

DOI:10.16356/j.1005-2615.2024.03.010

## 基于深度学习的复合材料开孔板拉伸失效行为预测

崔翼扬, 陈普会

(南京航空航天大学航空学院, 南京 210016)

**摘要:** 为研究复合材料开孔板在拉伸载荷下的失效行为, 基于开孔板的拉伸试验建立了高精度的有限元仿真模型, 并批量生成了拉伸载荷-位移曲线的数据集。提出了一种双长短时记忆(Long short-term memory, LSTM)神经网络模型用于预测载荷-位移曲线, 其中第 1 个 LSTM 模型进行输入特征的提取, 第 2 个 LSTM 模型直接给出载荷-位移曲线的预测。结果表明: 这一模型能够高效、准确地预测开孔板的拉伸载荷-位移曲线, 在测试集上的决定系数  $R^2$  可以达到 0.975 5, 关键特征如初始刚度  $E_0$  的预测误差仅为 1.85%, 极限载荷  $F_{\max}$  的预测误差仅为 2.16%。

**关键词:** 复合材料开孔板; 失效行为预测; 载荷-位移曲线; 深度学习; 长短时记忆模型

**中图分类号:** V214.8 **文献标志码:** A **文章编号:** 1005-2615(2024)03-0468-10

## Prediction of Tensile Failure Behavior of Open-Hole Composite Plates Based on Deep Learning

CUI Yiyang, CHEN Puhui

(College of Aerospace Engineering, Nanjing University of Aeronautics & Astronautics, Nanjing 210016, China)

**Abstract:** To investigate the failure behavior of composite open-hole plates under tensile loads, a high-precision finite element simulation model is established based on tensile tests of open-hole plates, and a dataset of tensile force-displacement curves is generated in batches. Then, dual long short-term memory (LSTM) neural network models are proposed to predict the force-displacement curve. The first LSTM model is responsible for extracting input features, while the second one directly predicts the force-displacement curve. The research results indicate that this model can efficiently and accurately predict the tensile force-displacement curves of open-hole plates. The coefficient of determination  $R^2$  on the test set reaches as high as 0.975 5, with the prediction error of key features such as the initial stiffness  $E_0$  being only 1.85% and the prediction error of the maximum load  $F_{\max}$  being only 2.16%.

**Key words:** composite open-hole plates; failure behavior prediction; force-displacement curve; deep learning; long short-term memory (LSTM) model

含开孔的复合材料层合板作为典型的含损伤结构, 常用于结构设计许用值试验和损伤容限分析中<sup>[1]</sup>。目前, 对复合材料开孔板的力学性能研究主要采用试验结合有限元仿真的方法<sup>[2-4]</sup>。通过试验研究能够真实反映开孔板的失效模式<sup>[5-6]</sup>, 但是试验成本高, 较难覆盖所有的设计空间。另一方面,

采用有限元仿真的方法虽然成本降低, 但是为了获得精确的仿真结果, 通常需要进行精细建模, 模型庞大, 计算效率不高<sup>[7-8]</sup>。

随着人工智能领域的飞速发展, 越来越多的学者开始将深度学习模型应用于复合材料的力学性能预测中<sup>[9-11]</sup>。Gu 等<sup>[12]</sup>采用计算机生成的数万张

收稿日期: 2023-12-13; 修订日期: 2024-03-07

通信作者: 陈普会, 男, 教授, 博士生导师, E-mail: phchen@nuaa.edu.cn。

引用格式: 崔翼扬, 陈普会. 基于深度学习的复合材料开孔板拉伸失效行为预测[J]. 南京航空航天大学学报, 2024, 56(3): 468-477. CUI Yiyang, CHEN Puhui. Prediction of tensile failure behavior of open-hole composite plates based on deep learning[J]. Journal of Nanjing University of Aeronautics & Astronautics, 2024, 56(3): 468-477.

两相夹杂复合材料二维图像,结合有限元分析得到的刚度和强度数据训练卷积神经网络(Convolutional neural network, CNN)模型,成功由二维结构图像预测了材料的韧性和强度,且计算速度较有限元方法提升了250倍。Ding等<sup>[13]</sup>开发了深度神经网络(Deep neural network, DNN)模型,实现了不同纤维体积分数和纤维半径下复合材料单向板的横观力学性能预测和微观裂纹模式分类。Zhang等<sup>[14]</sup>采用多种人工智能方法,以板的尺寸、孔径大小等为输入参数,预测了开孔层合板在经典失效理论下的失效因子和临界屈曲特征值,预测值与有限元结果的误差较小,证明了深度学习模型适用于预测复合材料层合板的力学性能。在以上这些尝试中,复合材料结构的大多数设计变量都可以作为输入参数被模型捕获并进行训练,而铺层顺序这个变量却难以传递到模型中去,主要原因是常规的深度学习模型(CNN、DNN等)没有区分参数之间先后顺序的能力,自然无法应用到铺层顺序的表征上来。为了解决这一问题,Shah等<sup>[15]</sup>创新性地使用长短时记忆(Long short-term memory, LSTM)神经网络模型来表征复合材料层合板的铺层顺序,得益于LSTM处理时序信息的优秀能力,成功预测了复合材料层合板的基本力学性能,但此模型只应用在部分典型铺层上,而不是任意的铺层顺序组合。

深度学习模型在复合材料的失效行为预测上已经有了很多的尝试<sup>[16-18]</sup>。Zhang等<sup>[19]</sup>提出了一种基于有限元法的人工神经网络(Artificial neural network, ANN)模型,以应力、应变和应变增量为输入变量,预测了开孔层合板的变形、强度和渐进损伤行为。结果表明,当应力-应变状态和应变增量保持在训练域内时,ANN模型可以很好地预测开孔层合板在任意载荷下的力学行为。Yan等<sup>[20]</sup>使用中尺度有限元模型生成的应力-应变数据,训练了一个复合材料结构非线性行为的ANN代理模型,并将其应用于宏观尺度有限元分析之中,在不影响精度的情况下大幅提高了计算速度。Lee等<sup>[21]</sup>利用1 270个聚合物基复合材料的拉伸试验数据训练LSTM模型,得到了一个包含失效点的应力-应变曲线预测模型,模型预测结果的决定系数可以达到0.92,但此模型需要用前一时刻的应力值来预测下一时刻的应力值,因此需要将应力-应变曲线的初始段作为模型的输入,而不能直接由材料参数预测完整的应力-应变曲线。

