

小样本下基于数据衍生与混合神经网络的7050铝合金高周疲劳强度预测

赵德望¹, 徐雨帆¹, 杨文平², 赵延广³, 樊俊铃⁴

(1. 安徽理工大学 机电工程学院, 安徽 淮南 232000; 2. 哈尔滨工程大学 航空航天学院, 黑龙江 哈尔滨 150001; 3. 大连理工大学 力学与航空航天学院, 辽宁 大连 116000; 4. 中国飞机强度研究所 强度与结构完整性全国重点实验室, 陕西 西安 710065)

摘要:针对7050铝合金高周疲劳试验周期长、成本高,且传统模型在小样本条件下预测精度低、高周外推鲁棒性差的问题,本文开展了5种不同应力比与应力集中系数工况的全寿命疲劳试验,获取了材料基础疲劳性能数据。提出一种融合浅层神经网络数据衍生与ANN+CNN-GRU-Attention混合网络的小样本疲劳强度预测方法,引入含物理先验的趋势感知损失函数抑制外推失稳,设计滑动时间窗增量迭代训练策略实现向 10^7 次循环的逐步外推。结果表明:模型有效克服了长短期记忆模型在外推阶段的预测失稳问题,预测精度较单次全量训练提升13.56%;增量迭代训练使5种工况疲劳强度预测平均偏差降至5.29%,在本文工况下表现出良好的工程适用性。本文方法可缩短材料高周疲劳性能试验周期,为航空铝合金疲劳性能快速评估提供了一种可行的数据驱动技术途径。

关键词:7050铝合金;高周疲劳;疲劳强度;小样本预测;数据衍生;混合神经网络;增量迭代训练;数据驱动

DOI:10.11990/jheu.20260612013

网络出版地址:<https://link.cnki.net/urlid/23.1390.U.XXXXXXXX.XXXX.XXX>

中图分类号:TB114.3;TG146.22;TP183 **文献标志码:**A **文章编号:**1006-7043(XXXX)XX-0001-14

High-cycle fatigue strength prediction for 7050 aluminum alloy using data augmentation and hybrid neural network in small sample scenarios

ZHAO Dewang¹, XU Yufan¹, YANG Wenping², ZHAO Yanguang³, Junling⁴

(1. School of Mechatronics Engineering, Anhui University of Science& Technology, Huainan 232000, China; 2. College of Aerospace Engineering, Harbin Engineering University, Harbin 150001, China; 3. School of Mechanics and Aerospace Engineering, Dalian University of Technology, Dalian 116000, China; 4. Aircraft Strength Research Institute of China, Xi'an 710065, China)

Abstract: To address the problems of long cycle time and high cost in high-cycle fatigue testing of 7050 aluminum alloy, as well as the low prediction accuracy and poor high-cycle extrapolation robustness of traditional models under small-sample conditions, full-life fatigue tests under five different stress ratios and stress concentration factor conditions were carried out to obtain the basic fatigue performance data of the material. A small-sample fatigue strength prediction method combining shallow neural network-based data augmentation and an ANN+CNN-GRU-Attention hybrid network was proposed. A trend loss function with physical priors was introduced to suppress extrapolation instability, and a sliding-window incremental iterative training strategy was designed to achieve gradual extrapolation to 10^7 cycles. The results show that the proposed model effectively overcomes the prediction instability problem of the LSTM model during the extrapolation stage, and the prediction accuracy is improved by 13.56 percentage points compared with single full-batch training. The incremental iterative training reduces the average deviation of fatigue strength prediction under the five working conditions to 5.29%, demonstrating good engineering applicability under the conditions investigated in this study. The proposed method can reduce the high-cycle fatigue testing duration and provides a feasible data-driven technical approach for the rapid evaluation of fatigue performance of aviation aluminum alloys.

Keywords: 7050 aluminum alloy; high-cycle fatigue; fa-

收稿日期:2026-06-12

基金项目:国家自然科学基金青年基金(C类)项目(12502084);安徽省自然科学基金项目(2308085ME166);安徽省高校科学研究重点项目(KJ2021A0417);中国博士后基金项目(2020M680947)。

作者简介:赵德望,男,副教授,博士;;
杨文平,男,副教授,博士。

通信作者:杨文平,E-mail: yangwenping@hrbeu.edu.cn.

tigue strength; small sample prediction; data augmentation; hybrid neural network; incremental iterative training; data-driven

疲劳失效是工程结构最主要的失效形式,80%以上的机械结构失效均与疲劳损伤直接相关^[1]。尤其在航空航天领域,关键承力构件的疲劳断裂会造成灾难性后果,是制约飞行器安全性与服役寿命的核心瓶颈。7050铝合金凭借高比强度、优异耐腐蚀性与加工性能广泛应用于飞机机身、机翼等核心构件^[2,3]。然而,传统高周疲劳试验周期长、成本高昂,是制约新材料疲劳性能评估与工程应用的关键技术难题。因此,开展7050铝合金高周疲劳强度的高效、精准预测研究,对于缩短材料研发周期、降低试验成本、保障航空结构安全服役具有重要的工程价值与现实意义。

