

## 基于 MATCN 的光纤周界入侵信号识别方法

尚秋峰<sup>1,2,3</sup>, 黄达<sup>1\*</sup><sup>1</sup>华北电力大学电子与通信工程系, 河北 保定 071003;<sup>2</sup>华北电力大学河北省电力物联网技术重点实验室, 河北 保定 071003;<sup>3</sup>华北电力大学保定市光纤传感与光通信技术重点实验室, 河北 保定 071003

**摘要** 针对光纤周界安防模式识别中机器学习算法依赖专家经验、现有深度学习算法学习关键特征能力不足的问题,提出了一种多注意力时间卷积网络(MATCN)识别模型。MATCN以时序信号为输入,通过利用通道和时序注意力优化网络学习机制,挖掘信号关键信息;在卷积过程中使用带泄露修正线性单元(Leaky ReLU)解决神经元坏死问题,提高模型的鲁棒性。搭建了基于相位敏感光时域反射系统( $\Phi$ -OTDR)的周界安防系统,模拟了攀爬、敲击、踩踏及无入侵事件。实验结果表明,MATCN的识别率达到了98.50%,识别时间为0.53 s,性能优于长短时记忆网络(LSTM)与融合卷积层的长短时记忆网络(CNN-LSTM)。所提方法能够有选择性地学习不同通道和时间片段中的关键信息,实现对周界入侵信号的准确、高效识别。

**关键词** 光纤传感; 模式识别; 时间卷积网络; 注意力机制; 周界安防

**中图分类号** TP212 **文献标志码** A

**DOI:** 10.3788/AOS230873

## 1 引言

相位敏感光时域反射计( $\Phi$ -OTDR)具有抗电磁干扰、耐腐蚀、质量轻等优点,能够以低成本进行大范围监测,同时具有单端无源性<sup>[1-3]</sup>。 $\Phi$ -OTDR能够实现振动事件的定位,同时结合信号识别方法可以实现对事件类型的判别,在周界安防领域具有重要的应用价值<sup>[4]</sup>。

由于周界入侵信号种类繁多,除了要能够识别攀爬、敲击、踩踏等入侵事件,还要对非危害性环境如无入侵事件进行准确判断,并根据事件类型决定是否需人工干预。当前周界入侵信号识别手段以机器学习与深度学习为主<sup>[5-7]</sup>。机器学习需要根据经验选取目标特征,然后将特征输入到分类器中进行识别,识别效果受限于所选特征与分类器的匹配程度<sup>[8-9]</sup>。此外,在面对大批量样本多分类问题时,机器学习存在泛化能力弱、识别能力有限等不足<sup>[10]</sup>。

以卷积神经网络(CNN)为代表的深度学习集特征提取和识别于一体,简化了模式识别的流程,成为当前研究热点。 $\Phi$ -OTDR采集的振动信号属于时序信号,其特征随着时间推移而改变。CNN具有强大的特征提取能力,但缺乏对时序信号准确表达和分析的能力<sup>[11]</sup>。因此在使用CNN识别时序信号时需要

进行预处理,如通过快速傅里叶变换获取信号的频域分布,或者对信号的时频图进行分析<sup>[12-13]</sup>,这在模式识别的基础上额外增加了计算量。因此陆续有学者采用循环神经网络(RNN)方法,如长短时记忆网络(LSTM),以获得信号的时序信息,结合CNN和RNN可以充分发挥两者的优势<sup>[14-15]</sup>。这种复合型网络较单类型网络获得了更好的识别效果,但也增加了网络的参数量,且由于RNN缺少并行性,降低了模型的效率<sup>[16]</sup>。

时间卷积网络(TCN)是一种CNN变体,具有因果膨胀卷积结构,能够同时提取振动信号的时频域特征,其残差模块使网络可以跨层传递信息,加快训练过程<sup>[17-18]</sup>。由于 $\Phi$ -OTDR实际采集的信号复杂多变,信号中频率成分复杂,对网络的性能提出了更高的要求。现有研究的不足主要有3点:1)TCN的残差模块以卷积结构为主,需要设置多个卷积核生成多个特征通道,但并非所有通道都富含振动信息,对通道的无差别对待会干扰网络的学习,增加计算资源;2)振动信号具有冲击性和突变性,往往只在部分片段中含有关键信息,其他的无关数据会影响最终的识别结果;3)传统卷积结构的激活单元一般采用修正线性单元(ReLU),而ReLU在训练时容易产生神经元坏死现象,降低网络性能。

收稿日期: 2023-04-25; 修回日期: 2023-05-22; 录用日期: 2023-05-29; 网络首发日期: 2023-06-28

基金项目: 国家自然科学基金(61775057)、河北省自然科学基金(E2019502179)

通信作者: \*huangda0217@163.com

针对上述问题,本文引入多注意力(MA)机制改良 TCN 的性能,提出一种多注意力时间卷积网络(MATCN)识别模型,通过利用通道和时序注意力优化 TCN 的学习机制,并使用带泄露修正线性单元(Leaky ReLU)代替 ReLU。搭建了  $\Phi$ -OTDR 周界安防实验系统,采集了攀爬、敲击、踩踏和无入侵 4 种信号进行实验验证。MATCN 能够从多角度学习信号关键信息,各项指标均优于时序信号识别任务中的典型网络 LSTM 和 CNN-LSTM,且相较于传统的机器学习算法,具有更高的分类精度,为其在周界安防领域的应用提供了有益参考。

## 2 基本原理

MATCN 包含 TCN 的因果膨胀卷积结构与残差模块,具有稳定的梯度、高效的计算效率、长跨度时间依赖等优势,且不会泄露未来时刻的数据信息,同时引入多注意力机制与 Leaky ReLU,提高了网络性能。

### 2.1 因果膨胀卷积

时序信号强调时间顺序,这就需要挖掘数据间的因果关系。传统 CNN 卷积计算的结果与过去的的数据有关,也与未来的数据有关,这就导致了从未来到过去信息的泄露,违反了自回归原则,使得其对时序信号识别能力有限。TCN 由多个因果卷积层堆叠而成,设输入为时序序列  $x = \{x_1, x_2, \dots, x_m\}$ ,  $m$  为输入序列长度,则因果卷积的条件概率计算公式为

