

基于小波包分析和支持向量机的光时域反射仪 光缆故障识别

李斌¹, 张敏¹, 周恒^{1*}, 李竣屹², 凌云¹, 石林², 邱昆¹

¹电子科技大学信息与通信工程学院, 四川 成都 610054;

²航空工业成都飞机设计研究所, 四川 成都 610091

摘要 针对传统故障识别方法过程复杂、用时长、准确率低等问题,提出了一种基于小波包分析和支持向量机的光纤故障自动识别方法。对光时域反射仪采集的数据进行事件点定位,选择最优基小波和尺度完成事件信号的分解和重构,提取归一化的小波包能量作为事件信号的特征向量;建立支持向量机模型,将特征向量作为输入进行训练和测试,最终实现故障识别。实验对机载光缆中由连接器引起的反射事件和弯折引起的非反射事件进行二分类测试,总样本数为2500。实验结果表明,当训练样本数为1750,测试样本数为750时,该方法对机载光纤中反射事件和非反射事件的正确识别率为99%,耗时3.03 s;与基于反向传播神经网络的识别方法相比,准确率提升了2%,且耗时仅为其1%左右。目前已成功应用于自主研发的机载光缆组件外场检测设备。

关键词 信号处理; 光时域反射仪; 小波包; 特征提取; 支持向量机; 模式识别

中图分类号 TN247

文献标识码 A

doi: 10.3788/LOP56.021205

Identifying Optical Cable Faults in OTDR Based on Wavelet Packet Analysis and Support Vector Machine

Li Bin¹, Zhang Min¹, Zhou Heng^{1*}, Li Junyi², Ling Yun¹, Shi Lin², Qiu Kun¹

¹ School of Information and Communication Engineering, University of Electronic Science and Technology of China, Chengdu, Sichuan 610054, China;

² AVIC Chengdu Aircraft Design and Research Institute, Chengdu, Sichuan 610091, China

Abstract As traditional fault identification methods typically exhibit considerable processing complexity, are often time-consuming, and display a low degree of precision, a novel approach based on wavelet packet analysis using a support vector machine (SVM) is proposed in this study for the automatic identification of fiber defects in optical time domain reflectometry (OTDR). OTDR is initially used to acquire the original data of the fiber under test (FUT). Further, the event signs are decomposed by the optimal basic wavelet packet after the events are located, and the normalized energy features of the event signs as eigenvectors are extracted as input of training and testing based on the results of signal reconstruction. Finally, the SVM model is built, and fiber defects can be identified with the eigenvector as input. Subsequently, the SVM identification technique is used to obtain effective classification of the events as either reflection events, which are caused by connectors, or as non-reflection events, which are caused by bent events. In this study, two classification tests have been performed on a total of 2500 reflection and non-reflection events in airborne optical cable samples. The experimental results indicate that our method achieves a recognition rate of 99% in 3.03 s when the number of training samples is 1750 and when the number of testing samples is 750. Additionally, the recognition rate is increased by 2% and the recognition time is observed to be only 1% when compared to the previously proposed recognition method that is based on the backpropagation neural network. At present, the proposed method is successfully applied in the field detection equipment of airborne optical cable components independently developed.

Key words signal processing; optical time domain reflectometry; wavelet packet; feature extraction; support vector machine; pattern recognition

OCIS codes 120.4825; 060.2300; 100.4996

收稿日期: 2018-07-20; 修回日期: 2018-07-26; 录用日期: 2018-08-02

基金项目: 国家自然科学基金(61705033)、教育部中央高校科研业务经费(ZYGX2016J014)

* E-mail: zhouheng@uestc.edu.cn

1 引言

随着航空电子系统的发展,传统的铜制机载数据总线(ARINC429、1553B等)已难以满足新型飞机研制过程对数据传输带宽、实时性和可靠性等的要求^[1]。光纤具有质量小、带宽大、误码率低、抗电磁干扰能力强等优点,以光纤为传输介质的新型数据总线在航空网络中得到了广泛应用^[2]。因此,研究机载光纤检测技术可为航空器的持续安全飞行提供更多的保障。机载网络中采用光缆进行数据传输,一根光缆由多根多模光纤组成,两端采用牢固的航空连接器。由于机载光缆距离短,出现故障后都是整体更换,不需要对光纤进行熔接,因此机载光缆中主要的事件类型为连接器和弯折,而快速准确地完成所有装机光缆中光纤的故障识别对于生产和检修部门具有重要意义。

