

基于多尺度特征融合的 φ -OTDR 系统相似信号识别方法宋文强, 丁哲文^{*}, 毛邦宁, 徐贲, 龚华平, 康娟, 赵春柳^{*}

中国计量大学光学与电子科技学院, 浙江 杭州 310018

摘要 为解决分布式相位敏感光时域反射计系统现有事件识别方法对于相似振动信号识别困难这一问题, 提出了一种基于多尺度特征融合的相似信号识别方法。在该方法中, 原始信号首先通过经验模态分解和小波包分解被分解为不同频率范围内的子信号。随后, 分别提取原始信号和子信号的时频特征和近似熵特征, 并利用主成分分析法对所提取的特征进行融合。最后, 通过构建一个 6 层轻量反向传播 (BP) 神经网络分类器, 训练分类模型并利用测试集验证模型分类度。该方法对小车经过和行走等相似信号的识别准确率可分别达到 98.5% 和 98.0%, 对于敲击和摇晃差异性大的信号的识别准确率可达 100%。相比于直接从原始信号中提取特征并结合时频图的卷积神经网络方式, 所提方法的综合识别准确率分别提高了 8.4% 与 9.0%, 相似信号的识别准确率分别提高了 13.5% 与 12.4%。结果表明, 该方法在保证差异性大的信号的高识别准确率的基础上, 显著提高了相似信号的识别准确率, 对于拓展分布式光纤传感的应用范围有重要的价值。

关键词 光通信; 相位敏感光时域反射计; 时频特征; 近似熵; 多尺度特征融合; 反向传播神经网络

中图分类号 O436

文献标志码 A

DOI: 10.3788/CJL230795

1 引言

相位敏感光时域反射计 (φ -OTDR) 系统是一种前置监测和预警技术^[1], 可以在空间上获取扰动的位置, 在时间上获取扰动的相位信息。该技术具有分辨率高、监测范围广、抗干扰能力强等优点, 在管道安全维护^[2]、入侵预警^[3]、大型设备监测^[4]等领域中已得到广泛应用。然而, 因应用环境的复杂多样, 其在实际使用中仍然面临识别准确率低和稳定性不足等问题。为此, 近年来许多学者提出了基于人工智能的特征提取和模式识别方案, 实现对各类光纤振动传感事件的精准识别和检测。

现有基于人工智能的特征提取和模式识别算法可分为两类: 人工提取特征结合分类器算法的方式和基于端到端深度学习的方式。针对第一类方式, 2017 年, 张俊楠等^[5]利用信号在时域和频域的方差、平均值、均方差和信号功率特征, 并结合支持向量机 (SVM) 算法, 对敲击、浇水和轻度碾压进行模式识别; 2018 年, Sheng 等^[6]利用功率谱密度和能量比作为特征, 并以线性判别分析 (LDA) 作为分类器, 对行走、晃动和钻孔信号进行识别; 2019 年, 刘琨等^[7]使用过零率和支持向量机 (SVM) 算法, 分别对剪切、攀爬、晃动、敲击和无入侵进行识别; 2020 年, Chen 等^[8]使用语音识别中的 Mel 频率倒谱数方法, 结合长短期记忆递归

神经网络 (LSTM), 对行走、挖掘、汽车经过、攀爬和下雨进行识别; 2022 年, 卜泽华等^[9]利用小波包能量比和 SVM 算法, 对敲击、晃动、行走、噪声进行特征提取及识别。上述方案在处理差异性大的信号时表现良好, 但它们的特征提取方法过于单一, 未能将频域尺度和信号特征结合起来。因此, 当信号相似时, 按照上述方案进行特征提取和识别, 系统很容易出现漏报和误报。

针对第二类方式, 2020 年, Shi 等^[10]使用时频图的形态特征结合卷积神经网络 (CNN) 和 SVM 的方法对 8 种不同事件进行识别。2021 年, 喻后聘等^[11]使用一维 CNN 提取输入信号的频域特征, 对剪切、敲击、晃动、风吹及树枝拍打等信号进行识别。2023 年, 王鸣等^[12]使用 LSTM 提取信号轮廓信息, 并结合 CNN 提取时频图的形态特征的模式识别方法, 对噪声、行走、挖掘和电击四类信号进行识别。2023 年, 薛康等^[13]使用时频图和无人机拍摄图片, 并结合 YOLO 算法, 对敲击、摇晃、踢、轰砸和无入侵信号进行识别。端到端深度学习方式使用自动的黑盒方式进行特征提取及模式识别, 但通常要求输入的参数为固定尺寸的二维图像或一维时序序列。对于相似信号, 其转换的二维图片特征和信号本身的序列特征均相似, 因此端到端深度学习的特点决定了其很难识别相似信号。

为解决上述相似信号识别准确率不高和识别困难的问题, 本文提出了一种多尺度特征融合的 φ -OTDR

收稿日期: 2023-05-04; 修回日期: 2023-05-30; 录用日期: 2023-07-11; 网络首发日期: 2023-08-07

基金项目: 国家自然科学基金青年科学基金 (62305319)

通信作者: *clzhao@cjlu.edu.cn; **dingzhewen@cjlu.edu.cn

系统相似信号识别方法。该方法首先从原始信号中提取不同频率尺度下的子信号,然后分别对原始信号和各个子信号进行时频特征和近似熵特征提取,以通过这种多尺度、多特征的方法放大相似信号之间的特征差异。由于多尺度、多特征的方法会造成数据维度的升高,为了降低输入算法的维度,所提方法还利用主成分分析法(PCA)对高维特征进行融合,降低系统的复杂度,提升系统效率。最后,将融合后的特征作为输入变量传入轻量级反向传播(BP)神经网络,实现信号数据的快速处理。

2 多尺度特征融合算法原理

本文提出的基于多尺度特征融合的 φ -OTDR 系

统相似信号识别方法的识别流程如图 1 所示,主要包括信号多尺度分解、多特征提取、特征融合和模式识别等步骤。对于信号多尺度分解和多特征提取,通过经验模态分解(EMD)和小波包分解(WPD)将信号分解为不同频域下的子信号,随后对原始信号和子信号进行多特征提取,可以有效放大相似信号的特征;对于特征融合,多尺度和多特征的方式会造成数据维度的升高,维度过高会使算法识别变得困难,通过特征融合可以在包含特征主要成分的情况下有效降低数据维度;模式识别算法采用 BP 神经网络算法,相较于其他传统类型的神经网络,BP 神经网络具有结构轻量、速度快等优点,因此能够更快地处理信号数据。

