

基于神经网络的复合材料层合板低速冲击 损伤面积预测方法

卓嘉永^{1,2}, 倪楷文^{1,2}, 陈清林^{1,2}, 彭苗娇^{1,2}

(1. 集美大学 轮机工程学院, 福建 厦门 361021; 2. 福建省船舶与海洋工程重点实验室, 福建 厦门 361021)

摘要: 目前, 复合材料层合板在船舶领域得到广泛应用, 但在其遭受低速冲击时, 传统试验和有限元方法无法真实、有效地描绘实际损伤情况。为此, 结合低速冲击实验结果和超声水浸扫描结果, 建立了 BPNN、CNN 的等效冲击损伤预测模型, 以快速预测复合材料层合板在冲击过程中的损伤情况。在使用试验样本数据模型进行训练后, 其能够高效准确预测复合材料层合板损伤面积。该方法简单实用, 可以推广使用。

关键词: 复合材料; 低速冲击; 神经网络; 损伤面积

中图分类号: TB333; TP183; U663.2

文献标志码: A

文章编号: 2096-7772-(2024)03-0034-10

0 引言

在船舶应用领域, 复合材料比传统金属材料更轻, 具有降低船舶自重、提高载重能力和航行速度等优势。此外, 复合材料具备耐腐蚀、低密度、高比强度、高比模量、热稳定性好、节能环保、易加工成型等优点, 因而其在船舶领域的应用越来越广泛。

海洋环境中, 船舶常见的碰撞包括与漂浮废弃物、其他船只、码头的碰撞和生产过程中的碰撞(例如工具坠落等), 这些属于低速冲击(1—10 m/s)^[1]。与高速冲击(50—1000 m/s)相比, 遭受低速冲击后, 在复合材料层合板表面无法观察到内部可能已发生的纤维断裂^[2]、基体开裂、扭结带和分层等损伤, 甚至损伤面积都无法确定。

对于低速冲击而言, 因其持续时间相对较长, 有研究者将其当作准静态问题进行研究^[3]。鉴于复合材料层合板分层损伤的空间复杂性, 通常将结构的厚度方向划分为不同的层次, 把这些不同层次的损伤投影叠加在一起获得总的受损面积。Liao^[4]研究了复合材料层合板的重复低速冲击响应及损伤累积机理。除了在接触的局部区域可能出现纤维断裂外, 非冲击面往往

承受较大的弯曲应力, 这使得非冲击面的铺层容易发生基体开裂, 从而导致分层损伤。通常情况下, 远离冲击面的层间分层面积大于靠近冲击面的分层面积。

近年来, 越来越多研究将神经网络应用于复合材料冲击损伤, 学者^[5,6]验证了基于概率神经网络算法损伤识别研究的可行性, 在冲击损伤预测上, Liu^[7]等建立了基于 LS-DYNA 层合板冲击分层的有限元模型, Wang^[8]等建立了预测复合材料层合板低速冲击下分层形状模型, Dhanisetty^[9]提出了一个能够将复合材料板上的损伤与给定的冲击器特性联系起来的模型, 用以进行风险评估。Chandrashekhara^[10]等人利用有限元分析和神经网络开发了一种确定低速冲击下复合材料层合板接触力的方法。但大多数研究^[11-13]仅限于损伤的识别和定位, 忽略了损伤程度的预测, 为此有必要开展相关研究。

确定低速冲击损伤面积涉及复杂的物理过程和不同材料的响应特性, 仅依靠少量试验或有限元分析往往难以全面准确确定, 且这些方法存在周期长、成本高以及无法直接获取损伤面积等限制。因此, 需要借助神经网络技术, 直接预测损伤面积, 以弥补试验和仿真的局限性。

收稿日期: 2024-03-02

基金项目: 福建省科技攻关项目(2021J05164, 2021J01844); 福建省科技厅对外合作项目(2022J0019)

