UHMWPE/LDPE 层合板复合材料损伤声发射信号识别

王　旭[1]　　杜增锋[1]　　倪庆清[2]　　刘新华[1]

（1　安徽工程大学纺织服装学院，芜湖　241000）

（2　信州大学纤维学部，日本 长野　3868567）

文　摘　为了掌握 UHMWPE/LDPE 复合材料的损伤机理，运用声发射技术结合聚类分析方法建立不同损伤形式的声发射信号训练样本，通过神经网络实现损伤信号的识别，并分别探讨了训练函数、传递函数、网络结构等因素对识别率的影响。研究表明，由系统聚类可提取幅度、峰值频率、持续时间为模式特征，结合 K-means 聚类可建立 11 个类别共 583 信号的训练样本。以混淆矩阵为识别率指标，当训练函数为 traingdx、隐层/输出层传递函数为 tansig/logsig、隐层神经元数量为 70 时，网络的识别率达 97.2%，为基于声发射技术的热塑性基体复合材料损伤识别提供参考。

关键词　复合材料，声发射，损伤机理，聚类分析，神经网络

中图分类号：TB332　　DOI：10.12044/j.issn.1007-2330.2019.02.015

Pattern Recognition of Damage Modes in UHMWPE/LDPE Composites Laminates by Acoustic Emission Technique

WANG Xu[1]　　DU Zengfeng[1]　　NI Qingqing[2]　　LIU Xinhua[1]

（1　College of Textile and Clothing, Anhui Polytechnic University, Wuhu　241000）

（2　Faculty of Textile Science and Technology, Shinshu University, Japan Nagano　3868567）

Abstract　In order to master damage mechanism of UHMWPE/LDPE composite material, training sample of acoustic emission signal with different damage modes was established by clustering analysis and acoustic emission technology. Acoustic emission signal generated from different damage modes were identified by neural network. The factors affecting the recognition accuracy of network such as training function, transfer function and network architecture were discussed respectively. The results revealed pattern characteristic consisting of amplitude, peak frequency and duration can be selected by hierarchical clustering method. The training sample consisting of 583 signals with 11 classes can be established by K-means clustering method. Using the confusion matrix as the recognition accuracy index, when the training function is traingdx, the hidden layer/output layer transfer function is tansig/logsig, and the number of hidden layer neurons is 70, the recognition accuracy of the network is 97.2%. The results provide reference for the damage identification of thermoplastic matrix composites based on acoustic emission technology.

Key words　Composite material, Acoustic emission, Damage mechanism, Clustering analysis, Neural network

0　引言

复合材料的多相结构及损伤的多种形式，导致其损伤机理及演化过程十分复杂。断口分析能有效提供损伤的微观形貌，但无法提供损伤过程的动态信息[1]。近年来，声发射（Acoustic Emission，AE）技术逐渐成为复合材料损伤机理研究的有效工具之一。研究表明，复合材料损伤过程的载荷历程和 AE 信号参数历程具有一致性[2]，通过分析伴随损伤产生的 AE 信号，可掌握损伤对应的 AE 特征，并在此基础上揭示材料的损伤演化过程[3-5]。通常复合材料不同损伤模式的 AE 信号在存在一定的差异。黄文亮等[6]发现 CFRP 切削过程入口和出口处撕裂的 AE 信号 RMS 参数不同。Q.Q.NI 和 I.YANG 等[7-8]发现不同损伤模式的 AE 信号频率特征不同。袁忠等[9]以 AE 信号的近似熵谱特征

收稿日期：2018-05-03

基金项目：安徽工程大学科研启动基金项目（2012YQQ008）；安徽高校优秀青年骨干人才访学研修项目（gxfx2017045）；安徽工程大学国家自然基金预研项目（2015yy02）；安徽工程大学研究生实践与创新资助项目（2017）