$$p(x) = \prod_{i=1}^m p(x_i | x_1, x_2, \dots, x_{i-1}), \quad (1)$$

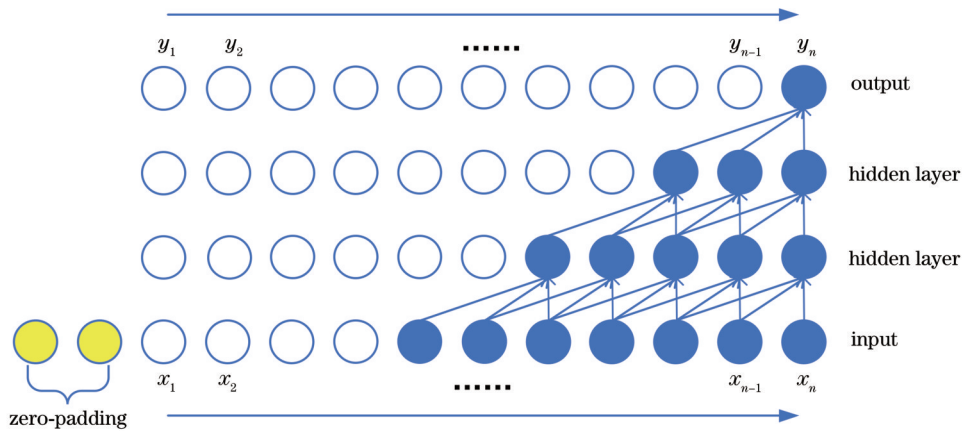


图 1 因果卷积示意图

Fig. 1 Schematic of causal convolution

### 2.2 改进的残差模块

对于时序信号,采用因果卷积提取特征时,为了提高卷积计算的感知范围,一方面是引入膨胀卷积模块,在卷积计算时增加膨胀因子,可以获得更长期的时序信息;另一个方面就是增加网络深度,但是随着网络深度的增加会出现梯度消失问题,使得网络性能退化。TCN 采用残差模块解决梯度消失问题,结构如图 3(a)

由式(1)可知, $t$ 时刻卷积计算结果只与过去的的数据有关,和未来的数据无关,解决了信息泄露问题。当每一时刻的数据经因果卷积后,输出又作为之前时刻的信息继续影响下一时刻。因此 TCN 遵守了时序信号的前后时序性,能充分提取振动信号的时序特征。在因果卷积结构中,每个输出在输入端的感知范围  $R_1$  与网络层数  $n$  和卷积核大小  $k$  有如下关系:

$$R_1 = (k - 1)n + 1. \quad (2)$$

图 1 为一个含有 3 层因果卷积的结构,卷积核大小为 3,由式(2)可知,每个输出在输入端有 7 个感知范围。当时间序列长度延长时,需要增加网络的深度或者更大尺寸卷积核才能满足对感知范围的要求,但会增加模型的复杂性,造成算力的增加。为了在网络层数一定的情况下扩大输出对输入的感知范围,TCN 模型引入膨胀卷积结构,通过调节膨胀系数  $d$  稀疏化卷积核,灵活改变卷积操作的感知范围。 $d$  通常是形如  $\{2^i | i = 0, 1, \dots, n - 1\}$  的指数序列。在因果膨胀卷积结构中,每个输出在输入端的感知范围  $R_2$  与网络层数  $n$  和卷积核大小  $k$  有如下关系:

$$R_2 = (k - 1)(2^n - 1) + 1. \quad (3)$$

如图 2 所示,在不改变网络结构的条件下,在因果膨胀卷积结构中输出在输入端的感知范围增加到了 15。TCN 通过引入因果膨胀卷积结构,使得输出端的感知范围个数随着网络深度增加呈指数型增加,在不大幅增加网络参数量情况下获得更长期的时序信息。

所示,包含两层因果膨胀卷积层,激活单元采用 ReLU,最后在每个因果膨胀卷积后进行 dropout 操作对信息进行正则化,在解决过拟合问题的同时提高模型训练速度<sup>[17]</sup>。区别于把输入直接添加到残差模块输出端的 ResNet 模型,TCN 使用额外的  $1 \times 1$  卷积核保证输出与输入有相同通道数。MATCN 中所采用的残差模块如图 3(b)所示,相比图 3(a)的 TCN,有如下调整与改进。




图 2 因果膨胀卷积示意图  
Fig. 2 Schematic of dilated causal convolution

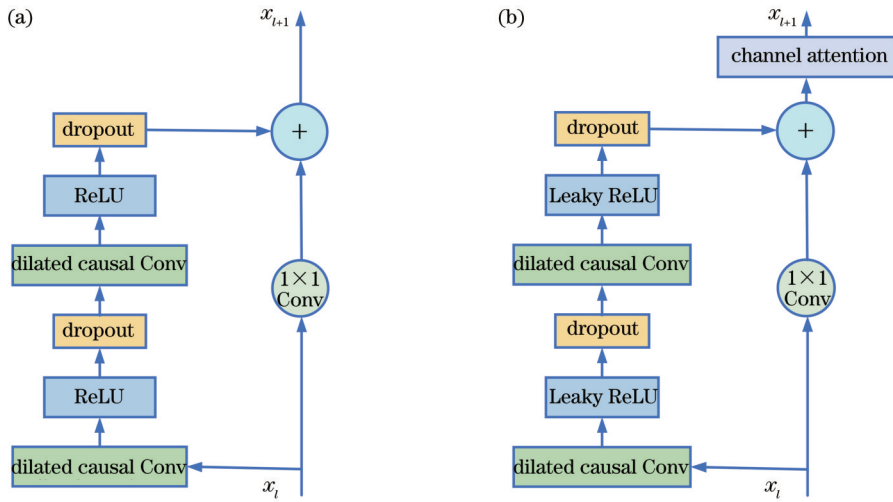


图 3 不同网络中的残差模块。(a) TCN; (b) MATCN  
Fig. 3 Residual module in different networks. (a) TCN; (b) MATCN

1) Leaky ReLU

ReLU 将所有负轴上的值都设为 0, 可以加快模型的收敛。但是当输入激活单元的值负值时, 反向传播时经过该处的梯度恒为 0, 对应的权重和偏置无法更新, 出现“死神经”问题。Leaky ReLU 通过给负轴的值赋予较小的非零权重  $\alpha$ , 产生一个较小的梯度, 能够

避免神经元坏死现象, 并提高模型的鲁棒性, 降低过拟合风险。ReLU 和 Leaky ReLU 函数形式如图 4 所示。

2) 融合通道注意力的残差模块

TCN 的残差模块以卷积结构为主, 为了提高特征表达能力, 需要设置多个卷积核提取不同特征以生成




图 4 不同激活单元对比。(a) ReLU; (b) Leaky ReLU  
Fig. 4 Comparison of different activation units. (a) ReLU; (b) Leaky ReLU



多个特征通道。为解决多个特征通道间信息价值不等问题,本文采用通道注意力改进残差模块,以获取不同通道的关键程度。

设输入的一维时间序列  $X \in \mathbb{R}^{C \times 1 \times N}$ , 其中  $C$  为通道数,  $N$  为序列长度。首先通过平均池化和最大池化操作压缩输入的全局信息, 并将其送入到具有“降维-升维”模块的多层感知器(MLP)中; 经过 MLP 网络处理并逐元素求和, 得到权重向量  $v \in \mathbb{R}^{C \times 1 \times 1}$ , 其在时间维度上已经得到压缩,  $v$  的值代表了通道维度上不同特征通道的关键程度, 数值越大意味着该特征通道中学习信号的特征信息越多; 通过 Sigmoid 函数将权重向量值映射为不同的通道权重, 通道权重与原输入相乘, 得到通道注意力的输出。整个流程如图 5 所示。

