

基于混合输入神经网络的 Φ -OTDR 系统模式识别方法李笑¹, 高毅^{1*}, 吴昊², 王道宇¹¹武汉数字工程研究所信息电子部, 湖北 武汉 430202;²华中科技大学下一代互联网接入系统国家工程实验室, 湖北 武汉 430074

摘要 相位敏感光时域反射仪(Φ -OTDR)已被广泛应用于周界安防以及轨道交通和管道监测等动态传感领域,进一步提升振动信号识别准确率对异常事件及时报警具有重要意义。针对长距离相干探测相位解调 Φ -OTDR易受干涉衰落影响而导致误报率较高的问题,笔者提出了基于强度和相位信号混合输入的模式识别方法。所提方法使用多层感知模块提取强度信号中的衰落噪声特征,采用常规一维卷积神经网络作为对照模型。实验结果表明:使用强度和相位作为混合输入的模型对人工敲击、机械挖掘、人为行走和跳跃等4种事件的平均识别准确率可以达到98.8%,优于仅使用相位信号作为输入的一维卷积神经网络模型的平均识别准确率96.1%。采用强度信号辅助相位信号检测的模式识别方法可进一步提高 Φ -OTDR的模式识别准确率。

关键词 光纤光学; 光纤传感; 相位敏感光时域反射仪; 混合神经网络; 模式识别; 深度学习

中图分类号 TN247

文献标志码 A

DOI: 10.3788/CJL221385

1 引言

基于相位敏感光时域反射仪(Φ -OTDR)的分布光纤传感技术具有测量精度高、响应速度快、监测距离长和抗电磁干扰等优点,已被广泛应用于周界安防、轨道交通和油气管道监测等领域。施加在光纤上的扰动信号会导致光纤折射率变化,进而导致光程和探测光相位发生变化。依据解调方式的不同, Φ -OTDR可分为强度解调型和相位解调型。由于散射信号强度随扰动信号强度不是线性变化的,因此,强度解调型 Φ -OTDR通常仅被用于定性测量。理论上,光纤扰动点两端的散射光相位差与扰动信号强度之间存在线性关系,因此,相位解调型 Φ -OTDR可以实现扰动信号的定量还原,展现出了显著的性能优势^[1-3]。随着激光器和相干检测技术的发展, Φ -OTDR的系统结构由直接探测方式逐渐发展为相干探测方式。基于相干探测的相位解调型 Φ -OTDR能够显著提高检测灵敏度和接收信噪比,可将传感距离拓展至50 km以上^[4-6]。在实际应用中,需要针对特定的振动事件对光纤全线进行实时检测和预警,但由于扰动信号种类繁多,光纤传感距离较长,末端信号的信噪比较低,光纤敷设环境复杂,相干探测系统的干涉衰落现象可导致传感信号严重失真,因此,研究高准确率、高实时性、易部署的 Φ -OTDR系统模式识别方法非常重要^[7-9]。

传统的 Φ -OTDR模式识别算法主要基于统计学原理,通过提取扰动信号的时频特征,设计特殊的分

类器来实现信号的检测和分类。由于提取过程较为繁琐,而且信号特征的设计有较强的依赖性,因此,传统的 Φ -OTDR模式不适用于复杂环境下的系统应用。深度学习是当前 Φ -OTDR信号识别的研究热点^[10-11]。Shi等^[12]使用卷积神经网络对背景噪声、行走、跳跃、敲击和机械挖掘等5种事件类型进行了分类检测,平均分类准确率为96.67%。Chen等^[3]比较了一维卷积神经网络(1DCNN)与二维CNN(2DCNN)在相同原始信号输入下的性能差异,实验结果显示一维CNN的平均识别准确率要显著优于二维CNN(95% VS 89.1%)。Bai等^[13]提出了一种卷积长短期神经网络(LSTM),并采用该网络在33 km长油气管道光纤上实现了入侵信号的检测和识别,平均识别准确率为97.2%。张耀鲁等^[14]提出了一种Wavenet深度神经网络,并采用该网络对人工模拟的脚踩、手拍、棒击三种事件实现了99.85%的识别准确率,但其实验传感距离仅为4.4 km,无法体现 Φ -OTDR长距离监测的优势。Wu等^[15]在34 km长光纤上采用多尺度卷积神经网络和隐马尔可夫模型对4种事件进行识别,识别率达到了98.2%,实现当前长距离 Φ -OTDR模式识别的最高准确率。

