

基于深度置信网络铝合金加筋板冲击损伤识别*

李 伟^{1,2}, 邹本健¹, 杨 宁², 张法业¹, 吕珊珊¹, 姜明顺¹, 贾 磊¹

(1. 山东大学控制科学与工程学院 济南, 250061) (2. 山东航天电子技术研究所 烟台, 264000)

摘要 铝合金加筋板是卫星、空间站和飞船等航空航天装备关键结构,对其损伤状态进行监测和识别是评估航天器健康状态的前提和基础。针对传统机器学习方法对人工特征提取的依赖性,利用实验模拟与数值仿真相结合的方法,获取铝合金加筋板损伤声发射信号并计算其幅频特性,建立损伤数据集,基于深度置信网络构建冲击损伤智能识别模型进行损伤特征自适应提取,结合 Softmax 分类器开展了冲击损伤识别研究,并与传统的支持向量机和反向传播(back propagation,简称 BP)神经网络识别结果进行了对比。实验结果表明:在 2 200 mm×500 mm×10 mm 的铝合金加筋板上对 68 个测试区域进行了多次冲击损伤识别,在 15 300 次实验中实现了 15 218 次冲击损伤准确识别,正确率为 99.47%。该研究结果为航天器结构的损伤监测提供了有效方法。

关键词 深度置信网络;铝合金加筋板;损伤识别;幅频特性

中图分类号 TP183;TH39

引 言

随着航天事业的快速发展,空间活动日益增多,由此产生的空间碎片急剧增加,严重威胁载人航天器的安全^[1-2]。由于结构设计理念的更新和制造工艺的发展,高性能的结构化材料广泛应用于航空航天领域。目前,航空航天普遍采用的结构壁板是铝合金材料,具有密度低、比强度高、耐腐蚀性强及可塑性高等特点^[3]。加筋板结构还具备优良的后屈曲承力性能,是舱体结构的重要组成部分^[4]。虽然这些筋体结构增强了铝合金板的性能,但当由冲击引起的板波经过加强筋、隔框等凸起时会发生反射、散射、衰减和叠加等复杂变化,影响冲击损伤的判断。

目前,冲击定位识别方法主要有时差定位法与智能算法。时差定位是利用至少 3 个传感器检测冲击产生的声发射信号到达传感器的时间差来计算冲击点的位置^[5-7]。对于各向同性板,使用时差法计算的波速为确定常数,但是对于各向异性或者不规则加筋板,冲击应力波在经过筋体处会发生散射和模态转换的现象,此时若将波速设置为确定常数,会使定位误差较大。近年来,由于计算机技术的高速发展,智能算法^[8-10]的应用非常广泛。研究人员将信号处理技术与智能算法相结合,利用传感器获取冲击声发射信号,通过神经网络^[11-12]、机器学习^[13]等算法

实现特征提取。文献[14]利用神经网络和概率椭圆法,采用能够激励并记录金属板动态响应的执行器与传感器阵列感应路径上的损伤指数来确定金属板的损伤位置。Chen 等^[15]提出了一种具有敏感性分析的层次贝叶斯学习方法,从测量的信号中提取模态量,经过训练能够在高噪声的环境下识别结构损伤。张法业等^[16]采用扩散映射与支持向量机相结合的方法,将声发射信号的振荡能量和波形指标作为特征对小尺寸铝合金薄板进行了冲击定位研究。以上方法的损伤识别结果过度依赖于人工处理,导致泛化能力低。

笔者以铝合金加筋板为载体,采用地面模拟与数值仿真相结合的方法,搭建冲击损伤声发射信号获取系统,研究冲击声发射信号传播特性并获取冲击损伤信号,建立冲击损伤样本库,利用深度神经网络自动提取损伤特征,提出基于深度置信网络的冲击损伤智能识别方法并进行实验验证。

1 冲击损伤识别算法

1.1 铝合金加筋板冲击应力波传播分析

铝合金加筋板的复杂加筋结构会引起冲击应力波的反射、散射、衰减和叠加等变化。为了解冲击产生的应力波在铝合金加筋板中的传播特性,利用

* 国家自然科学基金资助项目(61903224, 62073193);山东省重大科技创新工程资助项目(2022CXGC020902);山东大学基本科研业务费资助项目(2021JCG008)

