

季洋阳. 基于自适应小波包的光纤振动类型识别研究[J]. 智能计算机与应用, 2025, 15(6): 156–163. DOI: 10. 20169/j. issn. 2095–2163. 250624

基于自适应小波包的光纤振动类型识别研究

季洋阳

(三峡新能源海上风电运维江苏有限公司, 江苏 盐城 224600)

摘要: 相位敏感光时域反射仪(phase-sensitive optical time domain reflectometer)简称 Φ -OTDR。由于具有抗干扰能力强、感应灵敏度高,并且能适应各种复杂的外部条件等优点被大范围应用。因此本文基于 Φ -OTDR的分布式光纤系统,在小波包分解提取振动信号的基础上,提出了自适应小波包分解,根据信号的能量均方差选择分解层次,实现自适应。并验证,自适应小波包分解优于小波包分解特征提取。针对无扰动、踩踏以及攀爬三类信号进行采集、信号预处理后、再分别用自适应小波包分解和快速谱峭度实行特征处理,最后基于BP神经网络和SVM算法进行识别。实验结果表明2种方法对3种信号都有较好的识别结果,BP算法对无扰动信号的识别率为98.92%,对于踩踏信号,识别结果的平均正确率为97.88%;对于攀爬信号,识别结果正确率为96.36%。SVM算法的平均识别正确率为100%,86.47%,85.75%。得出结论:基于自适应小波包的BP神经网络算法对每种事件都有较好的识别率,对比小波包分解,能有效提高识别准确率。基于快速谱峭度的SVM分类算法对无扰动信号的识别效果最好,但对于踩踏信号和攀爬信号的识别效果没有BP神经网络好。

关键词: 光纤振动传感系统; Φ -OTDR; 自适应小波包分解; 快速谱峭度; BP神经网络; SVM算法

中图分类号: TB53

文献标志码: A

文章编号: 2095–2163(2025)06–0156–08

Research on fiber vibration type recognition based on adaptive wavelet packet

Ji Yangyang

(Three Gorges New Energy Offshore Wind Power Operation and Maintenance Jiangsu Co., Ltd., Yancheng 224600, Jiangsu, China)

Abstract: Phase-sensitive optical time domain reflectometer (Φ -OTDR) is widely used due to its advantages of strong anti-interference ability, high sensing sensitivity, and ability to adapt to various complex external conditions. Therefore based on Φ -OTDR distributed optical fiber system, this paper proposes adaptive wavelet packet decomposition, and selects the decomposition level according to the mean square error of the signal to achieve adaptation. It is also verified that adaptive wavelet packet decomposition is better than wavelet packet decomposition feature extraction. For the three types of signals such as non-disturbance, pedaling and climbing, the signal is collected and preprocessed, and then the feature processing is carried out by adaptive wavelet packet decomposition and fast spectral steepness, respectively, finally the recognition is conducted based on BP neural network and SVM algorithm. The experimental results show that the two methods have good recognition results for the three signals, and the recognition rate of the BP algorithm for the non-disturbance signal is 98.92%, and the pedaling signal 97.88%, the climbing signal 96.36%. The average recognition accuracy rate of SVM algorithm is 100%, 86.47%, and 85.75%. It is concluded that the BP neural network algorithm based on adaptive wavelet packet has a good recognition rate for each event, and has better performances compared with wavelet packet decomposition. SVM classification algorithm based on fast spectral steepness has the best recognition effect for non-disturbance signals, but it is not as good as BP neural network for other two signals.