直接探测强度解调型 Φ -OTDR受限于信号的信噪比,传感距离通常在25 km以下。长距离 Φ -OTDR系统主要采用相干探测和相位解调技术。由于相位信号可以实现扰动信号的线性还原,现有的相干探测相位解调型 Φ -OTDR系统的模式识别算法大多采用相

收稿日期: 2022-11-01; 修回日期: 2022-11-30; 录用日期: 2022-12-15; 网络首发日期: 2023-02-07

通信作者: *gaoyi709@163.com

位信号输入,并结合使用傅里叶变换、小波变换等时频特征提取方法。然而,相干探测系统干涉衰落现象会导致强度信号的信噪比严重恶化,进而导致解调相位异常,引起误报。最常用的消除干涉衰落的方法主要有频率多样性、啁啾脉冲等频域调控技术,系统硬件较为复杂。笔者提出了强度和相位二维信号混合输入的模式识别方法,该方法不会增加硬件的复杂度,在现有神经网络模型的基础上有效降低了干涉衰落对模式识别准确率的影响。为验证所提方法对模式识别准确度的提升效果,综合考虑算法实时性和易部署性,采用文献[3]所提1DCNN作为基础模型对照,同时使用多层感知模块(MLP)提取强度信号中的衰落噪声特征,构建混合输入神经网络模型。实验中,以光纤逐点的相位和强度信号在1s内的时间序列向量作为检测网络的输入,仅使用最大最小函数和tanh函数对输入数据进行归一化预处理。实验结果表明:对于模拟的4种扰动事件,混合输入模型的平均识别准确率可达98.8%,优于仅采用相位信号输入的1DCNN模型的检测结果(96.1%)。这一结果表明采用强度和相位二维

信号混合输入的模式识别方法可以进一步提高长距离 Φ -OTDR系统的识别准确率。

2 信号采集与预处理

2.1 Φ -OTDR 基本架构

Φ -OTDR通过探测传感光纤中背向瑞利散射光(RBS)的相位变化来感知外界的扰动信息。当光纤状态稳定时,RBS相位也近似保持一致;当光纤的某一段受到外界振动的影响时,相应位置处的RBS相位也会发生变化,且变化的起伏与振动源强度高度相关。长距离 Φ -OTDR通常采用相干探测相位解调方式,系统结构如图1所示。高相干的超窄线宽激光经过耦合器分光,其中一路输入到声光调制器(AOM)中进行脉冲调制并作为传感信号,另一路作为相干检测的本征参考光。AOM输出的调制脉冲光被掺铒光纤放大器(EDFA)放大后,通过光环行器注入到传感光纤中。反射回来的瑞利散射信号与本征光耦合拍频,经平衡探测器(BPD)转换为电信号后被数据采集卡(DAQ)接收处理。

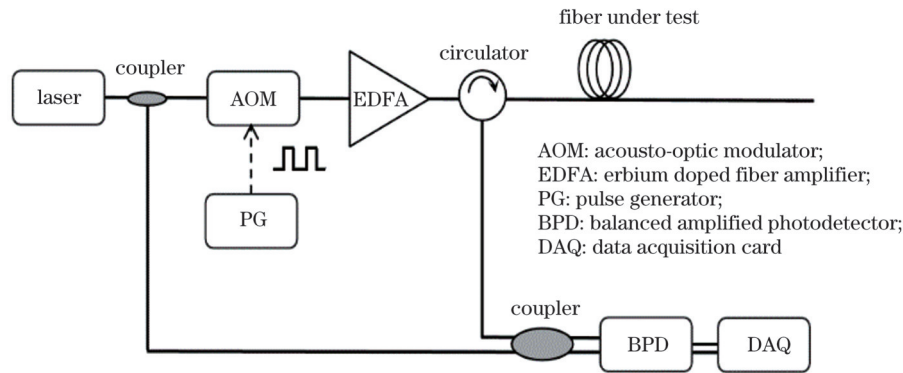


图1 Φ -OTDR系统结构图

Fig. 1 Structure diagram of Φ -OTDR system

忽略噪声的影响,BPD输出的拍频信号可以简化为

$$I(t) = A_{IF}(t) \cos[\Delta\omega t + \varphi(t)], \quad (1)$$

式中: $A_{IF}(t)$ 为 t 时刻信号的幅度信息; $\Delta\omega$ 为AOM引入的频率差; $\varphi(t)$ 为信号的相位信息。对于分布式光纤传感器,不同时刻 t 对应测试光纤上的不同位置。采用希尔伯特变换对采集的信号进行幅度和相位解调,即