光时域反射计(OTDR)作为一种常用的光纤检测设备,具有性价比高、携带方便等特点,因而得到了广泛应用。光纤故障检测的过程即分析 OTDR 曲线的过程,包含故障定位和故障识别两个步骤。目前,常用的故障定位手段有五点法^[3]、最小二乘法^[4-5]、短时傅里叶变换^[6]、小波变换^[7-8]等,定位精度达 99%以上;而有关故障识别方法的研究较少,文献[9]中通过设计不同事件模型,利用互相关运算对定位后的事件进行类型判断,该过程中分析模型的选取直接影响了识别精度。文献[10]中预先对不同事件设置衰减门限,形成数据库,通过与数据库中不同事件类型的门限进行比对完成事件分类。传统的识别方法不仅过程复杂,且识别效果往往依赖设

计人员的经验。

20 世纪 80 年代以来,人工智能引起了人们的广泛关注,并被越来越多的引入到故障诊断的领域中来,形成故障的智能诊断方法。随着该技术的不断发展和完善,其在故障诊断中的作用得到逐步加强^[11]。

本文提出一种基于小波包分析和支持向量机(SVM)的光时域反射故障自动识别方法,可对传统光时域反射数据处理方案中的事件识别模块进行替换,而不会造成原系统中故障输出信息的丢失。基于小波包分析的能量特征提取机载光纤中反射事件(主要为活动连接器)和非反射事件(主要为弯折)两种常见故障信号,并送入 SVM 模型完成故障识别。为验证 SVM 的高效性,设置了反向传播神经网络(BPNN)识别模型作为对照组^[12-13]。

2 算法简介

2.1 小波包特征提取

小波变换具有多分辨分析的特点,在时频两域都有表征信号局部特征的能力,是一种时频局部化的分析方法,在低频部分具有较高的频率分辨力和较低的时间分辨力,在高频部分具有较低的频率分辨力和较高的时间分辨力,适用于探测正常信号中夹带的瞬态反常现象^[14]。小波包变换(WPT)是小波变换的延伸,已被证明是一种有效的信号处理技术^[15]。

从多分辨分析的角度来看,小波包分解的实质是让信号通过高低通组合滤波器组,每次分解总是把原信号分解到高低两个频率的通道内,接着对高低频部分分别进行同样的分解直到满足需求为止。图 1 为 3 层小波包分解树形图,其中的 F_s 为采样率^[16]。

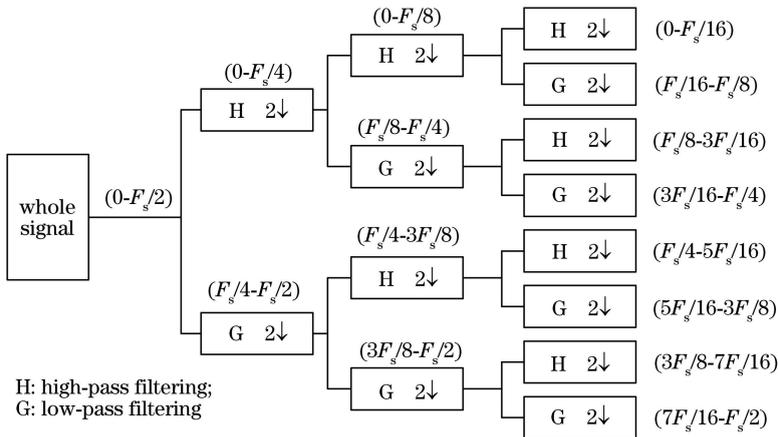


图 1 3 层小波包分解树图

Fig. 1 Decomposition tree of wavelet packet for three layers

小波包变换是一种线性变换,满足能量守恒定理,即

$$\int_{-\infty}^{+\infty} |f(t)|^2 dt = \sum_j \sum_k |c_{j,k}|^2, \quad (1)$$

式中: $f(t)$ 为原始信号; $c_{j,k}$ 为小波包分解系数。由此可知,小波包系数具有能量的量纲,可用于能量分析,因此,可以根据信号的小波包系数确定各个频段能量的大小^[17-19]。基于以上原理,对信号进行子带能量特征提取的步骤如下:

1) 选择适合的基小波和分解尺度 J , 对信号进行小波包分解。如 $J = 6$ 时, 信号被分解为 $K = 2^J = 64$ 个频带, 每个频带对应分解树中的一个节点。用 X_{6j} ($j = 1, 2, 3, \dots, 64$) 表示每个节点的分解系数, 对应(1)式中的 $c_{j,k}$ 。

