

基于数据驱动的复合材料层合板疲劳分层扩展研究



王杰雄¹, 李兴福², 裴兆东¹, 姚辽军¹, 果立成¹

1. 哈尔滨工业大学, 黑龙江 哈尔滨 150001

2. 中航西安飞机工业集团股份有限公司, 陕西 西安 710089

摘要: 疲劳分层扩展(FDG)是导致复合材料结构失效破坏的重要原因之一。纤维桥联作为一种屏蔽机制对FDG有重要影响,导致FDG与载荷历程密切相关。如何实现纤维桥联作用下复合材料FDG的有效分析预测成为当前复合材料疲劳研究中需要解决的一个关键问题。为此,本文以不同纤维桥联强弱下的复合材料疲劳分层扩展试验为基础,提出了一种基于长短期记忆网络(LSTM)的机器学习模型,采用该模型能够对不同纤维桥联强弱下复合材料的FDG进行有效分析预测,预测结果在两倍误差带以内,为复合材料FDG行为的表征和预测提供了一种准确快速的方法。

关键词: 数据驱动; 疲劳分层扩展; 纤维桥联; 复合材料

中图分类号: V258

文献标识码: A

DOI: 10.19452/j.issn1007-5453.2025.05.005

碳纤维增强树脂基复合材料因其优异的力学性能和在结构减重方面的巨大潜力,已经广泛应用于航空航天领域^[1-2]。然而需要指出的是,复合材料层间力学性能较为薄弱,易于发生分层损伤和扩展。疲劳载荷作用下,分层损伤的发生和扩展将导致复合材料结构强度/刚度的逐渐退化,甚至会导致结构在服役过程中发生灾难性破坏^[3-4]。此外,美国联邦航空局(FAA)于2009年将民机复合材料结构的适航认证标准由“无裂纹扩展”修改为“缓慢的裂纹扩展”^[5];适航认证标准的这一重大修改,必然会对民机复合材料结构的设计、分析和验证产生深远影响。当前,我国民机复合材料结构设计依然沿用“无裂纹扩展”这一旧标准,这不利于充分发掘复合材料在结构轻量化方面的潜力,也不符合当前绿色航空、清洁航空的发展理念。因此,为了确保复合材料结构在长期服役过程中的完整性和安全性,迫切需要建立可靠的分析方法,实现复合材料疲劳分层扩展行为的高效准确预测。

以断裂力学为基础,可以通过建立疲劳裂纹扩展速率 da/dN 与应变能释放率(SERR) G 之间的相互关系(即Paris准则),实现复合材料疲劳分层扩展行为的分析表征。值得

注意的是,在基于Paris准则的疲劳分层扩展研究中,研究人员对基于SERR的相似性参数的具体表达形式并未达成共识^[6-8]。Khan等^[9]选择最大SERR G_{max} 和SERR幅值 ΔG 作为复合材料疲劳分层扩展行为的相似性参数,并提出了双参数形式的疲劳分层扩展准则。Gong Yu等^[10-11]尝试同时采用 G_{max} 和 ΔG 对不同应力比下的疲劳分层扩展行为进行分析表征,并获得了理想的结果。Jia Junhui等^[12]提出了基于SERR幅值 ΔG 和SERR均值 G_{mean} 的Paris准则,同样可以有效地考虑应力比对疲劳分层扩展的影响。Yao Liaojun等^[13]在Paris准则研究中,基于能量耗散分析和损伤机理分析,提出了有效应变能释放率幅值 ΔG_{eff} 的概念,实现了纤维桥联作用下复合材料疲劳分层扩展行为的有效描述。

在复合材料疲劳分层扩展过程中,可以观察到大量的桥联纤维,桥联纤维的出现对分层扩展存在重要影响^[14-17]。Yao Liaojun等^[18-19]对含有纤维桥联作用的复合材料疲劳分层扩展问题开展了系统深入的研究,发现纤维桥联对疲劳分层扩展存在显著抑制作用;随着纤维桥联作用的增强,对应的Paris疲劳分层扩展曲线在双对数坐标系中将逐渐向右平移,即桥联纤维的出现将导致复合材料疲劳分层扩展