$$A_{IF}(t) = \sqrt{I^2(t) + H[I(t)]^2}, \quad (2)$$

$$\varphi(t) = \arctan\left\{\frac{H[I(t)]}{I(t)}\right\}, \quad (3)$$

式中: $H[\cdot]$ 表示希尔伯特变换。幅度信息通过求解原信号与希尔伯特变换后信号的均方根得到。相位信息通过求解希尔伯特变换后的信号与原信号比值的反正切,再经过解卷绕得到。为减小激光器相位噪声的影响,对相位信息在距离上计算差分相位。差分相位可

以反映相位信息的动态变化,实现光纤扰动信号的还原,计算公式为

$$\Delta\varphi(t) = \varphi(t) - \varphi(t + \tau), \quad (4)$$

式中: τ 为差分时延,其取值通常与脉冲宽度一致。由于相干衰落的影响,瑞利散射强度 $A_{IF}(t)$ 不可避免地存在极小值点,叠加探测器强度噪声后,再经过式(3)和式(4)进行相位解调,解调结果就会出现异常值。如图2所示,在无扰动情况下,28.4 km处的RBS强度由于干涉衰落而出现了低于噪声水平的极小值。经过相位解调得到的差分相位在28.4 km附近出现了两个相位剧烈变化的点。若仅采用相位信息进行事件模式识别,通常很难区分干涉衰落引起的相位跳变和由实际扰动引起的跳变,从而导致事件的误报。然而,干涉衰落点在强度上会显著表现为强度极小值点,因此强度信号可以辅助鉴别此种事件,提升事件模式的识别准确率。




图2 无扰动场景下相干衰落导致的相位变化。(a)瑞利散射强度曲线;(b)解调后的相位曲线

Fig. 2 Phase change caused by coherent fading without fiber disturbance. (a) RBS intensity trace; (b) phase trace after demodulation

2.2 数据采集

图1所示为搭建的 Φ -OTDR传感系统。测试光纤由3段光纤组成,分别为25 km的室内传输光纤、30 m的室外传感光纤和5 km的室内传输光纤,其中30 m传感光纤铺设在地下0.5 m深度处,并在附近分别模拟扰动事件的发生。在入纤端口采用可调光衰减器(VOA)来改变信号的信噪比,模拟扰动事件发生在光纤沿线的不同位置。VOA的衰减值范围为1 dB~7 dB。实验中按照式(1)~(4)采用希尔伯特变换法进行强度和相位信号的解调,同时获得整条光纤沿线的差分相位和强度信息。将各点的差分相位和强度信息按照时间顺序组合,即可得到对应的时空图。图3是得到的模拟敲击事件的相位时空图,可以看到在敲击点附近的相位随着敲击对光纤的扰动产生了剧烈变化。




图3 人工敲击传感光纤引起的相位瀑布图

Fig. 3 Three-dimensional map of phase caused by beating fiber

实验模拟的事件类型和样本数量如表1所示。背景噪声表示无扰动情形下相位波动均方根超过0.5 rad的异常事件,包含大量低信噪比情况下发生的干涉衰落异常;人工敲击表示人为使用工具锤敲打传感光纤地表附近,敲打频率在1 Hz左右;机器挖掘表示使用机械电钻在地表附近作业,频率约为10~100 Hz;人为行走和跳跃表示在传感光纤沿线上方地表的行走和

跳跃。

表1 样本采集种类和数量

Table 1 Type and quantity of the samples

Event type	Sample size	Event label
Background noise	5400	0
Human beating	7620	1
Machine excavation	5130	2
Human walking	5070	3
Human jumping	5040	4

实验中各点差分相位的大小与差分前后两点的强度值有关,差分时延为200 ns,对应的差分长度约为20 m。提取差分点对1 s内的强度序列并将其分别记为 $\{A_1(k), k=1, 2, 3, \dots\}$ 和 $\{A_2(k), k=1, 2, 3, \dots\}$,取两者中每时刻的较小值 $A = \min(A_1, A_2)$ 作为后续分类模型的强度输入数据。将逐点1 s内的差分相位时间序列作为模型的相位输入。实验采用的脉冲频率为1 kHz,强度和相位输入均为 1×1000 的一维向量。由于光纤不同位置处的强度响应差异较大,且与相位响应不在一个量级上,因此需要进行归一化处理。首先将强度数据转换为信噪比数据并取对数,即

