

引用格式: MA Yuzhao, WANG Ruisong, XIONG Xinglong. Fiber-optic Vibration Signal Recognition Based on BLCD Decomposition and ACO-DBN Network[J]. Acta Photonica Sinica, 2021, 50(2):0206003

马愈昭,王瑞松,熊兴隆. 基于BLCD分解与ACO-DBN网络的光纤振动信号识别[J].光子学报,2021,50(2):0206003

基于BLCD分解与ACO-DBN网络的光纤振动信号识别

马愈昭^{1,2},王瑞松¹,熊兴隆^{1,2}

(1 中国民航大学 电子信息与自动化学院,天津 300300)

(2 中国民航大学 天津市智能信号与图像处理重点实验室,天津 300300)

摘要:针对光纤振动信号受噪声干扰严重、特征提取单一和识别时间长的问题,提出了改进的局部特征尺度分解和蚁群算法优化深度置信网络的识别方法。首先,采用三次B样条函数插值拟合均值曲线改进局部特征尺度分解算法,并对原始信号进行分解得到一系列内禀尺度分量之和。其次,利用峭度因子和能谱系数构成融合指标筛选有效分量。然后,分别提取有效分量在时域、频域和时-频域的熵值特征进行融合并降维。最后,将综合特征向量馈入蚁群优化后的深度置信网络进行训练和识别,提高算法效率和识别率。采用实测数据进行实验验证,结果表明,信噪比平均提升8 dB,信号平均识别率可达95.83%,平均识别时间为0.715 s。

关键词:光纤光学;光纤振动信号;深度置信网络;局部特征尺度分解;三次B样条插值;蚁群算法

中图分类号:TP212

文献标识码:A

doi:10.3788/gzxb20215002.0206003

Fiber-optic Vibration Signal Recognition Based on BLCD Decomposition and ACO-DBN Network

MA Yuzhao^{1,2}, WANG Ruisong¹, XIONG Xinglong^{1,2}

(1 College of Electronic Information and Automation, Civil Aviation University of China, Tianjin 300300, China)

(2 Tianjin Key Laboratory for Advanced Signal Processing, Civil Aviation University of China, Tianjin 300300, China)

Abstract: Aiming at the problems of severe noise interference of fiber-optic vibration signals, single feature extraction and long recognition time, an improved local characteristic-scale decomposition and ant colony algorithm optimize deep belief network are proposed. Firstly, cubic B-spline function interpolation is used to fit the mean curve to improve the local characteristic-scale decomposition algorithm, and the sum of a series of intrinsic scale components is obtained by decomposing the original signal. Secondly, the fusion index is formed by kurtosis factor and energy spectrum coefficient to screen the effective component. Then, the entropy features of the effective components in the time domain, frequency domain and time-frequency domain are extracted respectively to perform feature fusion and dimensionality reduction. Finally, the integrated feature vectors are fed into ant colony algorithm optimized deep belief network for training and recognition to improve the algorithm efficiency and recognition rate. Experimental verification using measured data shows that the signal-to-noise ratio is increased by 8 dB on average, the average signal recognition rate can reach 95.83%, and the average recognition time is 0.715 s.

基金项目:国家自然科学基金民航联合基金(No.U1833111)

第一作者:马愈昭(1978—),女,副教授,博士,主要研究方向为大气光学、光通信。Email:yzma@cauc.edu.cn

通讯作者:熊兴隆(1961—),男,教授,硕士,主要研究方向为信号与信息处理、激光雷达气象探测。Email:xx_long@126.com

收稿日期:2020-08-06;录用日期:2020-09-30

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

Key words: Fiber optics; Fiber-optic vibration signal; Deep belief network; Local characteristic-scale decomposition; Cubic B-spline interpolation; Ant colony algorithm

OCIS Codes: 060.2310; 070.4340; 070.5010; 100.4996

0 引言

分布式光纤周界系统以灵敏度高、反应速度快、可实时监测的优势被广泛应用在国防边界、军事基地、民航机场等安防监测领域^[1-4]。其中双 Mach-Zehnder 光纤周界系统具有远距离监测和实时性强的优点。然而光纤振动信号具有随机性和非平稳性,易受环境噪声干扰,影响特征提取和模式识别。因此如何在噪声环境下有效提取入侵信号特征和高效识别入侵种类是当前研究的热点问题^[5-8]。

针对以上问题,国内外相关学者进行了广泛的研究。在信号分解方面,张燕君等^[9]采用经验模态分解(Empirical Mode Decomposition, EMD)方法提取分量的高阶谱特征,运用粒子群优化的反向传播神经网络识别信号类型,但 EMD 存在模态混叠和端点效应的缺陷。朱程辉等^[10]采用局部均值分解(Local Mean Decomposition, LMD)将信号自适应分解为一系列单分量调频信号(Production Function, PF)的乘积,LMD 虽然可以抑制端点效应,但模态混叠依然存在,且易产生虚假分量影响后续特征提取。在特征提取方面,黄金等^[11]采用改进的自适应噪声完备集合经验模态分解(Complete Ensemble Empirical Mode Decomposition with Adaptive Noise, CEEMDAN)将信号分解为本征模态分量(Intrinsic Mode Function, IMF),在频域使用方差贡献率和功率谱密度筛选 IMF 分量,然后利用小波包进行分层滤波得到信号特征信息。若直接选取前几个小波系数会造成部分信息丢失,导致信息特征提取不准确。SEEDAHMED S M 等^[12]在时域通过提取信号波形图特征的方法,直接提取电平过零率、持续时间和最大振幅强度等参量组成特征向量,利用人工神经网络决策树方法识别入侵事件。然而仅从单一维度描述敏感信号是经验性的,不足以反映模式之间的差异性。在信号识别方面,喻晓芒等^[13]提取信号的小波三层分解能量特征向量,采用(Back Propagation, BP)神经网络分类识别,可以识别三种入侵种类,但识别时间较长。ZHU hui 等^[14]采用过阈值率算法,直接将过阈值率作为特征输入到分类器进行识别。但是该方法识别率较低。局部特征尺度分解(Cubic B-spline Local Characteristic-scale Decomposition, BLCD)是一种新型时频分析方法,它将信号分解为一系列内禀尺度分量(Intrinsic Scale Components, ISCs)之和,BLCD 分解误差较小,可以更准确地描述信号成分。深度置信网络(Deep Belief Network, DBN)是一种概率生成模型,有强大的映射能力和广泛的适用性,能够深度挖掘信号特征^[15]。然而,网络结构参数的设置具有依赖性和经验性。而蚁群优化算法(Ant Colony algorithm, ACO)具有良好的分布式计算能力和全局搜索能力,且易与其他算法结合。