### 2.3 MATCN 结构

#### 2.3.1 时序注意力

通过在残差模块中引入通道注意力和 Leaky ReLU, 解决了残差模块输出特征通道间信息差异性判别问题, 并提高了模型的鲁棒性。但是 MATCN 是由多个残差模块堆叠而成的, 共同组成特征提取模块,

其最终输出的特征通道内不同时间片段所包含的信息仍存在差异, 其他的无关数据会影响最终的识别结果。针对此问题, 本文参考文献[19]中的注意力方法, 提出一种时序注意力以获取时间序列上各点的权重分布。时序注意力没有平等地考虑每个时间序列点, 而是更多地聚焦于包含关键信息的位置。

考虑到池化操作会丢失信息, 因此在时序注意力中采用单个  $1 \times 1$  元卷积核代替文献[19]中的池化操作, 以完整地保留信号特征。设残差模块输出的特征通道为  $Y \in \mathbb{R}^{H \times 1 \times N}$ ,  $H$  为特征通道数。具有相同通道数的元卷积核沿时序方向进行卷积, 实现每个特征通道内部时序特征的非线性映射, 使其在通道维度上得到压缩, 生成权重向量  $t \in \mathbb{R}^{1 \times 1 \times N}$ ,  $t$  的值代表了时序方向上不同片段的重要程度, 数值越大意味着在此处特征越明显。同样经过 Sigmoid 函数将此权重向量映射为不同的时序权重, 时序权重与原输入相乘, 得到时序注意力的输出。时序注意力是对通道注意力的补充, 通过编码每个通道内部的时序特征以获取信息位置, 整个流程如图 6 所示。




图 5 通道注意力机制

Fig. 5 Channel attention mechanism




图 6 时序注意力机制

Fig. 6 Temporal attention mechanism

#### 2.3.2 MATCN 模型

基于以上分析, 设计了 MATCN 识别模型, 结构如图 7 所示。首先将信号输入到批归一化(BN)层进行处理, 以加快模型收敛速度; 然后将结果送入特征提取部分, 特征提取部分由多层残差模块堆叠而成, 每个残差模块的结构如图 3(b)所示; 残差模块采用因果膨

胀卷积结构, 因果卷积能充分提取振动信号前后时序特征, 膨胀卷积保证了网络在相同层数下具有更大的感知范围; 特征提取部分后加入时序注意力模块, 充分挖掘不同时间段内的关键信息, 降低无关信号的干扰, 以提高识别效果; 信号经时序注意力模块后, 在全连接层得到相应的信号类型, 实现端到端的识别。

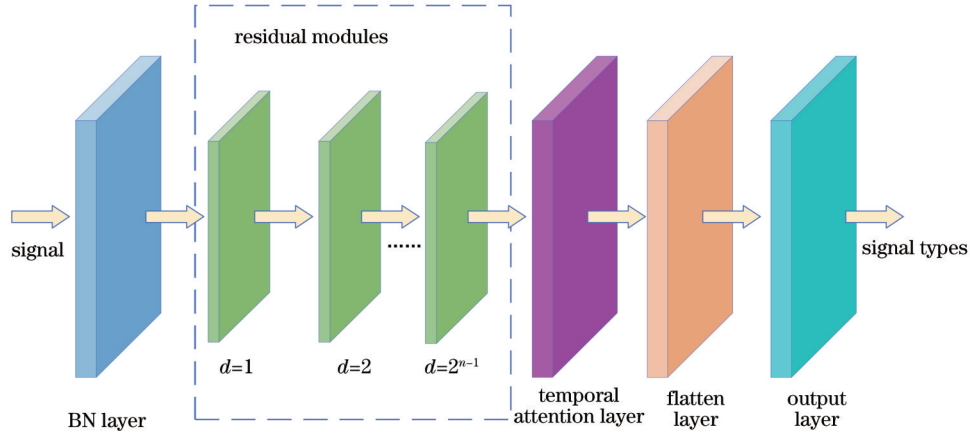


图 7 MATCN 模型

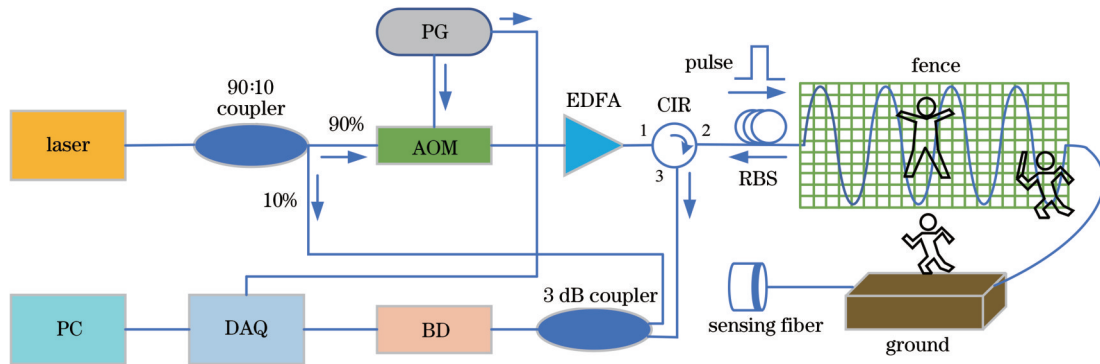
Fig. 7 MATCN model

### 3 实验与分析

#### 3.1 数据获取

周界信号的采集由 DAS 系统完成,系统光路如图 8 所示。激光器输出功率为 13 dBm、中心波长为 1550 nm、线宽为 1.5 kHz 的窄线宽光,光通过 90:10 耦合器后分为探测光和本地光;声光调制器(AOM)将探测光调制为脉宽为 100 ns 的脉冲光,并产生 50 MHz 的移频;脉冲发生器(PG)为 AOM 提供调制信号的同

时,还为数据采集卡(DAQ)提供同步触发信号;掺铒光纤放大器(EDFA)对脉冲光放大后,光进入传感光纤并返回为后向瑞利散射光(RBS),然后经环形器(CIR)进入 3 dB 耦合器,与本地光发生拍频后进入平衡探测器(BD)实现光电转换。输出的拍频电信号经 DAQ 得到模数转换,变为数字信号,采样率为 250 MSa/s。计算机(PC)用于信号处理。该系统入纤峰值功率为 23 dBm,有效传感距离为 20 km,空间分辨率为 10 m。



AOM: acousto-optic modulator; PG: pulse generator; EDFA: erbium-doped optical fiber amplifier; RBS: Rayleigh backscattering; CIR: circulator; BD: balanced detector; DAQ: data acquisition board; PC: personal computer

图 8 实验系统结构

Fig. 8 Experimental system structure

DAQ 采集的拍频信号  $S(z)$  可以表示为  $S(z) = E_R(z)E_O(z) \cos[2z\pi\Delta f/f_s + \varphi_s(z)]$ ,  $z = 1, 2, 3, \dots, Z$ , 式中:  $z$  为采样点序号;  $Z$  为 DAQ 单次采样点总数;  $E_R(z)$  和  $E_O(z)$  分别为 RBS 和本地光的振幅;  $\Delta f$  为 AOM 移频量;  $f_s$  为 DAQ 的采样率; 相位  $\varphi_s(z)$  为外界振动引起的相位变化量,反映了振动信号的时域波形<sup>[20]</sup>。通过后续的 IQ 解调法<sup>[3]</sup>可以实现振动信号波形还原。