$$R_{\text{SNR}} = \lg\left(\frac{A}{N_s}\right), \quad (5)$$

式中: A 表示输入的原始强度向量; N_s 表示无脉冲输出时采集到的噪声数据的均值; R_{SNR} 为表示得到的信噪比数据。然后采用tanh函数对信噪比数据进行归一化。tanh函数仅对 $[-2, 2]$ 内的输入数据较为敏感,适用于信噪比数据的归一化处理,归一化后的数据取值范围为 $[-1, 1]$ 。最后采用最大最小归一化方法对相位数据进行归一化处理,即

$$P_n = \frac{P - P_{\min}}{P_{\max} - P_{\min}}, \quad (6)$$

式中: P 表示输入的原始相位向量; P_{\min} 和 P_{\max} 分别表示该向量的最小值和最大值; P_n 为最大最小归一化后得到的最终相位向量,取值范围为 $[0, 1]$ 。

3 基于混合输入神经网络的模式识别

3.1 分类模型的构建与优化

神经网络已被广泛应用于 Φ -OTDR 系统的模式识别中,常用的神经网络模型有卷积神经网络(CNN)、递归神经网络(RNN)、长短期记忆神经网络(LSTM)^[11]。由于 Φ -OTDR 系统散射信号的强度不随扰动信号呈线性变化,且扰动点两端的散射光相位差与扰动信号存在线性关系,因此,现有的相位解调型 Φ -OTDR 的模式识别通常将差分相位信号作为模型网络的输入。然而,相干探测系统的干涉衰落现象会导致强度信号的信噪比严重恶化,进而导致衰落点的解调相位出现异常,若仅采用相位信息进行检测就会导致事件的误报。如 2.1 节所述,干涉衰落点的强度信息会表现为明显的极小值点,特征较为显著。因此,笔者提出了基于强度和相位二维信号混合输入的模式识别方法,在

现有神经网络模型的基础上,通过提取强度信号中的衰落噪声特征,辅助相位信号进行事件检测。为验证二维信号混合输入方法的有效性,综合考虑算法复杂度和部署的难易程度,选用文献[3]提出的 1DCNN 模型作为基础模型,构建二维信号混合输入的深度学习(HDNN)。HDNN 包含 1DCNN 模块和多层感知(MLP)模块,改进后的网络模型结构如图 4 所示。相位向量 input1 输入到 1DCNN 模块中,经过共计 12 层的卷积层(Conv1D)、激活层(Activation)和池化层(Pooling)后(作为 CNN 模块的输出)输入到一个全连接层(FC),其中激活层采用线性整流函数(ReLU),池化层采用最大值池化;强度向量 input2 输入到 MLP 模块中,经过 2 层 FC 和 1 层 tanh 函数激活后(作为 MLP 模块的输出),连接到一个 FC 层。CNN 模块和 MLP 模块的输出经过联合后输入到连续 2 层 FC+ReLU 进行压缩激活,之后经过柔性最大值层(Softmax)进行分类输出。