目前,疲劳寿命预测多依赖 Manson-Coffin 方程、Morrow 修正模型及 Smith-Watson-Topper (SWT) 模型等经典模型与半物理模型^[4-6]。这类方法基于唯象损伤理论建立,在低周疲劳、单一稳定加载工况下具有较好的适用性,但难以准确描述7050铝合金受材料微观组织、表面加工状态、应力集中、环境介质等多因素强耦合作用下的复杂非线性疲劳演化行为。其固有缺陷主要体现在3个方面:1)参数标定繁琐,需要通过大量全工况试验获取材料常数,且参数仅适用于特定热处理状态与加载条件;2)工况适应性差,当应力比、应力集中系数等关键工况参数发生变化时,预测精度会显著下降;3)高周外推能力不足,尤其在 10^7 次循环的高周疲劳区间,由于损伤演化机制从塑性累积主导转变为裂纹萌生扩展主导,传统模型的外推误差往往超过工程允许范围,无法满足航空航天领域对7050铝合金构件全工况、高精度、快速疲劳性能评估的迫切需求。

近年来,机器学习作为强大的数据驱动方法,能够从试验数据中自主学习复杂的非线性映射关系,有效突破了传统物理模型对多因素耦合疲劳行为描述能力不足的瓶颈,相较于传统方法具备更强的工况适应性与预测能力,广泛应用于金属材料疲劳寿命预测领域^[7]。Heng等^[8]构建了CNN-LSTM混合神经网络,实现了金属材料多轴疲劳寿命的高精度预测;Wang等^[9]建立了基于遗传算法优化的BP神经网络模型,完成了钛合金结构件低周疲劳寿命的高效预测;Zhan等^[10]融合损伤力学疲劳模型与随机森林算法,提出了增材制造钛合金疲劳寿命的数据驱动预测方法;Jing等^[11]采用多尺度深度残差网络,实现了飞机结构疲劳裂纹扩展的精准监测;Liao等^[12]构建自适应物理信息神经网络,完成了多轴疲劳寿命的精准预测;Zhang等^[13]采用长短期记忆神经网络,

实现了航空TC4钛合金缺口件断裂性能的精准预测。但目前仍未能解决疲劳预测领域小数据样本与模型泛化能力的核心矛盾:由于疲劳试验成本高、周期长,可用训练样本稀缺,深度学习模型易发生过拟合;同时,现有模型多基于全量数据一次性训练,缺乏对超长跨度疲劳损伤演化规律的分步学习机制,导致高周区间外推能力差、工况适配性不足,无法实现小样本条件下7050铝合金高周疲劳强度的精准预测。

本文以航空常用7050铝合金为研究对象,开展5种不同应力比与应力集中系数工况下的疲劳试验,获取材料全寿命周期疲劳性能数据并拟合标准S-N曲线;在此基础上,针对小样本高周疲劳预测的核心难题,提出一种基于浅层神经网络数据衍生与ANN+CNN-GRU-Attention的混合神经网络预测方法,并设计增量迭代训练策略,充分利用低中周获取试验数据实现样本扩充与分步学习,解决小样本条件下高周疲劳预测精度不足、预测序列失稳等问题,实现材料高周疲劳强度的可靠预测。本文研究旨在为新型金属材料疲劳性能的低成本、快速评估提供一种有效的数据驱动技术方案,同时为航空铝合金构件的疲劳设计与寿命校核提供参考。

1 7050 铝合金疲劳试验

1.1 材料表征

本试验所用材料为7050铝合金,供货热处理状态为T7541态。该状态为拉伸消除应力后人工时效处理,广泛应用于航空承力构件,可使合金兼顾强度、断裂韧性与抗应力腐蚀性能。其主要化学成分质量分数(%)为:Zn: 6.2, Cu: 2.1, Mg: 2.0, Zr: 0.1, Cr: 0.02, Si: 0.1, Fe: 0.08, Mn: 0.06, Ti: 0.02,其余为Al。材料的室温基本力学性能为:屈服强度469 MPa,抗拉强度524 MPa,弹性模量70.3 GPa,伸长率11.6%。

1.2 试验设备与试样

依据GB/T 3075-2008《金属材料 疲劳试验 轴向力控制方法》^[14],通过QBG-50型电磁谐振式高频疲劳试验机(如图1所示)开展疲劳试验,采用正弦波形等幅载荷谱,试验温度为20℃。疲劳试验机的最大载荷为 ± 100 kN,工作频率范围为60~300 Hz。

试验所用7050铝合金试样由北京航空材料研究所(中国航空工业集团子公司)提供,所有试样均按照标准要求进行加工处理。试样分为2类:1)标准光滑平板试样,2)两侧缺口平板试样(应力集中系

数为3)。试样几何尺寸如图2所示。




图1 QBG-50电磁谐振高频疲劳试验机
Fig. 1 QBG-50 electromagnetic resonance high-frequency fatigue testing machine




图2 标准和缺口平板试样几何尺寸
Fig. 2 Geometric dimensions of standard and notched flat plate specimens

1.3 工况设置与试验方法

本文设置5种工况开展7050铝合金轴向等幅疲劳试验,系统考察应力比与应力集中系数对材料高周疲劳性能的影响。具体工况如表1所示。

表1 疲劳工况设置 Table 1 Fatigue condition settings			
工况	温度/℃	应力比R	应力集中系数K _t
1	20	0.06	3
2	20	0.06	1
3	20	-1	3
4	20	-1	1
5	20	0.5	3

疲劳试验采用分级加载方案,根据寿命区间分别采用成组法与升降法:

中短寿命区($N < 10^7$):采用成组法^[15],设置4—6级应力水平,每级应力水平至少3—5根试样,用于获取S-N曲线的下降段数据;