将所提系统应用于周界安防场景中,在实验室搭

建了如图 8 所示的实验环境。实验传感光纤总长度为 5.5 km。设置了挂网式和铺地式两种环境,其中挂网式环境是将光纤敷设在 2 m 高的围栏上,铺地式环境是将光纤掩埋在泥土中,深度为 0.2 m,并夯实处理,采集了几种周界安防中的典型信号,包括攀爬、敲击、踩踏及无入侵信号。实验人员由体重不等的 3 人组成,分别为 62 kg、72 kg、80 kg,各事件作用长度均为 5 m。实验过程分两阶段进行:第一阶段,在挂网式环境中采集攀爬信号和敲击信号,为避免结果的特殊性,攀爬信号由不同体重的人员连续攀爬围栏模拟,敲击信号由不同的人员手持不同材质的棍棒(木质、铁质)

以不同的力度敲击围栏模拟,以围栏抖动幅度的大小判断力度,棍棒直径为 3 cm,长度为 0.5 m;第二阶段,在铺地式环境中采集踩踏信号,实验人数 1~3 人不等,由实验人员来回脚踩铺地光缆,无入侵信号则是在光缆没有外界干扰的情况下采集的信号,即背景噪声。为了保证模型的泛化能力,在每种事件采集后,使用随机数种子将不同事件情况下采集的结果乱序排列,每种事件均采集 2000 组数据,共计 8000 组样本。每个事件样本信号时长为 1 s,可包含事件所有的信号变化模

式。利用移动差分求和法与 IQ 解调法可以得到振动事件的位置和时域信号,对还原后的信号进行高通滤波,以消除解调算法引入的直流偏置以及系统干涉带来的低频扰动信息。图 9 为各事件典型信号和定位结果。攀爬、敲击、踩踏事件均有振动信号定位峰,峰值幅度分别在 113 m、117 m、153 m 处,代表了事件发生的位置,而无入侵事件没有信号定位峰。将振动信号直接输入到网络中,由网络自动学习特征并进行识别,以减少模式识别外的计算量。

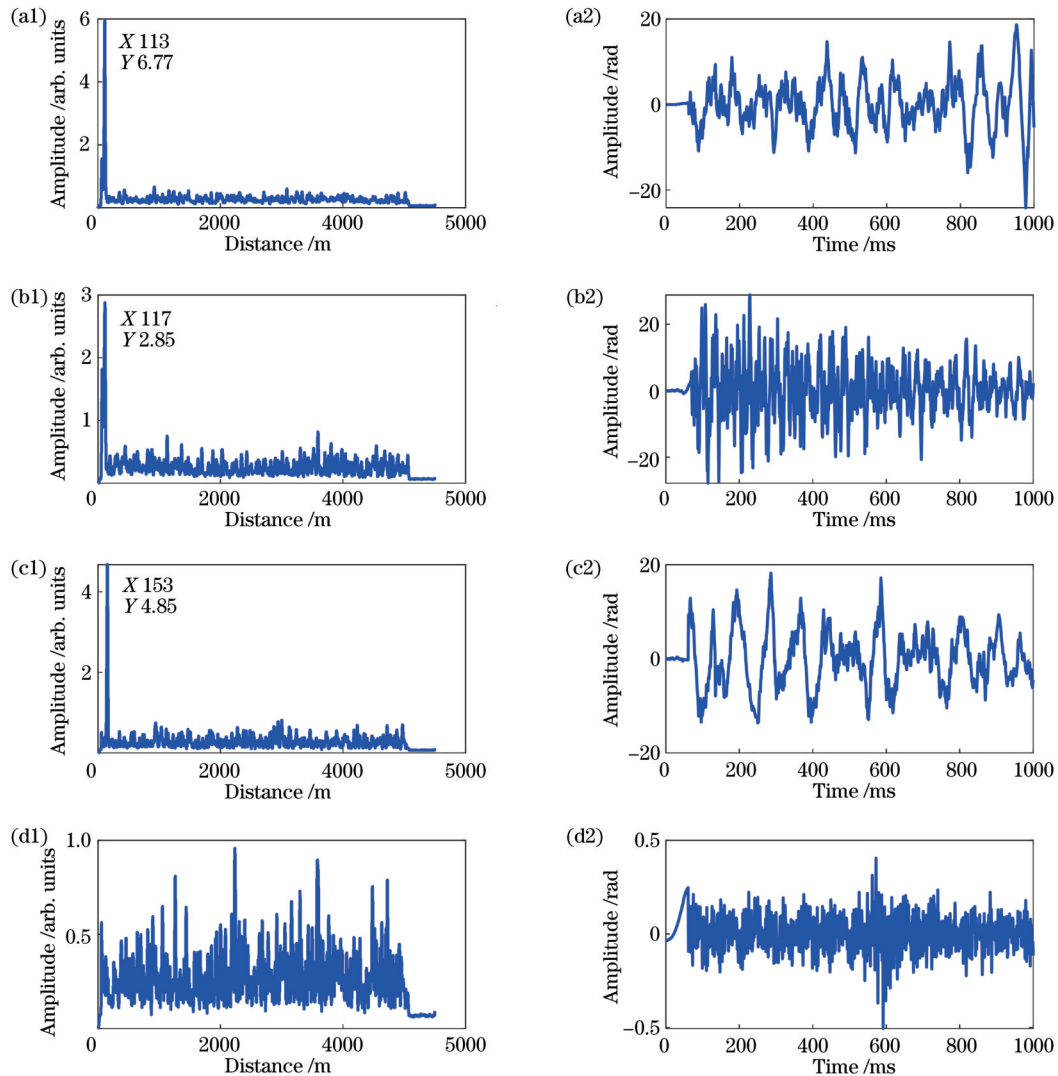


图 9 振动事件定位与典型波形。(a)攀爬;(b)敲击;(c)踩踏;(d)无入侵

Fig. 9 Vibration event location and typical waveforms. (a) Climbing; (b) knocking; (c) trampling; (d) no invasion

## 3.2 网络评估

### 3.2.1 模型参数设置

采用的网络结构如图 8 所示。网络残差模块中卷积核大小设为 3,卷积核数量为 16,Leaky ReLU 的  $\alpha$  值设为 0.01。同时为了降低过拟合风险,在网络中加入 dropout 层,丢弃率为 0.3。输入为实验所采集的 8000 组样本,并将每类事件按照 8:2 的比例分为训练样本和验证样本。训练前采用独热编码(one-hot encoding)

设置类别标签,并使用随机数种子对混合后的训练样本与验证样本进行乱序处理。训练过程中 batch\_size 为 20,最大训练 epoch 设为 40,优化器为 Adam,输出层激活函数为 Softmax,损失函数为 Categorical\_crossentropy。软件环境为 64 位的 Win10 操作系统,网络模型使用以 TensorFlow 为后端的 Keras2.9.0 学习框架,开发语言为 Python3.9。