第一作者简介: 卓嘉永(1999—), 男, 福建福州人, 硕士在读, 主要从事复合材料研究。

通信作者简介: 陈清林(1974—), 男, 教授, 博士, 主要从事船舶与海洋结构物设计及可靠性研究。

1 神经网络训练集准备

1.1 试验数据

神经网络需要大量的训练数据集来进行有效训练。因此, 为了建立可靠的神经网络模型, 需要进行低速冲击试验以获取足够的数据, 以便后续训练和验证。在本研究中, 使用三种材料进行试验, 这三种材料采用了三种不同的碳纤维铺层。碳纤维铺设方式如图 1 所示, 详细的铺层数据见表 1。None 铺层方式表示基础层合板, 未添加碳纤维; Mid 铺层方式在中间铺设一层碳纤维; Bottom 铺层方式在远离冲击面的底部铺设一层碳纤维。




图 1 铺层示意图

表 1 铺层顺序表

None	Mid	Bottom
CSM300	CSM300	CSM300
CSM300	CSM300	CSM300
EGBM6025	EGBM6025	EGBM6025
EGBM8025	CBM300	EGBM8025
CSM300	EGBM8025	CSM300
CSM300	CSM300	CSM300
EGBM6025	CSM300	EGBM6025
	EGBM6025	CBM300

表 1 中 CSM 代表玻璃纤维短切毡, 是由连续的玻璃纤维束组成的无纺布, 其后的数字表示每平方米的质量 (单位为 g/m^2)。EGBM 代表由 0° 和 90° 的 GUD 叠加组成的双轴向布, 其中 GUD 是一种单向编织的玻璃纤维织物, 纤维排列方向呈一致性, 主要用于增强复合材料中的特定方向, 提高其在该方向上的拉伸强度和刚度。而 CBM 代表 45° 和 -45° 的 CUD 叠加组成的双轴向布, 其中 CUD 是一种单向编织的碳纤维织物, 纤维排列方向呈一致性。CUD 主要用途与 GUD 相同, 但其重量较轻。基体树脂类型为环氧树脂, 固化方式为热固化, 树脂含量控制在 65%。三种单层纤维织物的加工工艺都为树脂预浸料共同压制, 铺层的材料性能见表 2。

表 2 铺层材料性能表

	模量 /Mpa				泊松比					强度 /Mpa				
	E1	E2	G12	V12	xt	xc	yt	yc	S13	xt	xc	yt	yc	S13
CSM	7700	7700	2700	0.41	120	80	120	80	80					
GUD	41290	4210	3160	0.31	884	837	145	37	44					
CUD	134000	9600	4800	0.31	1258	2097	150	42	119					

基于 ASTM-D7136 标准中给出的基座尺寸、夹具尺寸及冲击试样尺寸, 遵循低速冲击试验要求, 对材料进行切割, 得到长 150 mm、宽 100 mm 的光滑试样。落锤冲击试验机 (图 2) 型号为 ZCJ1302-AD, 设有 200 kHz 采样频率的压力传感器, 能在极短时间内采集足够的数据。试样和夹具如图 3 所示。

在冲击实验中, 要确保层合板光滑面朝上。选择质量为 5.7 kg, 直径为 20 mm 的半圆冲头进行冲击试验。为增强预测模型的普适性, 在保持其他参数相同时, 通过改变热压罐成型压力, 制备了两组厚度不同的层合板, 详见表 3—表 5。以能量水平为 4 到 40 J (间隔 2 J) 对两组试样进行低速冲击试验。