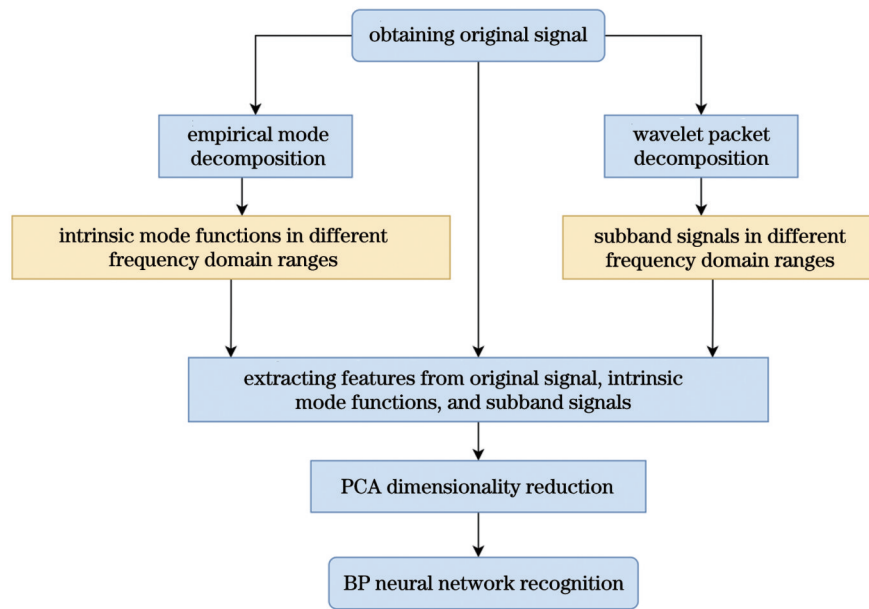


图 1 信号识别方法流程

Fig. 1 Process of signal recognition method

2.1 多尺度分解和多特征提取

在采集到振动信号后,首先使用 EMD 和 WPD 对其进行分解处理,从而获取不同频率下的子信号。EMD 算法能够自动地将原始信号分解成为一系列频率分量的本征模态函数(IMF),这些 IMF 分量是通过递归计算原始数据得出的^[14]。通过计算可以得到若干个 IMF 分量和一个残差函数,以此来准确描述原始信号的特性和频率成分。原始信号与 IMF 分量和残差分量之间的关系为

$$q(t) = \sum_{i=1}^n I_{\text{imf}, i}(t) + r_n(t), \quad (1)$$

式中: t 为时间; $q(t)$ 为原始信号; $I_{\text{imf}, i}(t)$ 为分解后得到的第 i 个 IMF; $r_n(t)$ 为通过分解获得 n 个 IMF 后的振动数据的残余分量。不同的 IMF 包含不同频段的信号特征,通过计算 IMF 和原始信号的 Spearman 相关系数,筛选出信号的主要分量,剔除干扰分量。

而 WPD 可以通过小波变换将原始信号分解为若

干个子频段信号,然后进一步对子频段信号进行分解,得到细粒度更小的子频段信号,重复上述步骤,直到达到预设的分解层数^[14]。在每一层分解过程中,都需要选择合适的小波基函数和分解系数,以在滤除噪声的基础上保留原始信号的重要特征。

在完成多尺度分解后,对原始信号和子信号进行特征提取。在特征提取过程中,单一特征在处理相似信号时极不稳定。为了避免这一问题,本文从两个角度对原始信号和子信号进行多特征提取。第一种角度是利用时域和频域信息的统计学参量,时域和频域特征是 φ -OTDR 系统中常用的经典特征提取方案,具有计算速度快、特征区分度高等优点,可以保证系统的实时性。在该类特征中,选择提取原始信号和子信号的峰峰值、标准差、峭度、偏度、裕度因子、波形因子、脉冲因子、峰值因子和重心频率^[15-16],上述 9 个特征对应的特征标签分别为 feature 1~feature 9。第二个角度是利用近似熵作为评估信号复杂度和规律性的特征,该

特征标签记作 feature 10。近似熵的值受到嵌入维度 (m') 和容忍系数 (r) 的影响, 研究^[17]表明, 在计算采样点数量为 100~5000 的信号复杂度时, 为了包含更多信号及加大不同信号之间的近似熵区分度, 通常取 $m'=2, r=0.25D_{SD}$, 其中 D_{SD} 为序列的标准差。本文单条信号的长度为 2000, 根据上述结论, 本文计算近似熵时取 $m'=2, r=0.25D_{SD}$ 。通过提取原始信号、子信号的这两类特征, 可以得到更加稳定且有区分性的特征值。

2.2 主成分分析法

主成分分析法是一种典型的特征融合工具, 能够将高维数据投射到一个低维的特征空间中, 从而降低数据的复杂度, 同时又不会减少原始数据的内在信息^[18]。首先对原变量进行标准化处理得到 \mathbf{X}^* , 计算 \mathbf{X}^* 的协方差矩阵 $\mathbf{F} = \text{Cov}(\mathbf{X}^*)$; 通过特征方程 $|\lambda_i \mathbf{I} - \mathbf{F}| = 0$ (\mathbf{I} 为单位矩阵), 求得矩阵 \mathbf{F} 的特征值 λ_i ($\lambda_1 \geq \lambda_2 \geq \lambda_3 \geq \dots \geq \lambda_n$) 和相应的正交单位化特征向量 \mathbf{u}_i 。

主成分得分 (Y_i) 的表达式为

$$Y_i = \mathbf{u}_i \mathbf{X}_i^* \quad (2)$$

式中: \mathbf{X}_i^* 为第 i 个原变量的标准化结果。

前 k 个主成分累计贡献率 (Q_k) 为

$$Q_k = \frac{\sum_{i=1}^k \lambda_i}{\sum_{i=1}^n \lambda_i}, k \leq n. \quad (3)$$

为了保证信号的主要信息不丢失, 实验中选取贡献率超过 90% 的前 k 个主成分特征。

2.3 轻量 BP 神经网络

BP 神经网络是一种使用误差反向传播算法的神经网络^[19], 由输入层、隐藏层和输出层组成, 每层包含

着多个节点。BP 算法通过计算实际输出值与期望输出值之间的误差来更新网络的权重和偏置, 从而提高预测准确性。提取原始信号、IMF 分量、小波包子信号的特征, 然后对提取到的特征进行 PCA 融合, 随后送入 BP 神经网络进行识别。

本次实验中使用的数据集是 10000 条 4 分类的信号数据集, 属于较小的数据集, 并且信号在采集过程中不可避免地存在一些噪声, 因此根据样本数据集的特点设计的 BP 神经网络的结构如图 2 所示, 其中 o_1, o_2, o_m (m 为分类类别数) 为对应 $\mathbf{X}_1, \mathbf{X}_2, \mathbf{X}_n$ 的输出参数, \max 代表选择 $o_1 \sim o_m$ 中的最大值对应的类别作为结果, y 为输出结果。6 层 BP 神经网络包括输入层、5 个隐藏层和输出层。输入层为 33 维输入特征, 输出层为 4 分类输出, 输出层采用 Softmax 函数作为激活函数, 网络损失函数选择均方根误差函数。学习率设置为 0.001, 其可以防止过拟合, 加快模型的收敛。5 层隐藏层参数如表 1 所示, 其中隐藏层 2~隐藏层 5 (hidden 2~hidden 5) 的随机丢弃 (dropout) 比例均设置为 0.2。