高周疲劳强度区($N = 10^7$):采用升降法^[16]测定材料条件疲劳强度,为保证统计显著性,每组升降法

试验所用试样数不少于10个,具体试验流程参照相关标准执行^[16]。

试验数据按以下步骤进行标准化处理:

1)成组法对数寿命计算。

50%存活率下的对数疲劳寿命 $\lg N_{50}$ 计算公式为

$$\bar{X} = \lg N_{50} = \frac{1}{n} \lg N_i \tag{1}$$

式中: N_i 为第*i*个试样的实测疲劳寿命; n 为该应力水平下的有效试样数。

2)S-N曲线拟合。

采用三参数幂函数模型拟合S-N曲线,拟合有效范围为最小对数平均寿命至疲劳强度对应的循环次数区间

$$\lg N = A + B \lg (\sigma_{max} - C) \tag{2}$$

式中: A 、 B 、 C 为材料在特定工况下的拟合常数,其取值受应力比、应力集中系数影响。

3)条件疲劳强度计算。

10^7 次循环对应的条件疲劳强度 $\sigma_{R(10^7)}$ 计算公式为^[17]

$$\sigma_{R(10^7)} = \frac{1}{m} \sum_{i=1}^n V_i \sigma_i \tag{3}$$

式中: m 为有效试验总数; n 为升降法试验的应力水平数; σ_i 为第*i*级应力水平; V_i 为第*i*级应力水平下的有效试验次数。

2 7050铝合金疲劳试验结果

通过1.3节数据处理方法,得到5种工况1—5不同批次7050铝合金的平均疲劳强度分别为:122、272.5、75.4、153.4、170.7 MPa。

5种工况下的疲劳试验数据与拟合S-N曲线如图3所示,可以看出,试验数据点整体分布规律一致,均呈现出随着循环次数增加,最大应力逐渐降低并趋于稳定的典型高周疲劳特征。

图4—8给出了本次疲劳试验中典型试样表面裂纹萌生及扩展特征结果。通过对比不同试样构型及不同应力比条件下的扩展趋势,结合图3,可得出如下规律:

缺口试样的缺口使裂纹定点萌生于缺口根部,沿垂直载荷方向向内扩展。 $R=-1$ 时,条件疲劳强度最低,但应力范围最大,裂尖驱动力最强,压缩半循环引起的裂纹闭合效应也最显著。高应力下,裂纹快速扩展并贯穿试样表面,路径呈不规则锯齿状,边缘粗糙并伴随明显挤压研磨痕迹;中等应力下,裂纹稳定延伸至中等长度,路径波浪状弯曲,边缘因循环闭合咬合而钝化;低应力下,仅在缺口根部萌生极短

初始微裂纹,扩展显著放缓甚至停滞,呈现典型的非扩展裂纹特征。 $R=0.06$ 时,条件疲劳强度与应力范围居中,裂纹面基本不闭合。高应力下,裂纹向内延伸较长,路径整体平直、仅局部轻微起伏,无挤压磨损;中等应力下,裂纹平稳扩展至中等长度,形貌均匀连续;低应力下,缺口根部仅见微观损伤,无宏观扩展裂纹。 $R=0.5$ 时,条件疲劳强度最高,应力范围最小,驱动力波动最弱,裂纹几乎全程张开。高应力下,双侧缺口同步萌生并向内扩展,但整体长度较短,路径平直规整、边缘锐利、表面光洁无磨痕;中等应力下,单侧裂纹延伸有限,表面光亮均匀,无偏转与磨损;低应力下,试样表面无宏观疲劳裂纹,保持原始加工状态。




图3 7050 铝合金 5 种工况下疲劳试验数据及 S-N 曲线
Fig. 3 Fatigue test data and S-N curves for 7050 aluminum alloy under 5 different conditions

对于平滑试样,裂纹随机萌生于表面加工缺陷处,起裂位置分散,应力比与应力水平的调控更为直接。 $R=-1$ 时,应力范围最大,表面微损伤易累积。高应力下,裂纹快速萌生并贯穿试样表面,路径规整度较低,存在挤压错动与摩擦磨损;中等应力下,主裂纹垂直载荷扩展,局部路径出现偏转抖动,周边表面因循环咬合而粗糙化;低应力下,仅形成短尺度表面微裂纹,边缘钝化毛糙,扩展受闭合效应显著抑制。 $R=0.06$ 时,接近脉动拉伸:应力范围居中,萌生门槛较高。高应力下,裂纹沿垂直载荷方向平直扩展至贯穿,路径规整、无挤压磨损;中等应力下,裂纹路径平直锐利、连续稳定、表面干净;低应力下,仅萌生极浅表面微裂纹,边缘清晰锐利,无闭合钝化。

缺口与平滑试样在同等应力比下,缺口试样因应力集中而条件疲劳强度显著降低,裂纹定点萌生于缺口根部;平滑试样裂纹萌生位置分散、萌生门槛更高,条件疲劳强度明显提升。应力比对 2 种试样的调控规律一致:应力范围控制裂纹扩展速率与损伤程度,应力比越低,对应疲劳强度下应力范围越大、驱动力越强、扩展路径越粗糙;应力比越高,路径越平直光洁。

综上,加载应力水平直接决定表面宏观裂纹的损伤程度与延伸长度;应力比通过应力范围调控扩展行为与路径形貌;应力集中通过降低萌生门槛与定点起裂,改变起裂特征并劣化疲劳性能。