图 2 低速冲击试验装置




图 3 试样和夹具

1.2 损伤数据

采用超声水浸技术对冲击后的层合板进行扫描，8 J 冲击能量下，某典型 Bottom 试样扫描结果如图 4 所示。




图 4 超声水浸损伤图

首先对扫描后的图像进行损伤识别，使用 matlab 程序对图像进行预处理，具体包括图像灰度化、高斯滤波等，再根据比例尺计算出真实的损伤面积，具体公式如式（1），试样损伤处理过程见图 5。通过设定一个阈值，将图像分割为损伤区域和非损伤区域。所有灰度值大于该阈值的像素点被认为是损伤像素。

$$\text{损伤面积} = \frac{\text{损伤像素数量}}{\text{图片总像素数量} / \text{图片实际面积}} \tag{1}$$

由于复合材料层合板成型工艺的复杂性和不可控性，导致同种压力下层合板有 6% 以内的厚度偏差。试样铺层损伤数据见表 3 至表 5。





图 5 损伤处理图

表 3 None 铺层损伤数据

冲击能量 /J	厚度 /mm	吸收能量 /J	损伤面积 /mm ²	冲击能量 /J	厚度 /mm	吸收能量 /J	损伤面积 /mm ²
4	2.92	0.74	101.43	4	5.34	0.21	110.27
6	3.17	1.22	122.13	6	5.4	1.53	143.46
8	2.8	2.06	139.46	8	5.46	2.91	176.64
10	3.21	2.58	207.72	10	5.26	3.57	223.34
12	2.94	2.75	236.19	12	5.06	4.23	270.05
14	3.17	4.03	263.68	14	4.96	5.05	466.34
16	2.99	4.76	283.98	16	4.86	5.82	662.63
18	3.14	5.49	294.74	18	5.145	6.48	543.43
20	2.84	6.19	324.9	20	5.43	7.14	424.23
22	3.22	7.07	379.34	22	5.455	8.23	416.3
24	3.04	8.36	431.59	24	5.48	9.31	408.37
26	3.01	8.68	438.31	26	5.335	10.08	411.27
28	2.96	9.26	469.32	28	5.19	10.9	414.17
30	3.01	10.42	533.03	30	5.23	11.93	434.9
32	2.96	11.59	549.15	32	5.27	12.97	455.63
34	2.87	12.17	603.04	34	5.435	13.87	571.87
36	3.1	12.97	633.4	36	5.6	14.82	688.11
38	3.12	14.05	644.59	38	5.215	15.82	697.14
40	3.03	14.98	649.71	40	4.83	16.83	706.17

表 4 Mid 铺层损伤数据

冲击能量 /J	厚度 /mm	吸收能量 /J	损伤面积 /mm ²	冲击能量 /J	厚度 /mm	吸收能量 /J	损伤面积 /mm ²
4	3.86	0.85	70.44	4	3.85	0.85	78.2
6	3.73	1.52	83.1	6	4.095	1.35	83.18
8	3.73	2.28	95.76	8	4.34	1.91	88.51
10	3.82	3.11	113.59	10	4.29	2.73	97.05
12	3.79	3.81	131.41	12	4.24	3.55	115.22
14	3.94	4.76	133.2	14	4.29	4.15	125.26
16	3.66	5.72	134.98	16	4.34	4.71	152.67
18	3.92	6.43	164.66	18	4.46	5.4	153.3
20	3.6	7.3	194.34	20	4.58	6.09	196.8
22	3.72	8.2	208.61	22	4.535	6.72	197.89
24	3.54	9.16	222.87	24	4.49	7.36	210.48
26	3.82	9.99	224.05	26	4.43	7.73	237.28
28	3.74	10.69	225.23	28	4.37	8.15	243.2
30	3.87	11.89	234.91	30	4.415	8.76	247.04
32	3.52	13.12	244.6	32	4.46	9.37	260.49
34	3.78	13.81	246.79	34	4.395	10.61	265.84
36	3.83	14.71	248.99	36	4.33	11.91	262.81
38	3.71	15.83	250.53	38	4.36	13.79	266.96
40	3.77	16.88	252.07	40	4.39	15.66	272.48