MATCN 的深度由残差模块的堆叠层数所决定,



更深的网络会拥有更好的特征提取能力,但是过深的网络会增加网络复杂度,增加算法运行时间。参考文献[21],采用网络训练过程中验证样本损失函数值来评估网络的性能,设计了包含不同层次的网络进行对比实验。图 10 是 MATCN 不同层次的残差模块训练时验证样本损失函数值的变化情况。随着网络训练次数的增加,各损失函数曲线均趋于收敛,而在残差模块层数为 3 的情况下,损失函数收敛速度最快,因此在 MATCN 结构中选择 3 层残差模块较为合理。

为评估 MATCN 的特征提取能力,使用 t 分布随机近邻嵌入(t-SNE)对原始数据和经过特征提取模块后的数据进行可视化。如图 11(a)所示,原始数据经 t-SNE 可视化后,各类事件样本特征混合在一起,难以区分。图 11(b)为 MATCN 提取的特征的可视化结果,虽然存在少量特征区分不明显,但不同事件的界限




图 10 不同层次残差模块的损失函数值变化情况  
Fig. 10 Change of loss function values of residual modules at different levels

相较于原始信号已经十分清晰。MATCN 具有出色的特征提取能力,能够有效提取所需的特征,避免了人工选择特征的经验性。

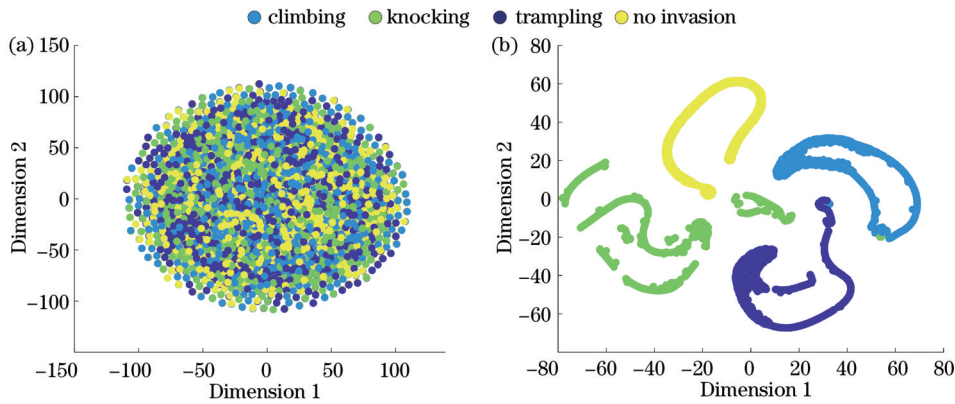


图 11 t-SNE 可视化结果。(a)原始信号特征分布;(b)特征提取结果  
Fig. 11 t-SNE visualization result. (a) Characteristic distribution of the original signal; (b) feature extraction result

### 3.2.2 消融实验

为了客观验证多注意力机制和 Leaky ReLU 的有效性,进行 4 组消融实验,设计了 Net1(TCN)、Net2(TCN+Leaky ReLU)、Net3(TCN+MA)、Net4(MATCN) 4 种结构进行对比研究,其中 Net1 和 Net3 中激活单元均采用 ReLU。设置网络迭代次数为 40,网络残差模块堆叠层数均为 3,其余训练参数均一致。采用训练阶段网络在验证样本上的表现(识别率和损失函数)评估性能,结果如图 12 和表 1 所示。

表 1 为各网络结构独立运行 10 次后取平均值的实验结果。结合图 12 和表 1 可知:在模型对验证样本的识别率和损失函数训练至稳定后,Net1 处理的样本出现了轻微的过拟合现象;相较于 Net1,Net2 抑制过拟合的能力更强,训练曲线也较为平缓,模型的鲁棒性更好,但是由于网络的学习能力基本一致,因此识别率并未有明显的提升;Net3 在 Net1 的基础上添加了多注意力机制,能够更加全面地提取信号中的信息,从而获得更高的识别率;Net4 综合了 Net2 与 Net3 的优势,训练曲线收敛速度最快,在验证样本上具有最高的识别率

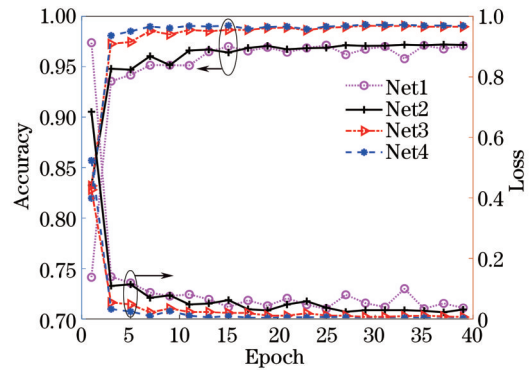


图 12 各网络结构的训练曲线  
Fig. 12 Training curve of each network structure

表 1 各网络结构对验证样本的识别结果  
Table 1 Identification results of each network structure for the validation sample

Parameter	Net1	Net2	Net3	Net4
Accuracy / %	96.56	96.87	98.82	99.03
Loss	0.051	0.033	0.011	0.005

和最小的损失函数值。

### 3.2.3 网络训练对比

为了准确评估 MATCN 性能,采用相同的训练样本与验证样本,与时序信号识别任务中典型网络进行对比研究,包括 LSTM、CNN-LSTM、TCN。LSTM 主要结构为两层 LSTM 堆叠,门大小设为 60;CNN-LSTM 结构参考文献[13],由两层 LSTM 与两层一维卷积-最大池化堆叠而成,LSTM 门大小均为 60,卷积核个数为 16,大小分别为 16 和 8,卷积层激活单元为

ReLU;TCN 中残差模块结构参考文献[17],堆叠层数为 3。为准确评估网络的性能,各网络其余训练参数均与 3.2.1 节中的一致。在网络的训练过程中加入早停机制,防止过拟合。以验证样本损失函数作为判断标准:当验证样本损失函数值最小,且再经过 5 轮的训练仍不再降低的情况下停止训练,否则模型会完成 40 轮训练后再终止。识别率、损失函数和效率都是综合性评价指标,图 13 为不同网络在训练过程中对验证样本的识别率与损失函数的变化趋势。