综上所述,以往学者使用深度学习模型捕获复合材料的铺层顺序特征或对复合材料的失效行为进行预测时仍有不足之处,因此,本文借助LSTM模型对时序信息的优秀处理能力,希望能够准确快速地预测不同参数(包含铺层顺序)下复合材料开孔层合板的拉伸失效行为。为了实现这一目标,本文采用编码器-解码器框架,搭建了一个双LSTM模型,其中第1个LSTM模型负责提取开孔板的铺层信息,并将提取信息与其他尺寸参数信息一起提供给第2个LSTM模型,通过第2个模型可以直接输出结构的载荷-位移曲线,在这个过程中不需要任何的初始载荷输入。其中,供深度学习模型训练和测试的数据集是依托有限元模型批量生成的。

## 1 试验与仿真

### 1.1 试验参数

复合材料开孔板拉伸试验件的形式如图1,共有13、25和50 mm 3种不同大小的孔径,试验件测试段的长度和宽度分别是孔径的20倍和5倍。试验中的开孔板都是对称均衡层合板,铺层角度只包含 $0^\circ$ 、 $\pm 45^\circ$ 和 $90^\circ$ 。不同类型的铺层信息如表1所示。孔径为13和50 mm的开孔板有L0、L2、L3这3种铺层,孔径为25 mm的开孔板增加了另外2种铺层,每种组合下的试验件都有6件。铺层材料采用中模高强碳纤维增强M21C环氧树脂单向带,符合材料规范CMS-CP-309,固化后单层名义厚度为0.187 mm。复合材料单向板的参数如表2所示。




图1 开孔拉伸试验件示意图

Fig.1 Schematic diagram of open-hole tensile specimen

表1 铺层信息

Table 1 Lay-up information

代码	铺层顺序	层数	名义厚度/mm
L0	$[45^\circ/0^\circ/-45^\circ/90^\circ]_{3S}$	24	4.488
L2	$[45^\circ/-45^\circ/90^\circ/0^\circ/45^\circ/-45^\circ/45^\circ/-45^\circ/90^\circ/0^\circ]_S$	20	3.740
L3	$[45^\circ/0^\circ/-45^\circ/90^\circ/45^\circ/0^\circ/90^\circ/-45^\circ/90^\circ/0^\circ]_S$	20	3.740
L01	$[45^\circ/0^\circ/-45^\circ/90^\circ]_{2S}$	16	2.992
L02	$[45^\circ/0^\circ/-45^\circ/90^\circ]_{4S}$	32	5.984

表2 复合材料单向板的材料参数

参数	数值	参数	数值
$E_1/\text{MPa}$	166 000	$X_C/\text{MPa}$	1 654
$E_2/\text{MPa}$	9 600	$Y_T/\text{MPa}$	63.9
$\nu_{12}$	0.31	$Y_C/\text{MPa}$	253
$G_{12}/\text{MPa}$	4 600	$S_{12}/\text{MPa}$	80
$G_{13}/\text{MPa}$	4 600	$S_{13}/\text{MPa}$	80
$G_{23}/\text{MPa}$	3 330	$S_{23}/\text{MPa}$	80
$X_T/\text{MPa}$	3 242	$\rho/(\text{kg}\cdot\text{m}^{-3})$	1 600

## 1.2 仿真模型

使用有限元分析软件 Abaqus 对复合材料开孔拉伸试验件进行数值仿真。采用连续壳单元对复合材料板进行模型搭建,划分网格采用 SCR8 单元。以 L2 铺层的 25 mm 开孔板为例,对比了 4 种不同尺寸的网格划分方法,如图 2 所示,综合考虑耗时(Time)和极限载荷的计算误差(Error),选择 Mesh-3 作为后续开孔板网格划分的形式。参照表 2 赋予材料参数,采用二维 Hashin 准则作为损伤起始判据。此准则区分了 4 种不同的失效模式,能够真实地仿真出不同铺层开孔板的破坏模式。再结合双线性刚度退化准则,可以进行后续的渐进损伤分析。为节省计算时间,采用 Explicit 显式动态分析步进行仿真分析,设置了 10 倍的总体质量放大系数,并且保证仿真过程中动能不超过内能

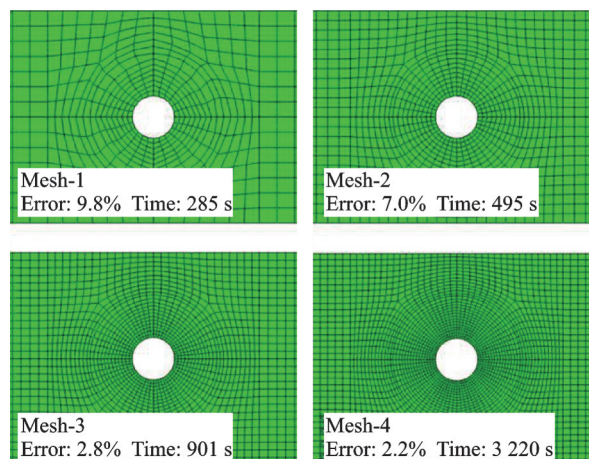


图2 孔边的不同网格密度

Fig.2 Various mesh densities around the hole

的 5%。

根据上述的建模方法,对所有开孔板都进行了有限元计算,初始刚度和极限载荷的计算结果汇总在表 3 中,并与试验结果进行对比。其中,试验结果取每种类型开孔板 6 件试验件的平均值。可以看出,开孔板初始刚度的计算误差都在 1.3% 以内,极限载荷的计算误差都在 10% 以内,符合工程常用的精度要求。证明了这种建模方式在开孔板的参数空间上,可以进行有效的仿真模拟,即可以用来进行大批量数据集的生成。图 3 中汇总了所有开孔板载荷-位移曲线的计算结果和试验结果,可以看出,上述有限元模型对载荷-位移曲线的捕捉也是有效的,证明模型有较好的仿真能力。