表 5 Bottom 铺层损伤数据

冲击能量 /J	厚度 /mm	吸收能量 /J	损伤面积 /mm ²	冲击能量 /J	厚度 /mm	吸收能量 /J	损伤面积 /mm ²
4	3.41	0.64	57.28	4	4.63	0.85	60.04
6	3.9	1.24	67.13	6	4.595	1.43	85.2
8	3.29	1.91	72.99	8	4.56	2.06	110.36
10	3.75	2.27	99.31	10	4.805	2.88	142.77
12	3.31	2.75	110.71	12	5.05	3.7	175.17
14	3.74	3.38	153.21	14	4.88	4.23	180.47
16	3.3	4.13	153.56	16	4.71	4.71	185.77
18	3.91	4.51	185.34	18	4.95	5.4	205.31
20	3.4	5.29	201.94	20	5.19	6.09	224.85
22	3.69	5.77	212.04	22	5.09	6.75	233.42
24	3.51	6.3	217.95	24	4.99	7.41	241.99
26	3.75	7.06	225.67	26	4.94	7.89	257.15
28	3.24	7.62	229.01	28	4.89	8.41	272.32
30	3.72	8.47	235.79	30	5.085	9.76	277.28
32	3.09	8.73	253.01	32	5.28	11.11	282.23
34	3.61	9.9	272.34	34	5.08	11.06	357.58
36	3.21	11.22	326.85	36	4.88	11.06	432.92
38	3.72	11.46	329.52	38	4.945	11.99	443.22
40	3.18	12.17	388.5	40	5.01	12.91	453.52

1.3 铺层方式对损伤面积的影响

根据冲击损伤形式和损伤面积的相似性，将冲击能量分为 3 组：低能量冲击（4—8 J）、中能量冲击（10—2 J）、高能量冲击（28—40 J）。

在低能量冲击下，损伤形式主要体现为冲击点形成的圆形凹坑。根据试验结果，在 0.4 MPa 的成型压力下，Bottom 铺层的损伤面积最小，这可能是因为 Bottom 铺层在这个成型压力下能够更好地分散冲击能量，减轻了冲击对复合材料层合板的损伤。Mid 铺层的平均损伤面积是最小的，这是由于 Mid 铺层表现出更好的吸能性能，能够更有效地吸收冲击能量，减少损伤面积的扩展。因此，虽然 Bottom 铺层损伤面积最小，但考虑到整体吸能性能，Mid 铺层可能更具有优势。

在中能量冲击下，试验结果显示，Mid 铺层方式和 Bottom 铺层方式的损伤仍然差距不大，但 Mid 铺层的损伤面积小于 Bottom 铺层。Mid 铺层能够更有效地吸收和分散冲击能量，从而减轻了复合材料层合板的损伤程度，此时铺层方式相同、厚度不同层合板的冲击损伤面积差异较小。

在高能量冲击下，试验结果表明 Mid 铺层的优势更为明显。在 40 J 冲击能量下，损伤面积最大差距达到了 66.44%。这意味着在高能量冲击条件下，Mid 铺层的耐冲击性能更强，两组厚度不同的层合板

冲击损伤面积差异逐步拉大。

综上所述，相同铺层方式但不同成型压力（导致厚度不同）的层合板，在相同冲击能量下，较薄的层合板损伤面积小于较厚的层合板。这主要是因为较高的成型压力提高了其能量吸收能力和应力分布均匀性，减少了应力集中和层间剪切应力。

在相同冲击能量条件下，不同铺层方式对吸收能量的表现存在明显差异。吸收能量在很大程度上反映了层合板在不同铺层形式下的性能特征，为了提高神经网络模型的泛化能力，本文将所有铺层方式的试验数据都纳入样本集中，而不对其进行区分。这意味着本文将不会对不同铺层方式之间的差异进行特别处理，而是将它们视为同一类型的数据，从而使得模型可以更全面地学习各种铺层方式的特征和规律。这种做法有助于模型更好地适应各种不同铺层方式下的情况，并且可以更好地应对实际应用中可能出现的多样性和复杂性。

2 BPNN 损伤面积预测

复合材料层合板的结构力学性能是结构设计中重要的考虑因素，尤其对于海洋航行中的主承结构而言，因其容易在运行期间受到各种物体冲击导致损伤。在大多数情况下，复合材料层合板结构的损伤破坏、应力 - 应变行为或冲击响应没有得到有效记录，