收稿日期:2021-04-12;修回日期:2021-05-18

ANSYS 软件建立某航天器舱壁铝合金加筋板冲击仿真模型,如图 1 所示。利用铝合金弹丸对板进行高速冲击,在板上设置 4 个观测点,采集高速冲击声发射应力波波形,仿真模型参数如表 1 所示,其中板的材料为 Al2017,弹丸材料为 Al7075,有限元单元为 3D164 单元,仿真算法采用拉格朗日乘子和惩罚函数。




图 1 铝合金加筋板冲击仿真模型

Fig.1 Impact simulation model of aluminum alloy stiffened plate

表 1 仿真模型参数

Tab.1 Simulation model parameters

参数名称	数值	单位
板的密度	2.79	g/cm ³
板的长度	2 200	mm
板的宽度	500	mm
板的厚度	10	mm
筋体高度	5	mm
筋体宽度	4/7/15/18/25/37	mm
弹丸密度	2.82	g/cm ³
冲击时长	200	μs
冲击速度	1 200	m/s
网格大小	8	mm

高速弹丸冲击铝合金加筋板产生的冲击应力波传播过程如图 2 所示。当四边固支铝合金加筋板受到高速运行的弹丸冲击后,钢球刚接触到铝合金加筋

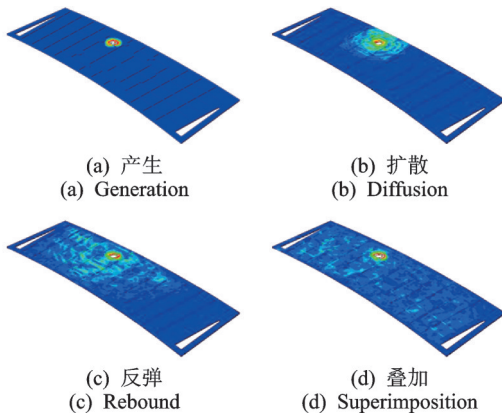


图 2 冲击应力波传播过程

Fig.2 Propagation process of impact stress waves

板时,应力波主要集中在冲击点附近,且有向四周扩散的趋势;然后,应力波开始向四周均匀扩散;当扩散的应力波碰到铝合金加筋板边界或筋体之后被反弹向中心传播,反弹应力波与扩散应力波相互叠加。

1.2 深度置信网络原理

深度置信网络 (deep belief networks, 简称 DBN) 由若干具有 2 层神经元的受限玻尔兹曼机 (restricted boltzmann machines, 简称 RBM) 组成^[17-19]。RBM 包含可见层神经元和隐藏层神经元^[20],其网络结构如图 3 所示。由图可见,层神经元用于接收声发射传感器采集的冲击损伤信号,隐藏层神经元用于信号特征提取。DBN 解决了深层结构的参数空间搜索问题^[21]。




图 3 RBM 网络结构

Fig.3 RBM network structure

考虑 RBM 为全连接层,层内没有连接,即同一层神经元之间是相互独立的,设网络输入为 v , 则可见层和隐藏层的神经元状态概率可表示为

$$P(\mathbf{h}|\mathbf{v}) = \prod_{j=1}^N P(h_j|\mathbf{v}) \quad (1)$$

$$P(\mathbf{v}|\mathbf{h}) = \prod_{i=1}^M P(v_i|\mathbf{h}) \quad (2)$$

其中: $\mathbf{v} = [v_1, v_2, \dots, v_M]^T$ 为可见层输入向量; $\mathbf{h} = [h_1, h_2, \dots, h_N]^T$ 为隐藏层输出向量; M 和 N 分别为可见层和隐藏层神经元的个数。

设 RBM 任意 2 个相连的神经元之间的连接权重为 W , 可见层神经元的偏置系数为 b , 隐含层神经元的自身权重为 c , 则其能量函数为

$$E(\mathbf{v}, \mathbf{h}; \theta) = - \sum_{i,j=1}^{M,N} W_{i,j} v_i h_j - \sum_{i=1}^M b_i v_i - \sum_{j=1}^N c_j h_j \quad (3)$$