Key words: optical fiber vibration sensing system; Φ -OTDR; adaptive wavelet packet decomposition; fast spectral kurtosis; BP neural network; SVM algorithm

0 引言

光纤传感技术日渐成熟,在光纤传感探测设备各方面性能增强的同时,为了让光纤传感技术能应

用在越来越多的场景,信号处理及研究也就显得尤为重要。通常,光纤传感技术主要通过扰动产生振动信号,当信号的绝对幅值超过规定大小,由此判断入侵或者破坏。随着智能安防需求迫切,对于扰动

的定位和识别也提出了更高的要求,小波包分解具有很强的时频局部化分解能力,为各类信号的特征提取和识别奠定了基础^[1]。目前,已广泛应用于语言、图像、地震、机械振动等领域。将小波分解技术应用到基于光纤传感设备采集到的目标振动信号上,可以在智能安防等领域有效发挥技术支撑作用^[2]。

1 小波包分解基本原理

小波包变换是从小波变换发展起来。在初始的正交小波上,拓展发展到半正交小波包和广义小波包。而小波变换由于其基函数的特性与尺度密切相关。当尺度增大时,会导致基函数的时间跨度增大从而引起对应频率宽度变小^[3]。小波变换的定义为:给定基函数 $\psi(t)$ 并通过移位以及伸缩加以处理,研究中令:

$$\psi_{a,b}(t) = \frac{1}{\sqrt{a}} \psi\left(\frac{t-b}{a}\right) \tag{1}$$

其中, a, b 表示常量,且 $a > 0$ 。给定输入信号 $S(t)$, 同时在 $L2(R)$ 的 2 范数定义为:

$$\|S\| = \int_R |S(t)|^2 dt \tag{2}$$

那么, $S(t)$ 的小波变换可以定义为:

$$WT_x(a,b) = \frac{1}{\sqrt{a}} \int S(t) \psi_{a,b}^*\left(\frac{t-b}{a}\right) dt = \langle S(t), \psi_{a,b}(t) \rangle \tag{3}$$

其中, a, b 和 t 皆为连续变量。 $\psi(t)$ 是小波变换中的基本小波,而小波包是一函数族。由于小波变换在做信号分解处理的时候,只对频率较低部分的分辨率较高,而对信号频率较高时却无法做到有效分解。但在信号信息构成中,高频信号中的细节更多,比如地震信号、遥感、振动信号等。而小波包是按照层次来对信号频带进行划分的,能够分析信号频率较高的部分,因此在复杂信号处理上独具优

势^[4]。而本次研究对象就是光纤振动信号,用小波包分解可以更高效地获取其信号的能量特征。

小波包的分解也是用一对滤波器 $H_0(z)$ 和 $H_1(z)$ 来实现的,其正交归一基 $\phi_{j,k}(t)$ 和 $\psi_{j,k}(t)$ 与该对滤波器有如下关系:

$$\begin{aligned} \phi\left(\frac{t}{2^j}\right) &= \sqrt{2} \sum_{k=-\infty}^{\infty} h_0(k) \phi\left(\frac{t}{2^{j-1}} - k\right) \\ \psi\left(\frac{t}{2^j}\right) &= \sqrt{2} \sum_{k=-\infty}^{\infty} h_1(k) \phi\left(\frac{t}{2^{j-1}} - k\right) \end{aligned} \tag{4}$$

当 $j = 0$ 时,可以得到二尺度差分方程如下所示:

$$\begin{aligned} \phi(t) &= \sqrt{2} \sum_{k=-\infty}^{\infty} h_0(k) \phi(2t - k) \\ \psi(t) &= \sqrt{2} \sum_{k=-\infty}^{\infty} h_1(k) \phi(2t - k) \end{aligned} \tag{5}$$

其中, 2 个共轭滤波器有以下关系:

$$h_1(k) = (-1)^k h_0(1 - k) \tag{6}$$

为了方便理解和表示,使 $\mu_{2n}(t) = \phi(t)$, $\mu_{2n+1}(t) = \psi(t)$, 则式(6)可以表达为:

$$\begin{aligned} \mu_{2n}(t) &= \sqrt{2} \sum_{k=-\infty}^{\infty} h_0(k) \phi(2t - k) \\ \mu_{2n+1}(t) &= \sqrt{2} \sum_{k=-\infty}^{\infty} h_1(k) \phi(2t - k) \end{aligned} \tag{7}$$