本文在课题组研究的基础上^[16-19],提出了一种基于 BLCD 分解和 ACO-DBN 光纤振动信号识别方法。首先,结合三次样条函数保形性和 B 样条函数的局部保凸性改进 LCD 算法,将信号进行分解并根据融合指标(Index Fusion, IF)筛选有效分量。其次,提取有效分量的奇异谱熵、功率谱熵、LCD 时频空间熵和 LCD 能量熵进行多尺度特征融合并降维。最后,将特征向量组馈入到 ACO-DBN 网络进行分类和识别。采用外场实测数据对该方法进行实验验证,并与传统和未优化识别方法进行对比分析。

1 光纤振动信号预处理

本文方法总体流程如图 1 所示。首先光纤振动信号经本文方法进行滤波、重构处理,其次对重构信号进行特征提取,然后将提取的特征进行降维并输入到蚁群算法优化后的深度置信网络进行学习和训练,最后用测试集测试该方法的识别效果。

预处理是光纤振动信号识别的首要步骤,由于外界扰动引起的光纤振动信号中含有大量的噪声,若直接提取信号特征,会导致特征提取不准确进而影响识别效果,因而需采用一定的方法进行信号预处理。局部特征尺度分解时频分析法可将信号按频率尺度展开,然后按照一定的筛选规则重构信号达到滤波的目的。因此,结合光纤振动信号非平稳、非线性的特点,采用局部特征尺度分解法和融合指标筛选规则进行信号预处理。

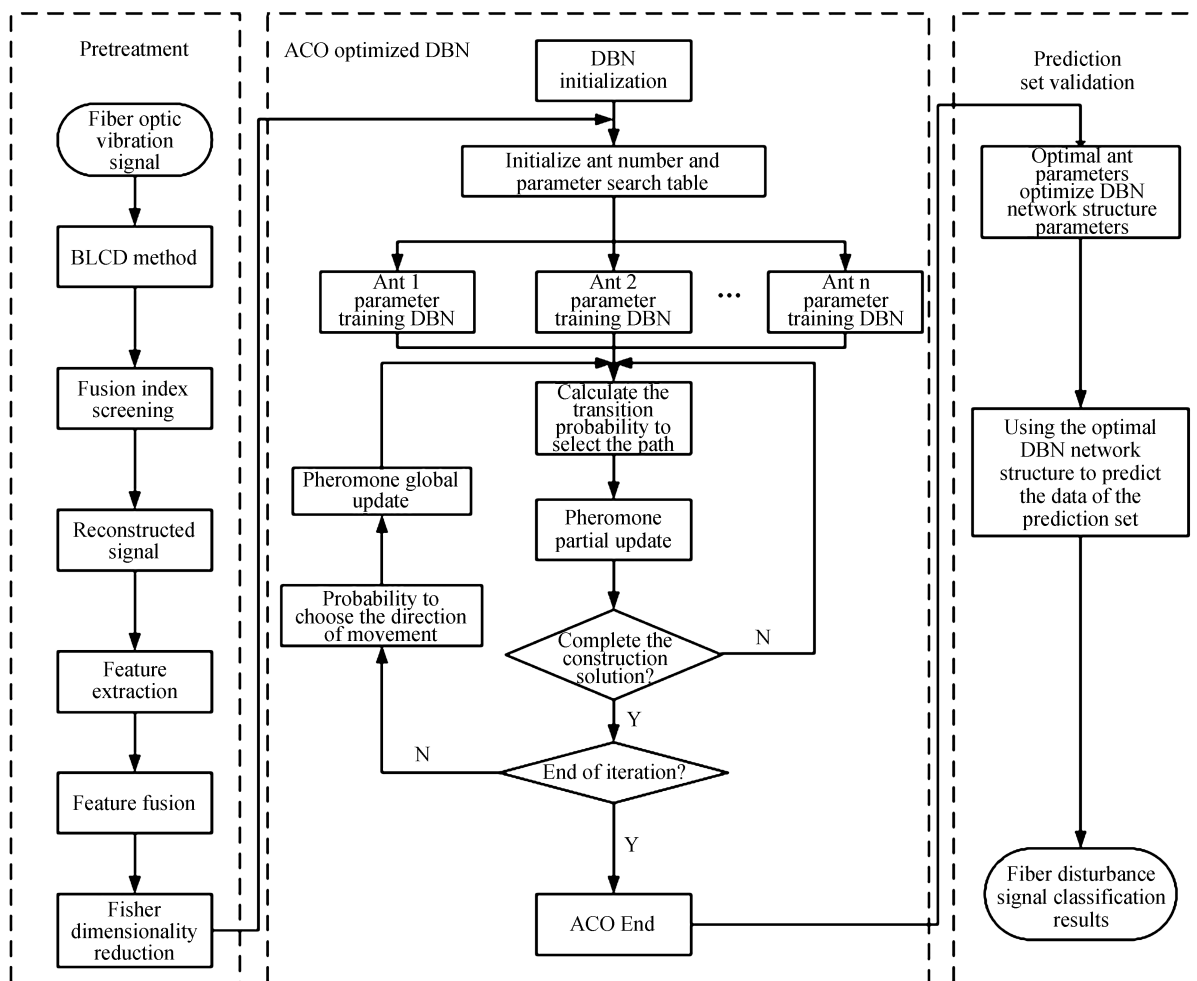


图1 本文方法总体流程

Fig.1 The overall process of the proposed method

1.1 基于双 Mach-Zehnder 光纤周界系统的基本原理

基于双 Mach-Zehnder 干涉原理设计光纤周界安防系统,系统传感原理如图 2 所示。激光器发出的连续光经光隔离器后被调制输入到 1×2 耦合器 Coupler1 分成分别是顺时针和逆时针方向的两束入射光信号。当有入侵扰动事件发生时,传感光纤部分(虚线方框)内部光纤发生应变,两路光信号与参考臂光信号分别在耦合器 Coupler2 和 Coupler3 处发生干涉,干涉光信号分别被光电探测器 Photodetector1 和 Photodetector2 探测。




图2 Mach-Zehnder 系统传感原理

Fig.2 Mach-Zehnder system sensing schematic diagram

光纤周界系统输出光纤振动信号表达式为

$$I(t) = I_0 \{1 + J \cos [\Delta\varphi(t) + \varphi_0]\} \quad (1)$$

式中, I_0 为激光器输入光信号的强度; J 为 Mach-Zehnder 干涉可见度; $\Delta\varphi(t)$ 为外界入侵扰动引起的相位差;

φ_0 为信号初始相位。由于外界扰动引起光信号相位变化的信息包含在 $\Delta\varphi(t)$ 中,通过相位解调算法不易获取敏感信号的相位信息,因此通常采取其他时频分析方法获取敏感信号的相关参量来分析识别敏感信号种类。

