

引用格式: ZHANG Yaolu, YU Miao, CHANG Tianying, et al. Phase-sensitive Optical Time-domain Reflectometric System Pattern Recognition Method Based on Wavenet[J]. Acta Photonica Sinica, 2021, 50(3):0306003

张耀鲁,于淼,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

# 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

张耀鲁<sup>1</sup>, 于淼<sup>2</sup>, 常天英<sup>1</sup>, 李姝凡<sup>3</sup>, 郑志丰<sup>4</sup>, 杨悦<sup>1</sup>, 王忠民<sup>1</sup>, 崔洪亮<sup>1</sup>

(1 吉林大学 仪器科学与电气工程学院, 长春 130012)

(2 电子科技大学中山学院 电子信息学院, 广东 中山 528402)

(3 山东大学 海洋研究院, 济南 250061)

(4 珠海任驰光电科技有限公司, 广东 珠海 519000)

**摘要:** 针对相位敏感光时域反射系统中传统人工特征提取和模式识别方法实时性差、准确率低的问题, 提出一种波网络模式识别方法。该方法通过因果空洞卷积结构充分分析光纤振动信号的时序因果性, 通过残差块结构使模型更快收敛, 以实现更高的识别准确率和效率。实验结果表明, 在对手拍、脚踩、棒击三种信号识别时, 与一维卷积神经网络结构和长短期记忆网络结构方法相比, 该方法识别准确率高达 99.85%; 且训练耗时最少, 低至 96 s, 测试耗时也仅为 30 ms, 满足应用实时性的要求。该模式识别方法既具有高准确率又具有高实时性, 对于  $\varphi$ -OTDR 系统在周界安防中的应用推广具有重要意义。

**关键词:** 相位敏感; 光时域反射系统; 深度神经网络; 因果空洞卷积; 残差网络; 模式识别

中图分类号: TP212

文献标识码: A

doi: 10.3788/gzxb20215003.0306003

## Phase-sensitive Optical Time-domain Reflectometric System Pattern Recognition Method Based on Wavenet

ZHANG Yaolu<sup>1</sup>, YU Miao<sup>2</sup>, CHANG Tianying<sup>1</sup>, LI Shufan<sup>3</sup>, ZHENG Zhifeng<sup>4</sup>, YANG Yue<sup>1</sup>,  
WANG Zhongmin<sup>1</sup>, CUI Hongliang<sup>1</sup>

(1 College of Instrumentation & Electrical Engineering, Jilin University, Changchun 130012, China)

(2 School of Electronic Information Engineering, University of Electronic Science and Technology of China, Zhongshan Institute, Zhongshan, Guangdong 528402, China)

(3 Institute of Marine Science and Technology, Shandong University, Jinan 250061, China)

(4 Zhuhai Pegasus Optoelectronics Technology Co., Ltd, Zhuhai, Guangdong 519000, China)

**Abstract:** To improve on the poor real-time performance and low accuracy of traditional manual feature extraction and pattern recognition method in the Phase-Sensitive Optical Time-Domain Reflectometric System ( $\varphi$ -OTDR), a new pattern recognition method based on wavenet is proposed. This method fully analyzes the temporal causality of optical fiber vibration signals through the causal dilated convolutions, and makes the model converge faster by the residual block structure, so as to achieve higher recognition accuracy and efficiency. The experimental results show that, when three signals are recognized, namely,

基金项目: 广东省引进领军人才计划项目(No.00201507), 海洋公益性行业科研专项(No.201405026-01)

第一作者: 张耀鲁(1995—), 男, 硕士研究生, 主要研究方向为光纤传感技术及其模式识别。Email: zhang\_yaolu@163.com

通讯作者: 常天英(1981—), 女, 副教授, 博士, 主要研究方向为光纤传感技术及应用、太赫兹科学与技术等。Email: tchang@jlu.edu.cn

导师: 崔洪亮(1956—), 男, 教授, 博士, 主要研究方向为光纤通信和传感、太赫兹科学与技术、纳米光学和纳米电子学等。Email: hcui@jlu.edu.cn

收稿日期: 2020-10-07; 录用日期: 2020-12-15

<http://www.photon.ac.cn>

hand tapping, foot stepping, and stick striking, compared with the other two common methods, one-dimensional convolutional neural network structure and long short-term memory structure, the recognition accuracy as high as 99.85% is achieved with the proposed method. And it consumes the least amount of training time, as short as 96 s. Also, its signal detection process takes only 30 ms, which can meet the real-time application's requirement. The proposed pattern recognition method has high accuracy and good real-time performance. It should be of great significance for the application and popularization of  $\varphi$ -OTDR systems in perimeter security and similar areas.

**Key words:** Phase-sensitive; Optical time-domain reflectometric system; Deep neural network; Causal dilated convolution; Residual network; Pattern recognition

**OCIS Codes:** 060.2370; 070.5010; 200.4260

## 0 引言

基于相位敏感的光时域反射系统(Phase-Sensitive Optical Time-Domain Reflectometric System,  $\varphi$ -OTDR),以光纤作为传感器,具备本征安全、耐腐蚀、功耗低的独特优势,可实时在线检测并定位光纤沿线的振动信号,在周界安防、管线安全监测、建筑物结构健康监测等领域具有重要的应用意义<sup>[1]</sup>。