表3 仿真结果与试验结果的对比

Table 3 Comparison of simulation results with test results

孔径/mm	铺层类型	初始刚度			极限载荷		
		试验结果/GPa	仿真结果/GPa	误差/%	试验结果/kN	仿真结果/kN	误差/%
13	L0	55.64	55.71	0.1	140.1	152.2	8.6
	L2	41.12	41.40	0.7	117.0	119.3	1.9
	L3	50.79	50.89	0.2	131.2	127.6	-2.7
25	L0	54.38	55.06	1.3	248.1	261.6	5.4
	L2	40.39	40.92	1.3	205.0	210.8	2.8
	L3	50.24	50.32	0.2	220.8	221.5	0.3
	L01	36.85	36.71	-0.4	169.1	174.4	3.1
	L02	73.32	73.42	0.1	347.3	348.4	0.3
50	L0	48.92	49.25	0.7	434.9	475.2	9.3
	L2	36.23	36.59	1.0	364.3	349.2	-4.2
	L3	44.97	45.03	0.1	391.4	388.5	0.8



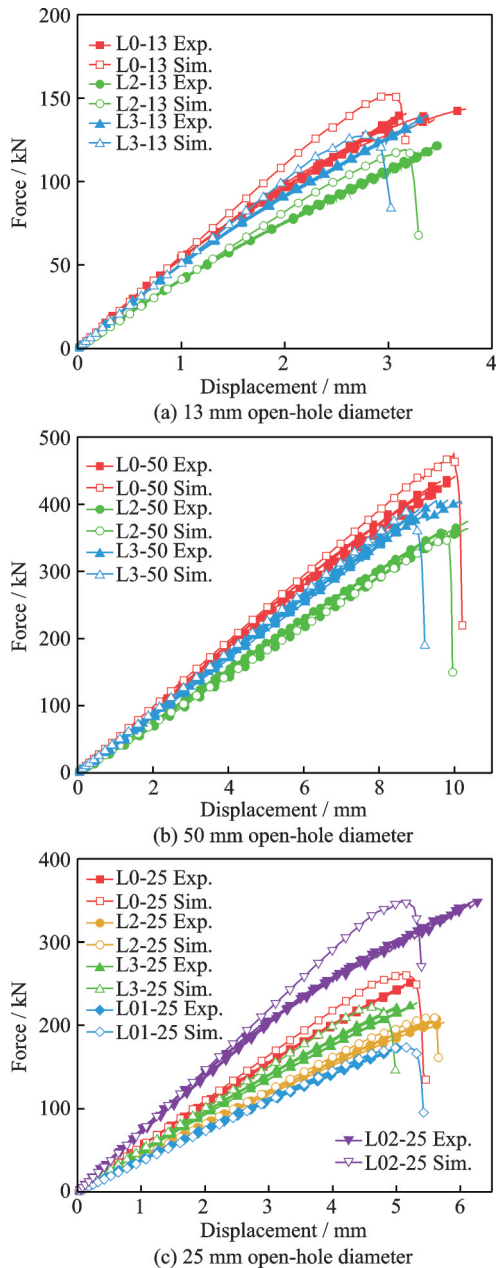


图3 载荷-位移曲线的对比

Fig.3 Comparison of force-displacement curves

## 2 数据生成与预处理

### 2.1 数据集生成

根据试验参数确定数据集的变量为铺层顺序、开孔板厚度和孔径大小。其中孔径大小的变化范围为13~50 mm,只选取整数。层合板采用对称铺层,铺层层数采用16、20、24、28、32这5种数量,对应的铺层厚度变化范围为2.992~5.984 mm。同时,铺层角度还必须满足以下要求:(1)层合板只由 $0^\circ$ 、 $\pm 45^\circ$ 和 $90^\circ$ 铺层组成;(2)相同角度的铺层连续层数不得大于2层。

确定好变量以及参数范围后,采用拉丁超立方取样方法随机取样,共生成1 000组参数组合。使

用Python语言编写自动处理脚本,在Abaqus中使用验证过的建模方法进行批量运算,计算得到1 000个有限元模型,并在后处理阶段对每一个有限元模型自动提取载荷-位移曲线。

### 2.2 数据预处理

Abaqus输出的载荷-位移曲线上的点不是均匀分布的,不利于深度学习模型的训练,所以对1 000条载荷-位移曲线进行了统一的线性插值重构:对横坐标(位移)均匀地取(0 mm,12 mm]范围内的600个点,通过线性插值得到每个点上对应的纵坐标(载荷)。曲线的处理效果如图4所示。原始曲线在破坏之后有一个明显的震荡期,这是由显式Explicit分析带来的,并不是试验中真实存在的现象,因此将破坏后的载荷震荡部分的纵坐标替换为0 kN。这样的处理既保留了模型原有的物理信息,又有利于深度学习模型的训练。同时,从载荷-位移曲线中还可以提取出开孔板的初始刚度 $E_0$ 和极限载荷 $F_{\max}$ 。




图4 载荷-位移曲线的处理效果

Fig.4 Processing effect of force-displacement curves

在本研究中,输入变量有铺层顺序、开孔板厚度以及孔径大小,输出变量是载荷-位移数据(所有板的位移数据是一致的)。为了提高计算稳定性,需要对这些变量进行预处理。对于除铺层顺序之外的常数变量,采用数据归一化的处理方式,将所有数据缩放到[0,1]区间,公式为

$$Y = \frac{X - X_{\min}}{X_{\max} - X_{\min}} \quad (1)$$

式中: $X$ 为某变量的实际值, $X_{\min}$ 为最小值, $X_{\max}$ 为最大值, $Y$ 为归一化后的变量值。归一化能消除数据尺度不一致带来的模型误差。