1.2 基于BLCD分解的滤波方法

光纤振动信号中含有复杂的环境噪声,LCD将振动信号分解为ISCs分量,若使用单一参数筛选有效分量,则不能全面表征信号的非线性关系,影响敏感信息的提取。因此采用改进的LCD算法结合IF规则筛选有效分量,实现扰动信号与噪声分离。

1.2.1 BLCD算法原理

改进的局部特征尺度分解的核心是构造“局部”均值曲线,采用三次B样条插值(Cubic B-Spline Interpolation, CBSI)代替三次样条插值拟合构造均值曲线。若采用传统的插值拟合方式,则会产生过包络和欠包络现象,这会增大分解误差影响后续的特征提取。而三次B样条插值拟合后的曲线光滑自然,能够抑制模态混叠和端点效应,因此适用于光纤振动信号。具体分解步骤为:

1)确定信号 $x(t)$ 所有极值点 (τ_k, X_k) ,并对两个端点进行时间序列延拓。

2)用三次B样条函数插值拟合信号所有极值点的包络曲线,三次B样条函数的基函数定义为

$$G_{i,3}(t) = \frac{1}{3!} \sum_{j=0}^{3-i} (-1)^j C_4^j (t+3-i-j)^3 \quad t \in [0, 1], i=0, 1, \dots, N \quad (2)$$

式中, t 表示插值时刻, N 表示插值总数。

3)计算每个均值算子 L_k ,用三次B样条插值方法依次拟合各个均值算子 L_k ,得到均值曲线 $m_k(t)$ 。 L_k 计算公式为

$$L_k = aA_k + (1-a)X_k = a \left[X_{k-1} + \left(\frac{\tau_k - \tau_{k-1}}{\tau_{k+1} - \tau_{k-1}} \right) (X_{k+1} + X_{k-1}) \right] + (1-a)X_k \quad (k=2, 3, \dots, N-1) \quad (3)$$

式中, $a \in (0, 1)$,为保证ISC分量局部吻合正弦曲线,使瞬时频率具有物理意义, a 取0.5。

4)将均值曲线不断从信号中扣除,即 $ISC_1 = x(t) - m_1(t)$,判断是否满足ISC分量条件,若满足条件则 $ISC_1 = h_1(t)$,否则将 $h_1(t)$ 视为原信号重复以上分解步骤,得到各阶 ISC_n 分量和一个余量 r ,即

$$x(t) = \sum_{n=1}^N ISC_n + r \quad (4)$$

1.2.2 筛选有效分量

光纤振动信号经BLCD分解后存在噪声分量,使用单一阈值筛选分量具有经验性,会影响后续特征提取,为此从不同角度选取两个指标构成筛选规则,从而保证筛选的有效性。

1) 峭度因子

峭度因子反映信号的统计分布特性,代表信号中冲击成分的数量。峭度因子 K 值越大,入侵信号冲击数量越多,信号抖动程度越大。其计算公式为

$$K = \frac{E(x - \mu)^4}{\delta^4} = \frac{1}{N} \sum_{i=1}^N \left[\frac{x_i - \mu}{\delta} \right]^4 \quad (5)$$

式中, K 为峭度因子; E 为均值, μ 为信号的均值; δ 为信号标准差; N 为信号的长度。

2) 能谱系数

能谱系数反映各个分量占原信号总能量的比值。该值越大说明分量所含能量越高,包含入侵信号的敏感信息越多,在分量中越重要。能谱系数定义为

$$E = \frac{E_i(j)}{E(j)} = \frac{\sum_{j=1}^N I_{isc_i}^2(j)}{\sum_{i=1}^k E_i(j)} \quad (6)$$

式中, $E_i(j)$ 为各分量的能量; $E(j)$ 为信号总能量; k 为分量的个数; i 为分量阶数。

峭度因子能反映光纤振动信号的抖动程度,但噪声也会引起振动信号峭度变化。能谱系数能很好地反

映各分量与原信号的相关程度,但容易受样本数的影响。故将两个指标进行参数融合^[20],结合其优缺点构成融合指标 $K - E$,计算公式为

$$K - E = \lg(1 + mK + nE) \quad (7)$$

式中, m 、 n 分别为峭度因子、能谱系数权重, $m + n = 1$ 。在此约束条件下 m 取0.6, n 取0.4,此时信号筛选分量效果最好,所得滤波信号的信噪比均大于其他权重比值下的信噪比。

考虑到实际光纤振动信号噪声的多样性,经BLCD分解后滤除噪声分量不彻底,将各个分量按照融合指标划分为有效模态和无效模态,在去除无效模态后,将有效模态重构再次进行BLCD分解,根据融合指标进行二次筛选,可以滤除更多的噪声,有利于后期特征提取。筛选过程如图3所示。




图3 BLCD-IF 筛选过程

Fig.3 BLCD-IF screening process

2 综合特征提取

有效提取信号特征是模式识别的关键,随机性的光纤振动信号在时域、频域、时-频域特征表述不同,若仅从单一域提取敏感信息的特征,不足以反映信号携带的全部信息,影响识别率。而信息熵是无量纲的随机量度,受此启发,将信息熵应用到不同域中,分别从时域、频域和时-频域等多角度进行时频分析,提取了基于时域分析的奇异谱熵 S 、基于频域分析的功率谱熵 P 、基于时-频域分析的LCD时频空间熵 R 和综合时频分析的LCD能量熵 E 等特征,采用多尺度特征融合和降维的方法构建信号表征体系,定量描述扰动信号的特征。

2.1 特征选取

2.1.1 奇异谱熵

奇异谱熵(Singular Spectral Entropy, SSE)反映光纤振动信号在时域中的特征,信号越复杂,奇异谱熵值越大。BLCD算法将信号分解为含有较多信源特征的ISC分量之和,将有效分量构成初始特征向量矩阵 $[I_1, I_2, \dots, I_i]$,对该矩阵进行奇异值分解,得到该振动信号的奇异谱 $\{\delta_i\}$, $1 < i < n$ 。其计算表达式为

$$S = - \sum_{i=1}^n \left(\frac{\delta_i}{\sum_{i=1}^n \delta_i} \right) \log_2 \left(\frac{\delta_i}{\sum_{i=1}^n \delta_i} \right) \quad (8)$$

式中, n 为不等于0的奇异值的个数; δ_i 为分解得到的第 i 个奇异值。

2.1.2 功率谱熵

功率谱熵(Power Spectral Entropy, PSE)是振动信号在频域的划分,反映光纤振动信号的谱形结构特征,表征信号频谱的不确定性和复杂程度。当有入侵行为发生时,熵值变大,光纤振动信号频谱变复杂。无扰动时,信号频谱结构组成较单一。其计算表达式为

$$P = - \sum_{i=1}^n \left(\frac{1}{N} \sum_{n=0}^{N-1} \left| \sum_{n=0}^{N-1} I_{ISC_i}(n) e^{-j\omega n} \right|^2 \right) / \sum_{i=1}^n U_i \log_2 \left(\frac{1}{N} \sum_{n=0}^{N-1} \left| \sum_{n=0}^{N-1} I_{ISC_i}(n) e^{-j\omega n} \right|^2 \right) \quad (9)$$