图4 工况 1 试样结果
Fig. 4 Condition 1 test results

上述基于传统高周疲劳试验获取 7050 铝合金 S-N 曲线历时近一年,且试验周期与成本随工况数增加而呈指数增长。为此,本文基于易获取的中短寿命疲劳数据,采用深度学习方法构建小样本高周疲劳强度预测模型,以实现材料疲劳性能的快速、低成本评估。本文后续模型训练与评价所用数据均来源于前述疲劳试验,其分工原则如下:循环次数低于

5×10^5 周的实测数据用于浅层ANN训练;高于 5×10^5 周的实测数据(含升降法测得的条件疲劳强度)全程不参与模型训练,仅作为最终评价的独立真值,以确保训练集与评价集的严格隔离。在模型评价环节,所有预测误差的量化指标,均以第2节所列升降法独立实测疲劳强度为唯一计算基准;S-N拟合曲线仅用于辅助判断预测趋势与疲劳演化规律的一致性,其数值不参与任何误差统计与精度计算。




图5 工况2试样结果

Fig. 5 Condition 2 test results




图6 工况3试样结果

Fig. 6 Condition 3 test results

3 基于浅层神经网络的数据衍生

为支撑后续混合神经网络的迭代训练,本文采用浅层人工神经网络(artificial neural network, ANN)开展限定区间的数据衍生,依托已有实测中短寿命试验数据实现密采样补充,为后续混合神经网络迭代训练提供数据基础。

万能逼近定理表明,浅层ANN具备拟合任意非线性映射的能力,可依托离散试验测点插值生成连续S-N数据^[18]。本文以应力比、应力集中系数、循环次数作为模型输入特征,以对应最大疲劳应力作为

输出,依托5种工况的实测试验数据开展网络训练。




图7 工况4试样结果

Fig. 7 Condition 4 Test results




图8 工况5试样结果

Fig. 8 Condition 5 test results

将循环寿命划分为低周(10^3 — 10^5 周)与高周(10^5 — 10^7 周)区间,设定采样步长为1000次循环;理想状态下全寿命区间(3×10^4 — 10^7 周)共可生成9971组等间隔数据。受原始样本分布约束,浅层ANN仅在训练数据覆盖的低周区间具备可靠插值能力,高周区间无试验数据约束、外推泛化效果差,因此需要划分有效衍生边界。

基于现有疲劳试验数据,验证浅层神经网络在该数据条件下的拟合能力,具体方法可参考文献[19]。

搭建双隐层浅层全连接神经网络,网络拓扑如图9所示:输入层包含3个输入神经元(应力比、应力集中系数、循环次数),2层隐藏层各设置17个神经元,输出层为单神经元(最大应力)。模型选用Trainlm(L-M)优化算法^[20]、均方误差MSE作为损失函数,设置学习率0.01,最大迭代次数200,收敛目标误差0.1;训练集选用各工况下循环次数小于 5×10^5 周的实测试验数据,完成网络参数优化。




图9 浅层神经网络结构拓扑图


Fig. 9 Topological diagram of the shallow neural network

采用训练完成的浅层 ANN 直接对 $3 \times 10^4 \sim 10^7$ 周全寿命区间进行全域预测,所得预测曲线与各工况实测 S-N 曲线对比如图 10 所示。结果表明:


1) 循环次数小于 5×10^5 周时,ANN 预测曲线与试验拟合 S-N 曲线重合度高,数据衍生精度满足使用要求;

2) 循环次数大于 5×10^5 周时,脱离训练数据约束的 ANN 预测结果严重偏离真实 S-N 变化趋势,出现应力数值异常畸变,泛化失效。


产生上述现象的本质原因是:原始训练样本全部集中在 5×10^5 周以内,缺少高周损伤演化规律约束,浅层网络无法学习长周期疲劳非线性演化特征,无法直接实现全寿命范围的数据扩充。




(a) 工况 1




(b) 工况 2



(c) 工况 3



(d) 工况 4



(e) 工况 5


图10 浅层神经网络衍生数据结果与试验 S-N 曲线对比

Fig. 10 Comparison between generalization data results of the shallow neural network and experimental S-N curves


基于上述研究,限定 ANN 有效数据衍生区间为 $3 \times 10^4 \sim 5 \times 10^5$ 周,在该区间内做等间隔密采样生成衍生数据,各工况衍生样本共计 471 组,组合得到全工况初始衍生数据集,衍生曲线与试验 S-N 对比如图 11。可以看出,限定区间内 ANN 衍生数据能够精准复现实测 S-N 变化规律,离散试验测点被转化为连续密集样本。此过程仅在数学层面实现测点加密,471 组衍生数据本质上是三参数幂函数 S-N 模型在 $3 \times 10^4 \sim 5 \times 10^5$ 周区间内的高密度插值表达,并未引入新的物理信息。在不额外补充疲劳试样的前提下,该衍生数据集完成了小样本向时序训练样本的转换,为后续混合网络提供训练数据源。

尽管插值曲线在限定区间内与试验拟合曲线吻


合较好,但插值结果不可避免地继承了原始试验数据的固有分散性及S-N模型自身的拟合偏差,该插值过程无法消除实测数据中的局部随机性。




(a) 工况 1




(b) 工况 2



(c) 工况 3



(d) 工况 4



(e) 工况 5

图 11 数据边界内 ANN 预测曲线与试验 S-N 曲线对比

Fig. 11 Comparison of the ANN prediction curve within the data boundary with the experimental S-N curve