对于铺层顺序,为了使深度学习模型能够有效识别,也应该进行特征预处理。本文的铺层角度限制为 $0^\circ$ 、 $\pm 45^\circ$ 和 $90^\circ$ ,这4种角度应当视为4种独立的选择,而非有大小关系的连续变量。因此,独热

编码提供了一种良好的处理方法。采用四维编码,每一层的铺层角度对应位置的编码为1,其他位置的编码都为0,这样就消除了不同铺层角度之间的大小关系,各自独立。由于是对称铺层且最大层数为32,故所有开孔板的铺层信息都可以用16×4的编码表示。铺层数量不足的位置用0填充,如图5所示。

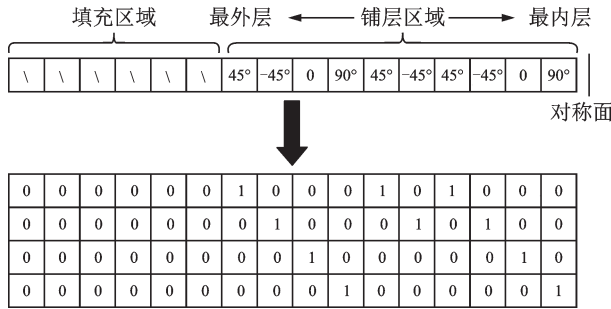


图5 某10层开孔板铺层顺序的独热编码

Fig.5 One-hot encoding for the stacking sequence of a 10-layer open-hole plate

### 3 模型搭建与训练

#### 3.1 LSTM网络

LSTM是一种深度学习模型,在自然语言处理、语音识别和股票预测等很多领域都表现不俗。它其实是循环神经网络(Recurrent neural network, RNN)的一种变体。LSTM和RNN都具有处理时间序列数据的能力,但是RNN的架构只对短期记忆有效,在处理长期记忆上的效果并不理想,并且还容易产生梯度爆炸和梯度消失等问题。因此,LSTM通过在RNN中增加一条长时记忆通道,实现了对长期记忆信息的捕捉。又加入了遗忘门、输入门、细胞门和输出门,利用门结构的逻辑控制决定数据的更新或丢弃,使模型能够更快、更好地收敛。

LSTM网络的结构示意图如图6所示,由多个单元(Cell)前后串联组成。单元的内部结构如图6(a)所示,“⊗”和“⊕”分别表示逐点乘法和逐点加法,σ表示Sigmoid函数,  $X_t$ 表示当前时刻的输入数据,输入经遗忘门  $f_t$ 、输入门  $i_t$ 、细胞门  $\bar{c}_t$ 以及输出门  $o_t$ 后,得到当前时刻的输出  $h_t$ 以及长时记忆  $c_t$ 。  $h_t$ 和  $c_t$ 会在网络中不断更新并向后传递。

LSTM中门结构的相关运算公式如下所示

$$f_t = \sigma(W_{f_h}h_{t-1} + W_{f_x}x_t + b_f) \quad (2)$$

$$i_t = \sigma(W_{i_h}h_{t-1} + W_{i_x}x_t + b_i) \quad (3)$$

$$\bar{c}_t = \tanh(W_{c_h}h_{t-1} + W_{c_x}x_t + b_c) \quad (4)$$

$$c_t = c_{t-1} \cdot f_t + i_t \cdot \bar{c}_t \quad (5)$$

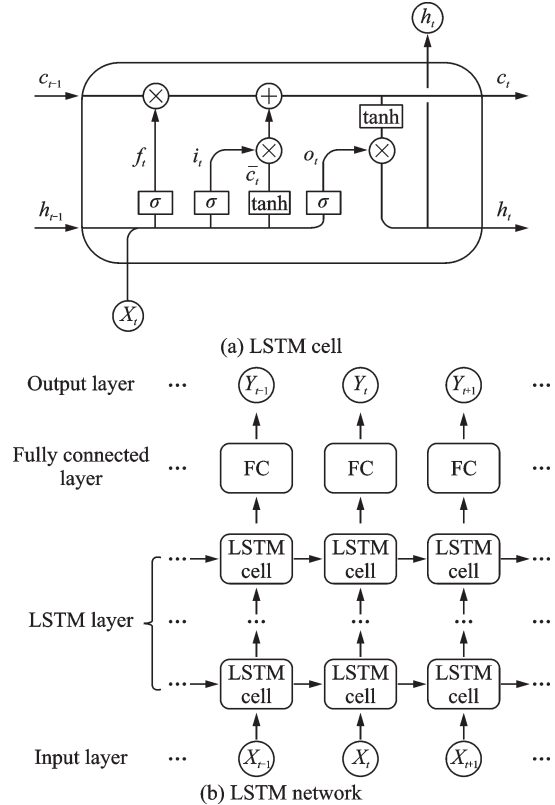


图6 LSTM网络的结构示意图

Fig.6 Schematic diagram of the LSTM network structure

$$o_t = \sigma(W_{o_h}h_{t-1} + W_{o_x}x_t + b_o) \quad (6)$$

$$h_t = o_t \cdot \tanh(c_t) \quad (7)$$

整个LSTM网络的结构如图6(b)所示,由若干个LSTM层组成,每层中又有若干个LSTM单元。单元的输出  $h_t$ 不一定和最终希望得到的输出  $Y_t$ 格式相同,所以通常需要增加全连接层来修正格式,使得网络输出可以直接与目标值进行误差对比。

#### 3.2 模型搭建

为了实现复合材料开孔板的拉伸载荷-位移曲线的预测,本文采用两步走的策略,使用双LSTM模型来解决这个问题,模型的输入和输出如表4所示,模型的框架如图7所示。

表4 双LSTM模型的输入与输出

Table 4 Input and output of the dual LSTM model

模型输入	模型输出
$\theta, d, t, u$	$f$

第1步可以理解为编码器(Encoder block),对开孔板的输入参数进行特征提取并编码。首先将1块板的16个铺层角度( $\theta$ )作为时序信息输入进第1个LSTM模型中,每一个角度对应其中的1个LSTM单元,共有16个单元。同时,模型还具有若干LSTM层,层数是一个超参数,需要在后