式中, n 为ISC分量的个数; N 为ISC分量的长度; U 为每个分量的平均能量。

2.1.3 LCD时频空间熵

LCD时频空间熵(Time-Frequency Spatial Entropy, TFSE)是光纤振动信号在时频域的统一体现,反映信号的空间特征。无扰动时,LCD时频空间熵值较小,时频分布较均匀;反之时频分布较分散。通过计算 $H(f, t)$ 的奇异值定义LCD时频空间熵,其计算表达式为

$$R = - \sum_{i=1}^n \left(\epsilon_i / \sum_{i=1}^n \epsilon_i \right) P_i \log_2 \left(\epsilon_i / \sum_{i=1}^n \epsilon_i \right) \quad (10)$$

式中, ϵ_i 为分解得到的第 i 个奇异值; n 为不等于 0 的奇异值个数。

2.1.4 LCD 能量熵

LCD 能量熵 (Energy Entropy, EE) 反映各个分量的平均能量分布, LCD 能量谱可看作能量随时间的变化程度。该值越大信号复杂程度越大, 振动信号的特征越明显。其计算表达式为

$$E = - \sum_{i=1}^n \left(E_i / \sum_{i=1}^n E_i \right) P_i \log_2 \left(E_i / \sum_{i=1}^n E_i \right) \quad (11)$$

2.2 多尺度特征融合及 Fisher 降维

多尺度特征融合是将不同域中提取的单一特征值组合成一组包含多个特征集的特征向量的处理方法。然而特征向量中冗余特征会降低模式识别的准确性并增加计算成本, 因此要进行特征降维, 去除冗余特征子集, 提高识别率和运算效率。采用 Fisher Score 方法对多尺度特征融合后的特征向量 $\Phi = [S, P, R, E]$ 降维, 通过分析不同特征的类间散度和类内散度评价该特征的区别度, Fisher 值越大表示特征差异性越大, 区分性越强。最后将最优特征子集馈入到分类器中进行学习和分类^[21]。一个含 m 类振动信号的数据集, 第 j 个特征的 Fisher 值的计算公式为

$$F = \frac{\sum_{i=1}^m n_i (u_j^i - u_j)^2}{\sum_{i=1}^m n_i (\sigma_j^i)^2} \quad (12)$$

式中, n_i 是第 i 类样本的数目; u_j^i, σ_j^i 分别表示第 i 类数据集中第 j 个特征的均值及标准差; u_j 表示特征向量 Φ 中第 j 个特征的均值。

3 模式识别

准确识别入侵种类是光纤周界系统最重要的环节, 优秀的识别方法是振动信号准确识别的关键之一。DBN 网络有结构简单、深度挖掘信号特征、识别性能好的特点, 而经验性选取参数会导致训练时间较长和陷入局部最优的问题, 进而影响识别效果。为了提高识别算法的识别效率, 结合 DBN 挖掘振动信号深度特征差异性的特性, 采用蚁群算法优化 DBN 参数权值, 提升网络收敛速度和泛化性能。

3.1 深度置信网络模型

深度置信网络与传统的神经网络不同, 由多层受限玻尔兹曼机 (Restricted Boltzmann Machine, RBM) 堆叠而成。其训练过程分为两个阶段, 第一阶段是无监督式对网络参数预训练过程, 相当于为有监督学习提供先验知识的学习阶段。RBM 的能量函数为

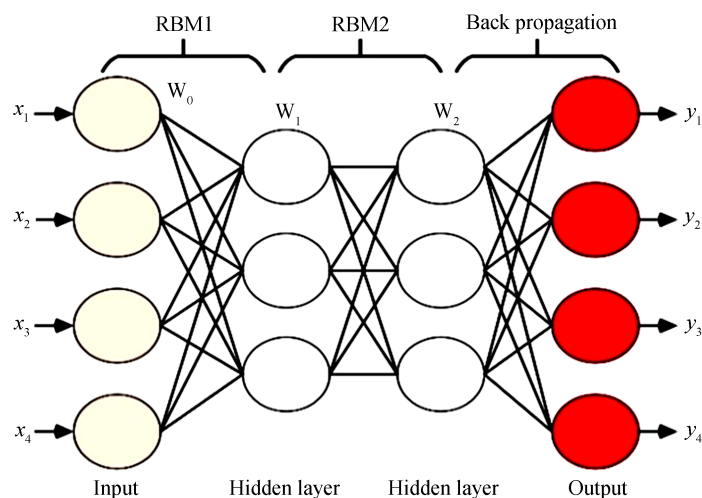


图 4 深度置信网络结构
Fig.4 Deep belief network structure

$$E(v, h|\theta) = - \sum_{i=1}^n p_i v_i - \sum_{j=1}^m q_j h_j - \sum_{i=1}^n \sum_{j=1}^m v_i \omega_{ij} h_j \quad (13)$$

式中, $\theta = \{p, q, \omega\}$ 表示RBM中的参数, p 和 q 分别表示可视层和隐藏层的偏置向量, ω 表示连接可视层与隐藏层之间的权重矩阵。

第二阶段是有监督式BP网络反向传播算法微调参数阶段。由于单层RBM学习训练的权重和偏置只能保证局部最优,故此阶段BP网络自上而下计算每层RBM参数误差,微调整个网络使权值和偏置达到全局最优,克服传统神经网络参数训练存在盲目性的缺点。由两层RBM构成的DBN网络训练过程如图4所示。其中输入层为特征向量 Φ 降维后的最优特征子集 X , 输出为类别标签 Y 。

3.2 蚁群优化算法

由于每层RBM均需计算权重矩阵和偏置,随层数增加,庞大的计算量会增加网络训练时长,不合理的DBN参数权重会影响网络学习分类的性能,而且BP神经网络微调参数时存在陷入局部最优解的问题。为解决此问题,采用蚁群算法优化深度置信网络,ACO算法具有良好的分布式计算能力和全局搜索能力,需要调节的参数少,易于其他算法结合。其基本思想基于蚂蚁在觅食行为过程中寻找最优路径的行为,每只蚂蚁走过的路径都会留存信息素,信息素浓度越高,蚂蚁选择该路径的概率越大,基于此机制寻找最优解确定网络最优参数配比和权值。其中转移概率计算公式为

$$P[\tau_j^k(I_{pi})] = \frac{\tau_j(I_{pi})}{\sum_{j=1}^N \tau_j^k(I_{pi})} \quad (14)$$