收稿日期: 2024-09-12; 退修日期: 2024-12-26; 录用日期: 2025-02-19

基金项目: 航空科学基金(2022Z055077004); 强度与结构完整性全国重点实验室开放基金(ASSIKFJJ202302003)

引用格式: Wang Jiexiong, Li Xingfu, Pei Zhaodong, et al. Fatigue delamination prediction of composite laminates based on data-driven [J]. Aeronautical Science & Technology, 2025, 36(5): 44-50. 王杰雄, 李兴福, 裴兆东, 等. 基于数据驱动的复合材料层合板疲劳分层扩展研究[J]. 航空科学技术, 2025, 36(5): 44-50.

行为具有载荷历程相关性。Murri^[20]在研究中同样发现,纤维桥联对复合材料疲劳分层扩展存在显著的抑制作用。Khan等^[21]在研究中指出,纤维桥联对最大和最小疲劳载荷都有影响,但对应力比 R 似乎没有影响。Jensen等^[22]在研究中同样指出,纤维桥联将导致疲劳分层扩展行为呈现载荷历程相关性。上述文献均说明纤维桥联对FDG行为具有重要影响,因此,为了充分揭示复合材料的疲劳分层扩展规律,需要开发可靠的分析预测模型,并充分考虑纤维桥联的重要影响,最终实现复合材料疲劳分层扩展的有效分析预测。

近年来,人工智能等新技术迅猛发展^[23-24],数据驱动方法为解决复合材料疲劳损伤监测识别和疲劳寿命预测评估提供了新的研究思路。在疲劳裂纹扩展预测研究方面,Zhang Ke等^[25]使用深度信念网络(DBN)对铝合金的疲劳裂纹扩展行为进行了有效预测,其预测精度较传统Paris准则相比有所提高。Long Xiangyun等^[26]建立了一种新型的全局/局部双尺度卷积神经网络模型,可以实现疲劳加载过程中裂纹扩展长度和裂纹扩展速率的准确分析。Zhang Jianqiang等^[27]建立了一种基于神经网络的数据驱动方法,对铝合金在恒幅疲劳载荷下的裂纹扩展行为进行了有效分析。Allegri^[28]建立了基于极限学习机的数据驱动方法,成功预测了纤维增强树脂基复合材料的疲劳裂纹扩展速率。在寿命评估方面,Sai等^[29]提出了一种基于回归树集成的机器学习模型,对复合材料疲劳寿命进行了有效预测。Yang Jingye等^[30]使用6组不同材料的疲劳寿命数据,验证了神经网络模型在预测多轴疲劳寿命中的有效性。Zhang Xiaocheng等^[31]建立了一种基于深度学习的数据驱动方法,实现了疲劳、蠕变和蠕变-疲劳载荷条件下构件寿命的有效评估。Tao Chongcong等^[32]将数据驱动方法与内聚力模型相结合,提出了神经疲劳内聚力模型,并对纤维增强树脂基复合材料的疲劳损伤演化和疲劳寿命进行了良好的表征与预测。

综上所述,采用数据驱动方法,可以实现复合材料疲劳性能的有效分析和预测。为此,本文以不同纤维桥联强弱下的疲劳分层扩展试验数据为基础,结合数据驱动的理念,建立了基于LSTM的机器学习模型,实现了纤维桥联作用下复合材料疲劳分层扩展的有效分析和预测。

1 数据收集与处理

本文的数据来源于作者^[33]前期研究中已经发表的试验数据。疲劳分层扩展试验的应力比 $R=0.3$,分层扩展试验件

两个(试验件编号S-1和S-2),每个试件在不同疲劳分层扩展长度 $a-a_0$ (即不同纤维桥联强弱)条件下进行7次试验。试验件S-1获得疲劳分层扩展数据量为673组,试验件S-2获得疲劳分层扩展数据量为619组;每组数据中具体包含:疲劳分层扩展长度 $a-a_0$ 、疲劳循环次数 N 、最大/最小应变能释放率 $G_{\max/\min}$ 、应变能释放率幅值 $\Delta\sqrt{G}((\sqrt{G_{\max}}-\sqrt{G_{\min}})^2)$ 和疲劳裂纹扩展速率 da/dN 。