图 2 BP 神经网络结构图

Fig. 2 BP neural network structure

表 1 隐藏层参数

Table 1 Hidden layer parameters

Hidden layer	Number of neurons	Activation function	Optimization method	Overfitting mitigation method
Hidden 1	256	ReLU	Adam	L1 regularization
Hidden 2	128	ReLU	Adam	Dropout
Hidden 3	64	ReLU	Adam	Dropout
Hidden 4	64	ReLU	Adam	Dropout
Hidden 5	64	ReLU	Adam	Dropout

3 原始数据采集及分析

3.1 原始数据采集

实验使用自制的 φ -OTDR 系统, 其具体光路图如图 3 所示。光源使用频率为 3 kHz 的超窄线宽激光器 (NLL), 传感光纤使用单模光纤, 两个耦合器 (coupler) 的耦合比分别为 90:10 和 50:50。NLL 发出的光经过耦合比为 90:10 的耦合器, 并通过声光调制

器 (AOM) 调制产生 8×10^7 Hz 的光脉冲移频。脉冲光经过掺铒光纤放大器 (EDFA) 放大功率, 并经环形器与传感光纤连接。平衡光电探测器 (BPD) 接收由耦合比为 50:50 的耦合器产生的拍频信号, 将其从光信号转换为电信号进行处理。最后由数据采集卡 (DAQ) 以 $500 \text{ MSa} \cdot \text{s}^{-1}$ 的采样频率采集记录数据, 完成整个过程。其中脉冲重复频率设置为 5 kHz, 脉宽为 100 ns, 系统空间分辨率为 10 m。

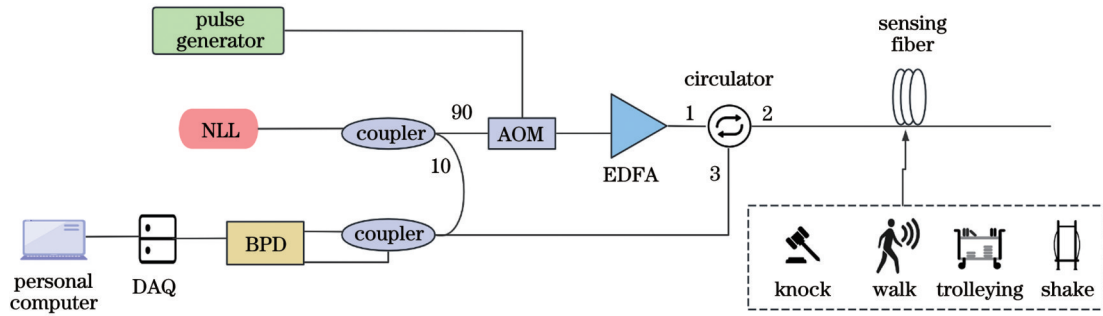


图 3 φ -OTDR 系统结构图

Fig. 3 Diagram of φ -OTDR system structure

在实验中,我们在传感光纤附近施加敲击(knock)、小车经过(trolleying)、人行走(walk)和光缆摇晃(shake)等 4 种类型的振动事件。在光缆上放置一块边长约为 0.5 m 的木板,并使用一个手锤对木板进行敲击,得到敲击信号。使一辆质量约为 50 kg 的四轮推车在光缆上作匀速运动,得到小车经过信号。使一个体重为 60 kg 的实验者在光缆上行走,步距为 1 m,得到

行走信号。而摇晃信号则是将光纤固定在栅栏上,使用较快的速率晃动栅栏得到的。为使实验结果具有连续性和准确性,每组事件均进行了 250 次连续重复采集,共得到了 1000 组信号。实验环境如图 4(a)所示,振动信号定位图以晃动信号为例,如图 4(b)所示。

采集信号经最大-最小归一化后的时域波形如图 5 所示,对于敲击信号,信号幅值在达到最高点后随着时





图 4 实验环境和定位图。(a)实验环境;(b)晃动信号定位图

Fig. 4 Experimental environment and location diagram. (a) Experimental environment; (b) shake signal location diagram

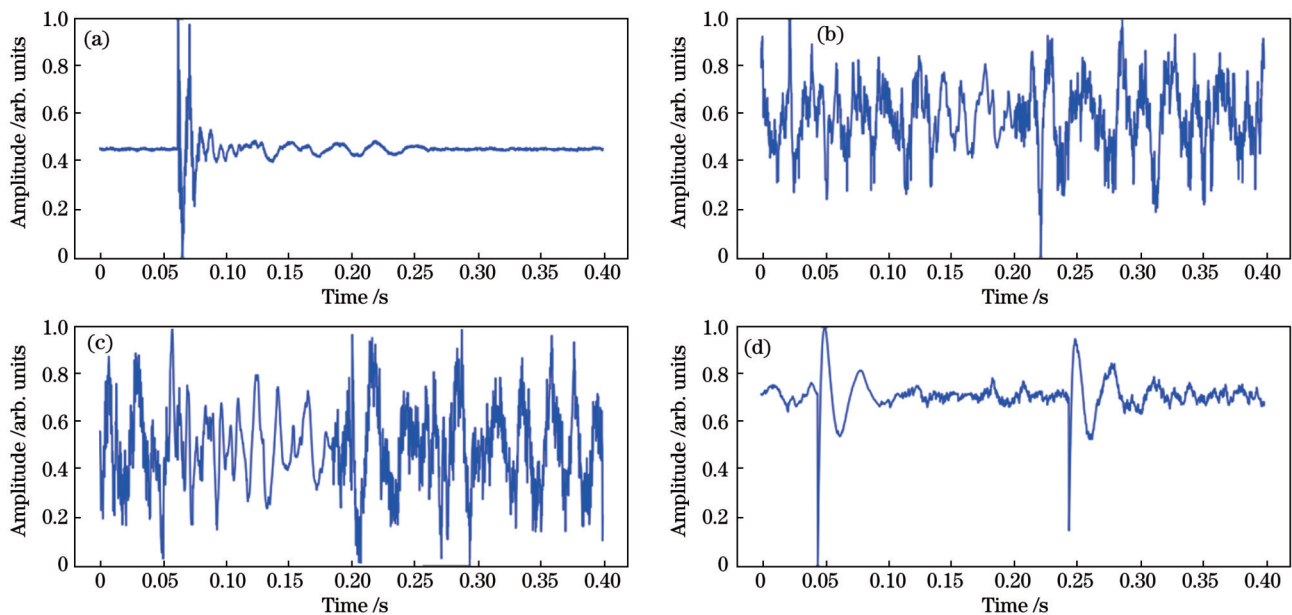


图 5 四种状态下的时域波形图。(a)敲击;(b)小车经过;(c)行走;(d)晃动

Fig. 5 Time-domain waveforms for four states. (a) Knock; (b) trolleying; (c) walk; (d) shake

间的推移呈现衰减的趋势。对于小车经过和人行走信号,由于小车在传感位置匀速行驶,行人在传感位置匀速步行,故信号幅值开始较高,之后降低,最后再次升高,降低幅值对应着小车通过和行人离地的时间点。而对于摇晃信号,其具有两个幅值突出点,分别对应向前和向后摇晃的施力时间点。