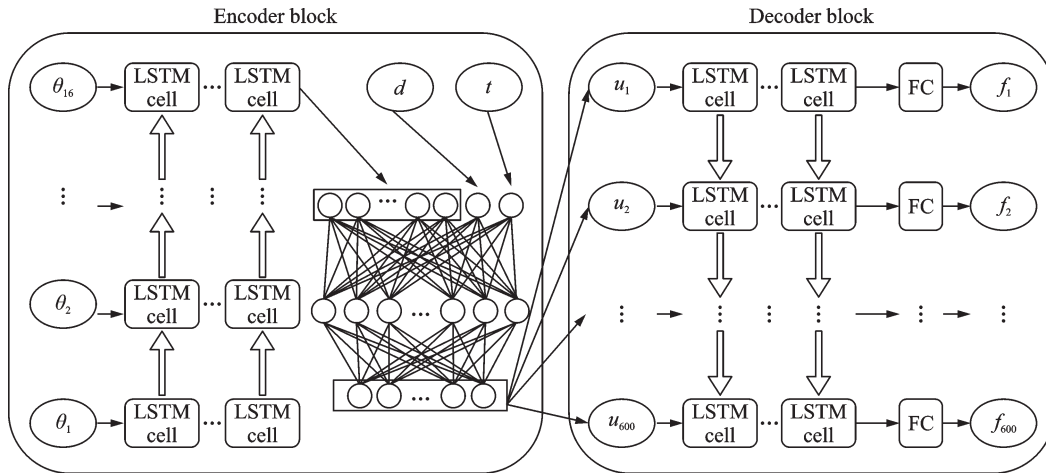


图 7 双 LSTM 模型框架

Fig.7 The dual LSTM model framework

续调参过程中进一步确定。提取最后一层的最后一个 LSTM 单元的数据作为输出,给这个输出添加上开孔板厚度  $t$  和孔径大小  $d$ ,并经过一个神经网络 ANN 模型,得到整个编码器的输出。其中 ANN 模型的隐藏层神经元使用线性整流(Rectified linear unit, ReLU)激活函数。

第 2 步可以理解解码器(Decoder block),对第 1 步提取的特征进行解码,并实现载荷-位移曲线的预测。将第 1 步的输出结合上开孔板所有时刻的位移量  $u$ ,作为时序信息输入进第 2 个 LSTM 模型中,并提取其中每一个单元的输出,经过全连接层后,输出为每一个时刻的载荷值( $f$ )。每层中有 600 个单元,对应有 600 组载荷和位移数据,即载荷-位移曲线上 600 个点的坐标。

通过这一编码-解码方法,可以实现一整条载荷-位移曲线的直接预测,并且不需要任何的载荷初始数据作为输入,使得模型有较为强大的泛化能力。整个模型在 Pytorch 环境中搭建并训练。

### 3.3 模型训练及测试

将数据集按 8:2 的比例随机划分为训练集和测试集,分别有 800 和 200 组数据,它们都分布在数据集的参数范围内。在训练集上调整模型的超参数,使得模型更好拟合数据,训练好的模型在测试集上进行性能检验,测试集上的效果可以反映模型在整个参数范围上的泛化能力。

在训练模型时,采用的损失函数为均方差(Mean-square error, MSE)损失,其数学公式为

$$MSE(X, h) = \frac{1}{n} \sum_{i=1}^n (h(x_i) - y_i)^2 \quad (8)$$

式中: $n$ 为数据点的个数, $h(x_i)$ 为第  $i$  个样本的预

测值, $y_i$ 为第  $i$  个样本的真实值。将损失函数值作为误差进行反向传播,不断迭代并优化模型的内部参数。在测试模型时,使用决定系数( $R^2$ )来反映模型拟合曲线的精度, $R^2$ 越接近 1,模型精度越高。具体数学公式如下

$$R^2(X, h) = 1 - \frac{\sum_{i=1}^n (h(x_i) - y_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (9)$$

$$\bar{y} = \frac{1}{n} \sum_{i=1}^n y_i \quad (10)$$

从载荷位移曲线中提取的初始刚度和极限载荷,则使用平均绝对百分比误差(Mean absolute percentage error, MAPE)来衡量预测效果,MAPE 越接近 0,模型误差越小。具体数学公式如下

$$MAPE(X, h) = \frac{1}{n} \sum_{i=1}^n \left( \frac{|h(x_i) - y_i|}{y_i} \times 100\% \right) \quad (11)$$

## 4 结果与讨论

### 4.1 模型超参数对比

通过一系列尝试,得到了双 LSTM 模型的最优超参数,汇总在表 5 中。本节中,对模型中较为核心的超参数进行了对比研究,除了作为对比的模型外,其他模型都采用最优超参数配置。所有模型均进行了 200 次迭代优化。首先对比了采用不同优化器和学习率的情况下,模型预测结果与真实值之间的决定系数  $R^2$  和损失函数 MSE,如图 8 所示。从图 8 中可以看出,随机梯度下降(Stochastic gradient descent, SGD)算法和带动量的随机梯度下降(Stochastic gradient descent with momentum, SGD-M)算法在所有学习率下的效果都较差,SGD-M 算法略好于 SGD 算法,但也表现出明显的不稳定



性。均方根传播(Root mean square propagation, RMSprop)算法、自适应矩估计(Adaptive moment estimation, Adam)算法和自适应梯度(Adaptive gradient, Adagrad)算法的拟合效果更好,主要得益于它们的自适应学习率优化策略,在合理选择初始学习率的情况下可以得到较高的 $R^2$ 和较低的MSE。其中,采用Adam算法搭配初始学习率为0.001的模型得到了最高的 $R^2$ 和最低的MSE。

表5 双LSTM模型的超参数设置

Table 5 Hyperparameter configuration for the dual LSTM models

超参数位置	名称	数值
共用	优化器	Adam
	学习率	0.001
	批量	10
第1个LSTM	层数	2
	每层神经元数	40
ANN	输入层特征数	6
	隐藏层结构	[120-160-120]
	输出层特征数	12
第2个LSTM	层数	4
	每层神经元数	40
全连接层	神经元数	160