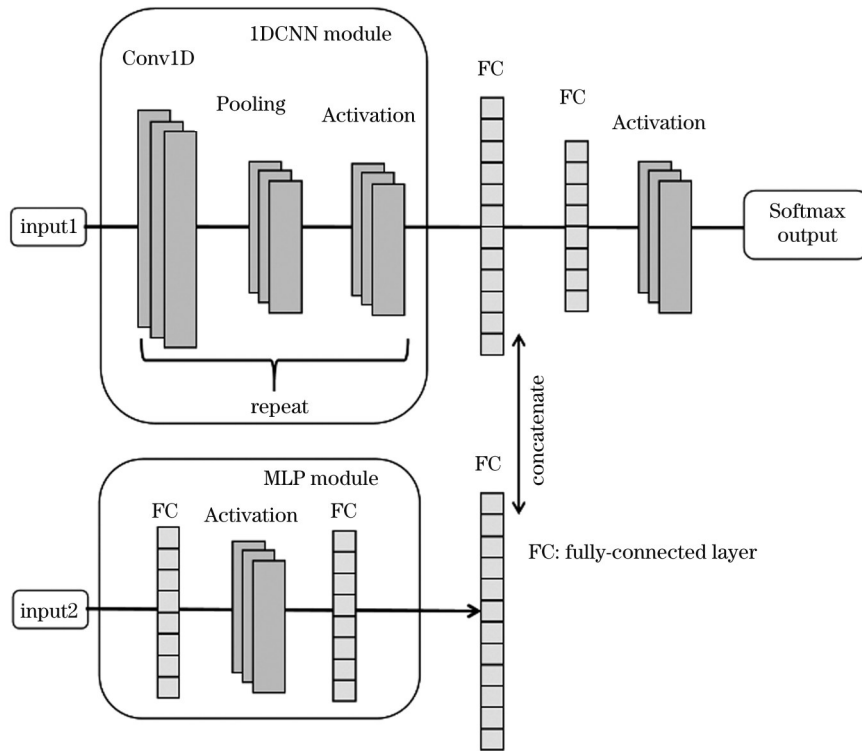


图 4 网络整体结构

Fig. 4 Structure of overall network

为了验证混合输入神经网络对模式识别准确度的提升效果,单独采用相位信号向量和 1DCNN 模块构建对照模型,模型参数与混合输入模型基本一致,仅在 FC 层的输出之后增加一轮 FC 层和 ReLU 层,以调整输出参数。

3.2 实验结果及对比

网络训练的初始学习率为 1×10^{-3} ,采用自适应矩估计(Adam)优化算法来更新网络参数。每个训练批次的大小为 128,并随机打乱顺序。采集样本按照标签种类随机分割成训练集和验证集,分割比例为 2:1。

训练集包含约 18000 组数据。训练平台为 TensorFlow2.6,共计训练 60 轮。训练损失函数选用交叉熵函数。训练设备为英伟达 GTX 1660Ti GPU,包括 1536 个 CUDA 核心,训练总耗时约为 20 min。模型的训练过程如图 5(a)、(b)所示,损失曲线和精度曲线经过多轮迭代后迅速收敛。两个模型由于结构相对一致,因而收敛速度比较接近,并最终均能在训练集中实现 100% 的分类准确率。

经过多轮训练得到最终的两种检测模型,使用验证集数据测试模型的分类效果。验证集包含约 9000

组数据。分别得到了两种模型的混淆矩阵,矩阵中的百分比为查全率。如图 5(c)所示,仅采用相位信号输入的 1DCNN 对标签为 2 的机器挖掘事件的识别精度最高,达到了 99.1%。由此可见,机械挖掘事件与其他三种人工扰动事件在相位响应上存在明显差异。模型对人工敲击事件的识别结果最差,分类精度仅为 91.0%,且模型将 8.7% 的人工敲击事件识别成标签类型为 0 的背景噪声事件。同时,模型对背景噪声的识别精度为 97.6%,而此类的全部错误分类均是将其识

别成人工敲击事件,这表明背景噪声引起的异常响应与人工敲击的响应较为相似。如图 5(d)所示,采用相位信号和强度信号混合输入的 HDNN 模型对背景噪声和人工敲击事件的识别率最高,均达到了 99.4%,识别率相比对照模型显著提升。HDNN 模型对人工行走事件的识别结果均不低于 97.4%,与 1DCNN 模型结果较为一致,且 HDNN 模型对人为行走事件的全部错误分类是将其识别成机械挖掘(0.7%)和人为跳跃(1.9%),误判的种类和比例也与对照模型较为一致。