第一作者：王旭，1973 年出生，博士，副教授，主要从事复合材料损伤机理研究工作。E-mail：wangxu_ahpu@hotmail.com

识别出层压板基体开裂、界面脱胶及纤维断裂等损伤。识别不同损伤模式的 AE 信号是掌握损伤机理及其演化的关键。童小燕等[10]运用 K 均值聚类得到基体开裂、界面层脱粘、分层及纤维断裂等损伤模式的 AE 信号。H.A.SAWAN 等[11]分别对±45°、0°及准各向同性碳纤/环氧层合板拉伸及弯曲过程的 AE 信号聚类,得到不同损伤机制的 AE 信号。张卫东等[12]以 AE 信号的累积撞击数、累积振铃计数和累积能量计数等为特征,运用神经网络识别出材料在弹性、屈服、塑性和断裂等力学行为。王健等[13]以运用神经网络对碳纤维增强复合材料纤维断裂、基材开裂、界面分离、分层等6种典型损伤形式的 AE 信号进行了识别,总的识别正确率高达 93.9%。上述基于 AE 技术的复合材料损伤研究大多是热固性基体,而针对热塑性基体复合材料损伤的研究尚不多见,同时损伤形式或程度的判定还部分依赖于人为经验。为此本文以 UHMWPE/LDPE 层合板为研究对象,由模型试样拉伸破坏诱导产生预期损伤形式的 AE 信号并聚类产生训练样本,借助神经网络方法实现对不同损伤 AE 信号的识别,并比较了不同网络结构、传递函数、训练算法等的识别正确率,以寻求客观、高效的复合材料损伤识别方法。

1 实验

1.1 材料制备

UHMWPE 纤维规格 145tex/240F,密度 0.97 g/cm^3,拉伸强度 3 013 MPa,弹性模量 91 GPa,断裂应变 3.3%。基体 LDPE,密度 0.92 g/cm^3。纤维束均匀缠绕在铺有 LDPE 薄膜的不锈钢芯板上,由硫化机热压制备成复合材料层合板。DSC(Modulated DSC 2910)测定纤维和基体熔融温度分别为 147 和 112℃。硫化机设定温度 120℃,压力 1.5 MPa,热压 10 min 后保压冷却固化成型。

1.2 拉伸及声发射试验

为了诱导产生特定的损伤,制备了 4 种拉伸试样,规格、测试速度及预期损伤如表 1 所示。

表 1 中 S1~S4,分别表示纯 LDPE 树脂、90°单层板、纤维束及[±45°]层合板。图 1 所示为拉伸及 AE 测试示意图,材料试验机为长春试验机研究所 DNS-100 型,试样工作距离均为 120 mm。每类试样均重复 5 次拉伸试验并同步采集 AE 信号。AE 系统为美国 PAC 公司 PCI-2 型,2 个 R15 型传感器间距 60 mm 沿试样中心线对称布置,传感器和试样间用真空脂耦合并用松紧带固定于试样表面。AE 信号触发门槛值为 40 dB。由断铅时差法分别得到各类试样 AE 信号的波速,其中 S1 为 2 800 m/s,S2 为 3 470 m/s,S3 为 2 780 m/s,S4 为 3 160 m/s。记录发生在传感器之间的 AE 信号供分析使用,其中峰值鉴别时间 50 μs,波击鉴别时间 100 μs,波击闭锁时间 300 μs,事件定义时间 100 μs,事件闭锁时间 110 μs,前置放大器 40 dB。

表 1 试样测试及预期损伤

Tab.1 Specimen test and damage mode

类别	规格/mm	速度/mm·min^{-1}	预期损伤
S1	180×20×0.8	20	基体损伤
S2	180×20×0.8	1	界面损伤
S3	180,145tex/240F	1	纤维断裂
S4	180×20×1.6	1	层间损伤