因而缺少一种快速方便的损伤面积预测方法。因此, 本文引入反向传播神经网络 (Back Propagation Neural Network, BPNN) 对复合材料层合板的损伤情况进行预测。在数据量较少的情况下, BPNN 可以通过适当的正则化方法避免过拟合, 具有稳定性和可靠性表现出良好的泛化能力, 其已经在许多工业应用中得到验证。

2.1 BPNN 参数

材料性能、冲击条件等因素会对复合材料层合板在低速冲击后的损伤面积产生影响, 而 BPNN 具有处理复杂非线性关系的能力, 通过训练和学习, 能够较为准确地估计损伤面积。

本文采用的 BPNN 由 1 个输入层、2 个隐含层和 1 个输出层组成, 输入层接收外部输入数据, 隐藏层负责对数据进行处理和特征提取, 输出层则产生最终的预测或分类结果。BPNN 的训练基于反向传播算法, 通过计算输出结果与真实值之间的误差, 并反向传播

误差, 依据链式法则调整权重值, 以使误差最小化。这个过程反复进行, 直到网络达到收敛状态, 即误差达到接受的范围或训练次数达到设定值。其网络拓扑结构如图 6 所示。采用非线性的激活函数时, 通过逐层增加网络的层数, 可以构建出各种复杂的函数。选用 ReLU 作为隐层的激活函数, ReLU 激活函数如式 (2):

$$y = \begin{cases} 0, & x < 0 \\ x, & x \geq 0 \end{cases} \quad (2)$$

设定估算模型的最大训练步数为 600 步, 学习率为 $\eta=0.01$ 。数据集为 114 组试验得出的损伤面积数据。采用了最小-最大归一化方法, 将数据线性映射到 [0,1] 的范围内, 保持了数据间的相对关系。归一化转换如式 2 所示。在划分数据集时, 训练集和测试集的比例为 17: 2, 即随机选择了 102 组数据用于训练模型, 剩下的 12 组数据用于测试模型的性能。




图 6 BPNN 拓扑结构图

2.2 偏差分析

图 7 展示了使用冲击能量、吸收能量、层合板厚度以及同时使用这三者作为输入参数的训练误差曲线和实际、预测值对比。从图 7(a) 可以观察到, 同时使用三者的均方误差随着代数的增大下降幅度更大。在训练末代时, 均方误差大小排列为: 同时使用三者 < 冲击能量 < 吸收能量 < 层合板厚度。这一排

列在一定程度上揭示了这三个因素对损伤面积的影响程度。同时, 使用三者的预测模型在大约 70 代时已达到较小的均方误差, 在 230 代时已降至 0.0295。图 7(b) 展示了单隐含层与双隐含层的均方误差对比情况。在 95 代之前, 单隐含层的均方误差较小, 而在 100 代之后, 双隐含层的均方误差更小, 并且误差更快地降至可接受的范围。




图 7 训练误差曲线和误差对比图

对 10 组测试集进行反归一化计算, 计算如式 (3):

$$X_i(k) = X_i'(k) \times (\max(X_i) - \min(X_i)) + \min(X_i) \quad (3)$$

测试集预测结果对比如图 8 示, 具体数据见表 6。计算结果显示, 误差率最大为 14.38%, 这表明预测精准度高且效率较高。相比之下, 使用冲击能量、吸收能量、层合板厚度的单神经网络模型的最大误差率分别为 24.31%、33.37%、35.63%, 呈现较低的准确性。