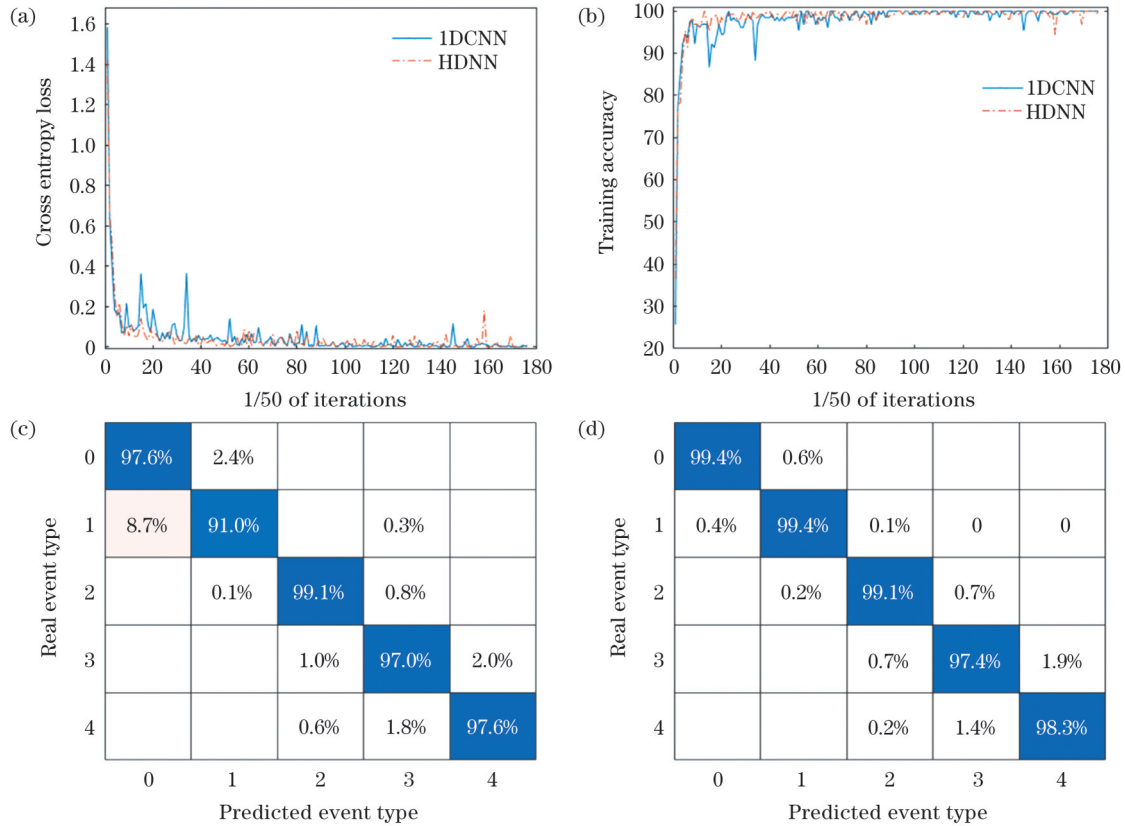


图 5 两种模型的训练过程和验证结果。(a)训练交叉熵损失曲线;(b)训练准确率曲线;(c) 1DCNN 模型的验证结果;(d) HDNN 模型的验证结果

Fig. 5 Training process and verification results of the two models. (a) Cross entropy loss for the training processes; (b) training accuracy traces; (c) validation results of 1DCNN model; (d) validation results of HDNN model

按照标准的 F -score 和准确率分别统计两种模型对 5 种类型事件的检测性能,结果如表 2 所示。对于背景噪声和人工敲击数据,HDNN 模型相比 1DCNN 模型在 F -score 上分别提升了 6.3 个百分点和 5 个百分点。这表明 HDNN 模型可以较好地改善此种类型的识别错误。而对于其他三种类型的事件,两种模型在 F -score 上基本持平。这三种类型事件的错误分类主要是在标签 1~4 之间的误判,这是因为强度信息并不具备对事件响应的线性还原能力,无法优化此种类型事件的识别错误,所以两种模型对这三种类型事件的表现结果比较接近。两种模型对 5 种类型事件识别的平均准确率为 98.8% (HDNN 模型) 和 96.1% (1DCNN),说明利用相位信号和强度信号的 HDNN 模型能够更好地识别干涉衰落引起的异常事件,相比

表 2 不同类型事件的 F -score 和准确率

Table 2 F -score and accuracy of different types of events

Model	Event type	F -score / %	Average accuracy / %
1DCNN	Background noise	93.1	96.1
	Human beating	94.4	
	Machine excavation	98.8	
	Human walking	96.9	
	Human jumping	97.8	
HDNN	Background noise	99.4	98.8
	Human beating	99.4	
	Machine excavation	99.0	
	Human walking	97.6	
	Human jumping	98.2	

利用单一相位信号输入的 1DCNN 模型具有更高的模式识别能力。

4 结 论

为进一步提高 Φ -OTDR 模式的识别准确率,针对长距离相干探测相位解调型 Φ -OTDR 易受干涉衰落影响而导致误报率较高的问题,笔者提出了强度和相位二维信号混合输入的模式识别方法,该方法可有效降低干涉衰落对模式识别准确率的影响。为验证所提方法对模式识别准确率的提升效果,采用 1DCNN 作为基础对照模型,同时使用多层感知模块提取强度信号构建混合深度神经网络。实验中,针对室外地理光缆进行了人工敲击、机械挖掘、人为行走和跳跃等 4 种扰动事件的模拟。分别使用最大最小函数和 tanh 函数对采集的光纤扰动点的相位和强度在 1 s 内的时间序列信号进行归一化处理,并将归一化结果作为检测网络的输入。在对比验证中,混合深度神经网络(HDNN)的平均识别准确率达到 98.8%,优于仅使用相位信号输入的 1DCNN 模型的平均识别准确率 96.1%,这表明强度和相位信号联合检测的方法可以显著提升 Φ -OTDR 模式的识别准确率。