设信号 $g_j^n(t) \in U_j^n$, U_j^n 是函数 $u_n(t)$ 的闭包空间,则该信号有以下特性:

$$g_j^n(t) = \sum_i d_i^{j,n} u_n(2^j t - l) \tag{8}$$

其小波分解算法为:

$$\begin{aligned} d_i^{j,2n} &= \sum_k a_{k-2l} d_k^{j+1,n} \\ d_i^{j,2n+1} &= \sum_k b_{k-2l} d_k^{j+1,n} \end{aligned} \tag{9}$$

从式(9)可以绘出小波包的信号分解结构如图 1 所示。




图 1 信号做 3 层小波包分解结构图

Fig. 1 The signal decomposed by 3 layers of wavelet packets

2 实验过程

2.1 光纤振动信号采集与预处理

为了保证信号特征的更快提取,前期对采集到的振动信号做预处理^[5]。采集、且做预处理的信号主要是背景信号以及踩踏信号。运用基于 ϕ -OTDR

的探测设备来采集目标振动信号,此处数据采集频率为 10 kHz,忽略系统反应时间并截取有效频段,设备采集到的时域信号如图 2 所示。在时域图中,可以很清晰地看到踩踏行为的发生会导致光纤振动信号的幅度有明显的起伏。




图 2 踩踏信号时域图

Fig. 2 Time domain plot of the pedaling signal

由于采集到的目标信号在时域上的绝对幅值意义不大,现在对采集到的时域信号数据进行归一化处理,放大了噪声信号与一次踩踏信号的幅值对比,可以更清晰分析两者差别,并有利于后续信号特征和噪声背景信号的提取。为了验证信号特征,对信号进行简单的处理。基于短时功率谱密度分析,通过短时功率谱密度可以观察到背景噪声和踩踏信号的幅度和功率谱特征明显不同,方便后续的特征提取。背景噪声和踩踏信号帧幅度曲线如图 3 所示。踩踏信号功率谱如图 4 所示。




图 3 背景噪声和踩踏信号帧幅度曲线

Fig. 3 Background noise and pedaling signal frame amplitude curves




图 4 踩踏信号功率谱

Fig. 4 Pedaling signal power spectrum

在光纤传感设备采集信号的过程中,会出现因为温度导致的零点漂移,以及由于设备性能导致不

能精准采集探测器采集频率范围外的信号。此外,外部环境干扰和信号本身也会存在一定范围内的震

荡,这些因素都会导致采集到的目标信号偏离基线、甚至偏离基线的大小还会随时间变化,整个过程称为信号的趋势项。具体信号表现为一个低频的曲线叠加到了原始信号上,使得原始信号有缓慢、轻微的上下浮动趋势。这些趋势项会导致信号分析时出现畸变,造成低频出现尖峰、甚至淹没主频成分,从而直接影响数据正确性。去除趋势项的常用方法包括多项式最小二乘法,或者采用滤波方法,即只取信号中的低频信号,如 sgolay 滤波求取趋势项。本文采用最常见的方法,即多项式最小二乘法去除趋势项^[6]。原理是以最小二乘法拟合直线作 BaseLine,用原始数据时域波形减去拟合的直线 BaseLine。假设实际测量的信号数据为 $S_k (k = 1, 2, \dots, m)$, 采样中时间间隔均为 1, 可得多项式:

$$\hat{S}_k = a_0 + a_1 k + a_2 k^2 + \dots + a_m k^m \quad (10)$$

其中, 待定系数 a_i 满足函数和数据的误差平方和最小, 定义公式如下:

$$E = \sum_{k=1}^m (\hat{S}_k - S_k)^2 = \sum_{k=1}^m \left(\sum_{i=0}^n a_i k^i - x_k \right)^2 \quad (11)$$