2) 对第 6 层的所有节点进行重构, 用 S_{6j} 表示 X_{6j} 的重构信号, N 表示原始信号的长度, x_{jk} ($j = 1, 2, 3, \dots, 64, k = 1, 2, 3, \dots, N$) 表示信号 S_{6j} 的离散值的幅度。因此每个频段的总小波能量为

$$E_{6j} = \int |S_{6j}|^2 dt = \sum_{k=1}^N |x_{jk}|^2. \quad (2)$$

3) 对各子带能量 E_{6j} 进行归一化处理, 得到一个 64 维的小波包能量特征向量 $\mathbf{E} = [E_{\text{norm}}(1), E_{\text{norm}}(2), E_{\text{norm}}(3), \dots, E_{\text{norm}}(64)]$, 其中

$$E_{\text{norm}}(j) = \frac{E_{6j} - E_{\min}}{E_{\max} - E_{\min}}. \quad (3)$$

2.2 支持向量机

支持向量机是由 Vapnik 等提出的一种新型机器学习算法, 是在小样本统计理论 (SLT) 的基础上慢慢发展起来的。SVM 方法突破了传统的经验风险最小化原则, 进而追求结构风险最小化, 所以具有很强的泛化能力, 有效地解决了其他方法不能解决的小样本问题^[11]。SVM 主要具有 3 个基本功能: 模式识别、回归预测和概率密度估计。模式识别又分为线性支持向量分类机和非线性支持向量分类机^[20-21]。而现实情况中, 遇到的大多数问题都是非线性情况, 这时需要通过特征变换将非线性数据集映射到某个高维线性空间, 求出其中的最优分类面。下面给出线性情况下的支持向量机数学模型^[22]。

已知一组线性的训练数据集 $D = \{(\mathbf{x}_1, y_1), \dots, (\mathbf{x}_l, y_l)\}$, $\mathbf{x} \in \mathbf{R}^n$, $y \in \{-1, 1\}$, l 为样本数量, 假设存在线性判别函数 $f(\mathbf{x}) = \text{sgn}(\omega \cdot \mathbf{x} + b)$, 对应的超平面记作 $(\omega \cdot \mathbf{x}) + b = 0$, 其中, ω 为权重系数, b 为偏置项。将 $f(\mathbf{x})$ 进行归一化, 使所有的 x_i 都满足 $|f(\mathbf{x})| \geq 1$, 可计算出分类间隔为 $2/\|\omega\|$, 因此求解

最优超平面即为求 $\|\omega\|$ 的最小值。通过构造 Lagrange 函数, 引入乘子 $\alpha = \{\alpha_1, \alpha_2, \dots, \alpha_l\}$, 可将上述问题转换成凸二次规划问题。最终求解得到线性判别函数 $f(\mathbf{x}) = \text{sgn}[\sum_{i=1}^l \alpha_i y_i (\mathbf{x} \cdot \mathbf{x}_i) + b]$ ^[23]。

2.3 反向传播神经网络

反向传播神经网络是指用反向传播 (BP) 算法进行训练的多层感知器 (MLP) 模型, 是神经网络的重要组成部分, 在模式识别、经济分析、控制优化等领域得到了广泛应用。MLP 是一种前向网络, 通常具有一个输入层、一个或多个隐含层、一个输出层。最前端的输入层主要用于特征向量的输入, 所需要的节点个数一般和向量维数相同; 中间部分的隐含层主要进行复杂的数学运算, 其节点数目直接决定了该网络的判别能力和训练时间; 末端的输出层对输入层信息的判别和决策结果进行输出, 节点个数一般等于分类类别数。MLP 网络中每一层神经元节点都与前一层或后一层通过权值相连。同一层内的节点之间相互独立^[24-25]。

MLP 模型中应用最广泛的学习算法即为 BP 算法。BP 算法由信号的正向传播和误差的反向传播两个过程组成。正向传播时, 样本输入到网络中后, 检测输出层的实际输出结果是否满足期望, 若满足则学习过程结束, 若不满足则转至误差反向传播过程; 反向传播时, 对各神经元的权值和阈值不断调整, 使得网络中的总误差收敛到最小值^[26]。

3 实验结果及分析

实验步骤如图 2 所示, 包括事件点定位、样本库构建、特征提取、样本训练和样本测试 5 个过程。通过输入实验数据, 依据系统输出的准确率对实验效果进行评估。其中事件定位可采用常用的方案, 用来获取故障点的精确位置。