目前在 $\varphi$ -OTDR系统中,对振动信号类型的识别主要包括特征提取和特征分类两个步骤<sup>[2]</sup>。其中特征向量提取主要在时域、频域、时频域、空间域等维度进行<sup>[3-5]</sup>;特征向量的分类主要有机器学习和深度学习算法等<sup>[6-10]</sup>。2016年FEDOROV A K等<sup>[11]</sup>提取振动信号的梅尔倒谱系数特征,采用高斯混合模型(Gaussian Mixture Model, GMM)算法对两种事件分类,最佳识别准确率接近90%。2017年张俊楠等<sup>[12]</sup>提取振动信号时域和频域的平均值、方差、均方差以及功率特征,采用支持向量机(Support Vector Machine, SVM)算法对四种事件进行识别,识别率可达94%。2019年SUN Zhenshi等<sup>[13]</sup>对振动信号进行变分模态分解,提取各频率模态的峭度统计特征,并融合振动信号的过零率特征,采用SVM算法对四种事件进行识别,对人为扰动的识别准确率为96.9%。2019年WU Huijuan等<sup>[14]</sup>在光纤某一固定位置上,将长时间序列信息分割为多个局部信号单元,而后在时域、频域、时频域、模型参数上共提取44个特征,采用隐马尔科夫模型(Hidden Markov Models, HMMs)对5种事件进行识别,识别率可达98.2%。目前大部分的信号特征提取方法是人工根据专业知识选取的,且日趋完备。但是人工提取的特征能否完全代表原始振动信号,直接影响了特征分类的准确度,且人工提取特征很大程度上额外增加了整个模式识别算法的计算复杂度,导致算法整体的处理效率较低、实时性较差。随着深度学习的深入研究,由于深度学习方法集特征提取和分类于一体,简化了模式识别的流程,日渐在光纤传感领域内流行起来。比如,2017年AKTAS M等<sup>[15]</sup>采用短时傅里叶变换提取时频图特征,采用二维卷积神经网络结构(Convolutional Neural Network, CNN)对6种信号识别,识别准确率在93%以上;但是仍然是需要人工提取时频图像特征,处理效率较低,实时性较差。2019年吴俊等<sup>[16]</sup>采用多尺度一维CNN直接对一维原始振动信号进行特征提取和识别,识别正确率为96.59%;2020年SHI Yi等<sup>[17]</sup>将 $\varphi$ -OTDR系统采集到的时间-空间数组形成灰度图像,并输入到二维CNN中自动获取信号特征,而后将这些特征传输给SVM进行进一步分类,对八种事件的分类准确率可达94.17%。但是由于振动传感信号随时间推移而改变,而CNN缺乏对时序信号准确表达和分析的能力,尤其对长跨度时间依赖信号, CNN的信号识别能力有限。长短期记忆网络(Long Short-Term Memory, LSTM)适合分析时序信号,2019年CHEN Xue等<sup>[18]</sup>提取信号频域上的梅尔频率倒谱系数、时域上的短时能量比和过零率特征,采用基于注意力的长短期记忆网络(Attention-based Long Short-Term Memory, ALSTM)对5种事件分类,准确率可达94.3%;2019年HE Ningyu等<sup>[19]</sup>对每个信号帧提取到线性预测系数、梅尔频率倒谱系数、小波包共96维特征,采用卷积层提取扰动信号的频域特征,采用LSTM层分析各信号帧之间的时域联系,卷积层中采用了残差模块以保证网络训练的收敛,防止网络退化,对有害和无害振动信号进行了识别,识别准确率可达84%以上。2019年BAI Yu等<sup>[20]</sup>应用LSTM网络直接对时间序列上的振动幅值信息进行识别,对两种人为干扰事件的平均识别准确率超过了97%;2020年WU Huijuan等<sup>[21]</sup>采用一维CNN提取每个空间点上的时间信息,采用双向长短期记忆网络(Bidirectional Long Short-Term Memory, BiLSTM)挖掘不同采样点之间的空间关系,对五种识别准确率可达97.2%,但是在每个采样点上均需要单独使用一维CNN,对于一维CNN输出的每个采样点上的时间信息也均需要多个BiLSTM单元处理,模型结构和参数较为复杂,且由于LSTM中

存在循环连接,在一定程度上限制了模型的训练速度。

因此,为解决目前额外人工提取特征造成的效率较低、CNN网络对时序信号理解能力较差、LSTM网络结构复杂等问题,本文采用一种一维CNN的变体一波网络(Wavenet)结构<sup>[22]</sup>,将采集到的原始振动信号形成时间-空间矩阵后,直接对其进行特征提取和识别,能够更有效率地充分获取振动信息。由于采集到的光纤振动数据具有重要的时间分布性,而Wavenet中的因果卷积结构保证了充分分析时序信号;空洞卷积结构通过增大感知野进一步满足信号的长跨度时间依赖,实现对较长持续时间振动信号的上下文时序关系理解的目的;Wavenet中的残差网络结构通过将浅层网络的信息直接引入到深层网络,可防止梯度随网络深度增加而消失,使得模型更快收敛。因而Wavenet网络可实现对分布式光纤振动信号的准确、实时识别。

## 1 DVS系统及其模式识别结构

本文采用 $\varphi$ -OTDR系统中的直接探测型结构,如图1所示。超窄激光器发出连续光,经声光调制器调制制成脉冲光;数据采集卡的触发信号同时为声光调制器驱动器提供脉冲宽度调制(Pulse Width Modulation, PWM)同步信号,来驱动声光调制器。脉冲光经掺铒光纤放大器放大光功率,通过环形器进入传感光纤感知外界振动信号。由于瑞利散射作用会返回后向散射光,其光场强度表达式<sup>[23]</sup>为

$$I(t) = E_s^2(t) = [A_s \cos(2\pi f_s t + \phi_s)]^2 = A_s^2/2 + (A_s^2/2) \cos(4\pi f_s t + 2\phi_s) \quad (1)$$

式中, $E_s$ 、 $A_s$ 、 $f_s$ 、 $\phi_s$ 分别为后向瑞利散射光的光场、振幅、频率和相位。当有振动信号作用于传感光纤时,相位 $\phi_s$ 发生改变,光强 $I(t)$ 变化,数据采集卡采集到幅值信息;最后由计算机对前后两个时刻的幅值作差,从而得到扰动作用位置及其扰动特征信息。

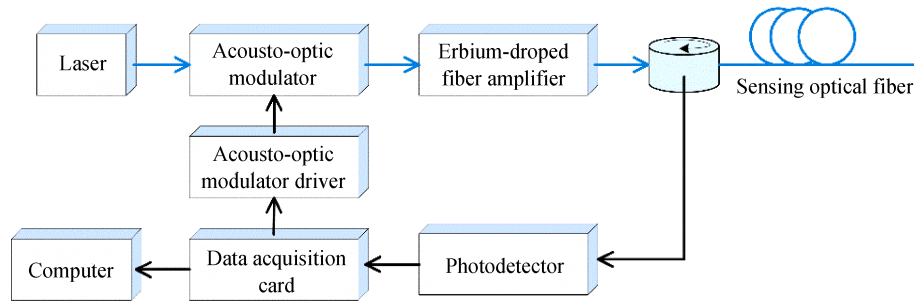


图1  $\varphi$ -OTDR系统结构图  
Fig.1 Structure of  $\varphi$ -OTDR System

由于采集到的扰动幅值数据无法直观识别出扰动类别,而信号特征的人工提取依赖于专业知识,且多种特征向量的单独提取以及对应分类算法的开发费时费力,导致识别系统流程繁琐,效率较低,模型可迁移能力较差,因此本文采用深度学习的方法自动提取光纤振动信号的特征并分类识别,根据振动信号在时间上具有重要的上下文关系,具体采用Wavenet方法对外界扰动进行模式识别。Wavenet结构是一种自回归的深度生成模型,由谷歌DeepMind公司的OORD A等<sup>[22]</sup>于2016年首次提出,用于语音信号的生成;根据语音信号的时序因果性以及长期依赖性,主要结构采用因果卷积、空洞卷积以及残差块结构。考虑到语音信号在本质上也是一种振动信号,且 $\varphi$ -OTDR系统采集到的振动数据具有重要的时序信息,所以本文将Wavenet深度神经网络应用于 $\varphi$ -OTDR系统中进行模式识别,具体结构如图2所示。