方差平方和 E 取得极值的条件是:

$$\frac{\partial E}{\partial a_i} = 0 \quad (12)$$

将式(11)代入式(12), 并对 a_i 求偏导, 可以得到线性方程组:

$$\sum_{k=1}^m \sum_{i=0}^n a_i k^i - \sum_{k=1}^m S_k k^j = 0, \quad j = 0, 1, 2, \dots, n \quad (13)$$

当 $n = 0$ 时, 趋势项为常数, 可以解得:

$$a_0 = \frac{1}{n} \sum_{k=1}^m S_k \quad (14)$$

从式(14)可以看出, 当 n 趋近 0, 那么该项为信号的算术平均值。可以得出常数趋势项的消除公式为:

$$Y_k = S_k - \hat{S}_k = S_k - a_0, \quad k = 1, 2, \dots, m \quad (15)$$

当 $n = 1$ 时, 为线性趋势项, 可以求得:

$$\begin{cases} \sum_{k=1}^m a_0 k^0 + \sum_{k=1}^m a_1 k - \sum_{k=1}^m S_k k^0 = 0 \\ \sum_{k=1}^m a_0 k^0 + \sum_{k=1}^m a_1 k^2 - \sum_{k=1}^m S_k k = 0 \end{cases} \quad (16)$$

同时解得:

$$\begin{cases} a_0 = \frac{2(2m-1) \sum_{k=1}^m S_k - 6 \sum_{k=1}^m S_k k}{m(m-1)} \\ a_1 = \frac{12 \sum_{k=1}^m S_k k - 6(m-1) \sum_{k=1}^m S_k}{m(m-1)(m+1)} \end{cases} \quad (17)$$

可以得出线性的趋势项的消除公式为:

$$Y_k = S_k - \hat{S}_k = S_k - (a_0 + a_1 k), \quad k = 1, 2, \dots, m \quad (18)$$

无踩踏信号及踩踏一次信号幅值对比如图 5 所示。由于 $n \geq 2$ 为曲线多次趋势项, 并不进行消除处理。最后采用滑动平均法进行平滑处理^[7-10]后的结果, 如图 6 所示。图 6 中, 毛刺减少, 去除了趋势项的干扰, 有利于后续的特征提取。




图 5 无踩踏信号及踩踏一次信号幅值对比图

Fig. 5 Comparison of the amplitude of non-pedaling signal and one pedaling signal




图 6 预处理后的信号

Fig. 6 Signal after pretreatment

2.2 基于能量阈值的自适应小波包特征提取

小波变换是对信号的低频部分做分解, 忽略其高频部分的细节部分, 而小波包分解则同时涵盖信号的低频部分和高频部分, 是一种能够对各类非平稳随机信号进行有效处理的现代时频分析和处理方法。通过小波包变换可将采集的信号分解为多个二维参量(时间、位置)和频率, 实现信号在不同频带、不同时刻的特征分解。小波包分解实际是对小波分解进行改进, 将信号高频分量和低频分量都进行分解, 比小波变换划分更加精细和全面, 更能体现出信号全频率特点, 特征向量能够自适应选择频带, 具有时频局部化特点, 特征与频谱对应, 从而提高信号的时频分辨率。对信号做 3 层小波包分解, 其结构见图 1。

2.2.1 小波包分解

图 1 中, $S_{0,0}$ 为分解前的原始信号, 下面的 $S_{i,j}$ 表示第 i 层的第 j 个节点对应的分解信号。分解信号满足下式:

$$S_{0,0} = S_{1,0} + S_{1,1} = S_{2,0} + S_{2,1} + S_{2,2} + S_{2,3} = S_{3,0} + S_{3,1} + S_{3,2} + S_{3,3} + S_{3,4} + S_{3,5} + S_{3,6} + S_{3,7}$$

(19)

其中, 节点数 j 为偶数时, 表示经过低通滤波系数 $g(k)$ 分解得到的低频成分信号; 反之, j 为奇数

时, 表示经过高通滤波系数 $h(k)$ 分解得到的高频成分信号。高通和低通滤波系数需要满足下式:

$$g(k) = (-1)^k h(1 - k)$$

(20)