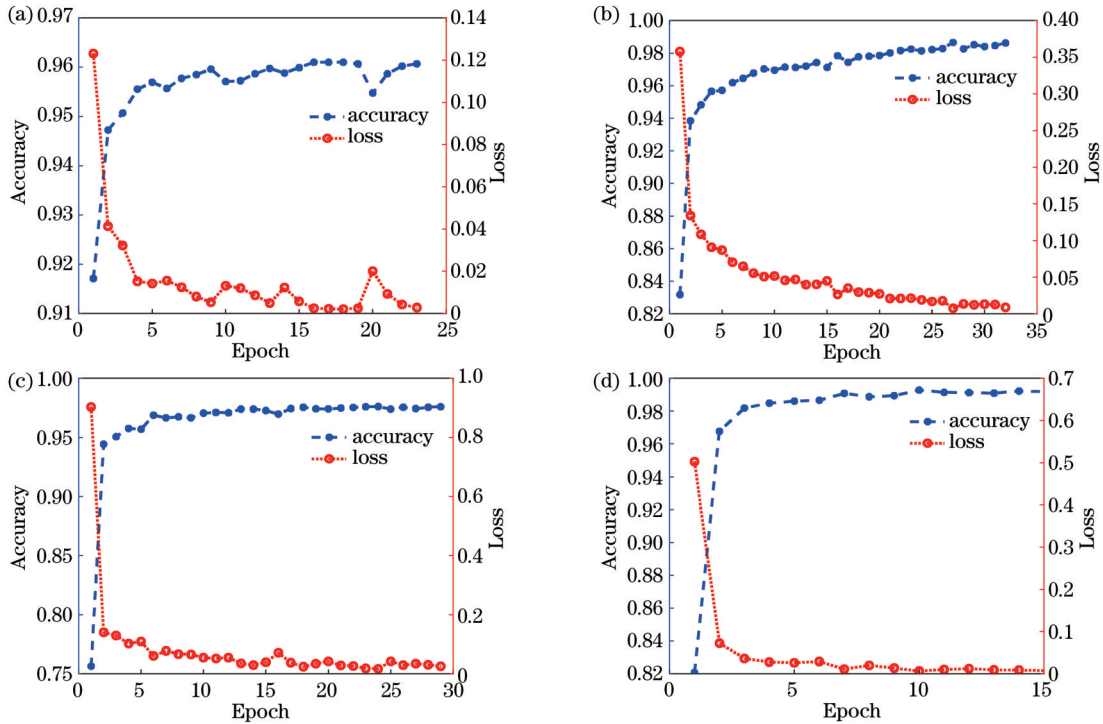


图 13 不同网络对验证样本的识别率和损失值曲线。(a) LSTM;(b) CNN-LSTM;(c) TCN;(d) MATCN

Fig. 13 Recognition rate and loss value curves of different networks for validation samples. (a) LSTM; (b) CNN-LSTM; (c) TCN; (d) MATCN

由于网络输入为 8000 组样本,其中 80% 作为训练样本,20% 作为验证样本,因此训练样本总数为 6400 组。训练过程中小批量样本数为 20,因此每次 epoch

需要迭代 320 次,迭代速度能反映模型的复杂程度。4 种网络的训练效率如表 2 所示。

表 2 4 种网络的训练效率对比

Table 2 Comparison of training efficiency of four networks

Network	Iteration time / (ms·step <sup>-1</sup> )	One training epoch / s	Number of epochs	Training time / s
LSTM	68	21.76	23	501
CNN-LSTM	74	23.68	32	758
TCN	14	4.48	29	130
MATCN	19	6.08	15	91

由图 13 可知:为了防止过拟合现象,4 种网络结构均使用了早停机制提前终止训练;其中 CNN-LSTM 相比于 LSTM 对验证样本具有更高的准确率;TCN 与 MATCN 训练曲线相比 LSTM 和 CNN-LSTM 更加稳定。由表 2 可知:CNN-LSTM 比 LSTM 迭代速度更慢,且网络达到收敛需要的训练次数更多,这是因为

CNN-LSTM 在 LSTM 的基础上增加了卷积层,使得网络参数量增加,需要大量训练使网络收敛;相较于 LSTM 和 CNN-LSTM,TCN 采用了残差模块,并具有 CNN 的并行计算优势,具有更高的效率;MATCN 迭代速度虽略低于 TCN,但是网络需要更少的训练次数达到收敛,总体效率最高。



### 3.2.4 网络测试

测试模型对非训练样本的识别率与效率。在采集非训练样本时,选择与 3.1 节中不同的实验人员,在相同场景下连续对光缆施加激励,每种事件均重复 5 次

采集流程,采集到 4 种事件各 500 组,共计 2000 组样本。每类事件均采用 one-hot encoding 设置类别标签,使用训练后的表 1 中的网络对非训练样本进行识别,识别效果如表 3 所示。

表 3 4 种网络对非训练样本的识别率和效率

Table 3 Recognition rate and efficiency of four networks for non-training samples

Network	Accuracy of climbing / %	Accuracy of knocking / %	Accuracy of trampling / %	Accuracy of no invasion / %	Average accuracy / %	Testing time / s
LSTM	93.40	88.40	81.60	94.40	89.45	2.03
CNN-LSTM	98.00	92.20	87.20	99.20	94.10	2.10
TCN	96.60	93.40	86.20	97.20	93.04	0.39
MATCN	99.60	98.80	96.80	98.80	98.50	0.53

不同网络的识别效果与效率各不相同。结合表 2 表 3 可知:LSTM 对 4 种事件的识别率最低,平均识别率为 89.45%,且耗时较长;CNN-LSTM 在 LSTM 的基础上添加了卷积层,这种复合网络相较于单一 LSTM 具有更高的识别率,但是网络训练困难,耗时最长,且对敲击事件和踩踏事件的识别率低于 95%;TCN 具有最高的识别效率,对 4 种事件的识别时间仅为 0.39 s,但平均识别率略低于 CNN-LSTM 和 MATCN,对敲击事件和踩踏事件的识别率仍低于 95%;MATCN 对 4 类事件的识别率均高于 95%,平均识别率达 98.50%,相较于 TCN 提升了 5.46 个百分点,耗时仅为 0.53 s,在保持高效率的同时,具有最高的识别率,能够满足实际应用需求。

### 3.3 与机器学习对比

为对比 MATCN 与机器学习算法识别效果的差异,提取信号多种特征并结合常用的分类器进行识别。由于 MATCN 能够通过因果膨胀结构提取信号时频域特征,使用变分模态分解(VMD)<sup>[22]</sup>对信号进行时频分析,将信号分解为本征模态分量(IMF),并提取各分量的特征构建特征向量组。为了定量描述信号特征,参考文献[8]与文献[9]中的方法,设计了 Feature1、Feature2 两组特征,其中 Feature1 包括过零率、峭度、能量熵、近似熵,Feature2 包括过零率、峭度、偏度、排列熵,并结合 K 近邻(KNN)<sup>[5]</sup>、随机森林(RF)<sup>[6]</sup>和支持向量机(SVM)<sup>[9]</sup>这三种常用的分类器进行识别。由于验证样本不参与网络训练,为保证实验结果的科学性,机器学习中所用的训练样本和非训练样本与 MATCN 中一致。设置 VMD 分解层数为 6;SVM 核函数选择径向基函数(RBF),使用网格搜索法选取最佳惩罚因子  $c$  和核函数参数  $g$ ;RF 中决策树构造法使用 C4.5 算法;其余模型参数均使用函数默认值。图 14 为不同特征-分类器组合与 MATCN 对非训练样本的识别效果对比。