实验分析的数据来自于自主研发的高精度光子计数 OTDR, 该设备可实现不低于 18 dB 动态范围且空间分辨率小于 9 cm 的 32 通道机载光缆自动检测。选取机载光缆一个通道上的光纤作为测试对象, 观察其物理结构可知, 包含 3 个活动连接器和 2 个弯折点。由于被测光纤处于开放空间中, 且弯折处的固定并不牢固, 随着外界环境因素变化, 光纤中各事件点的损耗等特征也会变化, 因此利用 OTDR 测试时无需人为改变光纤链路条件。改变测试间隔, 可以捕获不同时刻下事件点的状态, 从而避免实验数据的偶然性。改变测试时长可影响

OTDR的信噪比,单次测试时间越长,信噪比越高,生成的曲线越平滑。为了保证实验数据的一般性,每次测试时设置不同的测试时长。通过编

写脚本进行自动测试,共获取到500组OTDR曲线,每条曲线包含10000个数据点,数据点间的时间间隔为0.025 ns。

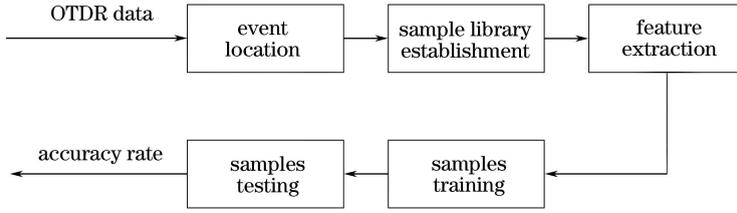


图2 实验步骤

Fig. 2 Experiment steps

对采集到的数据进行事件定位,可构造出一个包含2500个反射事件(正样本)和非反射事件(负样本)的样本库,其中正负样本比例为3:2。不同类型事件时域信号如图3所示,给出了样本库中一组反

射事件信号和非反射事件信号的时域图。将样本库一分为二,训练样本库容量为1750,测试样本库容量为750。

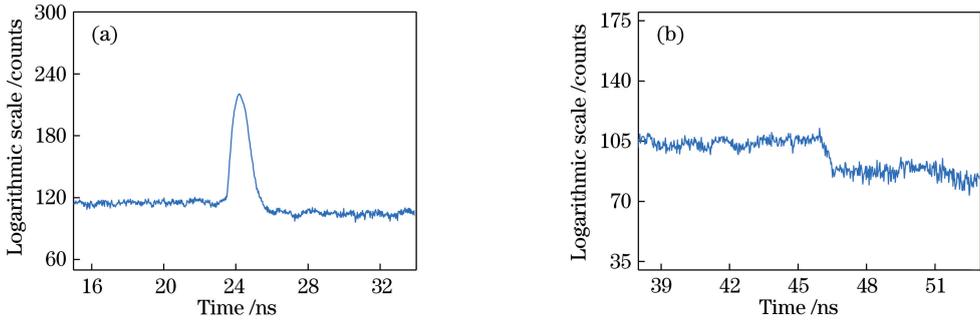


图3 不同类型事件时域信号。(a)反射事件;(b)非反射事件

Fig. 3 Time-domain signals of different-types events. (a) Reflection event; (b) non-reflection event

根据图2的实验步骤,样本库建立后,需采用小波包分析的方法进行信号特征提取,而基小波的选取会对提取出的特征向量产生巨大影响,需结合实际具体问题具体分析。这里通过定义能量均方根误差(RMSE)来评价基小波选取的好坏。RMSE值越大,表示特征向量的差异性越大,越适合用于故障表征。RMSE定义为

$$R_e = \sqrt{\frac{1}{M} \sum_{i=1}^M (E_{ri} - E_{nri})^2}, \quad (4)$$

式中: E_{ri} 为反射信号特征向量 \mathbf{E}_r 中第*i*个元素; E_{nri} 为非反射信号特征向量 \mathbf{E}_{nr} 中第*i*个元素; M 为特征向量长度。归一化的特征向量 \mathbf{E}_r 和 \mathbf{E}_{nr} 可利用(2)~(3)式得出,作为SVM和BPNN模型的输入使用。

选定一组反射事件信号和非反射事件信号,用Matlab软件提供的54个基小波(从1开始连续编号),逐一求解RMSE值。小波包分解尺度分别设置为3,4,5,6时,选择不同基小波计算得到的能量

均方根误差测试结果如图4所示。对比可知,不同尺度下采用第46号基小波(“rbio3.1”)对反射事件和非反射事件进行特征提取时,得到的RMSE值最大,即最优基小波的选取与尺度大小无关。因此,选用“rbio3.1”函数作为小波包分解用的基小波。