$S_{1,0}$ 一层是用来解析出低频信号里面蕴含 2 层分解的 $S_{2,0}$ 低频部分以及 $S_{2,1}$ 中的高频部分, $S_{2,0}$ 包含 3 层分解的 $S_{3,0}$ 的低频部分以及 $S_{3,1}$ 的高频部分^[11-13]。按此推算, 通过如上的一层层分解, 频率低的信号, 不断地被过滤去除掉, 频率高信号的局部特征也更趋细节化。逐层分解后, 其小波树如图 7 所示。




图 7 踩踏信号小波树图

Fig. 7 Wavelet tree diagram of the pedaling signal

将信号进行加固定窗并分成多帧处理, 表示为 Sx_i 。其中下标 i 是振动信号的第 i 帧, 帧长表示 N , 总帧数为 m , 则其每一段的能量可以表示为:

$$E(i) = \sum_{m=1}^N Sx_i^2(m), 1 \leq i \leq m$$

(21)

将每一采样点的能量归一化后可得:

$$T(i) = \frac{Sx_i^2(m)}{E(i)}$$

(22)

踩踏一次信号能量归一化结果如图 8 所示。从图 8 可以看出, 一次踩踏信号的能量归一图可以分成 12 帧, 并且每一帧的能量越靠后越小。其每一帧中还夹杂着部分高能量的噪声, 因此需要进行小波包分解。而在图 9 中, 噪声信号在低频的时候能量较大, 且有较强的冲击。到了高频, 能量比较稳定, 中间有一段能量比较集中, 且噪声信号较少。




图 8 踩踏一次信号能量归一化图

Fig. 8 Normalized diagram of the signal energy of a single pedaling




图 9 背景噪声信号能量归一图

Fig. 9 Background noise signal energy normalization plot

将能量归一化后,对每帧的能量进行统计,得到所有帧的能量概率,以踩踏一次的其中一帧能量概率为例(见图 10),由图 10 可以看出最大能量概率为 0.18。在层数不确定的情况下,先采用 3 层小波包进行分解,得到该信号的初始能量和特征值为 8。




图 10 能量概率图

Fig. 10 Energy probability graph

并将初始选择 db2 的 3 层小波分解得到 SSS3 信号,将 SSS3 信号的能量 E_{SSS3} 与每一帧的能量计算的差值求得均方根根率 ΔE :

$$\Delta E = \frac{\sqrt{\sum (E(i) - E_{SSS3})^2}}{E_{SSS3}} \times 100\% \quad (23)$$

通过该差值均方根率选择小波包分解层数,即:

$$k = \begin{cases} 3, & \Delta E < 1.0\% \\ 4, & 1.0\% \leq \Delta E < 1.5\% \\ 5, & 1.5\% \leq \Delta E < 2.0\% \\ 6, & \Delta E \geq 2.0\% \end{cases} \quad (24)$$

通过该小波包分解层数可以使得信号功率提取得更加准确,从而得到自适应小波包分解后的能量特征。

2.2.2 自适应小波包研究

自适应小波包算法流程如图 11 所示。其自适应体现在,与 3 层分解的小波包能量做比较,其差值均方根根率来确定小波包分解层数。再将其分解所得到的的小波能量特征作为后续分类算法的特征向量。这里将一组踩踏信号进行 db2 小波 3 层分解,可以得到结果如图 12 所示。






图 11 自适应小波包算法流程图

Fig. 11 Flow chart of adaptive wavelet packet algorithm



(a) 踩踏信号自适应小波包分解图



(b) 能量频段图

图 12 分解结果

Fig. 12 Results of decomposition

无扰动信号频带能量如图 13 所示。从图 13 可以看出,无扰动信号的绝大部分能量全都分布在低频区域,几乎占了 50%。由此可以看出小波包分解能够有效提取光纤振动信号特征,为后期识别提供保障。