其中: $\theta = \{W, b, c\}$ 为 RBM 网络参数, 需要利用数据集通过训练得到。

可见层和隐含层神经元激活概率分别为

$$P(h_j|\mathbf{v}) = \text{Sigmoid}\left(b_j + \sum_i W_{i,j} v_i\right) \quad (4)$$

$$P(v_i|\mathbf{h}) = \text{Sigmoid}\left(c_i + \sum_j W_{i,j} h_j\right) \quad (5)$$

将若干个RBM“串联”起来则构成了一个DBN,图4为DBN网络结构。其中,上一个RBM的隐藏层即为下一个RBM的可见层,上一个RBM的输出即为下一个RBM的输入。训练过程中,充分训练上一层的RBM后训练当前层的RBM,直至最后一层,在最后一层加上Softmax分类器,即可进行分类,实现损伤类型识别。




图4 DBN网络结构

Fig.4 DBN network structure

1.3 铝合金加筋板损伤识别算法

基于深度置信网络的铝合金加筋板冲击损伤识别算法流程如下。

1) 以某航天器舱壁铝合金加筋板为研究对象,将其划分为 p 个待识别区域,使用电动仿真枪发射直径为 $\phi 7$ mm的塑料弹丸冲击划分区域模拟低速冲击,产生声发射信号,利用搭建的声发射采集系统采集该信号作为无损伤原始数据样本。利用ANSYS软件,选择Lagrange算法,建立某航天器舱壁铝合金加筋板模型进行仿真模拟,获取成坑及穿孔




图5 低速冲击信号获取子系统

Fig.5 Low-speed impact signal acquisition subsystem

2.2 高速冲击信号获取子系统搭建

基于二级轻气炮的高速冲击实验能够直接获取高速冲击声发射信号,但由于实验成本高、靶件尺寸受靶舱大小限制、弹丸速度和弹道难以精确控制、实验过程难以测量等因素制约,难以满足损伤数据集

损伤工况下的高速冲击加筋板声发射信号作为损伤原始数据样本。

2) 对获取的原始数据样本进行快速傅里叶变换,获得其幅频特性并构建数据样本集,按照9:1的比例划分训练集和测试集。

3) 构建基于深度置信网络的损伤识别模型,利用训练集对模型的激活函数、优化器、学习率及隐藏层节点数等参数进行寻优。

4) 利用测试集数据样本对构建的损伤识别模型进行验证,实现损伤识别。

5) 与传统机器学习方法、其他深度学习算法进行对比,验证算法性能。

2 冲击信号获取系统搭建

冲击信号获取系统包含低速冲击信号获取子系统 and 高速冲击信号获取子系统。其中:低速冲击信号获取子系统利用模拟实验获取无损伤状态的冲击声发射信号;高速冲击信号获取子系统利用数值模拟获取成坑和穿孔状态的冲击声发射信号。

2.1 低速冲击信号获取子系统搭建

如图5所示,低速冲击信号获取子系统由电动仿真枪、铝合金加筋板、声发射传感器、信号调理及采集装置、计算机和数据采集软件组成。电动仿真枪通过压缩气体将塑料弹丸加速至约100 m/s左右,这一速度并不足以在加筋板上造成损伤,但是塑料弹丸冲击加筋板会出现破碎现象,产生声发射信号,声发射传感器采集该信号并将其转化为电压信号,计算机通过数据采集软件控制信号调理及采集装置采集号,并存储数据样本。

构建要求,因此选用可精确控制实验参数,精确重复各种冲击工况的数据仿真方法。笔者基于英伟达Tesla V100高性能计算GPU的数值仿真平台,利用ANSYS软件建立铝合金加筋板数值仿真模型,模拟弹丸高速冲击加筋板形成成坑和穿孔损伤的详细过程,获取高速冲击原始声发射波形。

3 冲击损伤信号识别实验及结果分析

3.1 铝合金加筋板损伤实验

以低速冲击实验为例,利用仿真枪对铝合金加筋板上划分的 $i(i=1,2,\dots,68)$ 个区域(图 6 为铝合金加筋板区域划分图)进行枪击实验,每个区域设置 5 个冲击点,标记为 $M_1\sim M_5$,每个冲击点冲击 k 次($k=1,2,\dots,150$)。数据采集流程如下:

1) 确定冲击区域 P_1 ,在该区域选择冲击点 M_1 ,

对其冲击 150 次,然后移动到冲击点 M_2 ,接着进行 150 次冲击,依次类推,直至完成 5 个冲击点的冲击试验;

2) 进入冲击区域 P_2 ,冲击方式与区域 P_1 相同,直至完成 68 个区域的冲击实验,最终通过低速冲击获取 $68\times 5\times 150=51\ 000$ 组无损伤数据;

3) 对于高速冲击的成坑与穿孔状态的数据采集流程和低速冲击相同,最终分别获取了 51 000 组成坑和穿孔数据。




图 6 铝合金加筋板区域划分图

Fig.6 Area division diagram of aluminum alloy stiffened plate

针对 3 种损伤程度的数据样本,按照 9:1 的比例将数据样本划分为训练集和测试集,数据集组成如表 2 所示。每种损伤程度的训练集与测试集的样本分别为 45 900 组和 5 100 组,在最终的数据集中,训练集为 137 700 组数据,测试集为 15 300 组数据。

表 2 数据集组成

Tab.2 The composition of the data set

损伤程度	训练集	测试集	合计
无损	45 900	5 100	51 000
成坑	45 900	5 100	51 000
穿孔	45 900	5 100	51 000
合计	137 700	15 300	153 000

3.2 铝合金加筋板冲击损伤信号分析

3 种损伤程度的冲击信号通过快速傅里叶变换被转换成频率信号。为了能够直观清晰地比较同类型损伤情况下冲击信号幅频特征与冲击区域的关系,将冲击不同区域声发射传感器 S_1 采集到的信号频率特征绘制在同一坐标系下。图 7 为在同种损伤程度下不同区域的信号幅频特性对比。图中: I 为区域 1 的信号幅频特性; II 为区域 24 的信号幅频特性; III 为区域 42 的信号幅频特性; IV 为区域 64 的信号频率特性。分析发现,冲击铝合金加筋板的不同区

域,声发射传感器监测到铝合金板的幅频特性在相同的频率下,不同区域的频率幅值不同。例如,无损状态时 4 个冲击区域在 21 kHz 频率下的幅值依次为 0.025 52, 0.059 97, 0.114 95 和 0.086 24 dB,这说明声发射传感器监测到的频率幅值和冲击区域有关。因此,冲击信号的幅频特征可以用于判断冲击区域。

为了确定在同一个冲击区域不同损伤程度的频率特性是否存在差异,将 3 种损伤程度的频率信号绘制在一个坐标系下。图 8 为在同一区域下不同损伤程度的信号幅频特性对比。图中: I 代表铝合金加筋板无损伤信号幅频特性; II 代表成坑损伤信号的幅频特性; III 代表穿孔损伤信号的幅频特性。对比分析发现,冲击同一区域,铝合金加筋板不同损伤程度的幅频特征也存在差异。因此,冲击信号的幅频特征可用于判断损伤程度。

3.3 铝合金加筋板损伤识别模型构建

DBN 作为一种深层概率有向图模型,隐藏层单元被训练用于捕捉在可视层表现出来的高阶数据的相关性。笔者设计的 DBN 模型结构如图 9 所示,由输入层、三层隐藏层以及输出层组成。输入层用来输入冲击响应频率信号;隐藏层用来提取幅频特征;




图 7 在同种损伤程度下不同区域的信号幅频特性对比

Fig.7 Comparison of signal amplitude-frequency characteristics in different areas under the same degree of damage




图 8 在同一区域下不同损伤程度的信号幅频特性对比

Fig.8 Comparison of signal amplitude-frequency characteristics of different levels of damage in the same area