首先,由 $\varphi$ -OTDR系统采集到振动数据,形成带标签的数据集,用于训练和测试;而在实际在线监测中,无标签振动数组直接作为测试数据。振动数据进一步形成时间-空间二维数组,即振动信号在每个时刻 $x_1, x_2, x_3, \dots, x_n$ 上带有空间维度信息,首先每个时刻的数据输入到Wavenet中的因果卷积结构,使得每一时刻的输出只与当前时刻和之前时刻的输入有关,而不依赖于未来时刻的信息,确保模型不会违反输入数据的顺序,严格遵守了输入振动信号在每个时刻上的前后时序性;而后进入到每层残差网络结构中,残差网络结构中含有空洞卷积结构,使Wavenet能够感知长时间跨度的振动信号输入,而且残差网络结构本身将浅层网络的信息直接引入到深层网络,防止网络在较深层数下梯度消失,促使模型较快收敛。训练后以形成固

定的模型和权重,并在测试过程中调用来预测振动数据的标签,从而判断振动事件类型。

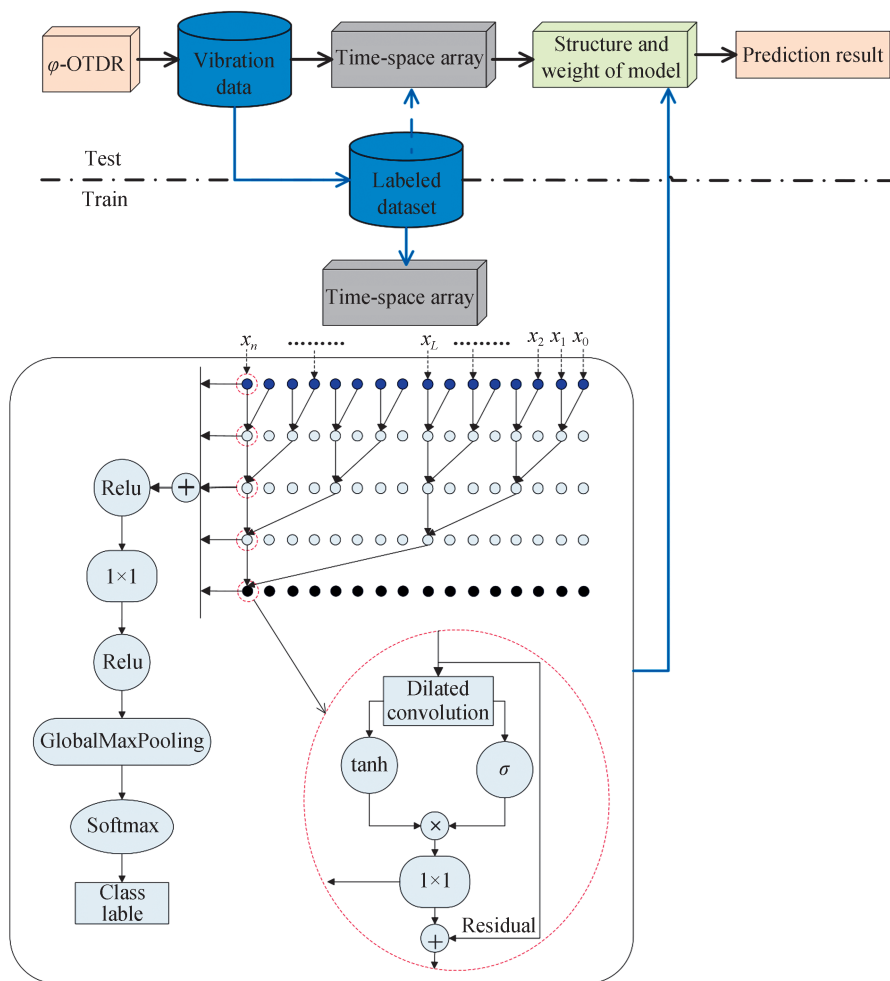


图2  $\varphi$ -OTDR 模式识别系统图

Fig.2 System of  $\varphi$ -OTDR pattern recognition

## 2 实验设置

### 2.1 数据采集

实验采用直接探测型  $\varphi$ -OTDR 系统<sup>[24]</sup>。数据采集卡的采样频率为 100 MS/s,提供频率为 5 kHz,脉冲宽度为 20 ns 的脉冲正沿触发信号,触发模式为后触发,采集模式为连续采集。该系统最大传感距离为 20 km,最小空间分辨率为 4 m,频率响应范围为 5 Hz~2 kHz。

实验传感光纤总长度为 4.4 km,在光纤的 2.25 km~2.4 km 范围内划分为三段,分别为“前”、“中”、“后”三个位置。若以距离光纤始端 2.25 km 处为起始点,“前”位置处于 0~50 m 范围内;“中”位置处于 50~100 m 范围内;“后”位置处于 100~150 m 范围内。由于该实验系统主要应用于周界安防事件识别,因此本文选取了三种常见的人为入侵事件:手拍、脚踩、棒击。

实验成员由年龄为 25 岁的男成员、年龄为 25 岁的女成员、年龄为 49 岁的男成员组成,在每个位置上,三个成员分别单独进行手拍、脚踩、棒击三种动作,如图 3(a)、(b)、(c) 所示。为了考察三个动作在不同位置同时作用时神经网络的识别能力,又进行了同时在“前”位置处脚踩、“中”位置处手拍、“后”位置处棒击的信号采集,如图 3(d) 所示。