图 13 无扰动信号频带能量图

Fig. 13 Plot of the frequency band energy of the non-disturbed signal

将小波包分解与自适应小波包分解后的能量特征样本作为训练样本,特添加攀爬信号,经过预处理之后,将 3 类事件各自 100 个数据样本特征分别随机选取 70 个(共 210 个)代入到 BP 神经网络中进行识别,并随机进行 5 次测试实验,观察其识别效果,可以得到的识别准确率见表 1。

表 1 小波包与自适应小波包识别准确率

Table 1 Wavelet packet and adaptive wavelet packet recognition accuracy %

测试次数	样本种类	小波包识别准确率	自适应小波包识别准确率
1	无扰动信号	95.37	99.85
	踩踏信号	95.28	99.82
	攀爬信号	94.33	99.15
2	无扰动信号	95.24	99.68
	踩踏信号	94.11	99.70
	攀爬信号	93.35	98.78
3	无扰动信号	96.58	99.88
	踩踏信号	95.78	99.82
	攀爬信号	94.67	98.15
4	无扰动信号	95.10	98.92
	踩踏信号	95.01	98.82
	攀爬信号	94.77	98.15
5	无扰动信号	96.12	99.75
	踩踏信号	95.56	99.62
	攀爬信号	94.12	97.89

3 实验结果分析

光纤振动信号经过预处理和小波包分解后,可以得到 8~32 个典型频域特征。首先,将 3 类事件

各自 100 个样本集分别随机选取 70 个(共 210 个)作为训练样本,另外其余采集到的数据作为测试样本。然后,对神经网络结构进行构造,神经网络最多训练次数为 1 000,目标的最小误差设置为 0.001%,学习速率为 0.01,激活函数使用 logsig 函数。最后,对网络结构进行构建,输入层神经元数量 n 随着自适应小波包变化,中间层神经元数量为 $2n + 4$,输出层神经元数量为 3。为了消除随机选择训练样本结果的随机性,对训练样本进行 200 次训练样本的随机选取,接着将不同的训练数据输入到神经网络中进行参数的更新,在此基础上计算这 200 个不同网络在训练样本集合和测试样本集合上预测结果的平均正确率,作为算法的性能评价指标。

对于无扰动事件,识别样本的平均正确率为 99.85%,对于踩踏事件,识别样本的平均正确率为 99.82%;对于攀爬数据,识别率为 98.15%。而攀爬信号由于没有幅值范围、没有踩踏信号那么大,在能量特征提取中较不明显,因此存在着识别率下降的情况。

对测试数据样本进行 200 次识别,其正确率变化见表 1。对于无扰动事件,识别的平均准确率为 98.92%,对于踩踏信号,识别结果的平均准确率为 96.88%;对于攀爬信号,识别的准确率为 95.36%。

从平均分类结果看出,基于自适应能量阈值的小波包分解特征 BP 神经网络算法能够对入侵事件进行有效识别和分类,在训练样本中对 3 种信号的识别率均在 98%以上,在训练样本上识别率在 95%以上,故在训练样本和测试样本集合上均表现出较高的预测精度。

为了进一步验证基于自适应小波包特征提取的分类识别的精度,研究中和基于快速谱峭度特征的 SVM 算法的结果进行对比,在训练样本集合和测试样本集合上对振动信号分类的正确率见表 2。

对表 2 中 2 个方法进行对比分析,可以如下结论:

(1)基于能量阈值小波包分解的 BP 神经网络算法和基于快速谱峭度特征的 SVM 算法得到的网络在训练数据上预测的结果正确率均显著高于在测试样本上的结果。因为研究可知,机器学习的训练过程就是对训练集合进行最佳的拟合。

(2)基于快速谱峭度特征的 SVM 算法对于无扰动信号的分类正确率可以达到 100%,相对于基于能量阈值小波包分解特征的 BP 神经网络算法更优。因此对于入侵事件识别的任务,可选取基于快速谱峭度特征的 SVM 算法。

表 2 2 种算法事件分类正确率对比

Table 2 Comparison of the accuracy of event classification between the two algorithms