3.2 原始数据样本扩充

为了丰富样本数量,同时保持振动信号的连续性,本实验采用数据窗口移位技术扩充原有数据样本,具体分割方式如图 6 所示。设信号的总长度为 L , 数据样本 (data sample) 长度为 l , 振动信号以某一偏移量 (k') 进行分割, 则重叠部分 (overlapping parts) 的





图 6 滑动窗口分割信号

Fig. 6 Sliding window split signal



数据长度为 $l-k'$ 。数据增强后样本集扩充的倍数 (β) 为

$$\beta = \frac{l(L-l+k')}{Lk'} \quad (4)$$

本文以晃动信号为例,采集到 250 条数据,单条数据的样本长度为 2000,所以信号的总长度 $L=500000$, 实验中偏移量为 $k'=200$ 。数据增强后,总体数据集的规模扩增至 10000 条,其中敲击、小车经过、行走和晃动信号各为 2500 条。数据增强使得样本数量得到丰富,不仅缩短了人工采集信号的时间,还避免了小样本带来的识别误差。

3.3 相似信号分析

在完成上述步骤后,对扩充后的数据进行多特征提取,提取到的特征如图 7 所示。从图 7 可以看出,对原始信号进行多特征提取后,图 7(a)、(d) 所示的敲击和晃动信号的 feature 1~feature 10 有较显著差异,但图 7(b)、(c) 所示的小车经过和人行走之间的 feature 1~feature 10 特征之间的区分度明显不够,特征差值均小于 0.1。在这种情况下,如果直接使用基于特征的模式识别算法,例如支持向量机、BP 神经网络等算法,将很难准确区分这些不同的信号。




图 7 原始信号的多特征。(a) 敲击; (b) 小车经过; (c) 行走; (d) 晃动

Fig. 7 Multi-features of original signals. (a) Knock; (b) trolleying; (c) walk; (d) shake

为进一步说明信号的相似性,使用傅里叶变换将小车经过和人行走的信号转化为常用于 CNN 识别的时频图,时频图结果如图 8 所示。图 8(a)、(d) 所示的敲击和晃动信号的时频图有较显著差异,但图 8(b)、(c) 所示的小车经过和行走的时频图之间的区分度明显不够。而 CNN 等算法都是基于图像特征,因此使用时频图结合端到端图像算法也很难区分这类相似信号。

4 多尺度特征融合算法结果

4.1 多尺度分解

本实验为了更准确地提取和放大相似信号的特征,首先使用 EMD 方法对实验数据进行分解,得到 8 个 IMF 和一个残差函数。计算各个 IMF 与原信号间的 Spearman 相关系数,具体结果如图 9 所示。根据统计学相关概念,相关系数低于 0.2 为弱相关^[20-21]。本文采集到的样本数据经过 EMD 后,95% 以上的数据样