4 混合神经网络构建与小样本疲劳强度预测

4.1 基于“浅层+LSTM”的 7050 铝合金疲劳强度预测

长短期记忆网络(long short-term memory, LSTM)依靠输入门、遗忘门、输出门的门控结构,可有效提取时序数据的长期依赖特征,在疲劳寿命时序预测领域应用广泛^[21, 22]。本文提出了 LSTM 与全连接前馈神经网络相融合的浅层+LSTM 混合模型,用于小样本场景下金属材料疲劳强度预测^[19-23]。依托第 3 节浅层 ANN 生成的衍生数据集搭建浅层 ANN+LSTM 混合模型,探究时序网络在小样本高周疲劳预测中的适配性。选取 2 组典型工况开展验证,如图 12 所示。结果表明:有监督训练模式下,该模型可较好地拟合试验 S-N 曲线,证实深度学习方法用于铝合金疲劳预测具备可行性,但伪标签自举式外推至高周区间时,模型外推稳定性无法满足工程需求,主要缺陷如下:

1) 模型工况敏感性较强,2 种工况疲劳强度预测相对误差分别达到 56% 和 19.5%;

2) 伪标签引导外推时易出现预测趋势失稳与剧烈震荡;

3) 回归分析得到工况 1、工况 2 决定系数分别为 0.725 和 0.612,表明模型泛化性能较差,无法精准描述疲劳应力与循环寿命的演化规律。

由曲线对比结果可见,浅层 ANN+LSTM 模型在标签完备的监督训练中预测效果优异,但高度依赖标注数据;缺少标签约束、向高周区间(大于 10^7)外推时,预测曲线严重偏离实测 S-N 曲线规律、外推趋势发散问题显著。为解决外推时鲁棒性不足、预测序列失稳的缺陷,本文融合卷积特征提取、GRU 时序建模与注意力机制,构建 CNN-GRU-Attention 新

型混合网络引入含物理先验的趋势感知损失函数(见第4.2节),从优化目标层面限制插值偏差在网络中的放大;同时,在增量迭代训练中(见第4.3节),原始低周实测数据始终保留于训练集,作为网络优化的客观物理参照,避免模型仅依赖插值样本自举而偏离真实规律。




图12 浅层+LSTM混合神经网络预测数据与试验S-N曲线
Fig. 12 Prediction data of the shallow +LSTM hybrid neural network and the experimental S-N curve

4.2 基于混合神经网络的疲劳强度直接预测

卷积神经网络(convolutional neural networks, CNN)凭借局部特征自适应提取能力,可有效挖掘疲劳损伤演化中的局部非线性特征^[24];但该模型对训练样本量依赖性较高,且缺乏长时序依赖建模能力,难以直接应用于小样本高周疲劳寿命预测问题。针对上述局限,本文构建ANN+CNN-GRU-Attention混合神经网络模型:首先依托第3节浅层ANN生成的限定区间衍生数据完成样本扩充,解决小样本训练数据不足的核心问题;其次融合CNN的局部特征提

取、GRU的长时序建模与注意力机制的全局信息聚焦能力,同时引入含物理先验的趋势感知损失函数,抑制小样本训练中的外推失稳,提升模型高周外推的稳定性。该混合神经网络的核心架构如图13所示,主要包含4个功能模块:

1)一维卷积特征提取模块:由1个一维卷积层、1个Dropout层和1个flatten层组成。设置32个尺寸为3的卷积核,采用ReLU激活函数以加快收敛速度;在卷积层后添加Dropout层(丢弃概率0.2),通过随机失活神经元增强模型稀疏性,缓解小样本下的过拟合问题;最后,通过flatten层将多通道特征映射为一维向量,输入至后续时序模块。

2)GRU时序建模模块:采用单层GRU网络并设置return_sequences=True,内部Dropout率为0.03,保留完整时序输出序列。相较于LSTM,GRU简化了门控结构,在保持时序特征提取能力的同时减少了模型参数,更适配小样本训练场景,可有效捕捉疲劳损伤演化的长周期依赖关系。

3)全局注意力模块:引入全局注意力机制对GRU输出的时序特征进行加权融合,通过可训练的权重矩阵、偏置向量与注意力参数向量,自动聚焦对高周疲劳强度预测贡献更大的关键时序片段,解决长序列预测中信息衰减的问题。其核心计算过程如下:

对于输入序列 $X \in R^{B \times T \times d}$ (其中 B 为批次大小, T 为序列长度, d 为嵌入维度),通过注意力机制计算得到上下文向量 c ,实现全局信息的有效整合。

$$C = \sum_{i=1}^T \text{softmax}(\tanh(X_i \cdot W + b) \cdot u)_i \cdot X_i \quad (4)$$

首先,对输入序列进行线性变换并通过tanh激活计算原始注意力分数 A :

$$A = \tanh(X \cdot W + b) \quad (5)$$

式中: $W \in R^{d \times d}$ 为可训练权重矩阵; $b \in R^d$ 为可训练偏置向量; $u \in R^{d \times 1}$ 为可训练注意力参数向量;输出 $A \in R^{B \times T \times 1}$ 为每个时间步的注意力分数。沿序列长度维度对原始注意力分数进行Softmax归一化,得到注意力权重 α :

$$\alpha = \text{softmax}(A, \text{axis} = 1) \quad (6)$$

最后,将注意力权重施加于输入序列,通过加权求和得到聚合后的上下文向量 C :

$$C = \sum_{i=1}^T \alpha_i \cdot X_i \quad (7)$$

4)含物理先验的趋势感知损失函数模块:在平均绝对误差(MAE)基础损失函数的基础上,引入趋势惩罚项。该惩罚项的作用是对相邻预测点之间的应力变化幅度施加软约束,抑制长周期外推中的异常振荡,使预测序列保持相对平稳的演化趋势。两