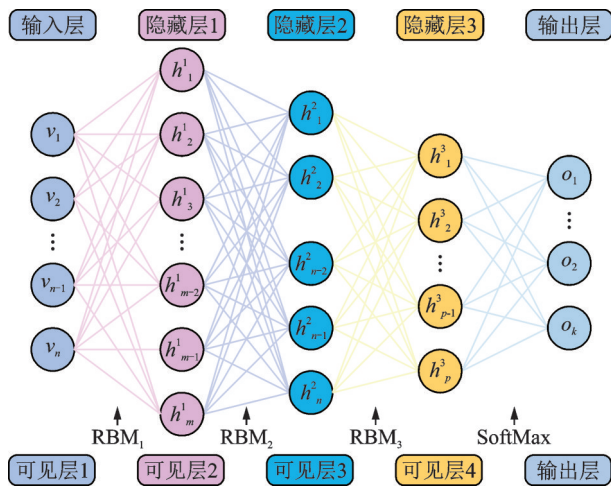


图 9 DBN 模型结构

Fig.9 The model structure of DBN

输出层使用 Softmax 分类器通过计算每种类别的概率来实现冲击位置与损伤程度识别。

初步建立基于深度置信网络的损伤智能识别模型,对激活函数、优化器、学习率以及模型结构等参数进行优化,提升模型收敛速度,减小模型损失,提高模型损伤识别准确率。

DBN 模型隐藏层神经元数如表 3 所示。隐藏层神经元数对损伤识别的影响如图 10 所示。可以看出,随着各个隐藏层节点数的增加,训练时间不断

表 3 DBN 模型隐藏层神经元数

Tab.3 The number of neurons in the hidden layer of the DBN model

层数	第 1 组	第 2 组	第 3 组	第 4 组	第 5 组	第 6 组	第 7 组	第 8 组	第 9 组
1	30	50	80	500	600	700	1 000	1 200	1 400
2	20	30	50	400	500	600	800	1 000	1 200
3	10	20	30	300	400	500	600	800	1 000

增加,而准确率却变化不大。从第 1~9 组的对比结果可以发现,第 1~3 组的训练准确率不足 98%,而第 3~9 组的训练准确率超过了 99.40%,测试准确率超过了 99.30%。但是,随着神经元数的增加,训练时间也逐渐加长,第 9 组的训练时间超过了 1 h。综合考虑,选择第 4 组作为损伤识别模型各层神经元参数,即 500-400-300。

DBN 模型优化参数设置如表 4 所示。不同模型参数对损伤识别性能的影响如图 11 所示。图 11(a)为不同激活函数对识别性能的影响比较。分别选取 relu, elu, tanh 和 sigmoid 4 种激活函数对 DBN 模型进行优化,发现在相同的迭代次数下,sigmoid 函数收敛较慢,其他 3 种函数的效果相差不大,在迭代 6 次之后,损失已经降低到很小了。相比之下,elu 函数收敛速度相对较快,选用 elu 函数作为 DBN 模型




图 10 隐藏层神经元数对损伤识别的影响

Fig.10 The influence of the number of hidden layer neurons on damage recognition

的激活函数。图 11(b)为不同学习率对识别性能的影响比较。选取 3 组学习率,训练发现学习率为 0.001 和 0.000 1 的这 2 组收敛过快,选取 0.000 01 作为模型的学习率比较适合。图 11(c)为不同优化器对识别性能的影响比较。实验发现,使用 sgd 和 adagrad 的这 2 组在迭代次数相同时,损失依然很大,准确率也较低,而使用 adam 优化器的损伤识别性能很好。最终,DBN 模型的激活函数、学习率以

及优化器分别选择 elu,0.000 01 和 adam。

表 4 DBN 模型优化参数

Tab.4 Optimized parameters of the DBN model

参数	参数设置	优化结果
激活函数	relu,elu,tanh,sigmoid	elu
优化器	sgd,adam,adagrad	adam
学习率	0.001,0.000 1,0.000 01	0.000 01