式中, $\tau_j(I_{pi})$ 为所有可能取值集合 I_{pi} 中第 j 个元素的信息素的值, I_{pi} 为所有蚂蚁构成的集合。

每只蚂蚁完成一次路径循环后按照式(15)进行信息素更新。

$$\tau_j(I_{pi})(t+n) = \rho \tau_j(I_{pi})(t) + \Delta \tau_j(I_{pi}) + \Delta \tau_j^*(I_{pi}) \quad (15)$$

式中, $\rho \in (0, 1)$ 是信息素保留系数。

3.3 ACO优化DBN

ACO优化算法基本实现步骤为:

1) 确定优化参数的个数 n , 每个参数 $P_i (i = 1, 2, \dots, n)$ 对应一个有 M 个元素的集合 I_{pi} , 这些元素为 P_i 的可能取值。

2) 设置蚂蚁个数 m , 启动所有蚂蚁, 每只蚂蚁在 I_{pi} 中随机选择候选值, 然后按概率转移选择下一个集合的某个元素, 直至每只蚂蚁均在 n 个集合中各选择了一个候选值。

3) 计算每个条路径所对应的信息挥发度值, 并更新每条路径的信息素。

4) 判断输出误差是否满足要求或循环次数达到上限, 若满足则进行步骤5), 否则返回步骤3)。

5) 将蚁群最终搜索到的组合作为深度置信网络的神经元初始权值, 进行网络训练。

4 实验结果分析

为验证本文方法的实用性, 使用自行设计的光纤周界系统调试实验设备。在天津空港实验基地进行实验, 光纤模式为标准单模, 布置长度为 2.5 km 的挂网式和埋地式光纤传感器。实验所用器材和相关参数如表1所示。

表 1 实验仪器及相关参数

Table 1 Experimental instruments and related parameters

Linewidth of a laser	Power	Sensor module	Sampling rate of the collector	Collected number
2 kHz	25 mW	Standard single mode fiber	5×10^6 sample/s	100 000

4.1 改进的LCD分解滤波

4.1.1 分解性能分析

为了验证本文方法在光纤振动信号预处理中的有效性和适用性, 随机选取1组实际中典型的攀爬类型引起的光纤振动信号, 分别采取三次样条插值和三次B样条插值的LCD算法对其进行分解。图5是实测信

号在不同插值拟合方式下的包络效果对比。

从图5可以看出,基于三次样条插值拟合的曲线过包络现象严重(绿色曲线),而基于三次B样条函数插值拟合的曲线包络(红色曲线)比三次样条函数拟合的包络曲线更接近原始曲线,说明改进的插值拟合方法误差更小,曲线更光滑,能够很好地抑制在分解过程中的过包络现象。

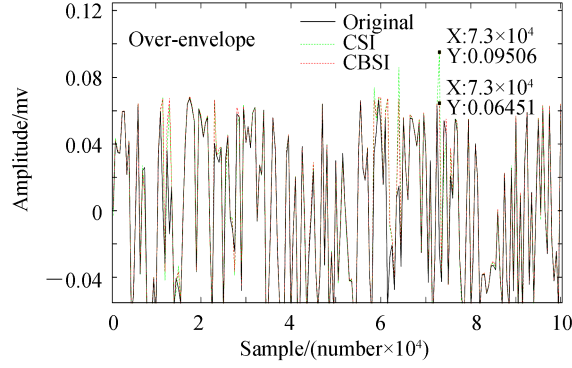


图5 实测攀爬信号包络
Fig.5 Measured climbing signal envelope

为了进一步验证本文方法在光纤振动信号应用中的分解性能,分别使用不同的分解方法对该攀爬信号进行分解,图6是经LCD分解和BLCD分解后截取部分分量的结果对比。

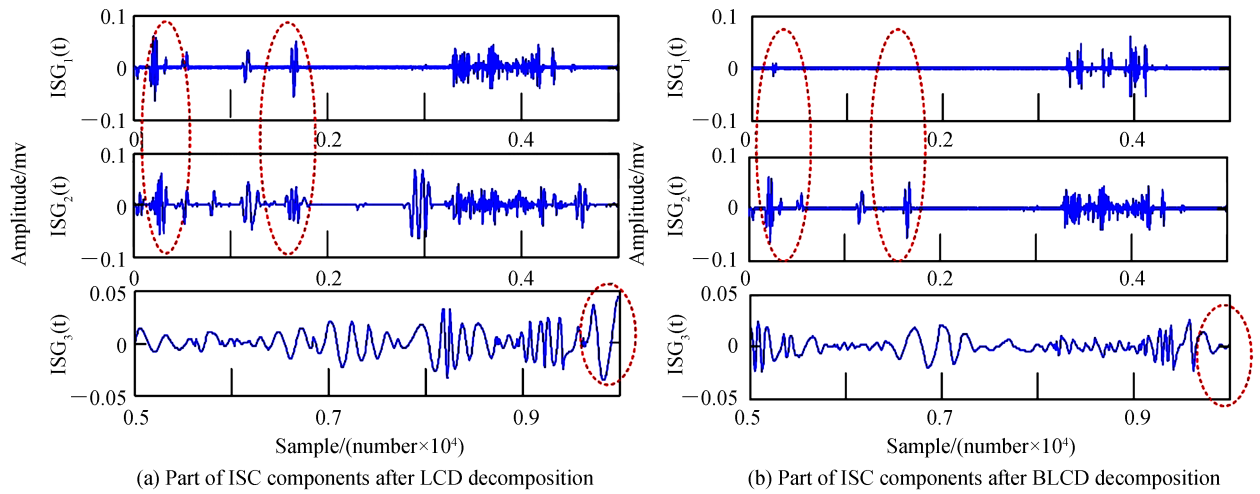


图6 不同分解方法分解结果对比
Fig.6 Comparison of decomposition results of different decomposition methods

根据图6(a)、(b)对比可见,LCD分解得到的ISC₁和ISC₂分量中出现严重的模态混叠现象,并且ISC₃分量出现端点效应,随着分解层数的增加会造成分解误差变大。而BLCD分解得到的ISC₁分量中模态混叠现象得到抑制,在ISC₃分量中端点效应得到改善。为了不失一般性地说明本文方法的分解效果,引入相关系数和R_{MSE}指标定量评估不同分解方法的分解性能,计算结果如表2所示。由表2可知,BLCD分解均方根误差较小,相关系数较大,而LCD则相反,说明BLCD分解精度相对较高,误差较小。其中相关系数、均方根误差公式为

$$C_{or} = \frac{\sum_{i=1}^N (X_i - \bar{X}_i)(Y_i - \bar{Y}_i)}{\sqrt{\sum_{i=1}^N (X_i - \bar{X}_i)^2 \sum_{i=1}^N (Y_i - \bar{Y}_i)^2}} \quad (16)$$

$$R_{MSE} = \sqrt{\frac{1}{N} \sum_{i=1}^N (\hat{x}_i - x_i)^2} \quad (17)$$

式中, N 为信号的长度; x_i 为原始信号; \hat{x} 为分量振动信号; X_i, Y_i 为信号分量; \bar{X}_i, \bar{Y}_i 为分量的平均值。