者加权组合后,模型既具备有监督学习的拟合精度,又具有符合物理规律的平滑外推能力。计算公式为:

$$L = \frac{1}{BT} \sum_{b=1}^B \sum_{t=1}^T |y_{true}^{(b,t)} - y_{pred}^{(b,t)}| + \lambda \cdot \frac{1}{B(T-1)} \sum_{b=1}^B \sum_{t=1}^{T-1} (y_{pred}^{(b,t+1)} - y_{pred}^{(b,t)}) \quad (8)$$

式中: $y_{true}^{(b,t)}$ 为**b**个样本在**t**时间的真实值; $y_{pred}^{(b,t)}$ 为相应预测值; λ 为趋势惩罚权重。该损失函数通过引入物理约束,在标注数据稀缺条件下抑制了小样本高周疲劳外推中的预测序列失稳与趋势偏离,使预测趋势符合疲劳损伤基本规律。此外,该物理约束亦从优化目标层面削弱了浅层 ANN 在衍生阶段所引入的局部偏差向混合网络深层结构传导的风险。






图 13 CNN-GRU-Attention 混合神经网络结构示意图
Fig. 13 Schematic diagram of the CNN-GRU-Attention hybrid neural network structure


基于上述混合模型,采用 5 种工况初始衍生数据集(各 471 个数据点)进行单次全量训练,并直接外推预测至 10^7 次循环对应的高周疲劳强度,预测结果与试验 S-N 曲线对比如图 14 所示。结果表明:混合模型解决了浅层 ANN+LSTM 模型的预测序列失稳问题,5 种工况下预测曲线均呈现平稳梯度下降趋势,符合疲劳损伤演化的基本规律。




(a) 工况 1




(b) 工况 2



(c) 工况 3



(d) 工况 4



(e) 工况 5

图 14 混合神经网络直接预测与试验拟合 S-N 曲线对比
Fig. 14 S-N curve comparison between direct prediction by hybrid neural network and experimental data

fitting

然而,单次全量训练模式下模型仍存在明显短板:5种工况疲劳强度预测平均偏差达18.85%(具体数值见表2),无法满足工程应用精度要求。其根本原因是:直接预测仅依托 3×10^4 — 5×10^5 周的局部衍生数据,模型难以全面捕捉 3×10^4 — 10^7 周全跨度高周疲劳的损伤演化规律。

4.3 基于增量迭代混合神经网络的疲劳强度预测

针对单次全量训练的核心局限:仅能学习 3×10^4 — 5×10^5 周局部衍生数据的损伤规律,无法捕捉 3×10^4 — 10^7 周全跨度高周疲劳的演化趋势,本文提出小样本增量迭代训练策略。该策略通过滑动时间窗构建时序数据集、动态数据增强逐步扩展学习区间,驱动模型分步学习疲劳损伤的长周期演化规律,逐步外推至 10^7 次高周疲劳强度。为抑制增量迭代过程中潜在的误差累积风险,本文分别从物理约束、数据基准保留与全局重训练3个方面构建了误差控制机制。ANN+CNN-GRU-Attention混合神经网络的迭代训练预测流程如图15所示,具体步骤如下:

1)初始数据集构建:利用第3节训练完成的浅层ANN模型,基于原始疲劳试验数据生成 3×10^4 — 5×10^5 周区间的高质量衍生数据,得到初始数据集 D_0 (共471组样本)。

2)时序数据集构建:对数据集 $D_i(i=0, 1, 2, \dots, n)$ 进行标准化处理,采用滑动时间窗法构建时序输入输出对:设置窗口长度为15、步长为1,将连续15个时间步的应力-寿命数据作为输入 D_{xi} ,将窗口下一时刻对应的最大应力值作为预测目标 D_{yi} 。

3)数据集划分:将时序数据集 (D_{xi}, D_{yi}) 以9:1按顺序划分为训练集和测试集,训练集用于模型参数更新,测试集用于评估模型泛化性能。

4)模型训练与校验:模型训练采用Adam优化器,学习率设为0.001,批量大小为16,最大训练轮数为1000轮。为防止过拟合,采用早停策略:若验证集损失在连续500轮内未下降,则终止训练并保存最优模型。所有输入特征在输入网络前均采用Z-Score标准化处理。构建CNN-GRU-Attention混合神经网络,利用训练集完成模型训练,通过测试集评估并筛选最优模型 M_i ;每轮迭代均进行重初始化全局训练,而非沿用上轮参数微调,从而避免历史偏差在迭代过程中被固化并传递。


5)数据增强与区间扩展:采用最优模型 M_i 预测下一区间的疲劳应力值,将预测得到的高质量数据按时间序列添加至原数据集,构建增强数据集 D_{i+1} ,在此过程中,原始低周实测数据与初始ANN插值数据始终保留于训练集中,使网络更新兼顾物理真值与预测趋势的双重信息,从而避免预测偏差随迭代