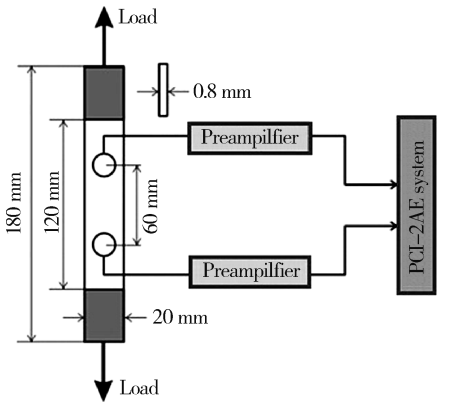


图 1 拉伸及 AE 测试示意图

Fig.1 Sketch map of tensile and AE test system

2 结果与分析

2.1 AE 信号模式特征的确定

聚类分析是根据数据集客观存在的多个类,以类内数据具有较强相似性而建立的一种数据描述方法。若聚类变量选择合适则由其构成的模式特征空间中同类数据相距较近且分布密集,不同类数据相距较远。聚类变量越多并非对聚类效果越有利,尤其是当变量间存在较强的相关性时,不仅不能提高聚类效果反而增加计算量。AE 参数是对 AE 波形信号的量化描述,如图 2 所示时域参数如幅度、振铃计数、峰值前振铃计数、上升时间、持续时间。此外通过时频转换得到频域参数,如频率质心、峰值频率、平均频率等。

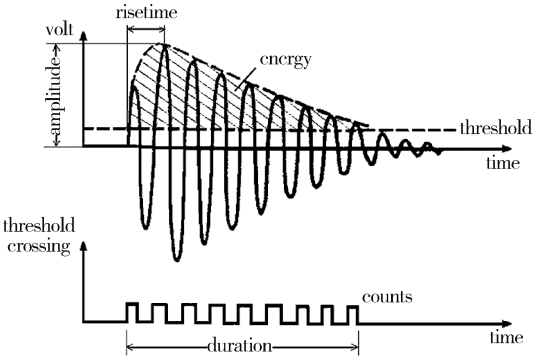


图 2 AE 参数示意图

Fig.2 Sketch map of AE parameters

对上述 AE 参数进行系统聚类,从中选择合适的 AE 参数作为模式特征。从试样 S1、S2、S3、S4 采集的 AE 信号数量分别为 63、227、127、166,输入 SPSS

软件执行分类/系统聚类命令,选择变量聚类方式,以欧氏距离为相似性测度,按照离差平方和法(Ward method)聚类结果如图 3 所示。

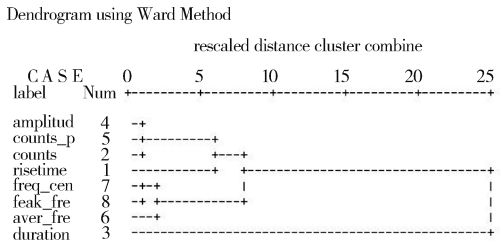


图 3 AE 参数的系统聚类

Fig.3 Hierarchical clustering of AE parameters

由图 3 将 8 个 AE 参数分为 3 类,其中第 1 类包括幅度、振铃计数、峰值前振铃计数和上升时间,第 2 类包括频率质心、峰值频率和平均频率,第 3 类为持续时间。由于类内的 AE 参数具有更大的相似性,可选择幅度、峰值频率和持续时间作为 AE 信号的模式特征。

2.2 AE 信号训练样本的建立

训练样本是已标记分类标签的 AE 信号。基于同类损伤模式 AE 信号具有更大相似性的原则,分别对试样 S1~S4 拉伸破坏过程的 AE 信号进行 K-means 聚类分析,从而得到不同损伤模式 AE 信号的训练样本。影响 K-means 聚类的因素包括聚类数 k 的确定和初始聚心,参照预备试验及文献[14]确定试样 S1~S4 的 k 值分别为 3、3、2、3,并确定相应的初始聚心,为消除量纲的影响,原始数据先进行 Z 标准化。执行 SPSS 软件分类/K-均值聚类,读入初始聚心文件,选择迭代与分类方式,分别对试样 S1~S4 的 AE 信号进行聚类,聚类完成后,各类别的 AE 信号个数及相应的最终聚心如表 2 所示。