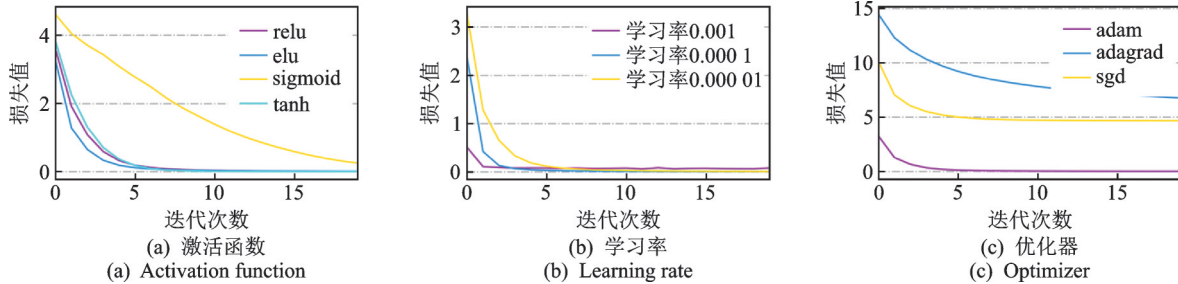


图 11 不同模型参数对损伤识别性能的影响

Fig.11 The influence of different model parameters on damage identification results

3.4 铝合金加筋板损伤识别

经过参数优化,将 DBN 的模型参数进行训练。将铝合金加筋板的 3 种损伤程度 68 个区域(合计 204 类)的冲击信号频谱作为 DBN 模型的输入,经过训练后,模型输出 204 个类别。其中:第 0~67 类为无损伤的 1~68 个区域;第 68~135 类为成坑损伤的 1~68 个区域;第 136~203 类为穿孔损伤的 1~68 个区域。DBN 各个隐藏层的特征提取过程通过主成分分析(principal component analysis,简称 PCA)展示出来,图 12 为 DBN 模型特征提取效果。

图 12(a)为原始数据经 PCA 降维后 3 种损伤程度的特征提取效果。可以看出,很多成坑和穿孔损伤的数据重叠,难以区分。图 12(b)为数据经过第 1

层隐藏层的特征提取效果,与图 12(a)相比,数据间距增大,成坑和穿孔损伤的数据重叠减少。图 12(c)为第 2 层隐藏层的特征提取效果,与图 12(b)相比,数据间距进一步增大。图 12(d)为数据经过第 3 层隐藏层的 3 种损伤程度的特征提取效果。与图 12(c)相比,数据间距再一次增加,3 种损伤类别仅有少量重叠。DBN 模型训练结果如图 13 所示。最终训练准确率为 99.47%,测试准确率为 99.39%。

除了使用 DBN 进行损伤识别外,还依次使用 BP、支持向量机(support vector machine,简称 SVM),堆叠式自编码器(stacked auto-encoder,简称 SAE)模型进行了冲击损伤识别,模型参数设置如表 5 所示。多种模型冲击损伤识别结果如表 6 所示。