图 8 BPNN 测试集预测结果对比图

表 6 BPNN 测试集

冲击能量 /J	厚度 /mm	吸收能量 /J	真实值 /mm ²	预测值 /mm ²	误差值 /mm ²	误差率 /%
8	2.80	2.06	207.72	225.21	17.48	8.42
12	5.05	3.70	175.17	200.36	25.18	14.38
12	3.03	2.75	99.31	108.63	9.31	9.38
24	2.86	7.69	185.34	186.34	1.00	0.54
28	3.24	7.62	201.94	220.36	18.42	9.12
4	2.87	1.17	70.44	60.95	-9.47	-13.46
12	4.24	3.54	131.41	139.89	8.48	6.46
16	4.84	6.06	134.98	140.08	5.10	3.78
32	3.52	13.12	260.49	281.14	20.65	7.93
28	4.89	8.41	272.32	294.93	22.61	8.31
28	5.44	11.49	414.17	377.62	-36.54	-8.82
4	2.92	0.74	139.46	129.29	-10.16	-7.29

总体上该模型预测值与试验值能很好地吻合, 但是个别预测样本数据偏差较大。经分析发现, 这些偏差源自图像质量、图像处理算法和数值计算的复杂性, 主要表现在损伤面积图像识别和程序处理过程中。除了图像识别和程序处理, 不同铺层条件下的冲

击数据对模型的训练产生了一定影响, 而模型在应对不同铺层情况时表现出更大的偏差。除此之外, 这种偏差还可能受到数据采集过程中噪声的干扰。这种噪声可能来自测量装置, 或来自环境因素, 如材料特性、温度、湿度等。

3 CNN 损伤面积预测

尽管 BPNN 具有容易实现和理解、计算资源需求较低、良好的特征表示、结构简单等优点, 但考虑到损伤区域的复杂性和多层次性, 卷积层神经网络 (Convolutional Neural Network, CNN) 则是一种更为高效的解决途径。通过对比两种模型的预测结果, 可以在不同应用场景中实现更高效、全面的冲击损伤预测。

CNN 在处理输入参数 (如冲击能量、厚度、吸收能量) 方面具有独特的优势。复合材料层合板结构常常具有复杂的微观结构, 而 CNN 的卷积层可通过输入参数让 CNN 有效地捕捉关键特征; 池化层可降低数据的维度, 让 CNN 集中关注复合材料层合板结构中可能受到冲击的特定区域。相对于传统的 BPNN, CNN 更加注重局部感知, 能够更有效地适应结构中的复杂变化。此外, CNN 的多通道输入特性使其能够灵活处理不同维度的信息。这在海洋环境下复合材料层合板受到各种物体冲击的情景中尤为重要, 因为不同类型的输入参数可能提供不同方面的信息, 而 CNN 能够更好地整合这些信息, 进行全面的损伤预测。

3.1 CNN 参数

使用随机梯度下降算法进行训练, 训练集和 BPNN 模型相同, 设置最大训练次数为 1200, 初始学习率为 0.01, 学习率下降因子为 0.1。在经过 800 次训练后, 学习率按照 0.01×0.1 进行更新。每次训练都将数据集打乱, 输入层的数据规模为 $[3, 1, 1]$, 表示输入数据为一个三通道的序列数据, 每个通道的高度和宽度为 1。

第一卷积层的卷积核大小为 3×1 , 说明使用 3 行 1 列的卷积核在输入数据上进行卷积, 生成 16 个卷积特征图。批归一化层用于加速神经网络的训练, 通过对每个批次的输入进行标准化来调整和缩放网络的激活值。引入线性整流函数, 对卷积层的输出进行非线性映射, 引入非线性特性。最大池化层的池化窗口大小为 $[2, 1]$, 步长为 $[1, 1]$, 用于降低特征图的尺寸并保留最显著的特征。第二卷积层的卷积核大小为 3×1 , 生成共 32 张特征图, 将上一层的特征图作为输入, 提取更高级的特征。再次应用批归一化, 再次应用线性整流函数。Dropout 层用于在训练过程中随机丢弃一些神经元, 以防止过拟合。全连接层将卷积层输出的特征图展平, 并连接到全连接层, 用于学习更高级的特征。回归层作为最终的输出层, 用于回归任务并输出值。网络结构图如图 9 所示。