参 考 文 献

- [1] 张旭莘,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.
- [2] 杨震,封皓. 基于深度学习的 Φ -OTDR 输油管道入侵监测研究[J]. 激光与光电子学进展, 2022, 59(8): 0806001.
Yang Z, Feng H. Oil pipeline intrusion monitoring based on deep learning of Φ -OTDR[J]. Laser & Optoelectronics Progress, 2022, 59(8): 0806001.
- [3] Chen J P, Wu H J, Liu X R, et al. A real-time distributed deep learning approach for intelligent event recognition in long distance pipeline monitoring with DOFS[C]//2018 International Conference on Cyber-Enabled Distributed Computing and Knowledge Discovery (CyberC), October 18–20, 2018, Zhengzhou, China. New York: IEEE Press, 2018: 290-2906.
- [4] Wang C, Shang Y, Liu X H, et al. Interferometric distributed sensing system with phase optical time-domain reflectometry[J]. Photonic Sensors, 2017, 7(2): 157-162.
- [5] 付群健,于森,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): 0722001.
Fu Q J, Yu M, Chang T Y, et al. Summarization of pattern recognition method for phase sensitive optical time domain reflecting system[J]. Infrared and Laser Engineering, 2018, 47(7): 0722001.
- [6] 林圣淘,王子南,熊吉,等. 光纤瑞利散射传感抗干涉衰落技术研究进展[J]. 激光与光电子学进展, 2021, 58(13): 1306008.
Lin S T, Wang Z N, Xiong J, et al. Progresses of anti-interference-fading technologies for Rayleigh-scattering-based optical fiber sensing[J]. Laser & Optoelectronics Progress, 2021, 58(13): 1306008.
- [7] Wang Y, Yuan H Y, Liu X, et al. A comprehensive study of optical fiber acoustic sensing[J]. IEEE Access, 2019, 7: 85821-85837.
- [8] 王辰,刘庆文,陈典,等. 基于分布式光纤声波传感的管道泄漏监测[J]. 光学学报, 2019, 39(10): 1006005.
Wang C, Liu Q W, Chen D, et al. Monitoring pipeline leakage using fiber-optic distributed acoustic sensor[J]. Acta Optica Sinica, 2019, 39(10): 1006005.
- [9] Fan C Z, Li H, Yan B Q, et al. 246 km long distance fiber optic DAS system based on multi-span bidirectional EDFAs and cascaded AOMs[C]//Optical Fiber Communication Conference, March 6–10, 2022, San Diego, California, USA. Washington, D.C.: Optica Publishing Group, 2022: W4D.4.
- [10] 田曼伶,刘东辉,曹晓敏,等. 相位敏感光时域反射仪的信号处理方法综述[J]. 光学精密工程, 2021, 29(9): 2189-2209.
Tian M L, Liu D H, Cao X M, et al. Signal processing methods of phase sensitive optical time domain reflectometer: a review[J]. Optics and Precision Engineering, 2021, 29(9): 2189-2209.
- [11] Kandamali D F, Cao X M, Tian M L, et al. Machine learning methods for identification and classification of events in Φ -OTDR systems: a review[J]. Applied Optics, 2022, 61(11): 2975-2997.
- [12] Shi Y, Wang Y, Zhao L, et al. An event recognition method for Φ -OTDR sensing system based on deep learning[J]. Sensors, 2019, 19(15): 3421.
- [13] Bai Y, Xing J, Xie F, 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.
- [14] 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.
- [15] Chen X, Xu C. Disturbance pattern recognition based on an ALSTM in a long-distance Φ -OTDR sensing system[J]. Microwave and Optical Technology Letters, 2020, 62(1): 168-175.