表 3 为 LDPE 基体的 3 类损伤及 AE 信号特征。由于拉伸过程应变能主要以塑性变形的释放,故 AE 信号具有幅度低、持续时间短的特征,仅在断裂时产生幅度高、持续时间长的 AE 信号。

表 2 试样 AE 信号最终聚心

Tab.2 Final cluster center of AE signal of specimen

类别	个数	幅度	峰值频率	持续时间
S1-1	7	2.499	-0.927	2.702
S1-2	28	-0.267	-0.862	-0.209
S1-3	28	-0.345	1.094	-0.467
S2-1	14	3.317	-1.942	3.324
S2-2	32	0.342	-1.933	0.32
S2-3	181	-0.317	0.491	-0.314
S3-1	34	1.42	-0.337	1.524
S3-2	93	-0.519	0.123	-0.557
S4-1	49	0.727	-1.517	0.317
S4-2	94	-0.723	0.719	-0.652
S4-3	23	1.408	0.292	1.987

表 3 基体损伤模式的 AE 信号特征

Tab.3 AE features of matrix damage modes

类别	损伤类型	AE 信号特征
S1-1	基体断裂	幅度高、持续时间长、峰值频率低
S1-2	塑性变形	幅度低、持续时间短、峰值频率较低
S1-3	塑性变形	幅度低、持续时间短、峰值频率较高

表 4 为界面的 3 类损伤及 AE 信号特征。其中 S2-2,S2-3 伴随加载的全过程均有产生,而 S2-1 仅在临近断裂时产生。UHMWPE 纤维的表面惰性导致界面强度低,伴随加载过程,界面损伤不断累积,最终导致材料因界面脱粘而破坏。

表 4 界面损伤模式的 AE 信号特征

Tab.4 AE features of interface damage modes

类别	损伤类型	AE 信号特征
S2-1	界面脱粘	幅度高、持续时间长、峰值频率低
S2-2	界面损伤	幅度低、持续时间短、峰值频率较低
S2-3	界面损伤	幅度低、持续时间短、峰值频率较高

表 5 为纤维的 2 类损伤及 AE 信号特征,其中 S3-2 类加载过程均有发生,该类信号源于损伤早期的单纤维随机断裂,具有幅度低、持续时间短的特征。S3-1 类主要发生于临近断裂大量纤维集中断裂时,具有幅度高、持续时间长的特征。

表 5 纤维断裂损伤模式的 AE 信号特征

Tab.5 AE features of fiber damage modes

类别	损伤类型	AE 信号特征
S3-1	纤维集中断裂	幅度高、持续时间长、峰值频率低
S3-2	部分纤维断裂	幅度低、持续时间短、峰值频率高

表 6 为层间的 3 类损伤及 AE 信号特征。观察试样发现侧边明显的分层且层内有界面剪切破坏。综合幅度和持续时间判断,S4-3、S4-1 分别源于较大、中等程度的损伤,S4-2 则源于较低程度的损伤。界面强度低是导致层内和层间破坏的重要原因。

综上分析,AE 信号分别对应为 11 种不同的损伤模式,则训练样本可由输入向量 $\boldsymbol{p}$ 和对应的目标向量 $\boldsymbol{t}$ 构成,每个 AE 信号均为含有 3 个元素(幅度、峰值频率和持续时间)的列向量 $\boldsymbol{p}$,并分别对应一个目标向量 $\boldsymbol{t}$,$\boldsymbol{t}$ 为具有 11 个元素的列向量,其中只有一个非零元素 1 所在的行代表损伤模式类型,其他元素均为 0。

表 6 层间损伤模式的 AE 信号特征

Tab.6 AE features of interlayer damage modes

类别	损伤类型	AE 信号特征
S4-1	层间中等损伤	幅度中、持续时间中、峰值频率低
S4-2	层间较低损伤	幅度低、持续时间短、峰值频率高
S4-3	层间较大损伤	幅度高、持续时间长、峰值频率中