图 9 CNN 结构图

3.2 预测分析

图 10 呈现了 CNN 对复合材料层合板冲击损伤面积进行预测的真实值与预测值的对比, 详细数据列举在表 7 中。从图表可见, CNN 的预测相较于真实值的误差较小, 与使用 BPNN 相比, 最大误差率仅为 8.99%。值得注意的是, 在这些预测点中, 有 4 个点的误差率低于 2%。这些结果清晰地表明, 使用 CNN 在复合材料层合板冲击损伤面积预测方面取得了更为准确的效果。相对于 BPNN, CNN 在捕捉复杂结构的损伤特性和实现更为精确的预测方面具有显著的优势。最大误差率的降低以及多个预测点的低误差率进一步验证了 CNN 在这一任务上的卓越性能。




图 10 CNN 测试集预测结果对比图

表 7 CNN 测试集

冲击能量 /J	厚度 /mm	吸收能量 /J	真实值 /mm ²	预测值 /mm ²	误差值 /mm ²	误差率 /%
40	3.77	16.88	272.48	260.71	-11.77	-4.32
24	4.49	7.36	222.87	239.06	16.19	7.26
28	4.37	8.15	225.23	229.65	4.42	1.96
12	4.24	3.55	131.41	143.23	11.82	8.99
20	3.6	7.3	197.89	200.70	2.81	1.42
40	3.03	14.98	549.15	579.32	30.17	5.49
28	10.9	5.19	414.17	394.76	-19.41	-4.69
20	4.58	6.09	194.34	199.05	4.71	2.42
28	2.96	9.26	431.59	394.05	-37.54	-8.70
12	5.05	3.7	175.17	173.93	-1.24	-0.71
12	4.24	3.55	131.41	132.90	1.49	1.13
8	2.80	2.06	207.72	205.71	2.01	0.96

4 结论

本研究首先建立了一个双隐含层 BP 神经网络模型，目的在于对复合材料层合板在低速冲击后的损伤面积进行预测。在模型构建的过程中，充分考虑了冲击能量、吸收能量和层合板厚度三个关键参数，并充分进行了误差的反向传递，通过与真实实验数据的对比分析，验证了该模型的高准确性，预测误差率最大值为 15%。此外，建立了一个 CNN 模型，相较于 BPNN 模型，该模型能更为精准地捕捉输入参数的关键特征，其最大预测误差率仅为 8.99%，且预测的多个点误差率低于 2%。

本文基于 BPNN 和 CNN 模型对复合材料层合板损伤面积的预测方法进行了研究。研究结果表明，这些模型可提升工程实践中的预测准确性和效率。

参考文献:

[1] SINGH H, NAMALA K K, MAHAJAN P. A damage evolution study of E-glass/epoxy composite under low velocity impact [J]. Composites Part B Engineering, 2015, 76(JUL.): 235-48.

[2] 孙旋. 复合材料加筋板冲击损伤模拟和剩余强度分析 [D]. 南京: 南京航空航天大学, 2010.

[3] 张少雄, 孙海虹, 陈念众. 高速船复合材料层合板非线性动力响应分析 [J]. 武汉造船, 2001 (1): 7-9.

[4] LIAO B, ZHOU J, LI Y, et al. Damage accumulation mechanism of composite laminates subjected to repeated low velocity impacts [J]. International Journal of Mechanical Sciences, 2020, 182 :105783.

[5] JIAO X, JING B, HUANG Y, et al. Research on fault diagnosis of airborne fuel pump based on EMD and probabilistic neural networks [J]. Microelectronics Reliability, 2017, 75: 296-308.

[6] YAO Y, WANG N. Fault diagnosis model of adaptive miniature circuit breaker based on fractal theory and probabilistic neural network [J]. Mechanical Systems and Signal Processing, 2020, 142 :106772.

[7] LIU Y J, JIANG Z, WEN H M. Predicting impact induced delamination of FRP laminates [J]. International Journal of Impact Engineering, 2020, 137.