由图 14 可知,不同特征-分类器组合对非训练样本的识别效果具有较大差异,结果受限于特征的选择与分类器的设计。就不同的分类器而言,Feature1 对 4

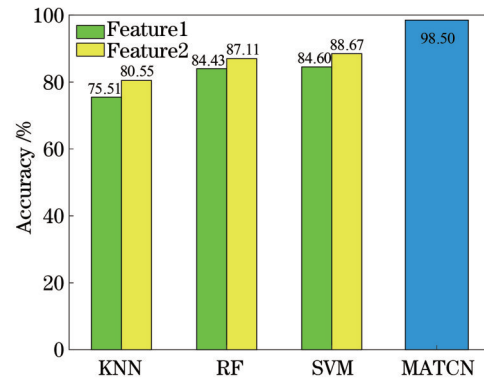


图 14 机器学习算法与 MATCN 识别结果对比

Fig. 14 Recognition result comparison of machine learning algorithms and MATCN

种事件的表征能力明显弱于 Feature2;而对于相同的特征组,SVM 的识别率比其他两种分类器更高,其中 Feature2-SVM 的识别率最高,达 88.67%,但仍与 MATCN 有较大差距,且低于 LSTM,表明机器学习算法在泛化性和分类性能上不足。此外,机器学习算法需要人工提取特征,导致算法整体效率较低,实时性较差。

## 4 结 论

针对光纤周界振动信号识别问题,提出一种基于 MATCN 的识别模型。MATCN 可以充分考量振动信号的时序性,使用通道注意力和 Leaky ReLU 改进残差模块,使得网络可以有选择性地学习不同通道的信息,并解决卷积过程中神经元坏死问题;特征提取部分后加入时序注意力模块,充分挖掘不同时间段内的关键信息,并降低无关信号的干扰,以提高识别效果。实验结果表明:MATCN 相较于 TCN 具有更高的识别率,达到了 98.50%,且训练总耗时最短,各项指标均优于 LSTM 与 CNN-LSTM;由于模型本身的复杂度,其识别时间略长于 TCN,为 0.53 s,但仍具有不错的实时性。此外,MATCN 相较于机器学习算法具有更好的泛化性和分类性能,在周界安防领域具有更好的

应用价值。

### 参 考 文 献

- [1] Li H, Liu T, Fan C Z, et al. Fading suppression for distributed acoustic sensing assisted with dual-laser system and differential-vector-sum algorithm[J]. IEEE Sensors Journal, 2022, 22(10): 9417-9425.
- [2] Zhang Y X, Liu J X, Xiong F, et al. A space-division multiplexing method for fading noise suppression in the  $\Phi$ -OTDR system[J]. Sensors, 2021, 21(5): 1694.
- [3] 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.  
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.
- [4] 张若飞. 周界安防系统光纤振动信号识别方法的研究与应用[D]. 武汉: 华中科技大学, 2020.  
Zhang R F. Research and application of fiber optic vibration signal recognition method for perimeter security system[D]. Wuhan: Huazhong University of Science and Technology, 2020.
- [5] Jia H Z, Liang S, Lou S Q, et al. A  $k$ -nearest neighbor algorithm-based near category support vector machine method for event identification of  $\Phi$ -OTDR[J]. IEEE Sensors Journal, 2019, 19(10): 3683-3689.
- [6] Wang X, Liu Y, Liang S, et al. Event identification based on random forest classifier for  $\Phi$ -OTDR fiber-optic distributed disturbance sensor[J]. Infrared Physics & Technology, 2019, 97: 319-325.
- [7] Sun Z S, Liu K, Jiang J F, et al. Optical fiber distributed vibration sensing using grayscale image and multi-class deep learning framework for multi-event recognition[J]. IEEE Sensors Journal, 2021, 21(17): 19112-19120.
- [8] 熊兴隆, 张琬童, 李猛, 等. 基于局部均值分解和串行特征融合的光纤周界振动信号识别[J]. 光学学报, 2019, 39(2): 0206002.  
Xiong X L, Zhang W T, Li M, et al. Fiber-optic perimeter vibration signal recognition based on local mean decomposition and serial feature fusion[J]. Acta Optica Sinica, 2019, 39(2): 0206002.
- [9] 马愈昭, 王强强, 王瑞松, 等. 基于SVD和MPSO-SVM的光纤周界振动信号识别[J]. 系统工程与电子技术, 2020, 42(8): 1652-1661.  
Ma Y Z, Wang Q Q, Wang R S, et al. Optical fiber perimeter vibration signal recognition based on SVD and MPSO-SVM[J]. Systems Engineering and Electronics, 2020, 42(8): 1652-1661.
- [10] 王亮, 吴昊, 唐明, 等. 基于机器学习的布里渊信号分析方法的研究进展[J]. 激光与光电子学进展, 2021, 58(13): 1306010.  
Wang L, Wu H, Tang M, et al. Research status of Brillouin signal analysis method based on machine learning[J]. Laser & Optoelectronics Progress, 2021, 58(13): 1306010.
- [11] 张耀鲁, 于森, 常天英, 等. 基于波网络的相位敏感光时域反射系统模式识别方法研究[J]. 光子学报, 2021, 50(3): 0306003.  
Zhang Y L, Yu M, Chang T Y, et al. Phase-sensitive optical time-domain reflectometric system pattern recognition method based on Wavenet[J]. Acta Photonica Sinica, 2021, 50(3): 0306003.
- [12] 喻后聃, 米秋实, 赵栋, 等. 基于一维卷积神经网络的光纤周界入侵模式识别[J]. 光子学报, 2021, 50(9): 0906003.  
Yu H D, Mi Q S, Zhao D, et al. Optical fiber perimeter intrusion pattern recognition based on 1D-CNN[J]. Acta Photonica Sinica, 2021, 50(9): 0906003.
- [13] 王鸣, 沙洲, 封皓, 等. 基于LSTM-CNN的 $\varphi$ -OTDR模式识别[J]. 光学学报, 2023, 43(5): 0506001.  
Wang M, Sha Z, Feng H, et al.  $\varphi$ -OTDR pattern recognition based on LSTM-CNN[J]. Acta Optica Sinica, 2023, 43(5): 0506001.
- [14] Zabin M, Choi H J, Uddin J. Hybrid deep transfer learning architecture for industrial fault diagnosis using Hilbert transform and DCNN-LSTM[J]. The Journal of Supercomputing, 2023, 79(5): 5181-5200.
- [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] 刘东远, 张耀, 刘洋, 等. 基于LSTM循环神经网络的fNIRS脑功能成像滤波方法[J]. 中国激光, 2021, 48(19): 1918007.  
Liu D Y, Zhang Y, Liu Y, et al. LSTM-based recurrent neural network for noise suppression in fNIRS neuroimaging: network design and pilot validation[J]. Chinese Journal of Lasers, 2021, 48(19): 1918007.
- [17] Bai S J, Kolter J Z, Koltun V. An empirical evaluation of generic convolutional and recurrent networks for sequence modeling[R]. Pittsburgh: Carnegie Mellon University, 2018: 7-9.
- [18] 任彦洁, 唐晓刚, 张斌权, 等. 基于时间卷积网络的通信信号调制识别算法[J]. 无线电工程, 2023, 53(4): 807-814.  
Ren Y J, Tang X G, Zhang B Q, et al. Communication signal modulation recognition algorithm based on temporal convolutional network[J]. Radio Engineering, 2023, 53(4): 807-814.
- [19] 李翔, 何森, 罗海波. 一种面向遮挡行人检测的改进YOLOv3算法[J]. 光学学报, 2022, 42(14): 1415003.  
Li X, He M, Luo H B. Occluded pedestrian detection algorithm based on improved YOLOv3[J]. Acta Optica Sinica, 2022, 42(14): 1415003.
- [20] 钟镇, 张旭苹, 邹宁睦. 相位光时域反射仪中声信号测量范围的提升[J]. 光学学报, 2021, 41(13): 1306023.  
Zhong Z, Zhang X P, Zou N M. Enhancement of measurable range for acoustic signal in phase optical time domain reflector[J]. Acta Optica Sinica, 2021, 41(13): 1306023.
- [21] 周子纯, 刘琨, 江俊峰, 等. 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[J]. 光学学报, 2021, 41(13): 1306019.  
Zhou Z C, Liu K, Jiang J F, et al. Optical fiber vibration-sensing event recognition based on CLDNN[J]. Acta Optica Sinica, 2021, 41(13): 1306019.
- [22] 尚秋峰, 郭家兴. 基于VMD-BSA-SVM的海缆振动信号识别方法[J]. 激光与光电子学进展, 2022, 59(17): 1701001.  
Shang Q F, Guo J X. Identification method of submarine cable vibration signal based on VMD-BSA-SVM[J]. Laser & Optoelectronics Progress, 2022, 59(17): 1701001.