图5为以“rbio3.1”为基小波时,不同类型事件64维小波包能量特征向量,能量已进行归一化处理。由图5可知,二者能量分布差异明显,且信号的能量主要集中在前40个频带内,更高的频带处能量可近似为0。

除了选定基小波之外,在小波包分析时还应重点考虑分解尺度的选取。尺度过大,会造成计算量增大,测试时间延长;尺度过小,由于分解层数有限,提取到的特征向量区别度不高,影响识别准确度。因此,为了确定最佳的分解尺度,首先获得了尺度分别为1,2,3,4,5,6,7时不同类型事件对应的特征向量,作为输入送入不同的事件识别模型中,得到识别率。基于上述原理,搭建了SVM识别模型(采用线

性支持向量分类,惩罚系数 C 设置为 0.1, 1.0, 10.0, 100.0, 1000.0, 10000.0), 用于对不同事件类型进行识别, 同时搭建了传统的 BP 神经网络识别模型(单次训练迭代次数 epochs 为 500), 用于进行实验结

果的对比。实验过程中不改变样本内容和大小, 其中训练样本个数为 1750, 测试样本个数为 750, 正负样本比例为 3:2。

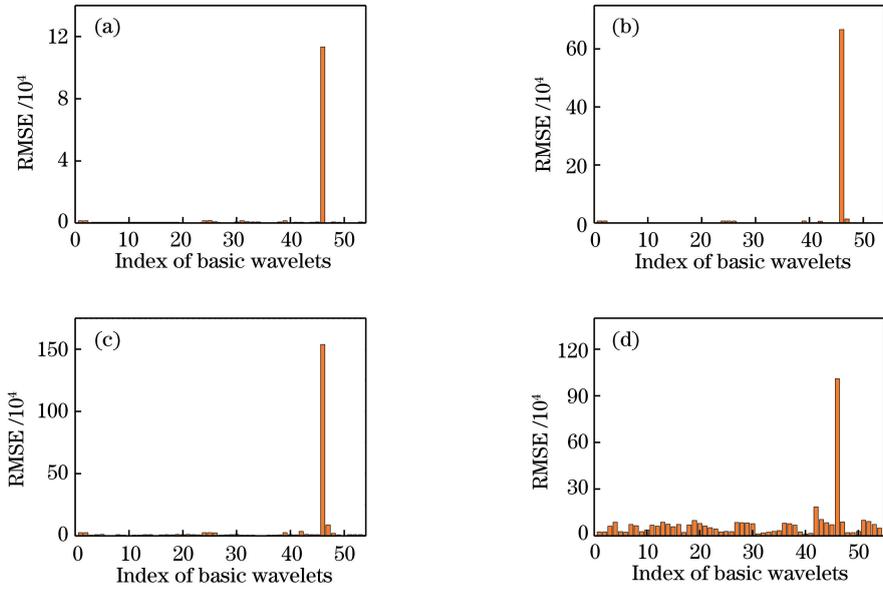


图 4 在不同尺度下选择不同基小波计算得到的能量均方根误差。(a) 尺度 3; (b) 尺度 4; (c) 尺度 5; (d) 尺度 6

Fig. 4 Root mean square errors calculated with different basic wavelet in different scales.

(a) Scale 3; (b) scale 4; (c) scale 5; (d) scale 6

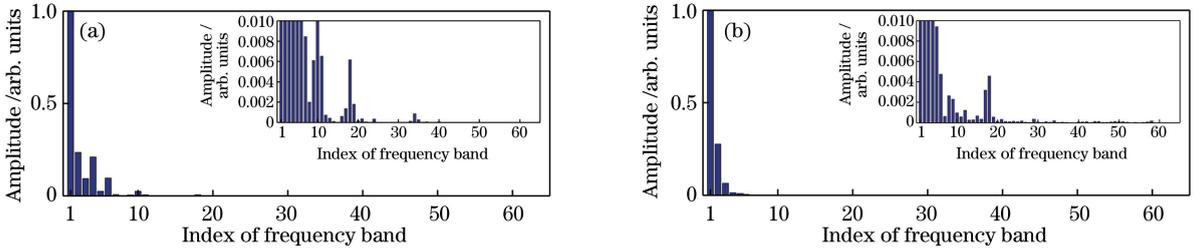


图 5 不同类型事件 64 维小波包归一化能量特征向量(主图为正常比例, 插图为放大 100 倍)。(a) 反射事件; (b) 非反射事件

Fig. 5 64-dimensional normalized feature vectors of different-types event signals