次数增加而单调放大。

6)迭代终止判断:重复步骤2—5,当预测循环次数达到 10^7 次时终止迭代。

迭代过程中,可根据模型收敛情况适度扩大单步预测跨度,在保证精度的前提下提升训练效率;每次迭代生成的新增数据均需通过趋势一致性校验,确保增强数据集的可靠性。该物理校验环节旨在及时识别并剔除偏离疲劳演化基本规律的异常数据,避免不合理预测值进入下一轮训练,从源头阻断误差在迭代链条中的传递与累积。

基于上述迭代策略,对5种工况下的7050铝合金高周疲劳强度进行预测,结果如图16及表2、表3所示。其中,相对误差(表2)及MAE/RMSE(表3)均严格基于未参与训练的升降法实测真值计算;图16中的S-N拟合曲线仅作为趋势参照线绘制,其数值不参与误差计算。由表2可知:单次全量训练模型的5种工况疲劳强度预测平均偏差为18.85%,而增量迭代训练模型的平均偏差仅为5.29%,相较于单次训练的平均预测偏差降低了71.9%;其中工况1的预测偏差从23.4%降至1.7%,工况3的预测偏差从21.5%降至7.9%,验证了方法在本文工况下的工程适用性。表3的性能指标进一步验证了迭代训练的优势:2种训练模式下模型的决定系数均接近1,表明混合神经网络本身具备优异的非线性拟合能力;但迭代训练模型的平均绝对误差(MAE)从16.78 MPa降至6.21 MPa,均方根误差(RMSE)从18.32 MPa降至6.58 MPa,泛化性能与预测稳定性明显优于单次全量训练模型。



(a) 工况1




图15 ANN+CNN-GRU-Attention混合神经网络迭代训练计算过程

Fig. 15 Iterative training procedure for the hybrid model comprising ANN, CNN, GRU, and Attention Mechanisms

图 16 疲劳试验 S-N 曲线与增量迭代混合神经网络预测结果对比

Fig. 16 Comparison of the fatigue test S-N curve with the prediction results of the incremental iterative hybrid neural network

表 2 混合神经网络模型疲劳强度预测结果对比
Table 2 Comparison of fatigue strength prediction results of hybrid neural network models MPa

工况	模型直接预测	迭代模型预测	升降法试验
1	93.4	119.9	122
2	243.6	270.6	272.5
3	59.2	69.4	75.4
4	124.2	142.2	153.4
5	137.1	155.7	170.7

产生上述差异的本质原因在于:单次全量训练仅依托 471 组局部衍生数据,模型无法学习高周区间的损伤演化特征;而增量迭代训练通过“预测-验证-增强-再训练”的闭环机制,将模型的学习区间逐步从 5×10^5 周扩展至 10^7 周,使模型能够逐步捕捉全跨度疲劳损伤的非线性演化规律。同时,每次迭代

均基于包含真实试验数据的增强数据集进行训练,有效避免了小样本下的过拟合与预测震荡问题。本文引入的物理约束与增量迭代策略,有效规避了 LSTM 在无监督长周期外推时的预测失稳问题。由表 3 可知,相对于单次全量训练,迭代训练策略将 5 种工况的平均绝对误差从 16.78 MPa 降低至 6.21 MPa,表明该方法能够有效保障模型在 7050 铝合金高周疲劳区间的工程实用性。

表 3 混合神经网络预测模型的性能指标
Table 3 Evaluation of performance indices for the hybrid neural network predictive model

工况	单次训练			迭代训练		
	R ²	MAE	RMSE	R ²	MAE	RMSE
1	0.811	16.8955	18.7990	0.958	2.0305	2.7268
2	0.970	21.1152	23.0779	0.992	8.5141	8.7020
3	0.954	10.3392	11.1175	0.990	4.5825	4.6968
4	0.991	16.2286	17.1334	0.996	6.5239	6.6387
5	0.936	19.3246	21.4841	0.985	9.3887	10.1151

表 4 本文模型与基准模型预测精度及外推稳定性对比
Table 4 Comparison of prediction accuracy and extrapolation stability between the model in this paper and the benchmark model

模型类型	工况	训练数据边界	预测目标	相对误差/%	R ²
浅层 ANN+LSTM(基准)	1	$3\times 10^4\text{—}5\times 10^5$	10^7 次疲劳强度	56	0.725
	2	$3\times 10^4\text{—}5\times 10^5$	10^7 次疲劳强度	19.5	0.612
本文混合网络	1	$3\times 10^4\text{—}5\times 10^5$	10^7 次疲劳强度	1.7	0.958
	2	$3\times 10^4\text{—}5\times 10^5$	10^7 次疲劳强度	0.7	0.992

为进一步评估混合架构对预测稳定性的改善效果,本文选取第 4.1 节中失稳现象最显著的工况 1、2,将本文混合网络与前期基准模型进行精度及外推表现的纵向对比,结果如表 4 所示。由表 4 可知,前期基础模型在无监督外推至高周区间时,工况 1 和 2 的预测严重偏离真实趋势,相对误差分别高达 56% 和 19.5%,决定系数仅为 0.725 和 0.612,且预测曲线出现剧烈震荡。而本文提出的混合网络通过引入 CNN 局部特征提取、GRU 长时序建模、Attention 全局注意力机制,配合含物理先验的趋势感知损失函数与增量迭代策略中的全局重训练机制,从根本上抑制了高周区间的外推失稳。在相同的数据来源与评价标准下,本文模型在工况 1、2 的预测相对误差分别降至 1.7% 和 0.7%,外推曲线均保持平稳,验证了该混合架构对克服小样本外推失稳问题的有效性。

