算法，将预处理后的一维振动事件信号作为输入，直接提取信号中的特征并得到相应的识别结果。为了更好地比较本文提出的算法与其他两种算法的性能，三种算法的网络层数、反向传播算法、迭代次数、学习率和采用的优化方法均相同，卷积核和池化核的数目、尺度及跨度等也均参照 VGG 模型配置。

采用交叉验证方法从样本集选取 80%的数据作为训练集，其他数据作为测试集。每种方法进行 10 次训练和测试，计算平均的识别结果。三种算法模型的识别结果如表 2 所示。

从表 2 所示的总识别率和标准差可以看出，2-D

CNN 对于三类振动事件的识别正确率最高；1-D CNN 识别率最低，而 MS 1-D CNN 识别率的均值略低于 2-D CNN，考虑到标准差反映的交叉验证中识别性能波动，二者识别效果可视为无明显差别。

MS 1-D CNN 和其他两种算法模型之间的差异仅在信号的特征提取阶段中多尺度的引入与否，所以识别性能相比 1-D CNN 提升的主要原因是 MS 1-D CNN 提取了振动事件信号不同尺度中丰富的高维特征，较好地均衡了频率分辨率和时间分辨率。MS 1-D CNN 通过使用端到端的特征提取和识别就能达到与已经初步提取特征时频信息的 2-D CNN 相近的识别效果，说明本文提出的方法能较好地原始信号中提取目标事件的特征，而无需人工设计特定特征。

除了识别性能，训练速度也是深度学习算法的重要指标之一。对于深度神经网络，其待定参数数量直接关系到计算训练速度，并且在样本有限的情况下，待定参数多的网络在训练中更容易出现过拟合问题。三种算法模型参数量及迭代时间如表 3 所示。

从表 3 可知，由于在全连接层前将信号转换为了维度更低的特征，降低了参数量最多的全连接层的参数量，因此 MS 1-D CNN 的参数量与 2-D CNN 和 1-D CNN 相比均得到降低。训练时每一次迭代速度与参数量的趋势基本一致：一次迭代速度 MS 1-D CNN 最快，2-D CNN 最慢。与 2-D CNN 相比，MS 1-D CNN 训练速度得到了较明显提升，并且由于参数量少，更容易避免过拟合问题。但是与另外两种算法相比，MS 1-D 的一次迭代时间没有随着参数量线性降低，主要是因为 MS 1-D CNN 是一种多尺度并行处理算法模型，其空间复杂度<sup>[17]</sup>稍高导致耗时有所增加。

表 2 三种算法模型识别结果  
Table 2 Recognition results of three algorithm models

算法模型	目标类别	识别类别/%			识别率/%	标准差/%
		破坏	敲击	干扰		
2-D CNN <sup>[8]</sup>	破坏	97.04	0.81	2.15	96.78	0.8
	敲击	0.99	97.42	1.59		
	干扰	2.05	1.84	96.11		
1-D CNN <sup>[9]</sup>	破坏	92.99	2.60	4.41	94.54	2.0
	敲击	3.37	92.29	4.34		
	干扰	2.43	1.74	95.83		
MS 1-D CNN	破坏	97.52	0.41	2.07	96.59	0.7
	敲击	0.96	95.91	3.13		
	干扰	2.33	0.64	97.03		

表3 三种算法模型的参数量及迭代时间

Table 3 Parameters and iteration time in three algorithm models

算法模型	2-D CNN <sup>[8]</sup>	1-D CNN <sup>[9]</sup>	MS 1-D CNN
第一层参数量	448	64	1040
第二层参数量	4640	1568	4704
第三层参数量	18496	6208	18624
第四层参数量	73856	24704	74112
全连接层参数量	6423296	4096768	1868544
总参数量	$6.52 \times 10^6$	$4.13 \times 10^6$	$1.97 \times 10^6$
总参数量比值	3.31	2.10	1
一次迭代时间/s	4.86	3.08	2.41

## 5 结论

本文提出了一种基于 MS 1-D CNN 的光纤振动事件识别方法, 将特征提取和识别融合为一个端到端的识别框架, 无需人工设计特征提取方法, 并利用多尺度卷积优化了卷积神经网络在振动信号特征表征中对时间和频率分辨率的均衡, 获取信号不同尺度中更丰富的特征信息, 以提升识别性能。真实试验数据结果表明, MS 1-D CNN 识别正确率达到了 96.59%, 与基于时频图的 2-D CNN 相近; 由于控制待参数量降低复杂度, 处理速度高于 2-D CNN 和 1-D CNN, 更有利于在光纤振动事件实时监测中使用。