Mode Recognition Method of Φ -OTDR System Based on Mixed Input Neural Network

Li Xiao¹, Gao Yi^{1*}, Wu Hao², Wang Daoyu¹

¹Department of Information and Electronics, Wuhan Digital Engineering Institute, Wuhan 430202, Hubei, China;

²National Engineering Laboratory for Next Generation Internet Access System, Huazhong University of Science and Technology, Wuhan 430074, Hubei, China

Abstract

Objective Phase-sensitive optical time-domain reflection (Φ -OTDR) has the advantages of high accuracy, fast response speed, long monitoring distance, and anti-electromagnetic interference and has been widely used in dynamic sensing fields such as perimeter

security and railway and pipeline monitoring. For direct detection intensity-demodulation Φ -OTDR, the pulse power is limited by the nonlinear effect, which causes a weak signal-to-noise ratio of the end signal, and its sensing distance is usually less than 25 km. Because the optical phase signal is linearly related to the vibration signal imposed on the fiber and coherent detection can significantly improve the detection sensitivity, the long-distance Φ -OTDR system mainly uses coherent detection and phase demodulation technology. Most coherent detection phase-demodulation Φ -OTDR system model recognition algorithms use phase signal as the input, combined with time-frequency feature extraction methods, such as Fourier transform and wavelet transform. However, interference fading occurs in the coherent detection system, which causes serious deterioration of the intensity signal, resulting in phase demodulation errors and false alarms. Common methods to eliminate interference fading are the frequency diversity, chirped pulses, and other frequency domain regulation technologies, which lead to complex system hardware. Moreover, owing to the variety of the disturbance signals and long sensing distance that results in a low signal-to-noise ratio of the end signal, Φ -OTDR systems suffer from false alarms in practical applications. It is of great significance to further improve the accuracy of the vibration signal identification for the timely detection of abnormal events.

Methods A pattern recognition method based on a coherent detection Φ -OTDR system with mixed intensity and phase signal inputs is proposed, which can effectively reduce the impact of interference fading on the accuracy of event alarms without increasing the hardware complexity. The proposed method uses a hybrid deep neural network (HDNN), which combines a one-dimensional convolutional neural network (1DCNN) and a multi-layer perceptron (MLP), as shown in Fig. 4. The phase and intensity signal vectors are recovered simultaneously using the Hilbert demodulation algorithm. The phase and intensity vectors within a second are simply normalized by the max-min and tanh functions separately and then fed into the model. The model uses MLP to extract the fading noise features of the intensity signal and uses the 1DCNN model as the basic model to extract the disturbance characteristics of the phase signal. After the fusion of two-dimensional features and a classification layer, the model outputs the final detection results.

Results and Discussions A long-distance Φ -OTDR system of more than 25 km was built. An adjustable optical attenuator (VOA) was used to simulate disturbance events occurring at different locations along the fiber, with attenuation of the VOA ranging from 1 dB to 7 dB. Four types of events, such as human beatings, walking, jumping, and machine excavating, are imposed at the outdoor optical cable buried 0.5 m underground. A 1DCNN network with only phase signal input was used as the comparison model. After multiple rounds of training, the experimental results show that the proposed HDNN model with intensity and phase signal inputs can achieve an average accuracy of 98.8%, which is better than the 1DCNN model result of 96.1% with only the phase signal input. Furthermore, comparing the confusion matrix of the two models, the 1DCNN model had the worst recognition accuracy of 91.0% with background noise and human beat events. In contrast, the HDNN model significantly improves the recognition accuracy of the two events to 99.4%. This shows that the interference fading anomalies contained in the background noise can be identified by the HDNN model with additional intensity input. For the other three types of events, the accuracy results of the two models are very close, indicating that the phase signal has a better ability to recover the vibration events than the intensity signal, which is consistent with the previous analysis.

Conclusions Aiming to further improve the event alarm accuracy of the long-distance coherent detection Φ -OTDR system, a pattern recognition method with a mixed input of intensity and phase signals was proposed. To verify the improvement of the proposed method, a 1DCNN network with only the phase signal input was used as the comparison model. A hybrid deep neural network, combining 1DCNN and MLP, was used for the intensity and phase signal mixed-input classification. The model used MLP to extract the fading noise features of the intensity signal and used 1DCNN to extract the disturbance features of the phase signal. The phase and intensity vectors within a second are simply normalized by the max-min and tanh functions separately and then fed into the model. The experimental results show that the proposed HDNN model can achieve an average accuracy of 98.8% for four types of events, including human beatings, walking, jumping, and machine excavation, which is better than the 1DCNN model detection result of 96.1% with only a phase signal input. The method using intensity signal-assisted phase signal detection can further improve the accuracy of Φ -OTDR pattern recognition.

Key words fiber optics; optical fiber sensing; phase-sensitive optical time-domain reflectometer; hybrid neural network; mode recognition; deep learning