2.3 BP 神经网络的建立

BP(back propagation)网络是基于误差逆向传播算法的多层前馈神经网络,它由多个神经元层构成,每层包含多个神经元,神经元是多输入单输出的信息处理单元。BP 网络结构如图 4 所示。

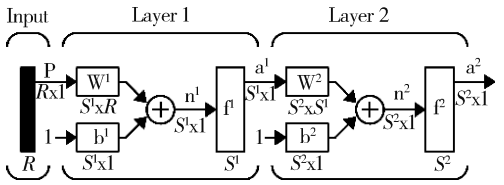


图 4 BP 网络结构示意图

Fig.4 Scheme of BP neuron network

图 4 中 Input 为网络输入,R 为输入节点数,$\boldsymbol{p}$ 为 R 行 1 列输入向量。隐层 Layer1 和输出层 Layer2 中,S^1、S^2分别为各层神经元数,$\boldsymbol{W}^1$、$\boldsymbol{W}^2$分别为各层网络权值,b^1、b^2分别为各层偏置值,f^1、f^2分别为各层 f 传递函数,$\boldsymbol{a}^1$、$\boldsymbol{a}^2$分别为各层输出。MatLab 软件的神经网络工具箱 nntool 可以方便的建立并训练 BP 网络。

2.4 网络参数对网络性能的影响

2.4.1 影响网络性能的网络参数

影响网络效果的网络参数包括网络结构、传递函数、训练算法等。图 4 所示的网络结构可记为 $R-S^1-S^2$,其中 R 由 $\boldsymbol{p}$ 的维数确定,S^2由目标向量 $\boldsymbol{t}$ 的维数决定。由 AE 信号的训练样本可知,$R=3$,$S^2=11$。隐层 Layer1 神经元数 S^1一般通过试探的方式确定,为减少计算量在满足要求时 S^1以少为宜,根据预备试验和训练样本量,S^1范围定在 10~90 之间。传递函数 f 不同会引起网络输出 $\boldsymbol{a}$ 的变化,进而影响网络性能,其关系见式(1)。

$$\boldsymbol{a}=f(\boldsymbol{W}\boldsymbol{p}+\boldsymbol{b}) \tag{1}$$

式中,$\boldsymbol{p}$ 为输入向量,$\boldsymbol{W}$、$\boldsymbol{b}$ 分别为网络权值矩阵和偏置值向量,nntool 提供的 f 包括阶跃函数 hardlim、线性函数 purelin 和非线性函数 logsig、tansig 等[15]。

网络训练的实质是通过训练样本不断调整 $\boldsymbol{W}$ 和 $\boldsymbol{b}$,使输出 $\boldsymbol{a}$ 和目标 $\boldsymbol{t}$ 更加接近,通常以两者的均方误差作为网络性能指数,其值越小说明网络性能越好。训练函数不同网络性能也存在差异,nntool 提供多种训练函数可供选择,训练后的网络分类效果可借助混淆矩阵(Confusion Matrix)评价[15]。

2.4.2 训练函数和传递函数对网络性能的影响

表 7 为不同训练函数对同一网络结构 3-50-11,隐层和输出层传递函数均为 logsig,每种执行 10 次,以训练时间和识别率均值反映的网络性能。5 种训练函数分别为 traingd(标准梯度下降法)、traingdx(动量及可变学习率法)、trainrp(弹性梯度法)、trainoss(一步正割法)、traincgf(共轭梯度法)[15]。终止训练条件为迭代 5 000 次或性能指数小于等于 10^{-4}。所有训练均以完成 5 000 次迭代而停止,其中以 traingdx 为训练函数训练时间最短 71 s,以 trainoss 为训练函数训练时间最长 191 s,其他在 71~191 s 之间。从识别率上看,标准梯度下降算法 traingd 最低仅为 36.0%,对于损伤识别几乎没有应用价值。经过一步正割法改进的 trainoss 和共轭梯度法改进的 traincgb 识别率有较大提高,分别达到79.1%和83.9%。经弹性梯度下降算法改进的 trainrp 和动量及可变学习率改进的 traingdx 是识别率最好的两种训练函数,分别达 96.2%和 96.6%。标准梯度下降算法受网络初始权值 $\boldsymbol{W}$ 和偏置值 $\boldsymbol{b}$ 的影响较大,且当学习率设置较小时算法容易陷入局部极小,学习率设置较大时算法又会变得不稳定。经过优化改进的训练函数识别率有较大的提高。综合识别率和训练时间分析,选择 traingdx 作为网络训练函数。