# Identification Method of Optical Fiber Perimeter Intrusion Signal Based on MATCN

Shang Qiufeng<sup>1,2,3</sup>, Huang Da<sup>1\*</sup>

<sup>1</sup>*Department of Electronic & Communication Engineering, North China Electric Power University, Baoding 071003, Hebei, China;*

<sup>2</sup>*Hebei Key Laboratory of Power Internet of Things Technology, North China Electric Power University, Baoding 071003, Hebei, China;*

<sup>3</sup>*Baoding Key Laboratory of Optical Fiber Sensing and Optical Communication Technology, North China Electric Power University, Baoding 071003, Hebei, China*

## Abstract

**Objective** Perimeter security technologies, such as electronic fences and tension networks, are currently outperformed by the phase-sensitive optical time domain reflectometer ( $\Phi$ -OTDR).  $\Phi$ -OTDR, known for its antielectromagnetic interference, high concealment, and large monitoring range, provides efficient large-scale monitoring at a reduced cost. Moreover, it not only can locate intrusion events but also identify event types when combined with signal recognition methods. These unique attributes make it valuable for perimeter security applications. Existing identification methods for perimeter intrusion signals are predominantly reliant on machine learning and deep learning techniques. However, machine learning methods require a high level of expert knowledge and their classification efficacy heavily depends on the chosen combination of features and classifiers. Furthermore, the currently available deep learning methods suffer from inadequate learning ability for time-series signals and require complex calculations. To address these challenges, we propose a deep learning recognition model that incorporates a multiattention mechanism. This model was designed to enhance the extraction of critical signal features and improve network learning capabilities. We used the DAS system to gather signals from climbing, knocking, trampling, and no intrusion events, to validate the effectiveness of our proposed method. We also contrasted the recognition rate and efficiency of various deep learning models and assessed the differential impacts of machine learning and deep learning for large sample multiclassification issues.

**Methods** We first extracted the time-domain waveform of the vibration signal using a signal demodulation technique and then employed a mobile difference method to locate the intrusion event. Following this, we introduced a multiattention temporal convolutional network (MATCN) recognition model, which provides the collected vibration signals directly for identification. This model utilized the channel attention mechanism to optimize the residual module, thereby enabling the selective learning of crucial information from different feature channels. Moreover, we employed the leaky rectified linear unit (Leaky ReLU) to mitigate the issue of neuron death during convolution and to enhance the model's robustness. Furthermore, we incorporated a temporal attention mechanism to help the network identify critical information-laden time slices. We determined the depth of the MATCN based on number of stacked layers in the residual module, informed by the changes in the validation sample's loss function value during training. We conducted ablation experiments to validate the proposed strategy's effectiveness. We also compared MATCN with other typical networks for timing signal recognition tasks, including long short-term memory networks (LSTM), convolutional layers incorporated into long short-term memory networks (CNN-LSTM), and temporal convolutional networks (TCN). An early stop mechanism was added during the network training process to prevent model overfitting. We compared the iteration speed, training epoch, and recognition rates of the different deep learning models. Lastly, we contrasted the recognition effects of MATCN and machine learning methods using two feature sets: zero crossing rate, kurtosis, energy entropy, and approximate entropy; zero crossing rate, kurtosis, skewness, and permutation entropy. These features were combined with common classifiers such as random forest (RF), K-nearest neighbor (KNN), and support vector machine (SVM) for recognition. We compared the recognition effectiveness of different feature group-classifier combinations.

**Results and Discussions** We devised performance comparison experiments for different deep learning models, employing LSTM, CNN-LSTM, TCN, and MATCN to process the same training and validation samples. The network training effectiveness is evaluated by comparing the iteration time, number of epochs, training time, and recognition rate of validation samples throughout the training process for each network (Fig. 13, Table 2). Network performance was assessed based on the recognition rate of each event and the testing time for nontraining samples (Table 3). The results demonstrate that although the iteration speed of MATCN is marginally slower than that of TCN, MATCN require less training time to converge, resulting in the highest overall training efficiency. Moreover, the recognition rate of MATCN



for nontraining samples reaches 98.50%, and the recognition time is a mere 0.53s, thus outperforming LSTM and CNN-LSTM. Machine learning methods were also employed to identify the same training and nontraining samples, revealing that the recognition efficacy of machine learning relies heavily on feature extraction and classifier selection. The highest recognition rate achieved by machine learning is 88.67%, falling short of MATCN and even LSTM, thereby underlining the advantages of deep learning for large sample multiclassification problems (Fig. 14).

**Conclusions** To address the issue of high expert reliance in machine learning and inadequate learning ability in deep learning for critical time-series signal features in optical fiber perimeter security pattern recognition, we propose a MATCN-based optical fiber perimeter signal recognition model. This model considers the temporal sequence of vibration signals and combines channel and temporal attention mechanisms to extract critical information from various angles. It enhances network learning capability and employs Leaky ReLU to mitigate neuron death during the convolution process, thereby boosting the model's robustness. The recognition results for the four signals indicate that the recognition rate of MATCN for nontraining samples attains 98.50%, thus surpassing LSTM and CNN-LSTM. Furthermore, MATCN outperforms machine learning in handling large sample multiclassification problems. The proposed model can selectively learn critical information across different channels and time slices, facilitating precise and efficient identification for perimeter intrusion signals.

**Key words** fiber optic sensing; pattern recognition; temporal convolutional network; attention mechanism; perimeter security