由表 6 可知,与支持向量机和 BP 神经网络的传

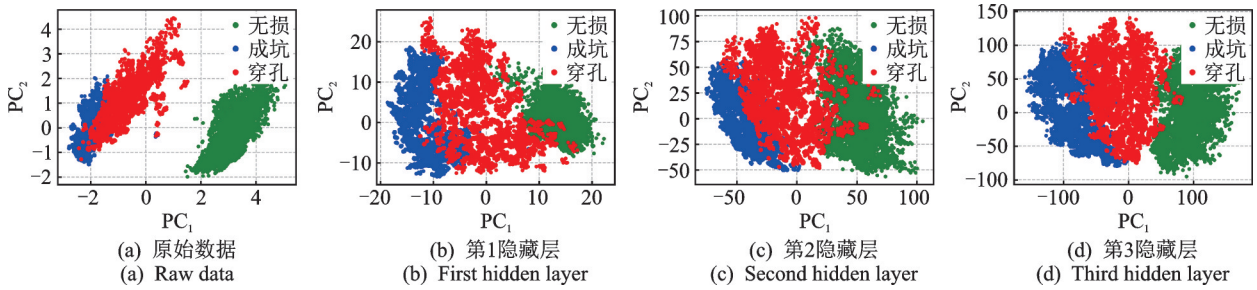


图 12 DBN 模型特征提取效果

Fig.12 The feature extraction effect of DBN model

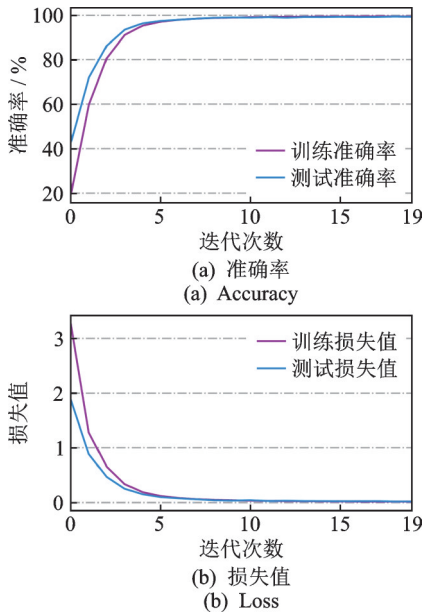


图 13 DBN 模型训练结果

Fig.13 The training results of the DBN model

表 5 多种模型的参数设置

Tab.5 Parameter settings of multiple models

模型	隐藏层节点	激活函数	优化器	学习率	核函数	惩罚参数
SAE	500-400-300	elu	adam	0.000 01	—	—
BP	800-400-300	relu	adam	0.000 01	—	—
SVM	—	—	—	—	RBF	1.0

表 6 多种模型冲击损伤识别结果

Tab.6 Impact damage recognition results of multiple models

模型	训练准确率/%	测试准确率/%	训练时间/s	识别时间/s
DBN	99.47	99.39	1 206	0.60
BP	96.63	96.30	2 417	1.11
SVM	99.47	99.39	17 460	1 802
SAE	99.45	99.33	2 364	60.80

统机器学习方法相比,基于DBN的损伤识别算法能节省大量训练时间;与稀疏自编码器深度学习算

法相比,基于DBN的损伤识别算法在损伤识别时间上具有明显优势。

4 结束语

面向航天器结构健康监测的工程需求,针对由于铝合金加筋结构冲击应力波的复杂特性导致传统损伤识别方法不准确的问题,提出了基于DBN网络的铝合金加筋板冲击损伤识别方法。利用DBN模型从冲击信号的幅频信息提取损伤特征,通过训练与参数优化使DBN模型的冲击位置和损伤程度识别达到良好的效果。实验结果表明:相对于BP神经网络的损伤识别准确率,DBN模型的识别准确率高出 3.07%;与 SVM 模型的训练时间相比,使用 DBN 模型的训练时间节省了 4.5 h。该方法为航空航天装备关键结构健康监测提供了一种技术手段。

参 考 文 献

[1] 刘治东, 庞宝君, 刘刚. 高速冲击声发射信号在加筋壁板中传播的模式转换现象研究[J]. 振动与冲击, 2014, 33(21): 114-118.
LIU Zhidong, PANG Baojun, LIU Gang. Hypervelocity impact induced AE wave mode conversion in a plate with vertical stiffeners [J]. Journal of Vibration and Shock, 2014, 33(21): 114-118. (in Chinese)

[2] 胡长富. 航天器含缺陷防护结构的高速冲击损伤及疲劳研究[D]. 哈尔滨: 哈尔滨工业大学, 2019.

[3] 王端志, 胡勇, 孙海霞, 等. 高强韧铝合金结构壁板研究进展[J]. 强度与环境, 2020, 47(5): 28-36.
WANG Duanzhi, HU Yong, SUN Haixia, et al. Research of high-strength and toughness aluminum structural panels for aerospace and warship [J]. Structure & Environment Engineering, 2020, 47(5): 28-36. (in Chinese)

[4] 马开开. 铝合金加筋板结构强度研究[D]. 哈尔滨: 哈尔滨工程大学, 2019.