表 7 不同训练函数的网络性能

Tab.7 Network performance of different training functions

训练函数	时间/s	识别率/%
traingd	74	36.0
traingdx	71	96.6
trainrp	79	96.2
trainoss	191	79.1
traincgb	87	83.9

表 8 为隐层/输出层的 6 种不同传递函数搭配,对训练函数为 traingdx,结构为 3-50-11 网络的训练结果。从识别率看,当隐层/输出层是非线性/非线性传递函数时,识别率均优于非线性/线性传递函数搭配的情况,其中以 tansig/logsig 搭配时识别率高达 96.9%,训练时间 55 s 也相对较短,更适合作为隐层/输出层传递函数。

表 8 不同传递函数的网络性能

Tab.8 Network performance of different transfer functions

传递函数	时间/s	识别率/%
logsig/logsig	71	96.6
logsig/tansig	57	83.9
logsig/purelin	52	81.8
tansig/tansig	58	88.9
tansig/logsig	55	96.9
tansig/purelin	52	84.9

2.4.3 网络结构对网络性能的影响

表 9 为以 traingdx 为训练函数、隐层/输出层传递函数为 tansig/logsig 时,不同隐层神经元数时的网络性能。根据预备实验,隐层神经元数量选择 10、30、50、70、90。终止训练条件为迭代 5 000 次或性能指数小于

等于 10^{-4}。由表 9 看出,识别率随隐层神经元数量增加而逐渐提高,但数量达 50 后继续增加对提高识别率作用有限且训练时间增加。说明适当增加隐层神经元数量,有利于提高网络性能,但隐层神经元过多有可能使网络出现过拟合现象导致识别率降低。

表 9　不同网络结构的网络性能

Tab.9　Network performance of different architecture

隐层神经元	时间/ s	识别率/ %
10	35	87.3
30	43	96.6
50	55	96.9
70	76	97.2
90	83	96.7

图 5 为网络结构为 3-70-11,隐层/输出层传递函数为 tansig/logsig,训练函数为 traingdx 时,某次训练后输出结果的混淆矩阵,其中对角线上为各类别识别正确的信号个数,最下行及右下角分别为各类别及总识别率。583 个 AE 信号有 566 个被正确识别,总识别率达 97.1%,其中试样 S1 的 3 类 AE 信号全部识别正确。试样 S2 的 3 类 AE 信号中,S2-1 和 S2-3 全部识别正确,S2-2 的 32 个信号有 29 个识别正确,识别率 90.6%。试样 S3 的 2 类 AE 信号 S3-1、S3-2 识别率分别为 97.1%,91.4%。试样 S4 的 3 类 AE 信号中,S4-1 和 S4-3 全部识别正确,S4-2 的 94 个信号有 89 个识别正确,识别率 94.7%。部分信号被错分是由于模式空间中信号参数存在重叠所导致。混淆矩阵的结果表明,合适网络参数训练后的 BP 神经网络能够实现损伤 AE 信号的正确识别。