(main picture is normal, and inserted figure is magnified to 100 times). (a) Reflection event; (b) non-reflection event

条件相同时, 不同尺度下分类识别准确率如表 1 所示。尺度为 1, 2, 3 时, SVM 和 BPNN 的识别准确率均较差。0.5 的识别率对于二分类问题来说意味着每次测试都是随机识别; 随着尺度的增大, 两种模型的识别率升高; 当尺度大于 6 时, 识别率不再随尺度的增加而升高。该结论与图 5 中展示的信号的能量主要集中在低频部分结果一致, 即尺度较

低时, 反射事件和非反射事件的特征向量差别很小, 识别准确率较低; 增大尺度, 特征向量维数增加, 差异明显化, 故识别准确率增大。同时, 考虑到有效能量主要集中在前 40 个频带内, 过大的分解尺度只会增加算法复杂度, 综合考虑, 选择分解尺度 6 即可满足实验的需求。

表 1 不同尺度下分类识别准确率

Table 1 Recognition accuracies at different scales

Pattern recognition algorithm	Scale 1	Scale 2	Scale 3	Scale 4	Scale 5	Scale 6	Scale 7
SVM	0.5	0.5	0.5	0.84	0.85	0.99	0.99
BPNN	0.5	0.5	0.5	0.79	0.81	0.97	0.97

为了进一步评价本方法的优势,基于以上实验中的分类模型设置,在不改变测试样本的情况下,分析了不同训练样本数时两种模型的识别率和收敛时间,得到不同训练样本数时支持向量机和反向传播神经网络的测试结果,如图 6 所示。由图 6(a)可知,随着训练样本数目的增加,两种模型的识别率都得到了提高,训练样本数达到 1750 时,SVM 模型的

识别率比 BPNN 模型提高了 2%;且在小样本数量时,SVM 模型的准确率更优于 BPNN 模型。由图 6(b)可明显看出,随样本数量的增加算法耗时逐步变长,但相比 BPNN 模型,SVM 的收敛速度快,用时仅约为其 1%,在不到 10 s 的时间内即可完成测试,满足实际应用过程中快速测试的要求。

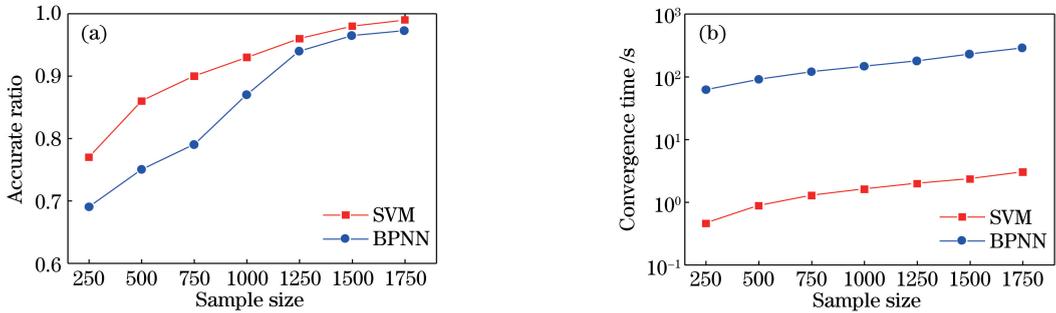


图 6 不同训练样本数时支持向量机和反向传播神经网络的测试结果。(a)准确率;(b)收敛时间

Fig. 6 Test results of support vector machine and back propagation neural network for different numbers of training samples. (a) Accurate ratio; (b) convergence time

4 结 论

提出了一种基于小波包分析和 SVM 的 OTDR 机载光缆故障识别方法,用于完成对机载光缆中反射事件(主要为活动连接器)和非反射事件(主要为弯折)的自动识别。实验结果证明小波包分析适用于 OTDR 曲线分析,可用于故障信号的能量特征提取。为选出小波包分析过程中的最优基小波,定义了能量均方根误差,通过遍历所有基小波得到最大能量均方根误差值,确定了基小波函数“rbio3.1”,进而依据实验测试结果和理论分析确定了最优分解尺度 6。最终的故障识别结果表明,将特征向量送入 SVM 模型能够实现故障类型的自动识别,在训练样本数量为 1750 时,准确率达到 99%,模型耗时 3.03 s,相比 BPNN 模型准确率提高了 2%,而耗时仅为后者的 1%左右,因此满足机载光缆快速检测的要求。由此可见,所提方法是一种合理有效的方法。虽然文中仅对机载光缆中的连接器和弯折事件进行分类测试,但如果将 SVM 模型中的二分类算法改为多分类算法,便可拓展到存在更多事件类型的民用光缆中使用,因此该方法可为 OTDR 光缆检测系统性能的进一步提高提供有益参考。

参 考 文 献

[1] Lu J H. Airborne bus technology research and summary[J]. Electronic Test, 2017(7): 72-73.