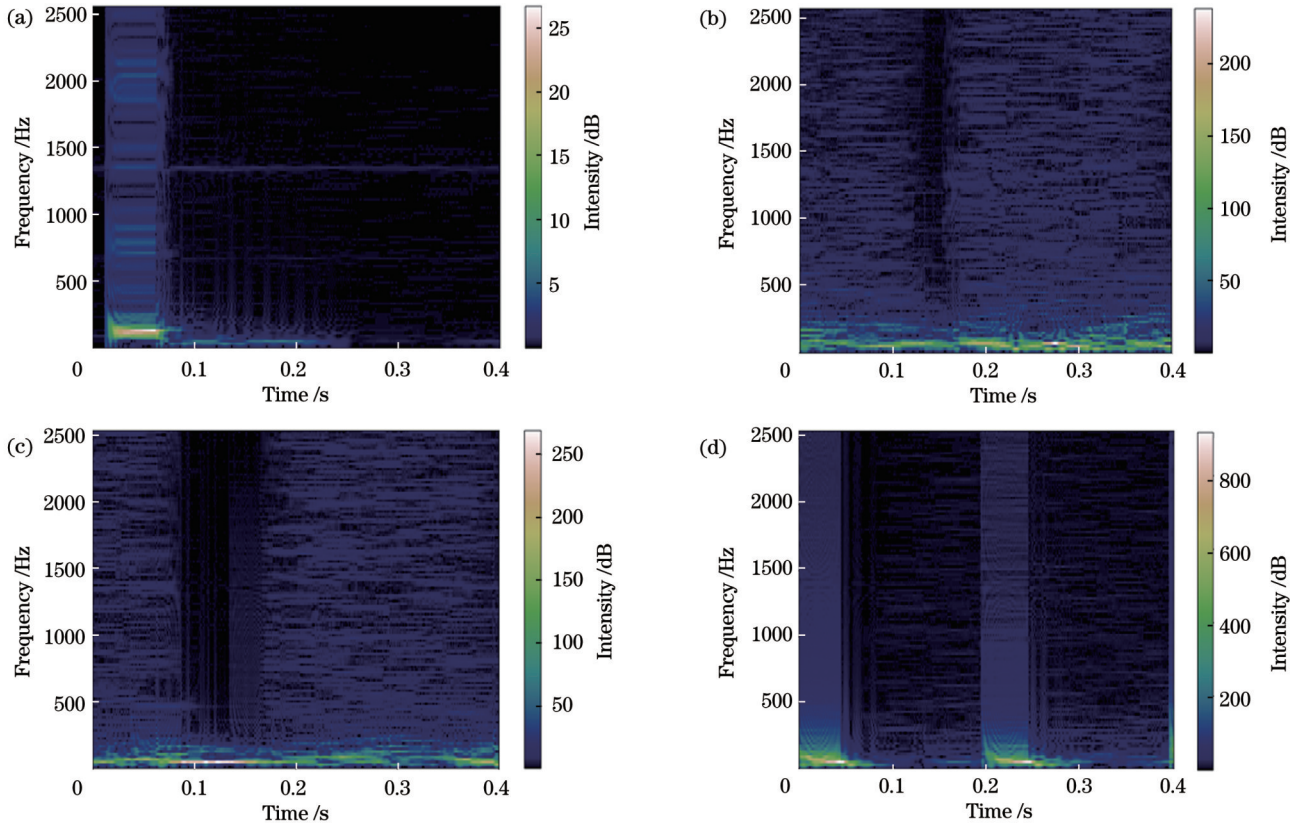


图 8 时频图。(a)敲击;(b)小车经过;(c)行走;(d)晃动

Fig. 8 Time-frequency diagrams. (a) Knock; (b) trolleying; (c) walk; (d) shake

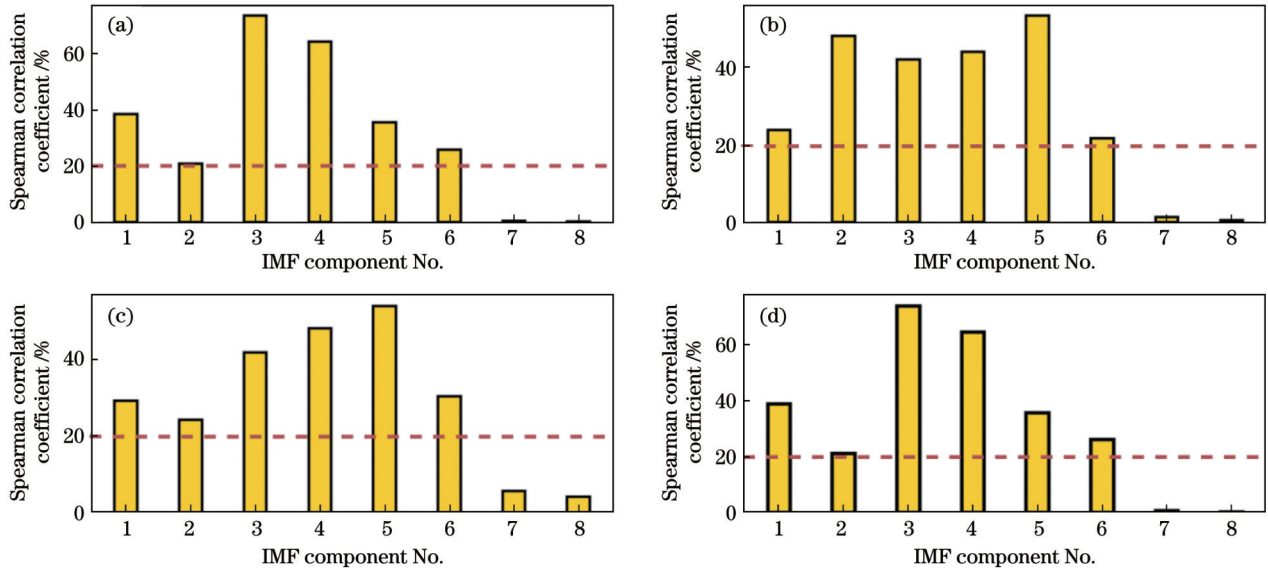


图 9 IMF 与原信号间的相关系数。(a)敲击;(b)小车经过;(c)行走;(d)晃动

Fig. 9 Correlation coefficient between IMF and original signal. (a) Knock; (b) trolleying; (c) walk; (d) shake

本只有前 6 个 IMF 分量的相关系数高于 0.2,因此选取前 6 个 IMF 分量 (IMF1~IMF6) 进行后续特征提取。EMD 的频率排布顺序是从低到高且实验中入侵信号多存在于中低频,对于其余少量维度不统一的数据,为了保证后续算法输入数据维度相同,其 IMF 分量同样选取相关系数高于 0.2 的前 6 个分量。

利用 WPD 对信号进行频域分解,选择 Dmeyer 小

波作为小波母函数,分解层数设定为 8 层。选择信息熵作为代价函数,即

$$M = - \sum_{s \in Z} |u_s|^2 \text{lb} |u_s|, \quad (5)$$

式中: Z 为整数集; u_s 为小波包分解系数; s 为系数编号。选择分解得到的前 4 个子频带信号 ($u_1 \sim u_4$), 从中提取信号特征参数。每条原始信号数据被上述两种分解方

式分解为 10 个子信号,以行走信号的实验数据为例,其 EMD 和 WPD 结果的时域图如图 10 所示。可以看出,EMD 和 WPD 后的子信号具有从低频到高频的多

尺度特性,且每段子信号包含原始数据主要频带范围内的部分信息,分解有助于放大不同信号之间的特征差距,方便后续的多维度特征提取。

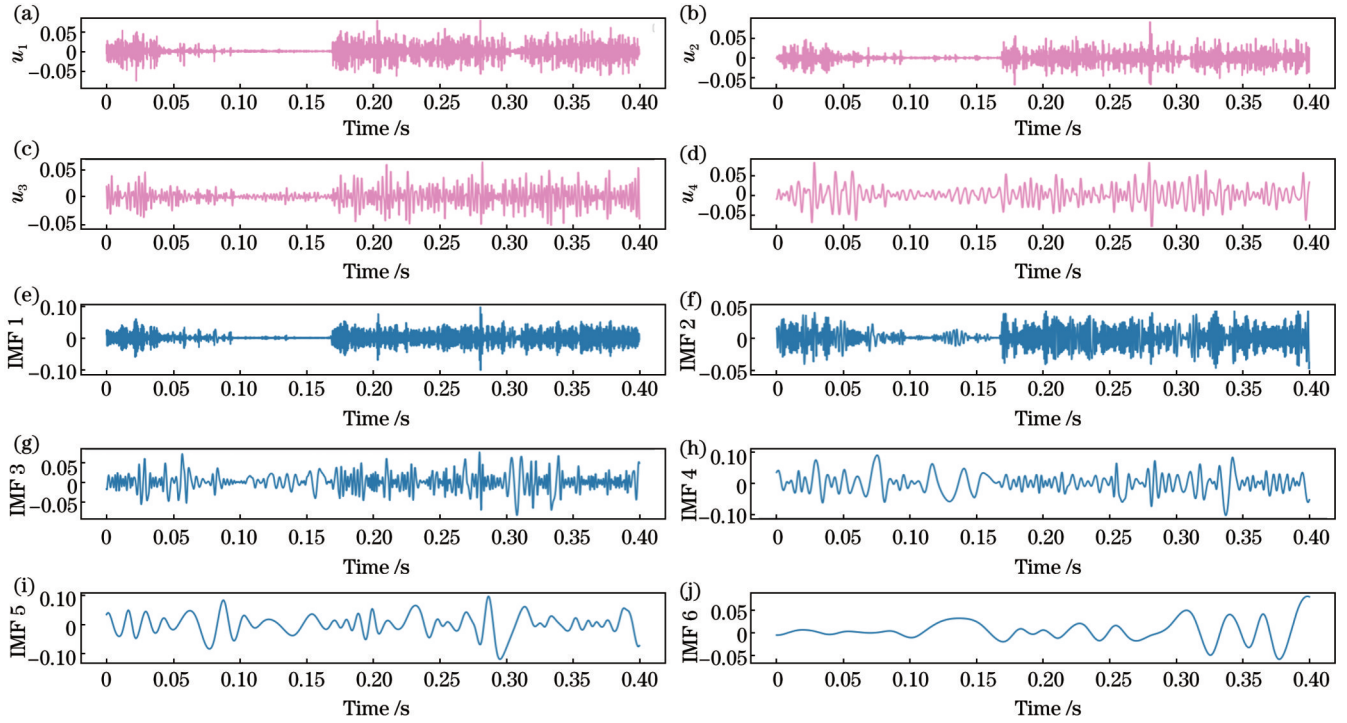


图 10 行走振动信号 EMD 与 WPD 结果的时域图。(a)~(d) WPD 结果;(e)~(h) EMD 结果

Fig. 10 Time domain plots of EMD and WPD results of walk vibration signals. (a)~(d) WPD results; (e)~(h) EMD results