## 参考文献

- [1] Jiang L H, Gai J Y, Wang W B, et al. Ensemble empirical mode decomposition based event classification method for the fiber-optic intrusion monitoring system[J]. *Acta Optica Sinica*, 2015, **35**(10): 1006002.  
蒋立辉, 盖井艳, 王维波, 等. 基于总体平均经验模态分解的光纤周界预警系统模式识别方法[J]. *光学学报*, 2015, **35**(10): 1006002.
- [2] Zhu C H, Zhao Y, Wang J P, et al. Ensemble recognition of fiber intrusion behavior based on blending features[J]. *Opto-Electronic Engineering*, 2016, **43**(12): 6–12.  
朱程辉, 赵益, 王建平, 等. 光纤入侵行为融合特征的集成识别[J]. *光电工程*, 2016, **43**(12): 6–12.
- [3] Kuang Y, Wu H T, Zhang J D, et al. Advances of key technologies on distributed fiber system for multi-parameter sensing[J]. *Opto-Electronic Engineering*, 2018, **45**(9): 170678.  
况洋, 吴昊庭, 张敬栋, 等. 分布式多参数光纤传感技术研究进展[J]. *光电工程*, 2018, **45**(9): 170678.
- [4] Zhu H, Pan C, Sun X H. Vibration pattern recognition and classification in OTDR based distributed optical-fiber vibration sensing system[J]. *Proceedings of SPIE*, 2014, **9062**: 906205.
- [5] Zhang Y, Lou S Q, Liang S, et al. Study of pattern recognition based on multi-characteristic parameters for  $\Phi$ -OTDR distributed optical fiber sensing system[J]. *Chinese Journal of Lasers*, 2015, **42**(11): 1105005.  
张颜, 姜淑琴, 梁生, 等. 基于多特征参量的  $\Phi$ -OTDR 分布式光纤扰动传感系统模式识别研究[J]. *中国激光*, 2015, **42**(11): 1105005.
- [6] Li X Y, Wu H J, Peng Z P, et al. A novel time sequence singular spectrum analysis method for  $\Phi$ -OTDR disturbance detection system[J]. *Acta Photonica Sinica*, 2014, **43**(4): 0428001.  
李小玉, 吴慧娟, 彭正谱, 等. 基于时间序列奇异谱特征的  $\Phi$ -OTDR 扰动检测方法[J]. *光子学报*, 2014, **43**(4): 0428001.
- [7] Xu C J, Guan J J, Bao M, et al. Pattern recognition based on enhanced multifeature parameters for vibration events in  $\Phi$ -OTDR distributed optical fiber sensing system[J]. *Microwave and Optical Technology Letters*, 2017, **59**(12): 3134–3141.
- [8] 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  $\Phi$ -OTDR[J]. *Optical Engineering*, 2018, **57**(1): 016103.
- [9] Ince T, Kiranyaz S, Eren L, et al. Real-time motor fault detection by 1-D convolutional neural networks[J]. *IEEE Transactions on Industrial Electronics*, 2016, **63**(11): 7067–7075.
- [10] Kiranyaz S, Ince T, Gabbouj M. Real-time patient-specific ECG classification by 1-D convolutional neural networks[J]. *IEEE Transactions on Biomedical Engineering*, 2016, **63**(3): 664–675.
- [11] Hu G, Wang K J, Peng Y, et al. Deep learning methods for underwater target feature extraction and recognition[J]. *Computational Intelligence and Neuroscience*, 2018, **2018**: 1214301.
- [12] Pan Z Q, Liang K Z, Ye Q, et al. Phase-sensitive OTDR system based on digital coherent detection[J]. *Proceedings of SPIE*, 2011, **8311**: 83110S.
- [13] Simonyan K, Zisserman A. Very deep convolutional networks for large-scale image recognition[OL]. arXiv:1409.1556 [cs.CV].
- [14] Ioffe S, Szegedy C. Batch normalization: accelerating deep network training by reducing internal covariate shift[C]//*Proceedings of the 32nd International Conference on International Conference on Machine Learning*, Lille, France, 2015: 448–456.
- [15] Hinton G E, Srivastava N, Krizhevsky A, et al. Improving neural networks by preventing co-adaptation of feature detectors[OL]. arXiv:1207.0580 [cs.NE].
- [16] Sutskever I, Martens J, Dahl G, et al. On the importance of initialization and momentum in deep learning[C]//*Proceedings of the 30th International Conference on International Conference on Machine Learning*, Atlanta, GA, USA, 2013: III-1139–III-1147.
- [17] He K M, Sun J. Convolutional neural networks at constrained time cost[C]//*Proceedings of 2015 IEEE conference on computer vision and pattern recognition*, Boston, MA, USA, 2015: 5353–5360.