图1为采用Paris准则对纤维桥联作用下的复合材料疲劳分层扩展分析结果,见式(1)。可以看出,随着分层扩展长度的增加(即纤维桥联作用的增强),Paris疲劳分层扩展曲线将逐渐向右平移并最终收敛于一个窄的带状区域。研究表明,纤维桥联是导致复合材料疲劳分层扩展速率随分层扩展长度增加而下降的主要原因

$$\frac{da}{dN} = C\Delta\sqrt{G}^n = C\left[\left(\sqrt{G_{\max}} - \sqrt{G_{\min}}\right)^2\right]^n \quad (1)$$

式中, C 和 n 为曲线拟合参数。




图1 不同分层长度下对应的试验分析结果

Fig.1 Comparative experimental analysis results for varying layer thicknesses

2 数据驱动模型

为了充分考虑载荷历程对疲劳分层扩展的影响,本文采用长短期记忆网络(LSTM)建立机器学习模型。LSTM是深度学习中循环神经网络的一种变体,可以很好地考虑数据之间的时序性,与本文考虑载荷历程相关性的需求相符合。

LSTM具有输入层、隐藏层和输出层,该网络采用反向传播算法对权重参数进行更新。LSTM是由最基本的全连接神经网络(FCNN)演变而来,如图2所示。其中,FCNN每一次前向传播都是相互独立的,这使得 $T-\Delta T$ 时刻的输出信息不会对后续时刻的预测结果产生影响,即FCNN不能考虑时序效应。通过对FCNN进行改进,诞生了循环神经网络(RNN)。RNN的隐藏层在 $T-\Delta T$ 的输出信息不仅会传




图2 LSTM演变过程示意图

Fig.2 Schematic diagram of the evolution of LSTM

递给输出层,同时会传递给 T 时刻的隐藏层;因此, T 时刻的输入层信息和 $T-\Delta T$ 时刻的隐藏层信息都将被作为 T 时刻隐藏层对应的输入信息,使得RNN具有了短期记忆能力。为了使神经网络具有长期记忆能力,可以进一步在RNN中嵌入一个长期记忆层,用以存储/传递先前时刻的信息,扩展网络的长期记忆能力,由此衍生出了LSTM。

在LSTM中, $T-\Delta T$ 时刻隐藏层的输出信息不仅会传递给 $T-\Delta T$ 时刻的输出层和 T 时刻的隐藏层,同时还会传递给 $T-\Delta T$ 时刻的长期记忆层;随着时间的增加,之前的所有信息都会被适当地存储于长期记忆层当中,并被用于当前 T 时刻的预测。

此外,在LSTM中,为了进一步提高预测效率,分别设置了遗忘门、输入门和输出门。遗忘门的作用是选择性地遗忘某些不重要的历史信息;输入门的作用是加强对某些重要历史信息的记忆;输出门的作用是整合信息并生成输出结果。这样处理可以显著减少噪声信息对预测结果的干扰,提高LSTM对时序数据预测的准确性。遗忘门、输入门、输出门以及最终输出的表达形式如下。