4.2 多特征融合

通过上述实验,由每种类型的信号可以获得原始信号、6 个 IMF 分量和 4 个子带信号($u_1 \sim u_4$),共计 11 个信号数据集。对这些数据集进行特征提取,可以获得 110 维特征。然而,对于输入算法而言,这些维度过高,因此通过 PCA 进行降维。在 PCA 中,累计贡献率 90% 是一个常见的默认值,其可以在保证较多主成分特征的情况下有效降低数据的维度。因此将式(3)中主成分累计贡献率阈值设置为 90%,可以得到,在包含原始数据 90% 信息成分时特征最低维度为 33 维。最后,形成了 4 个信号的 33 维数据集,其中数据组数为 10000,具体的贡献率如表 2 所示。

表 2 降维后特征累计贡献率

Table 2 Cumulative contribution rates of features after dimensionality reduction

Sample	Original feature dimension	PCA feature dimension	Cumulative contribution rate / %
Knock	110	33	92.6
Trolleying	110	33	92.5
Walk	110	33	90.1
Shake	110	33	96.0

为了防止激活函数中负值的导数为 0 并更好地收敛算法模型,需要对 33 维特征进行归一化和取绝对值的处理,其中归一化采用最大-最小归一化方式。经过处理后,4 种事件的 33 维特征如图 11 所示,可以看出,使用多尺度融合的特征集后,4 种信号在特征空间中,两两之间均表现出较大的差异性。其中,在图 11(b)、(c)所示的相似信号特征空间中,融合特征间存在较明显的差异。因此即使采用简单的分类器也可以很好地实现信号分类和识别。

4.3 BP 神经网络的识别结果

将构建好的数据集以 7:2:1 的数据量比例划分为训练集、验证集和测试集。首先,将训练集和验证集输入到 BP 神经网络中进行训练。为了与 CNN 算法进行对比,设计一个与 BP 神经网络结构类似的二维 CNN 结构。其中,输入层为信号时频图,卷积层共有 3 层,使用 3×3 卷积核,激活函数使用 ReLU 函数,池化层共有 2 层,采用 2×2 池化核进行下采样,全连接层共 2 层,将卷积层和池化层数据进行扁平化处理,输出层使用 Softmax 作为激活函数,并输出信号对应的标签。然后,利用训练好的模型进行测试集实验,测试集数据量占总体数据量的 10%,共计 1000 组数据,全程不参与模型的训练。

在模型训练和识别中,使用 110 维的数据训练 BP 神经网络的时间为 16.4 s,单条数据识别时间

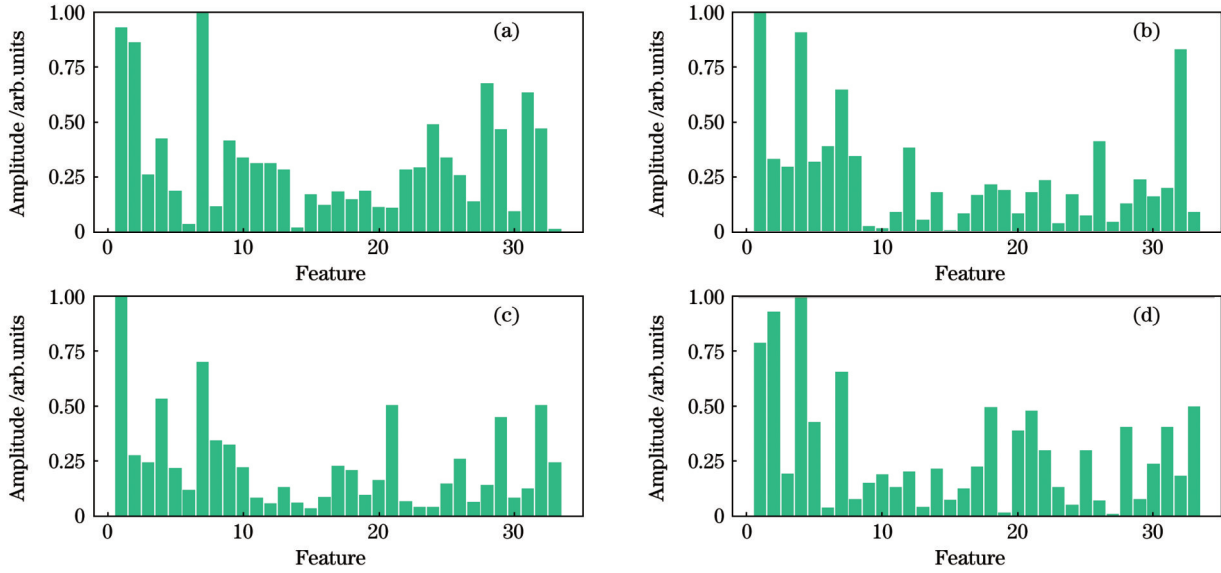


图 11 四种信号经 PCA 降维后的特征。(a) 敲击; (b) 小车经过; (c) 行走; (d) 晃动

Fig. 11 Features of four signals after PCA dimensionality reduction. (a) Knock; (b) trolleying; (c) walk; (d) shake

为 7.9 ms, 使用降维后的 33 维数据训练模型, 训练时间为 13.5 s, 单条数据识别时间为 6.7 ms。经 PCA 降维后, 模型训练时间降低 2.9 s, 单条处理时间降低 1.2 ms。降维后准确率的对比如表 3 所

示, 降维后模型的整体识别准确率提高 0.9%, 相似信号识别准确率提高 1.5%。PCA 特征融合缩短了模型的训练和识别时间并提高了模型的识别精度。

表 3 准确率对比

Table 3 Comparison of accuracies

Dimensionality	Accuracy / %				Total accuracy / %	Accuracy for similar signal / %
	Knock	Trolleying	Walk	Shake		
110	99.5	96.5	97	100	98.2	96.8
33	100	98.5	98	100	99.1	98.3

4.4 模型对比

图 12 为混淆矩阵结果图。可以看出, 图 12(c) 所示的多尺度特征融合分类的识别准确率最高, 其中敲击和晃动信号的识别准确率可以达到 100%, 小车经过和行走信号的识别准确率也分别为 98.5% 和 98.0%。图 13 所示为三种方法的识别准确率对

比。可以看出, 相比于直接从原始信号中提取特征的方式和结合时频图的 CNN 方式, 本文所提方法的综合识别准确率分别提高了 8.4 个百分点与 9.0 百分点, 相似信号的识别准确率分别提高了 13.5 个百分点与 12.4 百分点, 验证了该方法具有较高的识别精度。