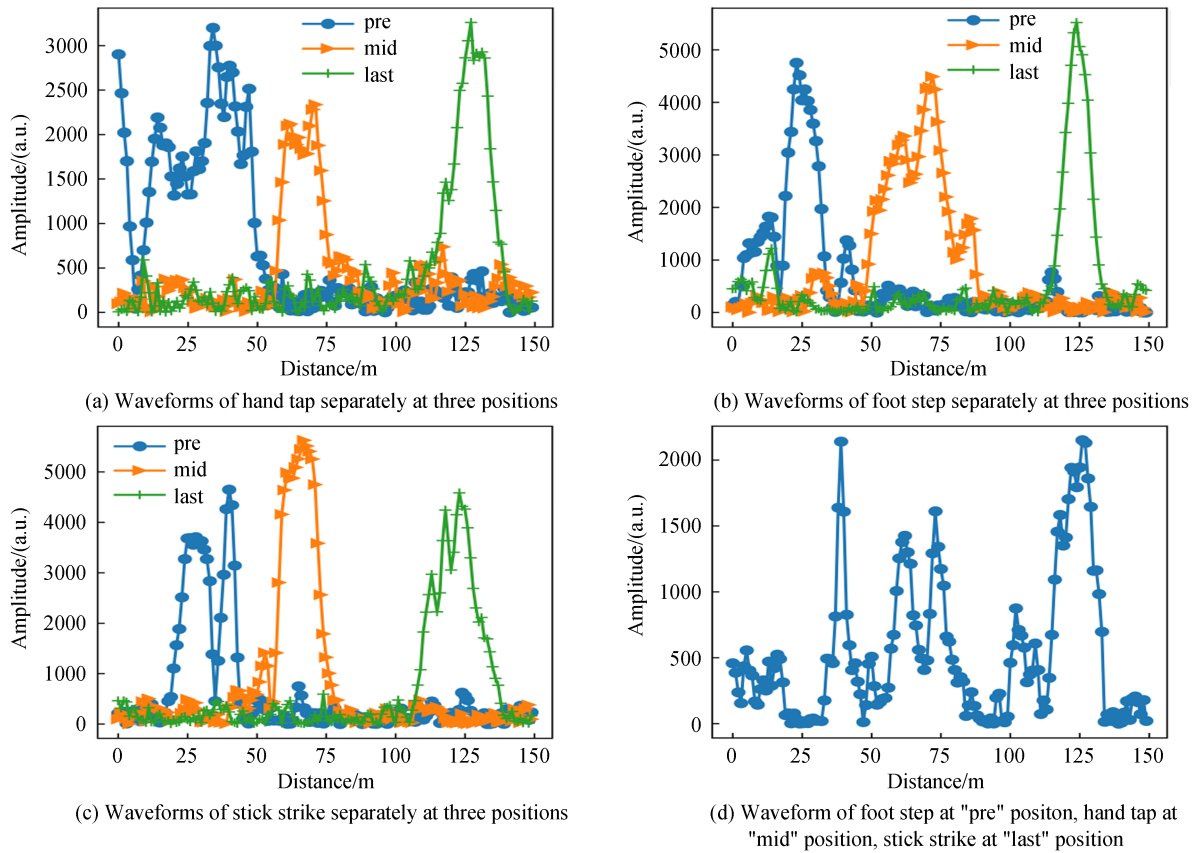



图3 三种振动信号在三个位置处单独和同时作用波形图  
Fig. 3 Waveforms of three vibration signals act separately and simultaneously at three positions

## 2.2 制作数据集

脚踩、手拍、棒击在三个位置处分别单独作用,采集到每个动作在每个位置 1 999 组数据,那么每个动作合计各 5 997 组数据,共得到 17 991 组数据。根据各扰动在三个位置的作用范围,每组数据取 50 m 的采样点;脚踩在“前”位置处、手拍在“中”位置处、棒击在“后”位置处同时作用时,采集到 1 999 组数据。在每组数据中,根据三种振动信号的各自作用位置,分别提取 50 m 采样点的单种振动数据,即每个动作各 1 999 组,共得到 5 997 组数据。那么将三个动作单独作用和同时作用两者数据集混合,共 23 988 组数据集。振动信号具有重要的时间分布信息,以固定滑动时间窗口对每种动作数据集在时间域上进行截取,以获得信号在时间域上的信息。对于滑动时间窗口的大小确定问题,如果滑动时间窗口过小,会无法充分获取振动信号的时序关系。而滑动时间窗口过大,一方面会使得单个输入样本数据庞大,造成训练速度过慢的问题;另一方






图4 二维时间-空间数组图

Fig.4 Two-dimensional time-space array diagram

面随着信号作用时间长度的增加,信号在时间域上的上下文关系会减弱。基于振动信号时序性和训练效率的均衡考量,经过多次试验确定,以50组的固定窗长,步长为1组滑动截取,得到23 838组的 $50 \times 50$ 的二维时间-空间数组,如图4所示。将其划分为19 866条训练集、1 986条验证集,1 986条测试集。

### 3 信号分析

对于二维时间-空间数据集,即带有空间特征的时序数据。为分析振动信号在时间维度上的上下文关联性,采用Wavenet结构进行训练识别,Wavenet与其它常用的神经网络如LSTM、一维CNN在结构上的区别如图5所示。




图5 LSTM、一维卷积、因果卷积结构

Fig.5 Structure of LSTM, one-dimensional convolution, causal convolution

由图5(a)可知,对于每个时间步,LSTM都有其对应的单元模块,每个单元模块均是基于当前时刻的输入和之前时刻的状态向量共同计算得到的,并将其状态再传递到下一节点单元。LSTM对上一节点输入的状态进行选择性忘记,对当前时间步的输入进行选择性记忆,因此LSTM网络对长序列训练过程中,在获取输入序列的前后顺序信息的同时,可以避免循环神经网络出现梯度消失和梯度爆炸的问题,但是LSTM本质上仍然是循环神经网络,具有循环递归结构,不能够并行运算,且每个LSTM单元有四个全连接层,当输入序列较长时,会消耗大量的训练时间。

由图5(b)可知,对于每个时间步,一维CNN以大小为2的卷积核,步长为1依次提取输入特征,但是当前时刻的输出用到了未来时刻的信息,无法充分获取输入序列的顺序关系,违反了自回归的原则,导致对时序信号的识别能力不足。