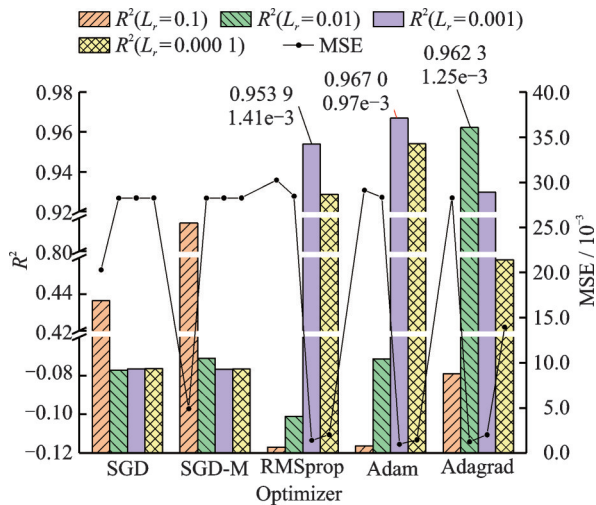


图8 不同优化器及学习率下的 $R^2$ 及MSE对比

Fig.8 Comparison of  $R^2$  and MSE under different optimizers and learning rates

LSTM模型的层数也是一个较为核心的超参数,图9对比了模型中两个LSTM模型采用不同层数组合下预测结果的对比。从图9中可以看出,层数越多,模型的预测效果并不一定越好。当LSTM-1采用1层或3层结构时,LSTM-2采用1层结构的预测效果最好,而当LSTM-1采用2层或

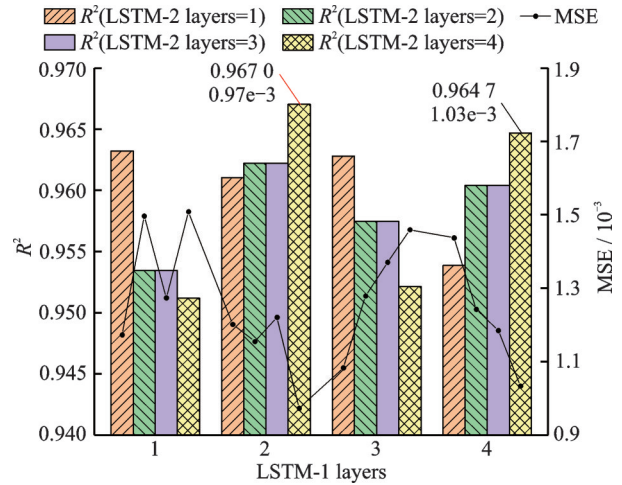


图9 采用不同LSTM层数的 $R^2$ 及MSE对比

Fig.9 Comparison of  $R^2$  and MSE under different numbers of LSTM layers

4层结构时,LSTM-2采用4层结构的预测效果最好。其中,两个LSTM模型分别采用2层和4层的结构时,模型可以取得最高的 $R^2$ 和最低的MSE。

除了模型的超参数外,也对数据集的大小进行了对比研究。测试集的200条数据固定不变,保持检验标准的一致性,将训练集的800条数据随机划分为不同的大小,每种大小下重复进行10次训练和测试,最终得到了训练集大小对模型 $R^2$ 的影响,如图10所示。可以看出,随着训练集数据量的增加,测试集上的 $R^2$ 持续上升。当训练集数据量达到400条以上时,10次重复测试得到的 $R^2$ 分散性较小,结果较为稳定。当训练集数据量达到600条以上时,测试集上的 $R^2$ 可以稳定达到0.94以上。

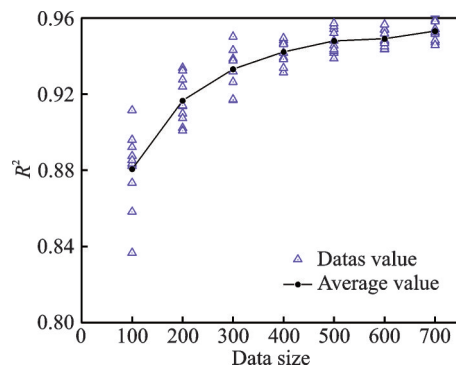


图10 采用不同大小训练集的 $R^2$ 对比

Fig.10 Comparison of  $R^2$  under different size of training set

### 4.2 模型预测效果

采用最优参数模型,在全部800组数据的训练集上进行500次迭代,迭代过程中的损失函数曲线和 $R^2$ 曲线如图11、12所示。可以看出,随着迭代次数的增多,训练集上的损失函数首先快速下降,之后一直保持缓慢减少的趋势,波动较小。而测试




图 11 模型训练和测试时的损失函数曲线

Fig.11 Loss function curves during model training and testing




图 12 模型训练和测试时的  $R^2$  曲线

Fig.12  $R^2$  curves during model training and testing

集上的损失函数在快速下降后出现了一定程度的波动,在 200 次迭代后达到一个稳定的状态。训练集和测试集上  $R^2$  的变化模式与损失函数的变化模式相似,也是在 200 次迭代之后达到一个较为稳定的状态并缓慢增加。

经过 500 次迭代后,模型在测试集上的  $R^2$  可以达到 0.975 5,表现出了不错的预测效果。此模型的独特之处,在于具有优秀的载荷-位移曲线预

测能力。图 13 展示了几种不同参数下开孔板载荷-位移曲线的有限元计算值和预测值。可以看出,双 LSTM 模型对初始刚度的捕捉很好,曲线的线性阶段十分吻合,进入非线性阶段后,预测值和计算值稍有偏差,但也能够准确反应曲线的变化细节,如刚度退化、载荷突变等。模型对于失效行为的预测也较为准确,能够很好地刻画失效后的曲线变化。整体来看,双 LSTM 模型给出的载荷-位移曲线足够精确,能够作为有限元软件的替代模型。