遗忘门

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (2)$$

输入门

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (3)$$

$$\tilde{C} = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c) \quad (4)$$

输出门

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad (5)$$

最终输出

$$C_t = f_t \otimes C_{t-1} + i_t \otimes \tilde{C} \quad (6)$$

$$h_t = o_t \otimes \tanh(C_t) \quad (7)$$

式中, f_t 为遗忘门的输出,表示遗忘的比例,其取值为0~1,1表示完全保留,0表示完全丢弃; i_t 为输入门的输出,其作用为决定当前输入信息的比例; $\tilde{C}$ 为当前时刻的候选细胞状态,表示可用来更新细胞状态的潜在信息; o_t 为输出门的输出,其取值范围为0~1; C_t 为长期记忆的信息; h_t 为输出到网络的下一层或者最终的预测结果。 h_{t-1} 和 x_t 为上一时刻的传递结果和下一时刻的样本; W_f 、 W_i 、 W_c 和 W_o 分别为三个门所需的权重参数矩阵; b_f 、 b_i 、 b_c 和 b_o 分别为三个门所需的偏置参数矢量; $\sigma(x)$ 为sigmoid激活函数,如式(8)所示; $\tanh(x)$ 为tanh激活函数,如式(9)所示; $\otimes$ 表示逐元素相乘

$$\sigma(x) = \frac{1}{1 + e^{-x}} \quad (8)$$

$$\tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (9)$$

综上所述,由于LSTM同时具有短期和长期记忆能力,使其适用于时序性问题的分析和预测,可以用于纤维桥联作用下复合材料疲劳分层扩展问题研究。

3 纤维桥联作用下疲劳分层扩展预测

3.1 数据预处理

对原始数据进行归一化预处理可以提高学习过程的效率和模型的预测能力。疲劳裂纹扩展速率的试验测试结果量级为 10^{-i} ($i=6\sim9$),不同数据之间的量级相差很大;为了降低数据量级对机器学习预测结果的影响,参照参考文献[30],先将数量级为 10^{-i} 的数据乘以 10^i 之后,再进行Min-

Max方法归一化处理。Min-Max归一化方法如下

$$x^* = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (10)$$

式中, x^* 、 x 、 $x_{\min}$ 和 $x_{\max}$ 分别为归一化后的样本值、数据样本值、样本中的最小值和最大值。

3.2 数据分配和模型设置

预处理后的数据被划分为训练集、验证集和预测集。本文试验件S-1的所有疲劳分层扩展数据被用于模型训练和验证,训练集与验证集的数据比例为8:2;试验件S-2的疲劳分层扩展数据被用于预测。本文共开展了试验件S-2在不同纤维桥联强弱下7个阶段的数据驱动预测,即以试验件S-1所有阶段(各阶段对应不同纤维桥联强弱下的疲劳分层扩展)的数据来训练机器学习模型,进而分别预测试验件S-2每一个阶段的疲劳裂纹扩展速率,预测矩阵如图3所示。




图3 数据驱动预测矩阵

Fig.3 Data-driven prediction matrix

合理的特征选取对于机器学习模型的建立至关重要。综合考虑纤维桥联和疲劳载荷对FDG的影响,本文选取最大SERR $G_{\max}$ 和SERR幅值 $\Delta\sqrt{G}$ 作为特征参数对疲劳载荷进行描述;选取疲劳裂纹扩展长度 $a-a_0$ 对纤维桥联强弱进行描述。因此,选择 $G_{\max}$ 、 $\Delta\sqrt{G}$ 和 $a-a_0$ 作为输入特征,选择疲劳裂纹扩展速率 da/dN 作为预测标签。

此外,超参数在训练数据驱动模型中同样起着重要的作用^[34]。LSTM的主要超参数包括网络层数、每层神经元个数、激活函数和学习率等。对于网络层数,作者在研究中发现,LSTM对计算资源消耗较大,参考已有研究^[35-36],学者们通常采用较少的LSTM层数进行模型训练;特别需要指出的是,Kang Guozheng等仅采用一个LSTM层和一个FCNN层便获得了较好的预测结果。因此,本文在试错法的基础之上,最终选取两个LSTM层和一个FCNN层建立数据驱动模型。对于每层所包含的神经元个数选取,本文开展了不同神经元个数下的预测结果对比分析,如图4所示。可以看出,将LSTM层的神经元个数分别设置为64和




图4 LSTM层神经元个数对预测结果的影响

Fig.4 Impact of the number of neurons in the LSTM layer on prediction results

32时,对应的预测误差最小(平均绝对百分比误差计算见式(11))。LSTM对应的激活函数选取为Sigmoid和Tanh。参考文献[30],FCNN激活函数选取为ReLU,见式(12)),学习率设置为0.0005~0.001。超参数的选取见表1。

$$\text{MAPE} = \frac{1}{n} \sum_{i=1}^n \left| \frac{\hat{y}_i - y_i}{y_i} \right| \times 100\% \quad (11)$$