算法名称	样本集	分类类型	精度/%
基于能量阈值小波包的神经网络算法	训练样本	无扰动	99.85
		踩踏	99.82
		攀爬	99.15
	测试样本	无扰动	98.92
		踩踏	96.88
		攀爬	95.36
基于快速谱峭度特征的 SVM 算法	训练样本	无扰动	100.00
		攀爬	97.35
		踩踏	97.67
	测试样本	无扰动	100.00
		攀爬	85.75
		踩踏	86.47

(3)从整体上来看,基于能量阈值的小波包分解特征的 BP 神经网络算法,在训练集合和测试集合上进行分类预测的正确率均显著高于基于快速谱峭度特征的 SVM 算法。因此对于事件分类的任务,可选取基于能量阈值的小波包分解特征的 BP 神经网络算法。

4 结束语

本文主要是基于光纤振动传感系统进行入侵的研究开展实验,并根据实验采集到的数据进行特征提取,并分别使用基于能量阈值的自适应小波包分解算法和快速谱峭度算法对事件进行入侵识别。最后对比分析结果可知,基于自适应小波包的 BP 神经网络算法对每种事件都有较好的识别率,并将自适应小波包的能量特征对 BP 神经网络的影响与小波包分解的 BP 神经网络的识别做了对比,证明有较好的成效,能够提高识别的准确率。同时又分析了基于快速谱峭度的 SVM 分类算法,该算法对无扰动信号的识别效果最好,但对于踩踏信号和攀爬信号的识别效果没有 BP 神经网络好。

参考文献

[1] 齐添添,陈尧,何才厚,等. 损伤声发射信号小波包神经网络特征识别方法[J]. 北京邮电大学学报,2021,44(1):124-130.
[2] 曹聪. COTDR 分布式光纤振动传感安防系统模式识别研究

[D]. 上海:上海交通大学,2017.
[3] 林家洋,张民威,苏疆东,等. 基于快速谱峭度的冲击能量法在水轮机空化评价中的应用研究[J]. 水力发电,2020,46(12):84-89.
[4] 逯旺旺,杨勇,张斌. 基于谱峭度特征识别的海杂波弱小目标检测方法[J]. 现代信息科技,2020,4(4):31-35.
[5] ARIYAN I. The generalized continuous wavelet transform on Hilbert modules[D]. Sydney :University of New South Wales, 2008.
[6] 张皓然,王学渊,李小霞. 基于自适应阈值活动语音检测和最小均方误差对数谱幅度估计的低信噪比降噪算法[J]. 计算机应用,2020,40(6):1763-1768.
[7] 王育飞,王成龙,李盟盟,等. 基于自适应小波包分解的混合储能平抑高渗透率光伏社区电网电压波动方法[J]. 太阳能学报,2020,41(9):78-85.
[8] 李新. 基于分布式光纤 Φ -OTDR 的特定振动信号识别研究[D]. 桂林:桂林电子科技大学,2020.
[9] 胡新超. 基于小波包变换的发动机活塞踩踏故障诊断研究[D]. 太原:中北大学,2017.
[10] 张皓然,王学渊,李小霞. 基于自适应阈值活动语音检测和最小均方误差对数谱幅度估计的低信噪比降噪算法[J]. 计算机应用,2020,40(6):1763-1768.
[11] 何志勇. 基于小波包分解的光纤振动特征提取方法[J]. 现代计算机(专业版),2018(21):24-28.
[12] PASTOR-GRAELLS J, MARTINS H F, GARCIA-RUIZ A, et al. Single-shot distributed temperature and strain tracking using direct detection phase-sensitive OTDR with chirped pulses[J]. Optics Express, 2016,24(12):13121-13133.
[13] WANG Jiao, HU Yanzhu, SHAO Yanchao. The Digging signal identification by the random forest algorithm in the phase-OTDR technology[J]. IOP Conference Series Materials Science and Engineering, 2018, 394(3):032005.