由图5(c)可知,因果卷积结构相比于一维CNN填充方式有所不同,因果卷积结构中,在输入序列的左侧填充0,从而使得当前时刻的输出只与之前时刻和当前时刻的输入有关,而不考虑未来时刻的影响,能够更加准确地获取序列信号的前后关系。

因此,Wavenet中的因果卷积结构具有分析时序信号的独特优势。基于 $\varphi$ -OTDR系统所采集的 $50 \times 50$ 的时间-空间二维数组。如图6所示,输入可以看做带有空间信息的时序数据点 $x = \{x_1, x_2, \dots, x_{50}\}$ ,通过因果卷积,可以得到整个输入序列的联合概率密度为

$$p(x) = \prod_{t=1}^{50} p(x_t | x_1, \dots, x_{t-1}) \quad (2)$$

式中, $x_1, \dots, x_t$ 为在某一时刻 $t$ 的振动空间信息输入,每一时刻的振动数据点均与之前时刻信息有关,而与未来的时刻无关。当每一时刻经因果卷积后,输出又作为之前时刻的信息继续影响下一时刻。因此Wavenet输入具有严格的时间前后关系,在用于手拍、脚踩、棒击三种信号的分类时,Wavenet能够有效提取振动信号的前后时序性特征。

Wavenet结构由多层因果卷积层堆叠而成,在卷积网络中没有池化层,在一定程度上能避免有效信息的损失。但存在的问题是在卷积层数一定的情况下,模型对输入序列的感知范围有限。如图6所示,一个含有4层的卷积层的模型,每进行一步卷积运算,对输入只有5个感知范围,要训练足够长的时序样本,需要多个卷积层的堆叠,或者更大的滤波器来增加足够长的感知野,但这又增加了计算资源。




图6 因果卷积层的堆叠结构  
Fig.6 Structure of a stack of causal convolutional layers

对于所输入的 $50 \times 50$ 二维时序数组,采用空洞卷积结构<sup>[25-26]</sup>可在同样的卷积层数下获得更大的感知野范围,即在卷积核中以固定间隔(被称为空洞系数)添加一些零值的权重,对于输入的时序数组 $x \in \mathbb{R}^T$ ,卷积核 $f \in \mathbb{R}^K$ ,那么 $x$ 与 $f$ 在第 $t$ 步的因果空洞卷积为<sup>[27]</sup>

$$x * f(t) = \sum_{s=0}^{K-1} f(s) x(t - d \times s) \quad (3)$$

式中, $K$ 为卷积核大小, $d$ 为空洞系数。通过稀疏化卷积核内部,使卷积核可被应用于大于其本身长度的区域,从而在同样卷积层数下获得更大的感知野,节省了计算资源。如图7所示,当卷积核空洞系数分别为1、2、4、8时,输入的感知范围增加到16个,感知野随卷积层数呈指数增长。为进一步扩大感知范围,将空洞系数分别为1、2、4、8的空洞卷积视为一个block,其卷积核大小为2;重复三次block,便产生12层因果空洞卷积。




图7 多层空洞卷积结构  
Fig.7 Structure of dilated convolution multilayers

然而,当卷积层增加到一定层数时,会出现梯度消失而导致训练网络退化的问题,因此需采用残差网络<sup>[28]</sup>结构,如图8所示。每层残差块中包含不同空洞系数的空洞卷积结构,因此产生12层的残差块。输入序列首先经过一维因果卷积(卷积核个数为16,卷积核大小为1,步长为1),而后进入第一层残差块。经过空

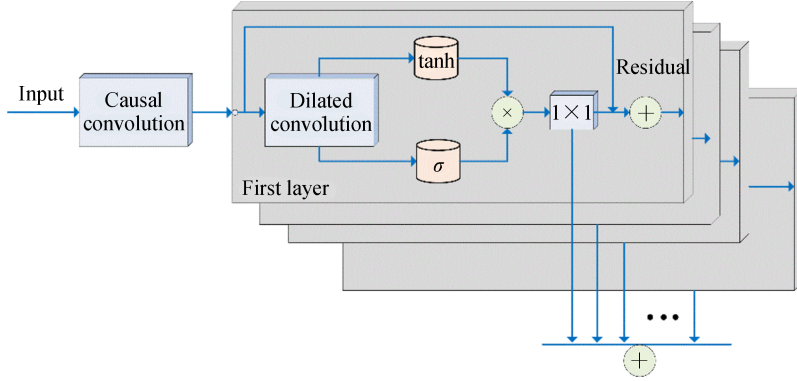


图8 残差网络结构

Fig.8 Residual network's structure

洞系数为1的空洞卷积层后,为增加卷积层之间的非线性、增强模型的表达能力,防止过拟合,输入经门控激活单元<sup>[29]</sup>进一步激活

$$z = \tanh(W_{f,k} * x) \odot \sigma(W_{g,k} * x) \quad (4)$$

式中,\*代表卷积运算, $\odot$ 代表点乘运算,tanh和 $\sigma$ 分别为tanh激活函数和sigmoid激活函数, $k$ 为层数, $f$ 和 $g$ 分别代表滤波器和门控, $W$ 为可学习的卷积核, $x$ 为输入。激活后,经 $1 \times 1$ 的卷积核来降低通道数;而后其输出分为两路:一路与该层残差块的输入相加,构成残差网络;另一路作为跳步连接直接输出与各层相累加。残差网络将浅层网络的输入直接传到深层的输出,恒等映射转化为两者的差作为下一层残差块的输入。浅层网络直接映射的引入,可更有效率地执行转化后的恒等映射,从而使模型收敛得更快,训练出更深的网络结构。

残差块的输出不仅仅取决于输入,还取决于前一层的残差块 $f(x, \{W_i\})$ ,其中 $W_i$ 是从第 $i$ 层残差块中学习的权值和偏差,那么残差块的输出为<sup>[30]</sup>

$$H(x) = f(x, \{W_i\}) + x \quad (5)$$

当采用多层残差块时,残差块的输出为

$$x_k = x_0 + \sum_{i=1}^k f(x_{i-1}, W_{i-1}) \quad (6)$$

式中, $x_k$ 是第 $K$ 层残差块的输出, $x_0$ 是残差网络的输入, $f(x_{i-1}, W_{i-1})$ 是前一层残差块的输出和相关权值。由于前一个残差块和最后一个残差块之间进行了多次累加,则残差网络对输入 $x_0$ 的反向传播公式为

$$\frac{\partial R}{\partial x_0} = \frac{\partial R}{\partial x_k} \frac{\partial x_k}{\partial x_0} = \frac{\partial R}{\partial x_k} \left[ 1 + \frac{\partial}{\partial x_0} \sum_{i=1}^k f(x_{i-1}, W_{i-1}) \right] \quad (7)$$