速计划. 机载总线技术发展研究[J]. 电子测试, 2017(7): 72-73.

[2] Huang X H, Hu Y, Zhang D Y. Testing technique and analysis of PC-OTDR applied on optical fiber linkage of civil aviation aircraft [J]. Journal of Chongqing University of Technology (Natural Science), 2014, 28(2): 106-110.

黄选红, 胡炎, 张德银. 光时域反射法在民航飞机光纤通信系统中的检测技术与分析[J]. 重庆理工大学学报(自然科学), 2014, 28(2): 106-110.

[3] Yang W K. Measuring joint loss with optical time domain reflectometry (five-point method)[J]. Optical Fiber & Electric Cable and Their Application, 1984 (3): 25-28.

杨文奎. 用光时域反射计测接头损耗(五点法)[J]. 光纤与电缆及其应用技术, 1984(3): 25-28.

[4] Hu Q. Effect of unreal peaks on measurement of fiber splicing loss with OTDR at least square method mode [J]. Optical Communication Technology, 2003, 27(10): 29-30.

胡庆. 在最小二乘法模式下幻峰对 OTDR 测试光纤接头损耗的影响[J]. 光通信技术, 2003, 27(10): 29-30.

[5] Ma S W. Application of Haar wavelet and least square estimation to fiber monitoring online system [J]. Railway Computer Application, 2007, 16(9): 32-35.