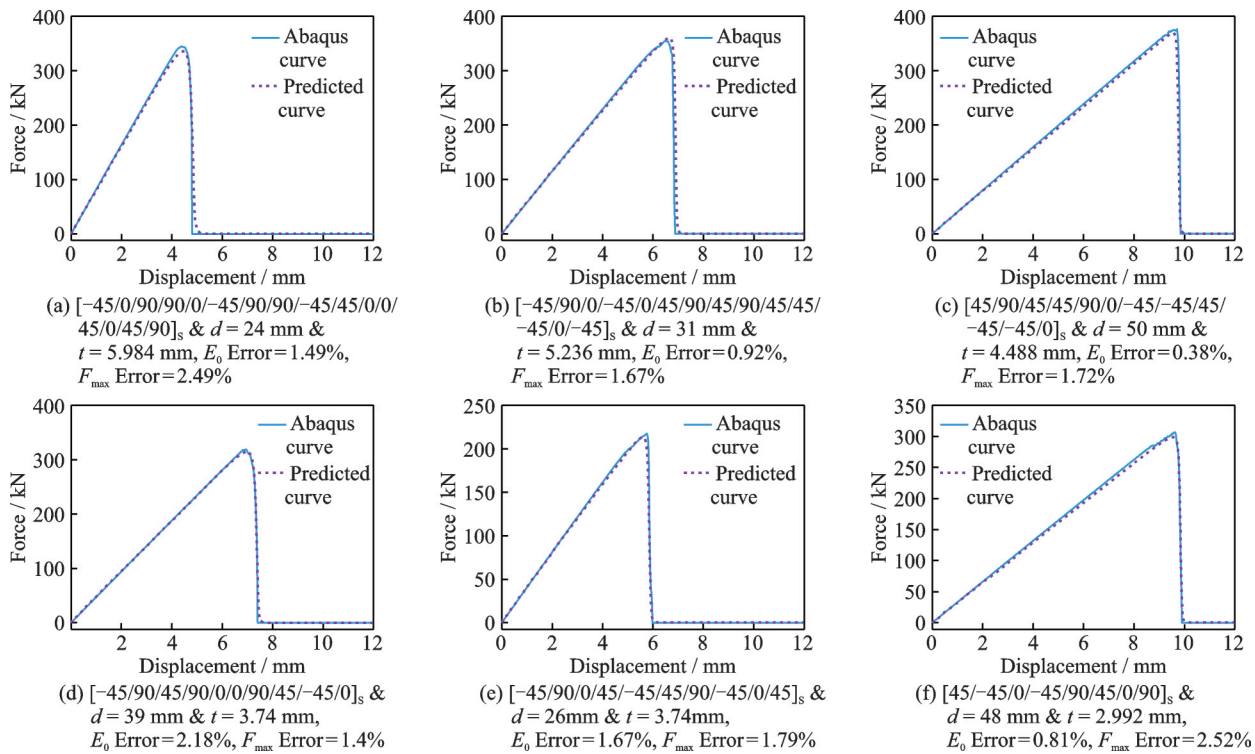


图 13 载荷-位移曲线的预测值与真实值对比

Fig.13 Comparison between predicted and actual values of force-displacement curves

从预测的载荷-位移曲线中提取初始刚度  $E_0$  和极限载荷  $F_{max}$ , 并与数据集中的仿真结果进行对比,结果如图 14 所示。可以看出,模型对这两者的预测误差都较小,图 14 上的点基本集中在对角线附近。在所有 200 条测试数据上,  $E_0$  的平均误差为 1.85%,  $F_{max}$  的平均误差为 2.16%, 都有较高的精

度。说明此模型也可以进行复合材料开孔板拉伸载荷下初始刚度和极限载荷的预测。

为了深入研究模型的预测效果,提取了测试集中初始刚度或极限载荷的预测误差大于 5% 的数据点,视为预测效果欠佳的点,将这些点的参数分布与测试集中其他数据点的参数分布进行对比,如




图14 模型对测试集上 $E_0$ 和 $F_{max}$ 的预测误差Fig.14 Model prediction errors for  $E_0$  and  $F_{max}$  on the test set

图15所示。由于铺层顺序无法直观展示,因此只考察了孔径和厚度这两个参数。可以看出,预测效果欠佳的点主要集中于厚度较厚的区域,此时铺层数量更多,潜在的铺层角度组合也更多,模型训练中所需的数据量也更大,因此模型在此区域较容易出现预测效果欠佳的情况。但整体来看,模型依然具有较高的预测精度。

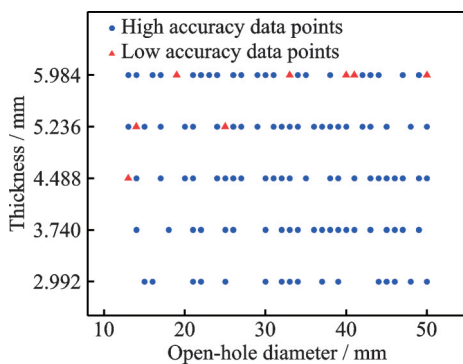


图15 测试集上数据点的参数分布

Fig.15 Parameter distribution of data points on the test set

如表6所示,双LSTM模型预测测试集上的200条曲线仅用时0.65 s,而在Abaqus中计算这200个开孔板需要耗费91 352 s。可以看出,双LSTM模型大幅提高了复合材料开孔板拉伸载荷-位移曲线(包括初始刚度和极限载荷)的计算效率。

表6 双LSTM模型和Abaqus模型的对比

Table 6 Comparison between the double LSTM model and the Abaqus model

参数	双LSTM模型	Abaqus模型
使用核数	1	10
数据量/条	200	200
耗时/s	0.65	91 352

## 5 结 论

本文提出了一种双LSTM神经网络模型,可以准确预测不同参数复合材料开孔板的拉伸载荷-位移曲线。主要完成了以下工作:

(1)通过Abaqus有限元软件建立了在全参数范围内误差都较低的开孔板模型,并计算了1 000个不同参数开孔板的载荷-位移曲线作为数据集。

(2)搭建了双LSTM模型,第1个模型用于提取铺层顺序等输入参数的特征,第2个模型直接预测载荷-位移曲线,并且不需要任何的载荷初始值作为输入。

(3)训练好的模型在测试集上的 $R^2$ 可以达到0.975 5,初始刚度 $E_0$ 的MAPE为1.85%,极限载荷 $F_{max}$ 的MAPE为2.16%。模型不仅具有优秀的载荷-位移曲线预测能力,而且计算效率较有限元方法大幅提高。本研究为复合材料开孔板的拉伸失效行为分析提供了一种全新的方法,借助双LSTM模型架构,可以准确、快速地解决拉伸载荷-位移曲线的预测问题。在未来的工作中,这一高效的力学性能预测工具有望扩展到别的复合材料结构或受载形式当中,也有望助力于复合材料结构的优化设计。

## 参考文献:

- [1] 益小苏,杜善义,张立同. 复合材料手册[M]. 北京: 化学工业出版社, 2009: 772-782.  
YI Xiaosu, DU Shanyi, ZHANG Litong. Composite materials brochure[M]. Beijing: Chemical Industry Press, 2009: 772-782.
- [2] DIVSE V, MARLA D, JOSHI S S. Finite element analysis of tensile notched strength of composite laminates[J]. Composite Structures, 2021, 255: 112880.
- [3] REINER J, FESER T, SCHUELER D, et al. Comparison of two progressive damage models for studying the notched behavior of composite laminates under tension[J]. Composite Structures, 2019, 207: 385-396.
- [4] TIAN Kun, ZHOU Song, YANG Chaozhi, et al. Tension failure simulation of notched composite laminate using floating node method combined with in-situ effect theory[J]. Journal of Materials Research and

- Technology, 2019, 8(3): 2494-2507.
- [5] HALLETT S R, GREEN B G, JIANG W G, et al. An experimental and numerical investigation into the damage mechanisms in notched composites[J]. Composites Part A: Applied Science and Manufacturing, 2009, 40(5): 613-624.
- [6] ERÇİN G H, CAMANHO P P, XAVIER J, et al. Size effects on the tensile and compressive failure of notched composite laminates[J]. Composite Structures, 2013, 96: 736-744.
- [7] HIGUCHI R, AOKI R, ONODERA S, et al. Multi-fidelity progressive damage simulation of notched composite laminates with various ply thicknesses[J]. International Journal of Solids and Structures, 2022, 242: 111518.
- [8] LEONG K H, ZHI J, LEE H P, et al. Adaptive multi-fidelity (AMF) modelling of progressive damage in notched composite laminates[J]. Composites Part A: Applied Science and Manufacturing, 2022, 154: 106790.
- [9] 霍冠良, 宁志华. 基于BP神经网络的含褶皱复合材料强度预测[J]. 南京航空航天大学学报, 2020, 52(3): 460-467.
- HUO Guanliang, NING Zhihua. Strength prediction of laminates containing embedded fiber wrinkles using BP neural networks[J]. Journal of Nanjing University of Aeronautics & Astronautics, 2020, 52(3): 460-467.
- [10] 张峻铭, 杨伟东, 李岩. 人工智能在复合材料研究中的应用[J]. 力学进展, 2021, 51(4): 865-900.
- ZHANG Junming, YANG Weidong, LI Yan. Application of artificial intelligence in composite materials [J]. Advances in Mechanics, 2021, 51(4): 865-900.
- [11] YUAN Mingqing, ZHAO Haitao, XIE Yuehan, et al. Prediction of stiffness degradation based on machine learning: Axial elastic modulus of  $[0m/90n]_s$  composite laminates[J]. Composites Science and Technology, 2022, 218: 109186.
- [12] GU G X, CHEN C T, BUEHLER M J. De novo composite design based on machine learning algorithm [J]. Extreme Mechanics Letters, 2018, 18: 19-28.
- [13] DING Xiaoxuan, HOU Xiaonan, XIA Min, et al. Predictions of macroscopic mechanical properties and microscopic cracks of unidirectional fibre-reinforced polymer composites using deep neural network (DNN) [J]. Composite Structures, 2022, 302: 116248.
- [14] ZHANG Chen, LI Yushu, JIANG Biao, et al. Mechanical properties prediction of composite laminate with FEA and machine learning coupled method[J]. Composite Structures, 2022, 299: 116086.
- [15] SHAH V, ZADOURIAN S, YANG C, et al. Data-driven approach for the prediction of mechanical properties of carbon fiber reinforced composites[J]. Materials Advances, 2022, 3(19): 7319-7327.
- [16] EL SAID B. Predicting the non-linear response of composite materials using deep recurrent convolutional neural networks[J]. International Journal of Solids and Structures, 2023, 276: 112334.
- [17] CHEN Jiayun, WAN Lei, ISMAIL Y, et al. A micromechanics and machine learning coupled approach for failure prediction of unidirectional CFRP composites under triaxial loading: A preliminary study[J]. Composite Structures, 2021, 267: 113876.
- [18] BALCIOĞLU H E, SEÇKİN A Ç. Comparison of machine learning methods and finite element analysis on the fracture behavior of polymer composites[J]. Archive of Applied Mechanics, 2021, 91: 223-239.
- [19] ZHANG Kun, MA Lianhua, SONG Zizhen, et al. Strength prediction and progressive damage analysis of carbon fiber reinforced polymer-laminate with circular holes by an efficient artificial neural network[J]. Composite Structures, 2022, 296: 115835.
- [20] YAN Shibo, ZOU Xi, ILKHANI M, et al. An efficient multiscale surrogate modelling framework for composite materials considering progressive damage based on artificial neural networks[J]. Composites Part B: Engineering, 2020, 194: 108014.
- [21] LEE J, LEE N, SON J, et al. An LSTM model with optimal feature selection for predictions of tensile behavior and tensile failure of polymer matrix composites [J]. Korean Journal of Chemical Engineering, 2023, 40(9): 2091-2101.

(编辑:陈璐)