式中, n 为样本的个数, $\hat{y}_i$ 为预测值, y_i 为真实值。

$$\text{ReLU}(x) = \max(0, x) \quad (12)$$

表1 超参数选取

Table 1 Value of hyperparameters

超参数项	数值
网络总层数	3
LSTM层数	2
FCNN层数	1
每层神经元个数	64, 32, 1
LSTM激活函数	Sigmoid, Tanh
FCNN激活函数	ReLU
学习率	0.0005~0.001

3.3 预测结果

采用本文建立的基于LSTM的机器学习模型,对不同纤维桥联强弱下复合材料疲劳分层扩展的预测结果如图5所示。图5中紫色区域表示两倍误差带,红色区域表示三倍误差带。可以看出,不同纤维桥联强弱下,采用本文所建立的机器学习模型的预测结果基本位于两倍误差带以内。这充分说明本文所提出的机器学习模型可以有效地考虑复




图5 试件S-2的FDG预测结果

Fig.5 FDG predicted results of S-2

合材料疲劳分层扩展行为的载荷历程相关性,实现不同纤维桥联强弱下疲劳分层扩展行为的有效分析和预测。

4 结论

本文基于之前作者开展的复合材料FDG试验,结合传统Paris疲劳分层扩展准则,分析了纤维桥联作用下复合材

料的FDG行为,明确了纤维桥联对FDG的影响规律;以此为基础,提出了一种基于LSTM的数据驱动方法来表征和预测纤维桥联作用下的复合材料FDG行为。通过研究,得到以下结论:

(1)基于传统Paris准则的复合材料疲劳分层扩展分析结果表明,纤维桥联作用下的FDG行为具有明显的载荷历程相关性。纤维桥联的存在是导致这种相关性的主要原因。因此,在FDG预测过程中考虑到这种相关性是至关重要的。

(2)采用基于LSTM的数据驱动方法,能够有效地考虑纤维桥联对复合材料FDG的影响,即载荷历程相关性,实现FDG行为的准确预测。预测结果位于两倍误差带以内,具有良好的预测精度,能够满足复合材料结构设计与分析的需求。

AST

参考文献

- [1] 冯志海,李俊宁,田跃龙,等. 航天先进复合材料研究进展[J]. 复合材料学报, 2022, 39(9): 4187-4195.
Feng Zhihai, Li Junning, Tian Yuelong, et al. Research progress of advanced composite materials for aerospace applications [J]. Acta Materiae Compositae Sinica, 2022, 39 (9): 4187-4195.(in Chinese)
- [2] 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.(in Chinese)
- [3] Kashtalyan M, Soutis C. The effect of delaminations induced by transverse cracks and splits on stiffness properties of composite laminates [J]. Composites Part A: Applied Science and Manufacturing, 2000, 31: 107-119.
- [4] Bak B L V, Sarrado C, Turon A, et al. Delamination under fatigue loads in composite laminates: A review on the observed phenomenology and computational methods [J]. Applied Mechanics Reviews, 2014, 66: 060803.
- [5] AC 20-107B. Composite aircraft structure[S]. Federal Aviation Administration, 2009.
- [6] Donough M J, Gunnion A J, Orifici A C, et al. Scaling parameter for fatigue delamination growth in composites under varying load ratios [J]. Composites Science and Technology, 2015, 120: 39-48.