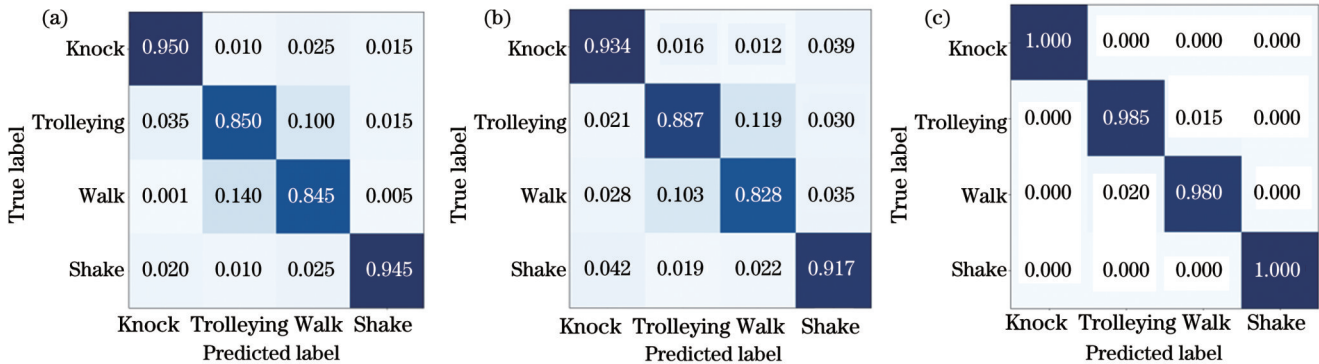


图 12 不同方法下的混淆矩阵图。(a) 从原始信号中提取特征; (b) CNN; (c) 多尺度特征融合

Fig. 12 Confusion matrix diagrams under different methods. (a) Extracting multi-features from original signal; (b) CNN; (c) multi-scale feature fusion

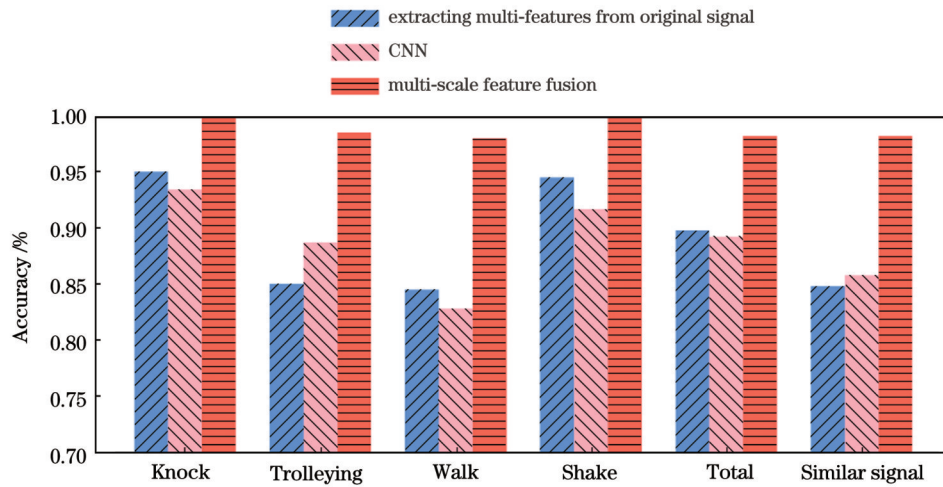


图 13 三种方法的识别准确率对比

Fig. 13 Comparison of recognition accuracies of three methods

5 结 论

提出了一种基于多尺度特征融合的 φ -OTDR 系统相似信号识别方法并进行了实验验证。实验结果表明,利用 EMD 结合 WPD 的方法,可以得到不同尺度下的子信号,之后对原始信号和子信号进行时频域和近似熵特征的提取,可以更有效地放大相似信号特征的区别度。通过滑动窗口可以有效地增加振动信号的样本数量,缩短人工采集信号的时间。利用 PCA 对高维数据进行处理有助于降低训练特征的维度,提高模型分类精度。在得到区别度大的信号特征的情况下,通过设计 6 层轻量的 BP 神经网络模型,可以很好地识别不同的信号类型。相比于直接从原始信号中提取特征的方法,所提方法的综合识别准确率提高了 8.4 百分点,相似信号的识别准确率提高了 13.5 百分点;相比于结合时频图的 CNN 方法,所提方法的综合识别准确率提高了 9.0 百分点,相似信号的识别准确率提高了 14.3 百分点。该方法在保证基础信号识别准确率的情况下,有效提高了相似信号的识别准确率,对于拓展 φ -OTDR 系统的应用范围具有重要价值。

参 考 文 献

- [1] Yang G Y, Fan X Y, Wang S, et al. Long-range distributed vibration sensing based on phase extraction from phase-sensitive OTDR[J]. IEEE Photonics Journal, 2016, 8(3): 6802412.
- [2] Mei X W, Pang F F, Liu H H, et al. Fast coarse-fine locating method for φ -OTDR[J]. Optics Express, 2018, 26(3): 2659-2667.
- [3] Yue H M, Zhang B, Wu Y X, et al. Simultaneous and signal-to-noise ratio enhancement extraction of vibration location and frequency information in phase-sensitive optical time domain reflectometry distributed sensing system[J]. Optical Engineering, 2015, 54(4): 047101.
- [4] Duan N, Peng F, Rao Y J, et al. real-time position and speed monitoring of trains using phase-sensitive OTDR [J]. Photonics Technology Letters, IEEE, 2014, 26(20): 2055-2057.
- [5] 张俊楠, 娄淑琴, 梁生. 基于 SVM 算法的 φ -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): 0422003.
- [6] Zhang J N, Lou S Q, Liang S. Study of pattern recognition based on SVM algorithm for φ -OTDR distributed optical fiber disturbance sensing system[J]. Infrared and Laser Engineering, 2017, 46(4): 0422003.
- [7] Sheng Z Y, Zhang X Y, Wang Y P, et al. An energy ratio feature extraction method for optical fiber vibration signal[J]. Photonic Sensors, 2018, 8(1): 48-55.
- [8] 刘琨, 翁凌峰, 江俊峰, 等. 基于过零率的光纤周界安防系统入侵事件高效识别[J]. 光学学报, 2019, 39(11): 1106002.
- [9] Liu K, Weng L F, Jiang J F, et al. Zero-crossing rate based efficient identification of intrusion events in fiber perimeter security systems[J]. Acta Optica Sinica, 2019, 39(11): 1106002.
- [10] Chen X E, Xu C J. 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.
- [11] 卜泽华, 毛邦宁, 司召鹏, 等. 基于小波包分解和 SVM 的 φ -OTDR 系统信号识别[J]. 光子学报, 2022, 51(11): 1106003.
- [12] Bu Z H, Mao B N, Si Z P, et al. Signal identification of φ -OTDR system based on wavelet packet decomposition and SVM[J]. Acta Photonica Sinica, 2022, 51(11): 1106003.
- [13] Shi Y, Wang Y Y, Wang L Y, et al. Multi-event classification for φ -OTDR distributed optical fiber sensing system using deep learning and support vector machine[J]. Optik, 2020, 221: 165373.
- [14] 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.
- [15] 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.
- [16] 王鸣, 沙洲, 封皓, 等. 基于 LSTM-CNN 的 φ -OTDR 模式识别[J]. 光学学报, 2023, 43(5): 0506001.
- [17] Wang M, Sha Z, Feng H, et al. Pattern Recognition for φ -OTDR Based on LSTM-CNN[J]. Acta Optica Sinica, 2023, 43(5): 0506001.
- [18] 薛康, 刘琨, 江俊峰, 等. 基于 YOLOv5s 模型的光纤振动传感事件精准检测研究[J]. 光学学报, 2023, 43(2): 0228001.
- [19] Xue K, Liu K, Jiang J F, et al. Optical fiber vibration sensing detection with high accuracy based on YOLOv5s model[J]. Acta Optica Sinica, 2023, 43(2): 0228001.
- [20] Liu C F, Zhu L D, Ni C B. The chatter identification in end milling based on combining EMD and WPD[J]. The International Journal of Advanced Manufacturing Technology, 2017, 91(9): 3339-3348.
- [21] 张颜, 娄淑琴, 梁生, 等. 基于多特征参量的 φ -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): 0606001-9