[5] 程竹明, 曾捷, 常晨, 等. 基于光纤 Sagnac 传感技术的

- 结构冲击定位[J]. 光学学报, 2018, 38(10): 87-93.
CHENG Zhuming, ZENG Jie, CHANG Chen, et al. Structural impact localization based on optical fiber sagnac sensing technique [J]. Acta Optica Sinica, 2018, 38(10): 87-93. (in Chinese)
- [6] KUNDU T, DAS S, JATA K V. Detection of the point of impact on a stiffened plate by the acoustic emission technique[J]. Smart Materials and Structures, 2009, 18(3): 035006.
- [7] QIU L, YUAN S, ZHANG X, et al. A time reversal focusing based impact imaging method and its evaluation on complex composite structures[J]. Smart Materials & Structures, 2011, 20(10):105014.
- [8] ZHENG K, LI Z, MA Z, et al. Damage detection method based on Lamb waves for stiffened composite panels[J]. Composite Structures, 2019, 225:111137.
- [9] LEI Y, LI N, GUO L, et al. Machinery health prognostics: a systematic review from data acquisition to RUL prediction[J]. Mechanical Systems and Signal Processing, 2018, 104: 799-834.
- [10] SHUAI Z, RISTOVSKI K, FARAHAT A, et al. Long short-term memory network for remaining useful life estimation[C]//2017 IEEE International Conference on Prognostics and Health Management. [S. l.]: IEEE, 2017:88-95.
- [11] 邓超, 钱有胜, 吴军, 等. BP网络在进给系统定位误差预测中的运用[J]. 振动、测试与诊断, 2017, 37(3): 449-455.
DENG Chao, QIAN Yousheng, WU Jun, et al. A forecasting method of positioning accuracy for CNC machine tools feed system based on BP neural network [J]. Journal of Vibration, Measurement & Diagnosis, 2017, 37(3): 449-455. (in Chinese)
- [12] 王丽华, 谢阳阳, 周子贤, 等. 基于卷积神经网络的异步电机故障诊断[J]. 振动、测试与诊断, 2017, 37(6): 1208-1215.
WANG Lihua, XIE Yangyang, ZHOU Zixian, et al. Motor fault diagnosis based on convolutional neural networks[J]. Journal of Vibration, Measurement & Diagnosis, 2017, 37(6): 1208-1215. (in Chinese)
- [13] 周绮凤, 杨小青, 周青青, 等. 基于随机森林的建筑结构损伤识别方法[J]. 振动、测试与诊断, 2012, 32(2): 197-201.
ZHOU Qifeng, YANG Xiaoqing, ZHOU Qingqing, et al. Damage identification technique for building structure based on random forest [J]. Journal of Vibration, Measurement & Diagnosis, 2012, 32(2): 197-201. (in Chinese)
- [14] DE FENZA A, SORRENTINO A, VITIELLO P. Application of artificial neural networks and probability ellipse methods for damage detection using Lamb waves [J]. Composite Structures, 2015, 133:390-403.
- [15] CHEN Z, ZHANG R, ZHENG J, et al. Sparse Bayesian learning for structural damage identification [J]. Mechanical Systems and Signal Processing, 2020, 140:106689.
- [16] 张法业, 姜明顺, 隋青美, 等. 基于光纤光栅的冲击激励声发射响应机理与定位方法研究[J]. 物理学报, 2017, 66(7): 202-210.
ZHANG Faye, JIANG Mingshun, SUI Qingmei, et al. Research on response mechanism and location method of shock excitation acoustic emission based on fiber grating [J]. Acta Physica Sinica, 2017, 66(7): 202-210. (in Chinese)
- [17] HINTON G, OSINDERO S, TEH Y W. A fast learning algorithm for deep belief nets [J]. Neural Computation, 2006, 18(7):1527-1554.
- [18] 郭晓慈. 基于压缩感知和深度学习的旋转机械故障诊断方法研究[D]. 秦皇岛:燕山大学, 2020.
- [19] 谢旭旭. 基于深度信念网络的无绝缘轨道电路故障诊断研究[D]. 北京:北京交通大学, 2020.
- [20] HINTON G. A practical guide to training restricted Boltzmann machines[J]. Momentum, 2010, 9(1):926.
- [21] BENGIO Y. Learning deep architectures for AI [J]. Foundations & Trends in Machine Learning, 2009, 2(1): 1-12.



第一作者简介:李伟,男,1978年10月生,硕士、研究员。主要研究方向为装备结构状态监测技术、装备故障诊断与损伤评估算法。曾发表《Hypervelocity impact monitoring and location identification on aluminum plate based on FBG sensing system》(《Optoelectronics Letters》2020, Vol.16, No.4)等论文。
E-mail:Li_Wei_2020@126.com

通信作者简介:张法业,男,1984年12月生,博士、高级实验师。主要研究方向为装备故障诊断与寿命预测技术。
E-mail:zhangfaye@sdu.edu.cn