式中, $R$ 是残差网络的总损失,常数1表示网络输出的梯度可以不考虑各层的权值和偏差直接反向传播,这样即便在权值和偏差都很小的情况下,各层不受梯度消失的影响。

## 4 实验结果

为了评估证实Wavenet结构模型具有高准确率和高效率,基于相同时间-空间数据集输入的前提条件,本文还采用了一维CNN结构和LSTM结构分别进行研究对比。其中一维CNN主要结构为三层一维卷积-最大值池化,采用Sigmoid和Relu作激活函数,卷积核个数为128,卷积核尺寸和步长均为1,池化窗口大小为1,网络模型优化器同Wavenet结构均选用自适应矩估计(Adaptive moment estimation, Adam)<sup>[31]</sup>;LSTM主要结构为三层LSTM堆叠,选用均方根传播(Root Mean Square prop, RMSprop)作优化器。二维时间-空间数据集分别输入到三种网络结构中,数据集的batch size均设为128;初始学习率均设为0.003;分类函数均



采用 softmax 函数;损失函数均采用稀疏多分类交叉熵函数,根据损失值来不断地调整学习率。本文采用 i7-9800X 处理器和 RTX Titan GPU 对三种结构进行训练和测试。

#### 4.1 准确率对比

整个训练集通过神经网络训练一次被称为一次 Epoch。三种结构在训练集和验证集的损失函数与准确率随训练 Epoch 数的变化曲线分别如图 9、10、11 所示。由图可知,在模型的损失函数和准确率训练至稳定

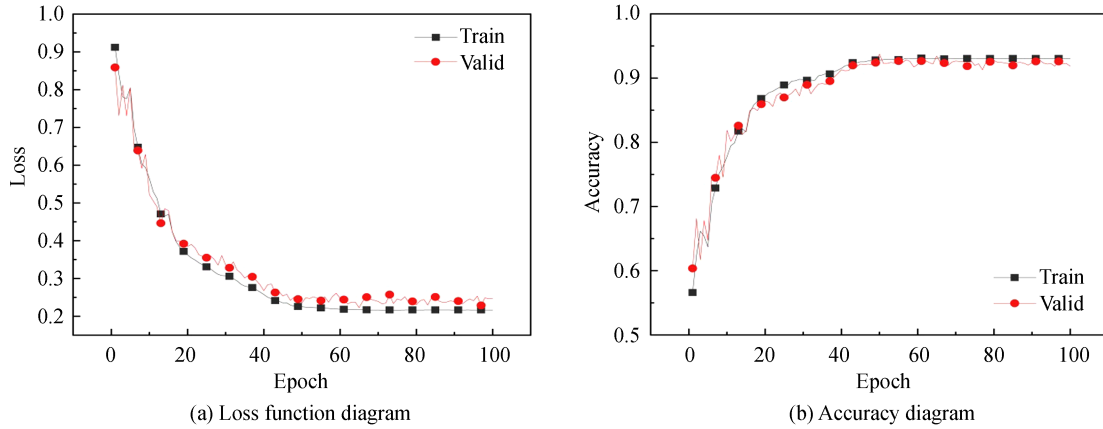


图9 一维 CNN 结构训练曲线图  
Fig.9 One-dimensional CNN structure's training diagrams

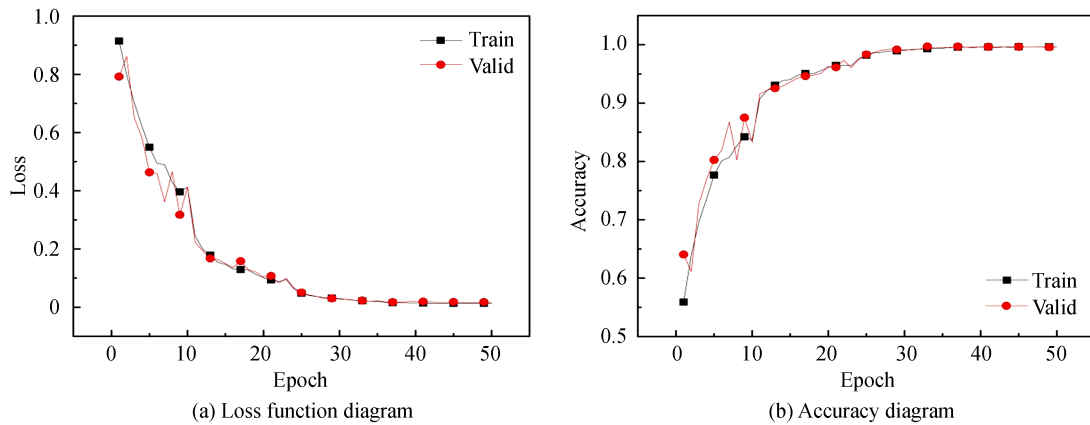


图10 LSTM 结构训练曲线图  
Fig.10 LSTM structure's training diagrams

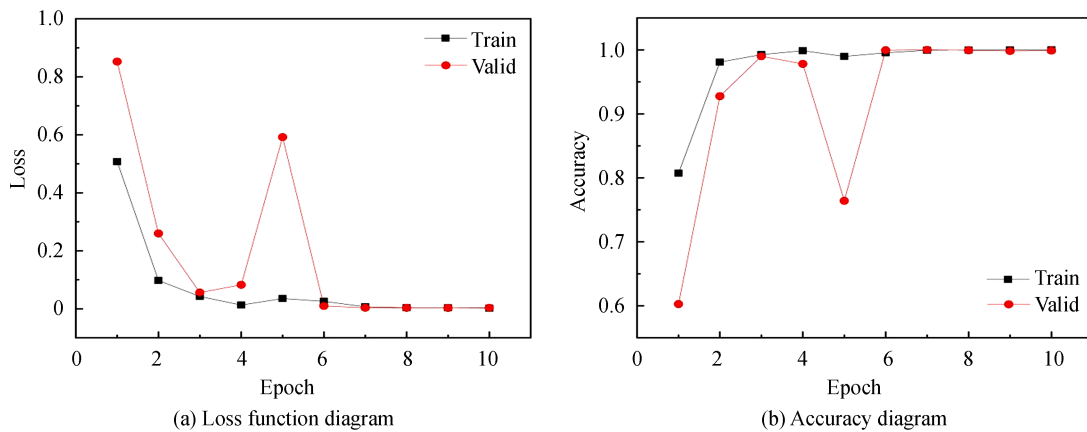


图11 Wavenet 结构训练曲线图  
Fig.11 Wavenet structure's training diagrams

时,一维 CNN 结构存在轻微过拟合现象;而 LSTM 结构和 Wavenet 结构的拟合效果较好。最终测试集的准确率如表 1 所示,Wavenet 结构的测试准确率最高,达到了 99.85%;LSTM 结构的准确率为 99.24%,也达到了较高的水平;而一维 CNN 的识别准确率最低,仅为 92.75%。