- [7] Rans C, Alderliesten R, Benedictus R. Misinterpreting the results: How similitude can improve our understanding of fatigue delamination growth [J]. *Composites Science and Technology*, 2011, 71: 230-238.
- [8] Atodaria D R, Putatunda S K, Mallick P K. Delamination growth behavior of a fabric reinforced laminated composite under mode I fatigue [J]. *Journal of Engineering Materials and Technology*, 1999, 121(3): 381-385.
- [9] Khan R, Rans C D, Benedictus R. Effect of stress ratio on delamination growth behavior in unidirectional carbon/epoxy under mode I fatigue loading [C]. *International Committee on Composite Materials (ICCM)*, 2009.
- [10] Gong Yu, Zhao Libin, Zhang Jianyu, et al. Crack closure in the fatigue delamination of composite multidirectional DCB laminates with large-scale fiber bridging [J]. *Composite Structures*, 2020, 244: 112220.
- [11] Gong Yu, Li Wangchang, Liu Hao, et al. A novel understanding of the normalized fatigue delamination model for composite multidirectional laminates [J]. *Composite Structures*, 2019, 229: 111395.
- [12] Jia Junhui, Julio F D. Study of load ratio for mode-I fatigue fracture of wood-FRP-bonded interfaces [J]. *Journal of Composite Materials*, 2004, 38: 1211-1230.
- [13] Yao Liaojun, Sun Yi, Guo Licheng, et al. A modified Paris relation for fatigue delamination with fibre bridging in composite laminates [J]. *Composite Structures*, 2017, 176: 556-564.
- [14] Sorensen B F, Jacobsen T K. Large-scale bridging in composites: R-curves and bridging laws [J]. *Composites Part A: Applied Science and Manufacturing*, 1998, 29: 1443-1451.
- [15] Jensen S M, Bak B L V, Bender J J, et al. Transient delamination growth in GFRP laminates with fibre bridging under variable amplitude loading in G-control [J]. *Composites Part B: Engineering*, 2021, 225: 109296.
- [16] Ghadirdokht A, Heidari-Rarani M. Delamination R-curve behavior of cured composite laminates [J]. *Composites Part B: Engineering*, 2019, 175: 107139.
- [17] Khan R. Fiber bridging in composite laminates: A literature review [J]. *Composite Structures*, 2019, 229: 111418.
- [18] Yao Liaojun, Sun Yi, Guo Licheng, et al. Mode I fatigue delamination growth with fibre bridging in multidirectional composite laminates [J]. *Engineering Fracture Mechanics*, 2018, 189: 221-231.
- [19] Yao Liaojun, Alderliesten R C, Jones R, et al. Delamination fatigue growth in polymer-matrix fibre composites: A methodology for determining the design and lifing allowables [J]. *Composite Structures*, 2018, 196: 8-20.
- [20] Murri G B. Effect of data reduction and fiber-bridging on Mode I delamination characterization of unidirectional composites [J]. *Journal of Composite Materials*, 2014, 48: 2413-2424.
- [21] Khan R, Alderliesten R, Badshah S, et al. Effect of stress ratio or mean stress on fatigue delamination growth in composites: Critical review [J]. *Composite Structures*, 2015, 124: 214-227.
- [22] Jensen S M, Bak B L V, Bender J J, et al. Transition-behaviours in fatigue-driven delamination of GFRP laminates following step changes in block amplitude loading [J]. *International Journal of Fatigue*, 2021, 144: 106045.
- [23] 何晓晓, 姚呈康. 人工智能等新技术在航空训练中的应用研究 [J]. *航空科学技术*, 2020, 31(10): 7-11.
- He Xiaoxiao, Yao Chengkang. Analysis of artificial intelligence and other new technologies in aviation training [J]. *Aeronautical Science & Technology*, 2020, 31(10): 7-11. (in Chinese)
- [24] 陈鹏鹏, 王若, 邢晨光, 等. 基于显著图数据增强的飞行器识别与检测算法 [J]. *航空科学技术*, 2023, 34(11): 118-124.
- Chen Pengpeng, Wang Ruo, Xing Chenguang, et al. Data augmentation method based on saliency map for aircraft identification and detection technology [J]. *Aeronautical Science & Technology*, 2023, 34(11): 118-124. (in Chinese)
- [25] Zhang Ke, Fan Caizi, Li Songhua, et al. Fitting and prediction for fatigue crack propagation of 7N01 aluminum alloy after long-term service based on deep belief network [J]. *Engineering Fracture Mechanics*, 2021, 258: 107980.
- [26] Long Xiangyun, Yu Mengchen, Liao Wangwang, et al. A deep learning-based fatigue crack growth rate measurement method using mobile phones [J]. *International Journal of Fatigue*, 2023, 167: 107327.
- [27] Zhang Jianqiang, Zhu Jiakai, Guo Wei, et al. A machine learning-based approach to predict the fatigue life of three-