表2 不同分解方法结果对比
Table 2 Comparison of results of different decomposition methods

Decomposition method	Correlation coefficient			Root mean square error		
	ISC ₁	ISC ₂	ISC ₃	ISC ₁	ISC ₂	ISC ₃
LCD	0.751 5	0.513 3	0.509 5	0.041 7	0.041 0	0.046 4
BLCD	0.763 0	0.577 5	0.522 2	0.040 1	0.040 4	0.044 7

4.1.2 去噪对比

合理筛选ISC有效分量对振动信号特征提取至关重要,若直接使用传统相关法筛选叠加ISC分量,会导致无关干扰分量相互混叠产生虚假分量。既考虑ISC分量的相关性,又结合分量对原始信号的重要程度,构成融合指标筛选有效分量。实地采集不同环境下的光纤振动信号,图7(a)为使用浇水模拟下雨天气环境下的振动信号,图7(b)、(c)分别为实验人员模拟入侵扰动时攀爬围栏和敲击围栏时产生的振动信号,图7(d)为大风天气下采集的无扰动振动信号。

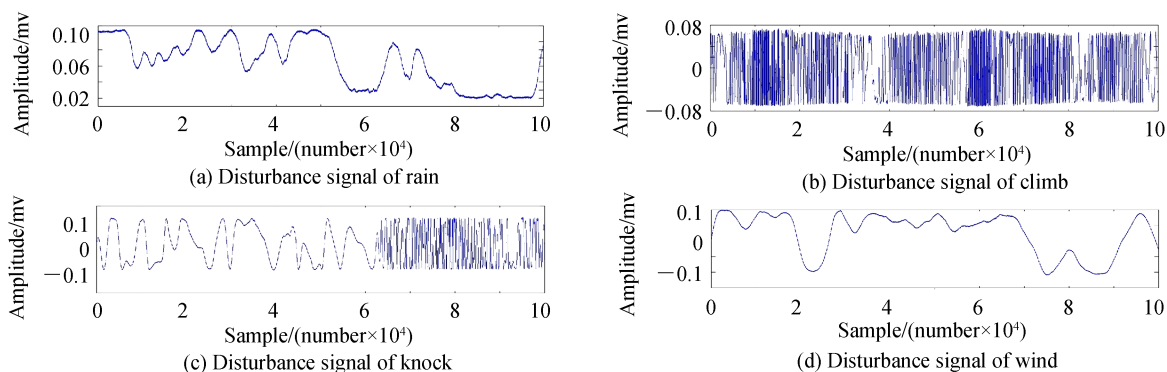


图7 四种典型光纤振动信号
Fig.7 Four typical intrusion signals

为了定量验证所提方法的去噪效果,分别计算直接叠加分量和融合指标筛选两种方式下的信号信噪比和均方根误差,其中均方根误差按照式(17)计算,结果如表3所示。由表可见,采用本文方法,不同类型振动信号信噪比均有所提升,平均信噪比提升8 dB,且均方根误差较小,说明该方法去噪效果好。

表3 两种滤波方式效果比较
Table 3 Comparison of the effects of two filtering ways

Filtering method	Signal	Signal to noise/ dB	Root mean square error
Add larger ISC	Rain	21.59	0.002 3
	Climb	7.372	0.019 5
	Knock	6.955	0.032 5
	Wind	8.132	0.028 3
IF	Rain	27.09 3	0.001 2
	Climb	12.11 6	0.011 3
	Knock	17.29 8	0.009 9
	Wind	9.732	0.007 4

4.2 特征参量提取

随机选取4种振动信号各10组,分别计算每组特征值,结果如图8所示。可见,下雨类型的不同特征值较其他三类,其熵值都比较小,说明下雨天气引起的光纤振动比较微弱,信号变化程度较小,易与其他类型区分开。人为攀爬类型的4种熵值均较大,说明攀爬引起的光纤振动信号变化较为剧烈,其熵值较大,易与

其他类型区别开。虽然自然风类型的功率谱熵 P 、LCD时频空间熵 R 、LCD能量熵 E 与其他三种类型有重叠部分,但是奇异谱熵 S 中风的类型与其他三种类型熵值范围明显不同,经过多尺度串行特征融合后,通过计算样本空间中的类间散度值和类内散度值将高维数据映射到低维数据空间,根据Fisher值可以滤除无效特征子集,减少特征间相似性,达到与其他类型区别开的目的。另外,深度置信网络自身具有深度挖掘敏感信息特性,可提取信号特征间细微的差异供分类器识别。