表 1 三种结构的测试集识别准确率  
Table 1 Test sets' recognition accuracy rate of three structures

Network model	True label	Prediction label			Accuracy rate/%
		Foot stepping/%	Hand tapping/%	Stick striking/%	
One-dimensional CNN	Foot stepping	93.35	3.47	3.18	92.75
	Hand tapping	1.06	95.47	3.47	
	Stick striking	5.44	5.14	89.42	
LSTM	Foot stepping	97.89	0.60	1.51	99.24
	Hand tapping	0.00	100.00	0.00	
	Stick striking	0.00	0.15	99.85	
Wavenet	Foot stepping	100	0.00	0.00	99.85
	Hand tapping	0.30	99.70	0.00	
	Stick striking	0.00	0.15	99.85	

与一维 CNN 相比,LSTM 和 Wavenet 具有适合分析时序信号的结构。LSTM 具有遗忘门、输入门和输出门结构;Wavenet 具有因果空洞卷积结构,这些结构均保证了对输入数据时序性的考量。因此对于相同的时间-空间二维数组输入,LSTM 和 Wavenet 比一维 CNN 均能够实现较好的识别准确率。

#### 4.2 效率对比

在实际应用中,除识别准确率外,训练和测试效率也是模型的重要指标之一。因此对比了三种结构的训练和测试时间,如表 2 所示。由于输入训练集均为 19 866 组,batch size 均为 128,那么进行完整的一代 Epoch 训练需要迭代 155 次。迭代速度能够反映模型的复杂程度,而模型的复杂程度能进一步影响模型的训练和识别效率。由表 2 可知,一维 CNN 的迭代速度最快;Wavenet 结构次之;LSTM 结构最慢,以此可以反映出三种模型的复杂程度。当模型的损失函数和准确率随 Epoch 的增加而不变时,说明模型的训练参数达到了最优稳定。由表 2 可知,Wavenet 模型达到稳定时所需 Epoch 最少;LSTM 次之;一维 CNN 最多。这是因为 Wavenet 结构相对于其它两种结构采用了残差块结构,使其在训练较深较复杂的网络过程中能够快速收敛。

表 2 三种结构的训练及测试效率  
Table 2 Three structures' training and testing efficiency

Network model	Iteration speed/ (ms/step)	One Epoch's time/s	Numbers of training epoch	Training time/s	Testing time/ms
One-dimensional CNN	12	2	60	120	12
LSTM	270	42	40	1 680	61
Wavenet	107	16	6	96	30

在模型达到最优稳定时,Wavenet 的训练总耗时最少;一维 CNN 次之;LSTM 最多。在训练好的模型用于测试时,一维 CNN 结构由于结构简单,耗时最少,仅为 12 ms;Wavenet 结构次之,为 30 ms;LSTM 结构最慢,为 61 ms。

## 5 结论

本文提出了将 Wavenet 深度神经网络作为模式识别方法应用于  $\varphi$ -OTDR 系统中。将  $\varphi$ -OTDR 系统采集到的原始信号处理成二维时间-空间数据集,输入到 Wavenet 神经网络中进行模式识别,Wavenet 具有 12 层因果空洞卷积结构和将浅层信息直接映射到深层的残差结构。利用 Wavenet 中的因果空洞卷积结构来充分考量振动信号的时序性;残差块可使模型在较深的网络中实现较快收敛。结果表明,Wavenet 相比于一维

CNN结构显著提升了识别准确率,可达99.85%;与一维CNN结构和LSTM结构相比,训练总耗时最短,为96 s;由于模型本身复杂度,测试时间稍长于一维CNN,为30 ms,但能够满足实际应用。该模式识别方法既具有高准确率又具有高实时性,将大大提高 $\phi$ -OTDR系统在周界安防中的应用价值。