- dimensional cracked specimens [J]. *International Journal of Fatigue*, 2022, 159: 106808.
- [28] Allegri G. Modelling fatigue delamination growth in fibre-reinforced composites: Power-law equations or artificial neural networks? [J]. *Materials and Design*, 2018, 155: 59-70.
- [29] Sai W, Chai G B, Srikanth N. Fatigue Life Prediction of GLARE Composites Using Regression Tree Ensemble-Based Machine Learning Model [J]. *Advanced Theory and Simulations*, 2020, 3: 1-11.
- [30] Yang Jingye, Kang Guozheng, Liu Yujie, et al. A novel method of multiaxial fatigue life prediction based on deep learning [J]. *International Journal of Fatigue*, 2021, 151: 106356.
- [31] Zhang Xiaocheng, Gong Jianguo, Xuan Fuzhen. A deep learning based life prediction method for components under creep, fatigue and creep-fatigue conditions [J]. *International Journal of Fatigue*, 2021, 148: 106236.
- [32] Tao Chongcong, Zhang Chao, Ji Hongli, et al. A Paris-law-informed neural fatigue cohesive model and its application to open-hole composite laminates [J]. *International Journal of Solids and Structures*, 2023, 267: 112158.
- [33] Yao Liaojun, Chuai Mingyue, Lyu Zhangming, et al. A proposal for similitude in characterizing fatigue delamination behavior with fibre bridging of carbon-fibre reinforced polymer composites [J]. *Engineering Fracture Mechanics*, 2024, 295: 109756.
- [34] Jin H. Hyperparameter Importance for Machine Learning Algorithms [J]. *ArXiv*, 2022, 2201.
- [35] Wang Junxia, Zheng Yuanjie, Luo Rong, et al. Prediction Method of Three-Dimensional Crack Propagation Path Based on Deep Learning Application [J]. *Advanced Engineering Materials*, 2021, 23(4): 2001043.
- [36] Mozaffar M, Bostanabad R, Chen W, et al. Deep learning predicts path-dependent plasticity [J]. *Proceedings of the National Academy of Sciences of the United States of America*, 2019, 116(52): 26414-26420.

Fatigue Delamination Prediction of Composite Laminates Based on Data-Driven

Wang Jiexiong¹, Li Xingfu², Pei Zhaodong¹, Yao Liaojun¹, Guo Licheng¹

1. Harbin Institute of Technology, Harbin 150001, China

2. AVIC Xi'an Aircraft Industry (Group) Company Ltd., Xi'an 710089, China

Abstract: Fatigue delamination growth (FDG) is one of the most important reasons for the failure of composite structures. Fiber bridging, as a shielding mechanism, can have significant retardation effects on FDG behavior, contributing to loading-history dependence on FDG. How to analyze and predict FDG effectively in composites with fiber bridging has become a key problem to be solved in the current composite fatigue field. In this study, a machine learning model, based on the long short-term memory (LSTM) network, is proposed for fiber-bridged fatigue delamination determination under FDG testing with different fiber bridging. The results clearly demonstrate that fatigue delamination behavior can be well represented via this machine learning model, as all predictions almost fall within the 2 times error band, which provides an accurate and fast method for characterization and prediction of FDG behavior in composites.

Key Words: data driven; FDG; fiber bridging; composites

Received: 2024-09-12; **Revised:** 2024-12-26; **Accepted:** 2025-02-19

Foundation item: Aeronautical Science Foundation of China (2022Z055077004); National Key Laboratory of Strength and Structural Integrity Science Foundation (ASSIKFJJ202302003)