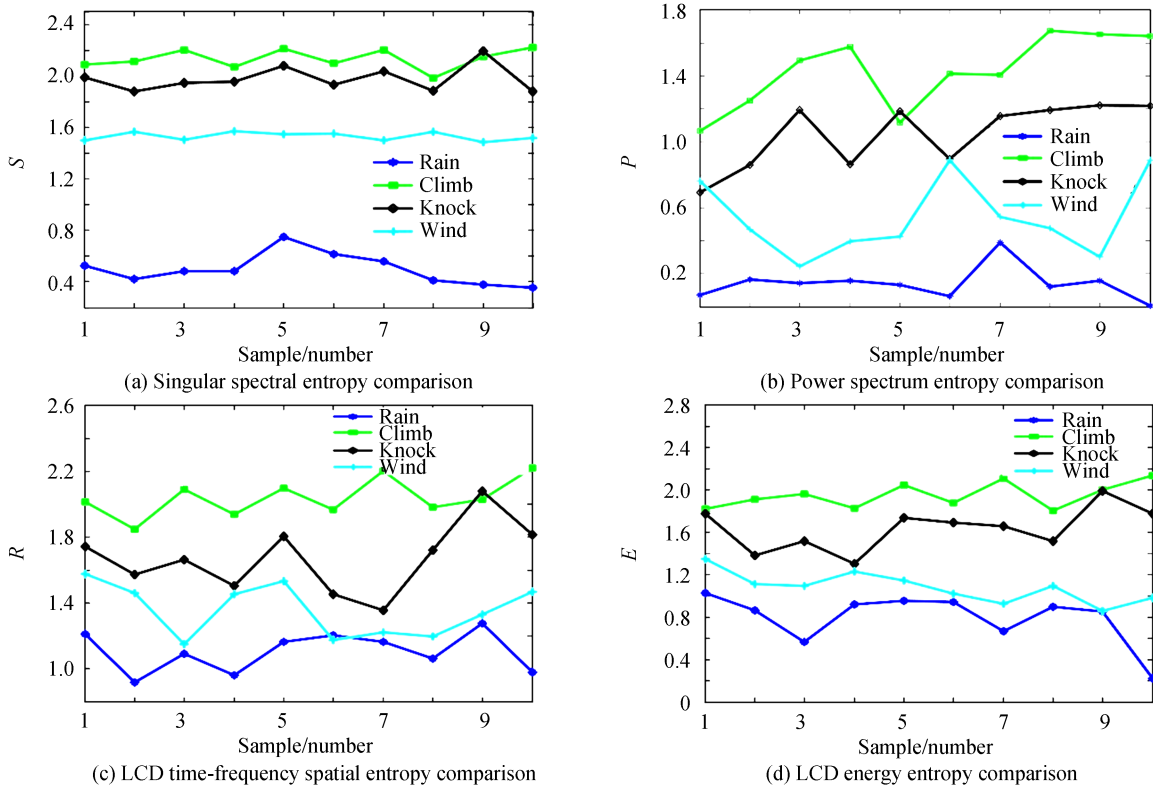


图8 四种特征参量对比
Fig.8 Comparison of four characteristic parameters

为验证本文降维方法对识别效果的影响,选取4种光纤振动信号各60组,共240个样本组成特征集,其中120组作为DBN网络的测试集,分别使用原特征集和Fisher降维后特征子集进行识别比较,结果如表4所示。由表可见,使用原特征集区分振动信号类型效果不理想,识别率为69.17%,识别时间为2.64 s。使用Fisher降维后识别率提升至94.17%,识别时间缩短为0.83 s,说明该方法可以提高识别率和识别效率。

表4 特征降维前后识别结果

Table 4 Recognition results before and after feature dimensionality reduction

Feature	Rain	Climb	Knock	Wind	Recognition rate	Recognition time
Direct Φ	40%	100%	90%	46.67%	69.17%	2.64 s
Fisher	93.33%	100%	100%	83.33%	94.17%	0.83 s

4.3 扰动信号识别

为了验证ACO-DBN网络识别性能,随机选取4类光纤扰动信号各60组,共240组样本。其中120组构成DBN的训练集,120组构成测试集,分别进行网络学习和分类。为了突出所提方法的识别性能,分别与传统的BP神经网络、ACO-BP神经网络、以及未经优化的DBN网络进行对比,结果如表5所示。由表可见,传统的识别方法尚未达到预期识别效果,而ACO-DBN平均识别率可达95.83%,平均识别时间为0.715 s,表明本文方法不仅误报率低,识别效率高,而且网络具有较强的泛化性能,可以满足实际需求。

表5 不同方法识别结果对比
Table 5 Comparison of recognition results of different methods

Method	Rain	Climb	Knock	Wind	Recognition rate	Recognition time
BP	76.67%(23/30)	96.67%(29/30)	17.86%(5/30)	100%(30/30)	73.48%	1.499 s
ACO-BP	90%(27/30)	86.67%(26/30)	80%(24/30)	93.33%(28/30)	87.50%	1.362 s
DBN	76.67%(23/30)	100%(30/30)	93.33%(28/30)	83.33%(25/30)	83.33%	1.523 s
ACO-DBN	93.33%(28/30)	100%(30/30)	93.33%(28/30)	96.67%(29/30)	95.83%	0.715 s

在实际中,存在多点振动事件,敲击是入侵事件中强度大、破坏力强的干扰事件,同时敲击能产生其他新的振动形式并与敲击信号特征相互叠加。为了检验文中算法对多点振动信号的识别能力,选取单点敲击振动信号和两点同时敲击振动信号各60组,其中各取30组作为测试集分别进行实验,实验结果如表6所示。由表可见,虽然多点振动信号识别结果有一定的浮动,识别率为90%,识别时间为0.815 s,略低于单点振动信号的识别率和识别时间,但是较传统识别方法而言,本文方法不仅能有效识别单点振动信号,而且对多点振动信号的识别具有一定的适应性和稳定性。

表6 多点振动识别结果对比
Table 6 Comparison of multi-point vibration identification results

Method	knock at one point	knock at two points	Recognition rate	Recognition time
BP	63.33%(19/30)	50%(15/30)	56.67%	1.214 s
ACO-BP	80%(24/30)	73.33%(22/30)	76.67%	1.327 s
DBN	90%(27/30)	86.67%(26/30)	88.34%	1.163 s
ACO-DBN	96.67%(29/30)	90%(27/30)	93.33%	0.815 s

为验证蚁群算法优化结构参数的效果,分别计算BP神经网络和DBN参数优化前后的均方根误差,结果图9所示。可见,未优化的BP神经网络在第10次时陷入局部最优解,而ACO-BP达到预期精度。DBN网络虽没有陷入局部最优解,但训练时间较长,而ACO-DBN网络训练次数明显减少,很快达到训练精度。综上,蚁群优化后的DBN网络可以避免陷入局部最优解的问题,提高网络识别效率,性能优于传统的识别算法。

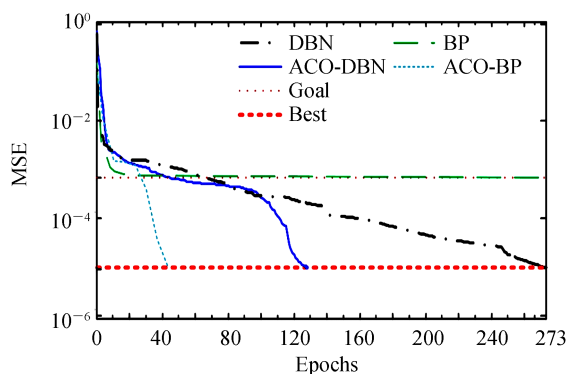


图9 不同方法收敛迭代次数对比
Fig.9 Comparison of convergence iteration times of different methods

5 结论

针对光纤周界系统中光纤振动信号信噪比较低和识别率不高的问题,本文提出了一种基于改进的局部特征尺度分解与融合指标筛选有效分量结合的特征提取方法,和一种基于深度学习的DBN网络识别方法。外场实验验证结果表明,该方法能够将复杂环境下不同扰动类型信号平均信噪比有效提升8 dB以上,平均识别率可达95.83%,平均识别时间为0.715 s。该方法不仅能准确提取入侵源的敏感信息,且能实时准确地识别不同入侵类型,为深度学习理论和分布式光纤周界系统相结合提供了新的思路。但在实际应用中,如