#### 参考文献

- [1] FU Qunjian, YU Miao, CHANG Tianying, et al. Summarization of pattern recognition method for phase sensitive optical time domain reflecting system[J]. *Infrared and Laser Engineering*, 2018, 47(7): 276-289.  
付群健, 于淼, 常天英, 等. 相位敏感光时域反射系统模式识别方法综述[J]. *红外与激光工程*, 2018, 47(7): 276-289.
- [2] BING Feibing. Application research of pattern recognition in fiber distributed perimeter security monitoring system[D]. Chengdu: University of Electronic Science and Technology of China, 2019: 9-11.  
郇飞兵. 模式识别在光纤分布式周界安全监测系统中的应用研究[D]. 成都: 电子科技大学, 2019: 9-11.
- [3] LI Meng, ZHAO Yifei, MA Yuzhao, et al. Intrusion discrimination in terms of LMD and ICA with combined features in the fiber-optic perimeter system[J]. *IEEE Photonics Journal*, 2020, 12(2): 1-14.
- [4] HUANG Liangliang, LI Yingchun, CHEN Song, et al. Building safety monitoring based on extreme gradient boosting in distributed optical fiber sensing[J]. *Optical Fiber Technology*, 2020, 55: 102149.
- [5] WANG Dawei, FENG Hao, YANG Yang, et al. Study on leakage identification method of water supply pipeline based on  $\Phi$ -OTDR optical fiber sensing technology[J]. *Chinese Journal of Scientific Instrument*, 2017, 38(4): 830-837.  
王大伟, 封皓, 杨洋, 等. 基于 $\Phi$ -OTDR光纤传感技术的供水管道泄漏辨识方法[J]. *仪器仪表学报*, 2017, 38(4): 830-837.
- [6] QU Hongquan, FENG Tingliang, ZHANG Yuan, et al. Ensemble learning with stochastic configuration network for noisy optical fiber vibration signal recognition[J]. *Sensors*, 2019, 19(15): 3293.
- [7] BAO Jiye, MO Jiaqing, XU Liang, et al. VMD-based vibrating fiber system intrusion signal recognition[J]. *Optik*, 2020, 205: 163753.
- [8] CHEN Peichao, YOU Citian, DING Panfeng. Research on pattern recognition of intrusion events in perimeter defense areas of optical fiber[J]. *Chinese Journal of Lasers*, 2019, 46(10): 275-284.  
陈沛超, 游赐天, 丁攀峰. 光纤周界防区入侵事件的模式识别研究[J]. *中国激光*, 2019, 46(10): 275-284.
- [9] ZHAO Hongduo, WU Difei, ZENG Mengyuan, et al. Assessment of concrete pavement support conditions using distributed optical vibration sensing fiber and a neural network [J]. *Construction and Building Materials*, 2019, 216: 214-226.
- [10] TEJEDOR J, MACIAS-GUARASA J, MARTINS H F, et al. A novel fiber optic based surveillance system for prevention of pipeline integrity threats[J]. *Sensors*, 2017, 17(2): 355.
- [11] FEDOROV A K, ANUFRIEV M N, ZHIRNOV A A, et al. Note: Gaussian mixture model for event recognition in optical time-domain reflectometry based sensing systems[J]. *Review of Scientific Instruments*, 2016, 87(3): 036107.
- [12] ZHANG Junnan, LOU Shuqin, LIANG Sheng. Study of pattern recognition based on SVM algorithm for  $\Phi$ -OTDR distributed optical fiber disturbance sensing system[J]. *Infrared and Laser Engineering*, 2017, 46(4): 219-225.  
张俊楠, 娄淑琴, 梁生. 基于SVM算法的 $\Phi$ -OTDR分布式光纤扰动传感系统模式识别研究[J]. *红外与激光工程*, 2017, 46(4): 219-225.
- [13] SUN Zhenshi, LIU Kun, JIANG Junfeng, et al. Variational mode decomposition-based event recognition in perimeter security monitoring with fiber optic vibration sensor[J]. *IEEE Access*, 2019, 7: 182580-182587.
- [14] WU Huijuan, LIU Xiangrong, XIAO Yao, et al. A dynamic time sequence recognition and knowledge mining method based on the Hidden Markov Models (HMMs) for pipeline safety monitoring with  $\Phi$ -OTDR[J]. *Journal of Lightwave Technology*, 2019, 37(19): 4991-5000.
- [15] AKTAS M, AKGUN T, DEMIRCIN M U, et al. Deep learning based multi-threat classification for phase-OTDR fiber optic distributed acoustic sensing applications[C]. *Fiber Optic Sensors and Applications XIV*, SPIE, 2017: 102080G.
- [16] WU Jun, GUAN Luyang, BAO Ming, et al. Vibration events recognition of optical fiber based on multi-scale 1-D CNN [J]. *Opto-Electronic Engineering*, 2019, 46(5): 79-86.  
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): 79-86.
- [17] SHI Yi, WANG Yuanye, WANG Liyuan, et al. Multi-event classification for  $\Phi$ -OTDR distributed optical fiber sensing system using deep learning and support vector machine[J]. *Optik*, 2020, 221: 165373.
- [18] CHEN Xue, XU Chengjin. Disturbance pattern recognition based on an ALSTM in a long-distance  $\phi$ -OTDR sensing system[J]. *Microwave and Optical Technology Letters*, 2020, 62(1): 168-175.
- [19] HE Ningyu, ZHU Jie. Deep learning approach for audio signal classification and its application in fiber optic sensor security system[C]. *2019 9th International Conference on Information Science and Technology (ICIST)*, IEEE, 2019: 263-267.
- [20] BAI Yu, XING Jichuan, XIE Fei, et al. Detection and identification of external intrusion signals from 33 km optical fiber sensing system based on deep learning[J]. *Optical Fiber Technology*, 2019, 53: 102060.

- 
- [21] WU Huijuan, YANG Mingru, YANG Siqi, et al. A novel DAS signal recognition method based on spatiotemporal information extraction with 1DCNNs-BiLSTM network[J]. *IEEE Access*, 2020, 8, 119448-119457.
- [22] OORD A, DIELEMAN S, ZEN H, et al. Wavenet: A generative model for raw audio[J]. *arXiv*, 2016, cs.SD: 1609.03499.
- [23] YU Miao. Research and application of phase-sensitive optical time-domain reflectometric system based on single-source dual heterodyne detection scheme[D]. Changchun: Jilin University, 2017: 35-36.  
于淼. 基于双重同源外差相干检测的 $\Phi$ -OTDR系统的研究及应用[D]. 长春: 吉林大学, 2017: 35-36.
- [24] TAYLOR HENRY F, CHUNG ELEE. Apparatus and method for fiber optic intrusion sensing: US, 5194847[P]. 1993-3-16.
- [25] CHEN L C, PAPANDREOU G, KOKKINOS I, et al. Semantic image segmentation with deep convolutional nets and fully connected crfs[J]. *arXiv*, 2014, cs.CV: 1412.7062.
- [26] YU F, KOLTUN V. Multi-scale context aggregation by dilated convolutions[J]. *arXiv*, 2015, cs.CV: 1511.07122.
- [27] WU Zonghan, PAN Shirui, LONG Guodong, et al. Graph wavenet for deep spatial-temporal graph modeling [C]. *Proceedings of the Twenty-Eighth International Joint Conference on Artificial Intelligence*, 2019: 1907-1913.
- [28] HE Kaiming, ZHANG Xiangyu, REN Shaoqing, et al. Deep residual learning for image recognition [C]. *2016 IEEE conference on computer vision and pattern recognition*, IEEE, 2016: 770-778.
- [29] OORD AVAN DEN, KALCHBRENNER N, VINYALS O, et al. Conditional image generation with PixelCNN decoders[C]. *Proceedings of the 30th International Conference on Neural Information Processing Systems, Advances in Neural Information Processing Systems*, 2016, 29: 4797-4805.
- [30] BUI D M, LE P D, CAO M T, et al. Accuracy improvement of various short-term load forecasting models by a novel and unified statistical data-filtering method[J]. *International Journal of Green Energy*, 2020, 17(7):382-406.
- [31] KINGMA D P, BA J. Adam: A method for stochastic optimization[J]. *arXiv*, 2014, cs.LG: 1412.6980.