[8] WANG H R, LONG S C, ZHANG X Q, et al. Study on the delamination behavior of thick composite laminates under low-energy impact [J]. Composite Structures, 2018, 184: 461-73.

[9] DHANISETTY V S V, MASSART P F R, ESRAIL F, et al. Prediction of damage due to impact for composites on the basis of possible impact threats [J]. International Journal of Impact Engineering, 2019, 132(OCT):103317.

[10] CHANDRASHEKHARA K, OKAFOR A C, JIANG Y P. Estimation of contact force on composite plates using impact-induced strain and neural networks [J]. Composites Part B (Engineering), 1998, 29(4): 363-70.

[11] LU S, DONG H, ZHANG R, et al. Low energy impact damage identification method of CFRP structure based on wavelet transform and probabilistic neural network [J]. Optik, 2021, 232(9):166490.

[12] 詹超, 马晓静, 张芝芳. 纤维增强复合材料梁的分层损伤识别 [J]. 玻璃钢 / 复合材料, 2017 (9): 5-12.

[13] 杨铄, 许清风, 王卓琳. 基于卷积神经网络的结构损伤识别研究进展 [J]. 建筑科学与工程学报, 2022,39(4):38-57.

Neural Network-based Prediction Method for Low-speed Impact Damage Area in Composite Materials

ZHUO Jiayong^{1,2}, NI Kaiwen^{1,2}, CHEN Qinglin^{1,2}, PENG Miaoqiao^{1,2}

(1. Institute of Marine Engineering, Jimei University, Xiamen 361021, China;

2. The Key Laboratory of Ship and Marine Engineering of Fujian Province, Xiamen 361021, China)

Abstract: Currently, composite laminates are widely utilized in the maritime sector. However, traditional experimental and finite element methods fail to accurately depict the actual damage situation when subjected to low-speed impacts. To address this issue, an equivalent impact damage prediction model based on BP neural network and CNN neural network is established by integrating low-speed impact test results and ultrasonic immersion scanning results. This model enables rapid prediction of the damage status of composite laminate structures during impact events. After training the model using experimental sample data, it efficiently and accurately predicts the damage area of composite laminates. This method is simple, practical, and can be widely applied.

Key words: composite materials; low-speed impact; neural network; damage area

(责任编辑 吕春红)

(上接第 28 页)

[8] 冯庆贺, 万林宾, 江铭凯, 等. 基于 SE-YOLOv8 网络模型的绝缘子缺陷识别方法 [J]. 广西电业, 2024 (Z1): 69-74.

visual rail surface inspection system[J]. IEEE Sensors Journal, 2017, 17(23): 7935-7944.

[9] GAN J, LI Q, WANG J, et al. A hierarchical extractor-based

A BiFPN-YOLOv8 for Rail Surface Defect Detection Network Model

FENG Qinghe¹, JIANG Mingkai¹, HAO Qiaohong¹, ZHAO Xiaolei²,

ZHAO Qiang¹, YANG Fuchao¹

(1.School of Intelligent Engineering, Henan Institute of Technology, Xinxiang 453003, China;

2.China Radiowave Propagation Research Institute, Qingdao 266107, China)

Abstract: Aiming to defect such as peeling, holes, scars, scratches, cracks and wear on the rail surface, a BiFPN-YOLOv8 rail surface defect detection network model is constructed. In the data preparation phase, the rail surface image data is augmented through Gauss noise transformation and rotation transformation; In the network construction phase, in order to improve the performance of rail surface defect detection, the BiFPN-YOLOv8 is constructed by introducing the weighted bidirectional pyramid structure BiFPN into the original YOLOv8 network model; In the experimental simulation phase, the quantitative comparison and qualitative detection result evaluation on the RSDDs data set illustrates the accuracy and applicability of the BiFPN-YOLOv8 network model in the rail surface defect detection task.

Key words: rail surface; defect detection; BiFPN-YOLOv8

(责任编辑 王 磊)