1105005.
Zhang Y, Lou S Q, Liang S, et al. Study of pattern recognition based on multi-characteristic parameters for φ -OTDR distributed optical fiber sensing system[J]. Chinese Journal of Lasers, 2015, 42(11): 1105005.
- [16] 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 φ -OTDR[J]. IEEE Sensors Journal, 2019, 19(10): 3683-3689.
- [17] 张淑清, 孙国秀, 李亮, 等. 基于LMD近似熵和FCM聚类的机械故障诊断研究[J]. 仪器仪表学报, 2013, 34(3): 714-720.
Zhang S Q, Sun G X, Li L, et al. Study on mechanical fault diagnosis method based on LMD approximate entropy and fuzzy C-means clustering[J]. Chinese Journal of Scientific Instrument, 2013, 34(3): 714-720.
- [18] Uddin M P, Al Mamun M, Ali Hossain M. PCA-based feature reduction for hyperspectral remote sensing image classification[J]. IETE Technical Review, 2021, 38(4): 377-396.
- [19] 胡军, 刘燕德, 孙旭东, 等. 基于BP神经网络的太赫兹时域光谱对面粉中苯甲酸的定量检测研究[J]. 激光与光电子学进展, 2020, 57(7): 302-308.
Hu J, Liu Y D, Sun X D, et al. Quantitative determination of benzoic acid in flour based on terahertz time-domain spectroscopy and BPNN model[J]. Laser & Optoelectronics Progress, 2020, 57(7): 302-308.
- [20] 陈仁祥, 汤宝平, 吕中亮. 基于相关系数的EEMD转子振动信号降噪方法[J]. 振动·测试与诊断, 2012, 32(4): 542-546, 685.
Chen R X, Tang B P, Lü Z L. Ensemble empirical mode decomposition de-noising method based on correlation coefficients for vibration signal of rotor system[J]. Journal of Vibration, Measurement & Diagnosis, 2012, 32(4): 542-546, 685.
- [21] 黄旺华, 王钦若, 徐维超, 等. 对椒盐噪声稳健的数字图像斯皮尔曼秩次相关法[J]. 光学精密工程, 2015, 23(6): 1800-1806.
Huang W H, Wang Q R, Xu W C, et al. Robust digital imaging Spearman's Rho correlation for pepper and salt noise[J]. Optics and Precision Engineering, 2015, 23(6): 1800-1806.

Similar-Signal Recognition Method for φ -OTDR Systems Based on Multiscale Feature Fusion

Song Wenqiang, Ding Zhewen^{**}, Mao Bangning, Xu Ben, Gong Huaping, Kang Juan, Zhao Chunliu^{*}

College of Optical and Electronic Technology, China Jiliang University, Hangzhou 310018, Zhejiang, China

Abstract

Objective A phase-sensitive optical time-domain reflectometer (φ -OTDR) system is a front monitoring and early warning technology that can acquire the location of disturbances in space and phase information of disturbances in time. With the advantages of high resolution, wide monitoring range, and strong anti-interference capability, this technology has been widely used in pipeline safety maintenance, intrusion warning, and large-equipment monitoring. However, due to the complex diversity of the application environment, the system suffers from low recognition accuracy and insufficient stability in actual use, particularly when similar signals are recognized in the system application. To solve these problems, this study proposes a similar-signal recognition method based on multiscale feature fusion. This method can effectively improve the recognition accuracy of similar signals while maintaining the recognition accuracy of the base signal.

Methods The original signal is first decomposed into sub-signals in different frequency ranges using empirical mode decomposition (EMD) and wavelet packet decomposition (WPD). The original signal and individual sub-signals are then subjected to time-frequency feature extraction and approximate entropy feature extraction. The time-frequency features are used to evaluate the details of the time and frequency variations of the signal, the approximate entropy features are used to evaluate the complexity and regularity of the signal, and the multiscale signal decomposition and multi-feature extraction are used to amplify the feature differences between similar signals. Because the multiscale and multi-feature approach increases the dimensionality of the data, the proposed method utilizes principal component analysis (PCA) to combine high-dimensional features and reduce the dimensionality of system features, thereby improving system efficiency. Finally, the fused features are passed into a lightweight back-propagation (BP) neural network as input variables for signal data processing. Compared to other traditional neural networks, BP neural networks have the advantages of lightweight structures and high speed, enabling them to process signal data quickly.

Results and Discussions Sub-signals decomposed by EMD and WPD have multiscale characteristics ranging from low to high frequencies. Each sub-signal contains a part of the signal domain within the main frequency-band range of the original data. Decomposition helps to amplify the feature gaps between different signals and facilitates subsequent multidimensional feature extraction (Fig. 10). Following feature extraction and fusion, the four signals show significant differences in the feature space. Thus, even with a simple classifier, signal classification and recognition can be achieved (Fig. 11).

A comparison among extracting multi-features from original signal [Fig. 12(a)], the CNN model [Fig. 12(b)], and the multi-scale

feature fusion[Fig. 12(c)] reveals that the multi-scale feature fusion has higher recognition accuracy, where knocking and shaking-signal recognition accuracies reach 100% and trolleying and walking-signal recognition accuracies reach 98.5% and 98.0%, respectively. A comprehensive analysis reveals that the comprehensive recognition accuracy of the proposed method is increased by 8.4 and 9.0 percentage points over extracting multi-features from original signal and CNN model, respectively, and the similar-signal recognition accuracy is increased by 13.5 and 12.4 percentage points (Fig. 13), respectively. These results verify that the method has high recognition accuracy.

Conclusions Experimental results show that the decomposition method using EMD combined with WPD can obtain sub-signals at different scales. The time-frequency domain and approximate entropy features can in turn be extracted from the original signal and sub-signal to enhance the differentiation of similar-signal features more effectively. The PCA algorithm can then reduce the dimensionality of high-dimensional data, thus effectively reducing the number of training features. A well-designed six-layer lightweight BP neural network model can also effectively identify different types of signals when identifying signal features with significant differentiation. Compared with the extraction of features directly from the original signal, the proposed method can improve the integrated and similar-signal recognition accuracies by 8.4 and 13.5 percentage points, respectively. Compared to those of the CNN method, the overall recognition accuracy is improved by 9.0 percentage points, and the similar-signal recognition accuracy is improved by 14.3 percentage points. This method effectively improves similar-signal recognition while maintaining the recognition accuracy of underlying signals, which is of great value for expanding the applications of φ -OTDR systems.

Key words optical communications; phase-sensitive optical time-domain reflectometer; time-frequency features; approximate entropy; multiscale feature fusion; back propagation neural network