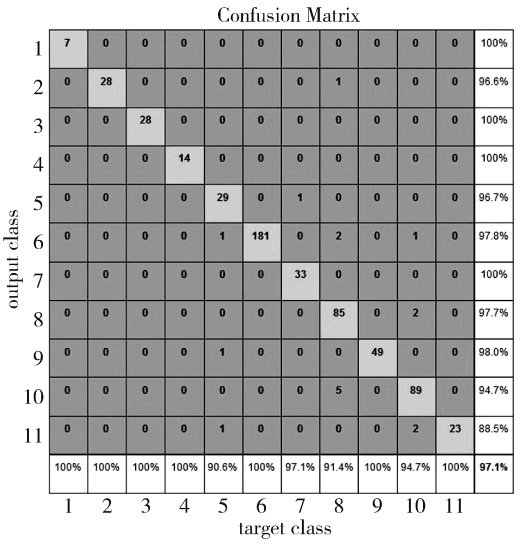


图 5　网络的混淆矩阵

Fig.5　Confusion matrix of network

3　结论

(1)AE 信号参数系统聚类结果可选择出 AE 信号损伤模式特征为幅度、峰值频率和持续时间。

(2)对 AE 信号进行 K-means 聚类可建立损伤模式的 AE 信号训练样本。

(3)运用 BP 网络可实现对不同损伤模式的识别,网络性能和训练函数、传递函数和网络结构有关,当训练函数为 traingdx,隐层/输出层传递函数为 tansig/logsig,隐层神经元为 70 时,网络识别率可达 97.2%。

参考文献

[1] 龙宪海,阳能军,王汉功.炭/环氧复合材料拉伸损伤声发射特性及细观力学分析[J].高分子材料科学与工程,2011,27(02):50-54.

[2] 周伟,孙诗茹,冯艳娜,等.风电叶片复合材料拉伸损伤破坏声发射行为[J].复合材料学报,2013(02):240-246.

[3] 严实,李冬华,泮世东,等.基于声发射技术的三维编织复合材料压缩破坏分析[J].材料工程,2013(02):22-28.

[4] 严实,赵金阳,陆夏美,等.基于声发射技术的三维编织复合材料低速冲击损伤分析[J].材料工程,2014(07):92-97.

[5] 孟松鹤,田晓晓,杜善义,等.三维编织碳/环氧复合材料力学性能测试及破坏机制[J].复合材料学报,2012(02):115-120.

[6] 黄文亮,李鹏南,邱新义,等.CFRP 在钻削加工中的声发射特性[J].宇航材料工艺,2017,47(06):46-50.

[7] NI Q Q, KURASHIKI K, IWAMOTO M. AE technique for identification of micro failure modes in CFRP composites[J]. Materials Science Research International, 2001,7(1): 67-71.

[8] YANG L, KANG H S, ZHOU Y C, et.al. Frequency as a key parameter in discriminating the failure types of thermal barrier coatings: Cluster analysis of acoustic emission signals[J]. Surface and Coatings Technology, 2015;264:97-104.

[9] 袁忠,黄频波,耿文霞.基于近似熵谱的碳纤维复合材料层压板拉伸损伤声发射分析[J].宇航材料工艺,2014,44(04):73-77.

[10] 童小燕,张佳丽,姚磊江,等.2D-C/SiC 拉伸损伤的声发射信号聚类分析[J].固体力学学报,2014,(02):109-114.

[11] SAWAN H A, WALTER M E, MARQUETTE B. Unsupervised learning for classification of acoustic emission events from tensile and bending experiments with open-hole carbon fiber composite samples [J]. Composites Science and Technology. 2015;107:89-97.

[12] 张卫冬,张习文,杨斌,等.基于声发射信号的铝合金材料损伤表征识别[J].北京科技大学学报,2013,35(5):626-633.

[13] 王健,金周庚,刘哲军.C/E 复合材料声发射信号小波分析及人工神经网络模式识别[J].宇航材料工艺,2001,31(01):49-57.

[14] 张素洁,赵怀慈.最优聚类个数和初始聚类中心点选取算法研究[J].计算机应用研究,2017,34(06):1617-1620.

[15] MARTIN T H, HOWARD B D, MARK H B.神经网络设计[M].北京:机械工业出版社,2002.