何自适应地提取敏感特征和多类型同时入侵识别是下一步研究的方向。

参考文献

- [1] RAO Yunjiang. Research progress of long-distance distributed optical fiber sensing technology[J]. Acta Physica Sinica, 2017, 66(7): 158-176.
饶云江. 长距离分布式光纤传感技术研究进展[J]. 物理学报, 2017, 66(7): 158-176.
- [2] WANG Siyuan, LOU Shuqin, LIANG Sheng, et al. Pattern recognition method of fiber distributed disturbance sensing system based on M-Z interferometer[J]. Infrared and Laser Engineering, 2014, 43(8): 2613-2618.
王思远, 姜淑琴, 梁生, 等. M-Z干涉仪型光纤分布式扰动传感系统模式识别方法[J]. 红外与激光工程, 2014, 43(8): 2613-2618.
- [3] PANG Shuo, LUO Zhengchun, WANG Zhongmin, et al. Interferometric optical fiber water level sensing system for marine water level monitoring[J]. Acta Photonica Sinica, 2019, 48(9): 0906003.
庞铄, 罗政纯, 王忠民, 等. 用于海洋水位监测的干涉式光纤水位传感系统[J]. 光子学报, 2019, 48(9): 0906003.
- [4] ZHANG Junnan, LOU Shuqin, LIANG Sheng. 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): 219-225.
张俊楠, 姜淑琴, 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): 219-225.
- [5] OLIVER W D, YU Y, LEE J C, et al. Mach-Zehnder interferometry in a strongly driven superconducting qubit[J]. Science, 2005, 310(5754): 1653-1657.
- [6] JIANG Jishan, JIANG Yi, LIU Da, et al. Fiber-optic perimeter security system based on dual Mach-Zehnder interferometer structure[J]. Optical Technique, 2015, 41(3): 193-196.
姜霁珊, 江毅, 刘达, 等. 基于双M-Z干涉仪的光纤周界防护系统[J]. 光学技术, 2015, 41(3): 193-196.
- [7] JIANG Lihui, GAI Jingyan, WANG Weibo, et al. Pattern recognition method of optical fiber perimeter early warning system based on overall average empirical mode decomposition[J]. Acta Optica Sinica, 2015, 35(10): 60-66.
蒋立辉, 盖井艳, 王维波, 等. 基于总体平均经验模态分解的光纤周界预警系统模式识别方法[J]. 光学学报, 2015, 35(10): 60-66.
- [8] LIU K, SUN Z S. A combined events recognition scheme using hybrid features in distributed optical fiber vibration sensing system[J]. IEEE Access, 2019, 7: 105609-105616.
- [9] ZHANG Yanjun, LIU Wenzhe, FU Xinghu, et al. An extraction and recognition method of the distributed optical fiber vibration signal based on EMD-AWPP and HOSA-SVM algorithm[J]. Spectroscopy and Spectral Analysis, 2016, 36(2): 577-582.
张燕君, 刘文哲, 付兴虎, 等. 基于EMD-AWPP和HOSA-SVM算法的分布式光纤振动入侵信号的特征提取与识别[J]. 光谱学与光谱分析, 2016, 36(2): 577-582.
- [10] ZHU Chenghui, ZHANG Si, LI Weitao, et al. The vibration signal recognition of optical fiber perimeter security system based on local mean decomposition[J]. Manufacturing Automation, 2018, 40(7): 107-111.
朱程辉, 章思, 李帷韬, 等. 基于局部均值分解的光纤周界安防系统振动信号识别[J]. 制造业自动化, 2018, 40(7): 107-111.
- [11] HUANG Jin, WU Qingliang, CHEN Fan. Study on energy distribution character about post-disaster rescue signal based on CEEMDAN-WPT denoising[J]. Journal of Nanjing University of Science and Technology, 2020, 44(2): 194-201.
黄金, 吴庆良, 陈钊. 基于CEEMDAN-WPT联合去噪的灾后求救信号能量分布特征研究[J]. 南京理工大学学报, 2020, 44(2): 194-201.
- [12] SEEDAHMED SM, JIM K, YUVARAJA V. Real-time distributed fiber optic sensor for security systems: Performance, event classification and nuisance mitigation[J]. Photonics Sensors, 2012, 2(3): 225-236.
- [13] YU Xiaomang, LUO Guangming, ZHU Zhenmin, et al. The multi target recognition of intrusion signal of perimeter security with distributed fiber-optic sensor[J]. Opto-Electronic Engineering, 2014, 41(1): 36-41.
喻晓芒, 罗光明, 朱珍民, 等. 分布式光纤传感器周界安防入侵信号的多目标识别[J]. 光电工程, 2014, 41(1): 36-41.
- [14] ZHU Hui, PAN Chao, SUN Xiaohan. Vibration pattern recognition and classification in OTDR based distributed optical-fiber vibration sensing system[C]. SPIE, 2014, 9062:906205.
- [15] LI Yibing, WANG Lei, JIANG Li. Rolling bearing fault diagnosis based on DBN algorithm improved with PSO[J]. Journal of Vibration and Shock, 2020, 39(5): 89-96.
李益兵, 王磊, 江丽. 基于PSO改进深度置信网络的滚动轴承故障诊断[J]. 振动与冲击, 2020, 39(5): 89-96.
- [16] XIONG Xinglong, CUI Yafeng, YANG Lixiang, et al. A new signal identification algorithm for airport environment optical fiber early warning system[J]. Journal of Optoelectronics·Laser, 2017, 28(9): 985-991.
熊兴隆, 崔雅峰, 杨立香, 等. 一种机场环境光纤预警系统的信号识别新算法[J]. 光电子·激光, 2017, 28(9): 985-991.
- [17] XIONG Xinglong, ZHANG Wantong, LI Meng, et al. Optical fiber perimeter vibration signal recognition based on local

- mean decomposition and serial feature fusion[J]. *Acta Optica Sinica*, 2019, 39(2): 0206002.
- 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.
- [18] MA Yuzhao, WANG Qiangqiang, WANG Ruisong, et al. Optical fiber perimeter vibration signal recognition based on SVD and MPSO-SVM[J]. *Systems Engineering and Electronics*, 2020, 42(8): 1-18.
- 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): 1-18.
- [19] XIONG Xinglong, ZHANG Wantong, FENG Lei, et al. Identification of vibration signals of optical fiber perimeter based on multifractal spectrum[J]. *Acta Photonica Sinica*, 2019, 48(2): 0206001.
- 熊兴隆, 张琬童, 冯磊, 等. 基于多重分形谱的光纤周界振动信号识别[J]. *光子学报*, 2019, 48(2): 0206001.
- [20] PENG S, LIAO Y H, LIN J. The shock pulse index and its application in the fault diagnosis of rolling element bearings [J]. *Sensors*, 2017, 17(3):535-560.
- [21] HUANG Xiangdong, ZHANG Haojie, LIU Kun, et al. High-efficiency intrusion recognition by using synthesized features in optical fiber perimeter security system[J]. *Acta Physica Sinica*, 2017, 66(12): 207-216.
- 黄翔东, 张皓杰, 刘琨, 等. 基于综合特征的光纤周界安防系统高效入侵事件识别[J]. *物理学报*, 2017, 66(12): 207-216.