马少伟. Haar 小波和最小二乘法在光纤监测系统的

- 应用[J]. 铁路计算机应用, 2007, 16(9): 32-35.
- [6] Man X J, Dong Y, He H, *et al.* Analysis of connection splice events in OTDR data using short Fourier transform method [J]. Chinese Journal of Scientific Instrument, 2010, 31(9): 2121-2125.
满晓晶, 董毅, 何浩, 等. 基于短时傅里叶变换的光时域反射计(OTDR)事件分析[J]. 仪器仪表学报, 2010, 31(9): 2121-2125.
- [7] Zhou H S. The application study on fiber monitoring system based on wavelet transform [D]. Beijing: Beijing Jiaotong University, 2008.
周宏晟. 小波变换在光缆监测系统中的应用 [D]. 北京: 北京交通大学, 2008.
- [8] Liao M M, Chen W. Positioning and detecting of fault points in optical communication cable lines [J]. Study on Optical Communications, 2011, 41(1): 26-27.
廖敏敏, 陈伟. 通信光缆线路中故障点的定位与检测 [J]. 光通信研究, 2015, 41(1): 26-27.
- [9] Kong H. Research on events analysis algorithms in optical time domain reflectometry [D]. Shanghai: Shanghai Jiao Tong University, 2015.
孔衡. 光时域反射的事件分析算法研究 [D]. 上海: 上海交通大学, 2015.
- [10] Li J. The applied research of OTDR curve analytic technique in optical fiber fault diagnosis [D]. Baoding: North China Electric Power University, 2011.
李俊. OTDR 曲线分析技术在光纤故障诊断中的应用研究 [D]. 保定: 华北电力大学, 2011.
- [11] Zhu X X. Research on rotating machine fault diagnosis and prediction method based on support vector machine [D]. Baoding: North China Electric Power University, 2013.
朱霄珣. 基于支持向量机的旋转机械故障诊断与预测方法研究 [D]. 保定: 华北电力大学, 2013.
- [12] Zhang J L, Zhao Y. Based on the improved neural network of fiber optic fault monitoring and optimization [J]. Laser Journal, 2016, 37(6): 131-134.
张景璐, 赵妍. 基于改进神经网络的光纤故障监测优化 [J]. 激光杂志, 2016, 37(6): 131-134.
- [13] Chen C, Xiao Y, Li A D, *et al.* OTDR events analysis algorithm based on wavelet transform and RBF neural network [J]. Optical Communication Technology, 2017, 41(2): 25-28.
陈诚, 肖逸, 李爱东, 等. 基于 RBF 神经网络的 OTDR 小波分析算法 [J]. 光通信技术, 2017, 41(2): 25-28.
- [14] Shi Q L, Lin J. Correlation analysis method based on wavelet packet decomposition and energy feature extraction [J]. Acoustics and Electronics Engineering, 2010(4): 18-20, 24.
史秋亮, 林江. 基于小波包分解与能量特征提取的相关分析法 [J]. 声学与电子工程, 2010(4): 18-20, 24.
- [15] Gui Z H, Han F Q. Neural network based on wavelet packet-characteristic entropy for fault diagnosis of draft tube [J]. Proceedings of the CSEE, 2005, 25(4): 99-102.
桂中华, 韩凤琴. 小波包特征熵神经网络在尾水管故障诊断中的应用 [J]. 中国电机工程学报, 2005, 25(4): 99-102.
- [16] Wang B J, Pi S H, Sun Q, *et al.* Improved wavelet packet classification algorithm for vibrational intrusions in distributed fiber-optic monitoring systems [J]. Optical Engineering, 2015, 54(5): 055104.
- [17] Li Q H. Introduction to sonar signal processing [M]. Beijing: Science Press, 2012.
李启虎. 声呐信号处理引论 [M]. 北京: 科学出版社, 2012.
- [18] Zeng Y, Wu H L. The energy characteristics on the frequency bands extracted based on the wavelet packet and intelligent diagnosis [J]. Computing Technology & Automation, 2008, 27(4): 115-117.
曾芸, 武和雷. 基于小波包的频带能量特征提取及智能诊断 [J]. 计算技术与自动化, 2008, 27(4): 115-117.
- [19] Gu X H, Zhang G X, Hou D B, *et al.* Detection of water pipe leak location using wavelet packet decomposition and power feature extraction [J]. Journal of Sichuan University (Engineering Science Edition), 2005, 37(6): 145-149.
谷小红, 张光新, 侯迪波, 等. 小波包分解与能量特征提取相结合的水管泄漏位置的确定 [J]. 四川大学学报(工程科学版), 2005, 37(6): 145-149.
- [20] Wang S T, Zhang C X, Wang Z F, *et al.* Application of least squares support vector machine in fluorescence detection of sodium methylparaben [J]. Laser & Optoelectronics Progress, 2017, 54(7): 073001.
王书涛, 张彩霞, 王志芳, 等. 最小二乘支持向量机在对羟基苯甲酸酯钠荧光检测中的应用 [J]. 激光与光电子学进展, 2017, 54(7): 073001.
- [21] Zhang Y J, Wang H M, Fu X H, *et al.*

- Identification of steel plate damage position based on particle swarm support vector machine[J]. Chinese Journal of Lasers, 2017, 44(10): 1006006.
- 张燕君, 王会敏, 付兴虎, 等. 基于粒子群支持向量机的钢板损伤位置识别[J]. 中国激光, 2017, 44(10): 1006006.
- [22] Li D, Zhou K F, Sun W D, *et al.* Application of BP neural network and SVM in mine environmental assessment[J]. Arid Land Geography, 2015, 38(1): 128-134.
- 李东, 周可法, 孙卫东, 等. BP神经网络和SVM在矿山环境评价中的应用分析[J]. 干旱区地理, 2015, 38(1): 128-134.
- [23] Zhan Y, Cheng H Z, Ding Y F, *et al.* S-transform-based classification of power quality disturbance signals by support vector machines[J]. Proceedings of the CSEE, 2005. 25(4): 51-56.
- 占勇, 程浩忠, 丁屹峰, 等. 基于S变换的电能质量扰动支持向量机分类识别[J]. 中国电机工程学报, 2005, 25(4): 51-56.
- [24] Li Y M. The study of BP learning algorithm of artificial neural network and its application in face recognition[D]. Jinan: Shandong University, 2012.
- 李永明. 神经网络BP学习算法的研究及在人脸识别中的应用[D]. 济南: 山东大学, 2012.
- [25] Han L. The Classification model of RS images based on artificial neural network: MLP [J]. Bulletin of Surveying & Mapping, 2004(9): 29-30.
- 韩玲. 基于人工神经网络: 多层感知器(MLP)的遥感影像分类模型[J]. 测绘通报, 2004(9): 29-30.
- [26] Ha Z Q, Yu H. Neural network control[M]. Xi'an: Xidian University Press, 2009.
- 哈宗泉, 喻晗. 神经网络控制[M]. 西安: 西安电子科技大学出版社, 2009.