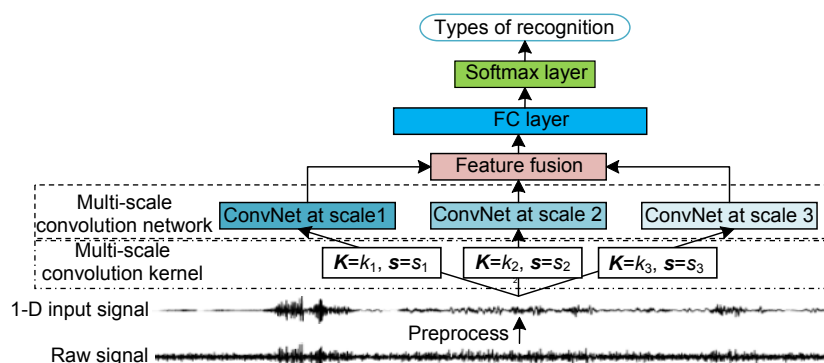
# Vibration events recognition of optical fiber based on multi-scale 1-D CNN

Wu Jun<sup>1,2</sup>, Guan Luyang<sup>2\*</sup>, Bao Ming<sup>2</sup>, Xu Yaohua<sup>1</sup>, Ye Wei<sup>3</sup>

<sup>1</sup>Key Laboratory of Intelligent Computing and Signal Processing, Ministry of Education, Anhui University, Hefei, Anhui 230039, China;

<sup>2</sup>Institute of Acoustics, Chinese Academy of Sciences, Beijing 100190, China;

<sup>3</sup>College of Control Science and Engineering, Zhejiang University, Hangzhou, Zhejiang 310058, China



The structure of MS 1-D CNN

**Overview:** As a new type of sensing technology, the phase-sensitive optical time domain reflection ( $\Phi$ -OTDR) distributed optical fiber sensing technology has the advantages of good environmental tolerance, low energy consumption, high sensitivity, long monitoring distance compared with traditional sensing technology, and has been the emphasis and hotspot of the researches. Among the manifold application fields of  $\Phi$ -OTDR distributed optical vibration sensing system, identification of vibration events is one of the most popular and advantaged applications. Therefore, efficient and accurate identification of different vibration events is the focus of this paper. The recognition speed of traditional methods is fast, but their recognition rate and robustness are not ideal and strongly dependent on the artificial feature design. Although the method based on two-dimensional convolutional neural network (2-D CNN) has obtained a high recognition rate, the slow recognition speed and feature extraction process hamper its use in real-time systems. In view of the fact that one-dimensional convolutional neural network (1-D CNN) has been used in other real-time identification fields and achieved good results, this paper proposes a multi-scale one-dimensional convolutional neural network (MS 1-D CNN) method which takes the vibration signals as the input of this network and needs not to manually extract features. Feature extraction of the intrusion vibration signals in the MS 1-D CNN takes into account the rich feature information of the signals in time and frequency scales, thus achieves efficient and accurate identification. In order to control the spatial complexity and parameter quantity, three scales and four layers are used in the MS 1-D CNN method. The raw vibration signals are pre-processed firstly to remove noise as far as possible, including pre-emphasis filtering, normalization and spectral subtraction. The pre-processed waveform signals are directly inputted into the MS 1-D CNN, and the recognition results are achieved by using fully-connected layer (FC layer) and Softmax layer. In comparison with the methods based on 2-D CNN and 1-D CNN, the proposed method balances the time and frequency scales well during feature extraction and reduces the number of pending parameters. A vibration recognition experiment was designed to classify the three different vibration events, including damaging, knocking and interference. The recognition results show that MS 1-D CNN achieves similar recognition performance at twice processing speed compared to 2-D CNN. Hence, it is beneficial to improve the real-timing of vibration monitoring while maintaining the recognition performance.

**Citation:** Wu J, Guan L Y, Bao M, *et al.* Vibration events recognition of optical fiber based on multi-scale 1-D CNN[J]. *Opto-Electronic Engineering*, 2019, **46**(5): 180493

Supported by the Strategic Priority Research Program of the Chinese Academy of Sciences (XDC02040600)

\* E-mail: guanluyang@mail.ioa.ac.cn