在模型评价环节,本文采用实测数据作为唯一标尺。具体而言,浅层 ANN 的插值精度通过 5×10^5 周以内的原始数据点校核,混合网络的外推趋势通过 S-N 拟合曲线参照,而最终疲劳强度的误差严格

对照未参与训练的升降法独立实测值进行计算,从根本上避免训练数据与评价数据的交叉使用。

综上,本文提出的增量迭代训练策略与 ANN+CNN-GRU-Attention 混合神经网络相结合,实现了小样本条件下 7050 铝合金高周疲劳强度的高精度预测。该方法仅需少量低周疲劳试验数据,即可快速获得全工况、全寿命区间的 S-N 曲线,缩短了材料疲劳性能评估周期,降低了试验成本,具备重要的工程应用价值。

5 结论

1)设计了一种基于浅层 ANN 的限定区间数据衍生方法,在不新增试验的前提下,将离散测点扩充为 $3\times 10^4\text{—}5\times 10^5$ 周的连续样本,为小样本条件下的模型训练提供了数据基础。

2)构建了 ANN+CNN-GRU-Attention 混合神经网络,融合多尺度特征提取与时序建模能力,并引入含物理先验的趋势感知损失函数。在本文工况下,该网络结构未出现传统 LSTM 模型中的预测序列失

稳现象。

3)采用“预测-增强-再训练”的增量迭代训练策略逐步扩展学习区间。对于本文所涉及的5种工况,疲劳强度预测的平均偏差为5.29%,与单次全量训练相比,预测误差降低了71.9%。

在本文试验条件范围内,该方法利用少量低周疲劳试验数据获得了各工况下的S-N曲线,缩短了材料疲劳性能的评估周期,可为航空铝合金的小样本疲劳性能评估提供一种数据驱动的技术思路。后续工作拟将材料种类扩展至其他牌号铝合金及不同金属体系,并在更宽泛的应力比、应力集中系数及加载条件下检验该方法的外推能力,以进一步明确其适用范围与边界。

参考文献:

- [1] 王金龙, 彭文杰, 冀秀坤, 等. 不同类型表面粗糙度对钛合金疲劳失效影响的试验研究[J]. 哈尔滨工程大学学报, 2025, 46(5): 1032-1038, 1046.
WANG Jinlong, PENG Wenjie, JI Xiukun, et al. Experimental study on the effect of different types of surface roughness on fatigue failure of titanium alloys[J]. Journal of Harbin Engineering University, 2025, 46(5): 1032-1038, 1046.
- [2] ZAWADA-MICHAŁOWSKA M, PIEŚKO P, MRÓWKA-NOWOTNIK G, et al. Effect of the technological parameters of milling on residual stress in the surface layer of thin-walled plates[J]. Materials, 2024, 17(5): 1193.
- [3] VIJAYANANDH R, KUMAR K N, KUMAR G R, et al. Comparative approaches for fatigue life estimation of aluminium alloy for aerospace applications[J]. International journal of vehicle structures and systems, 2018, 10(4): 282.
- [4] SWANSON S R. Handbook of Fatigue Testing[M]. West Conshohocken: ASTM International, 1974.
- [5] MANSON S S, HALFORD G R. Practical implementation of the double linear damage rule and damage curve approach for treating cumulative fatigue damage[J]. International journal of fracture, 1981, 17(2): 169-192.
- [6] SMITH K. A stress-strain function for the fatigue of metals[J]. Journal of Materials, 1970, 5: 767 - 778.
- [7] ZOU Li, SUN Yibo, YANG Xinhua. An entropy-based neighborhood rough set and PSO-SVRM model for fatigue life prediction of titanium alloy welded joints[J]. Entropy, 2019, 21(2): 117.
- [8] HENG Fei, GAO Jianxiong, XU Rongxia, et al. Multiaxial fatigue life prediction for various metallic materials based on the hybrid CNN-LSTM neural network[J]. Fatigue & fracture of engineering materials & structures, 2023, 46(5): 1979-1996.
- [9] WANG Yanju, ZHU Zhenyu, SHA Aixue, et al. Low cycle fatigue life prediction of titanium alloy using genetic algorithm-optimized BP artificial neural network[J]. International journal of fatigue, 2023, 172: 107609.
- [10] ZHAN Zhixin, HU Weiping, MENG Qingchun. Data-driven fatigue life prediction in additive manufactured titanium alloy: a damage mechanics based machine learning framework[J]. Engineering fracture mechanics, 2021, 252: 107850.
- [11] JING Hutao, YUAN Shenfang, CHEN Jian, et al. A multi-scale deep residual network-based guided wave imaging evaluation method for fatigue crack quantification[J]. Measurement science and technology, 2025, 36(1): 016115.
- [12] LIAO Huiya, PAN Jun, SU Xihui, et al. A path-dependent adaptive physics-informed neural network for multiaxial fatigue life prediction[J]. International journal of fatigue, 2025, 193: 108799.
- [13] 张红哲, 王德鹏, 鲍永杰, 等. 基于长短期记忆网络的航空用TC4钛合金缺口件断裂行为分析[J/OL]. 哈尔滨工程大学学报, 2026 (2026-04-09). <https://link.cnki.net/urlid/23.1390.u.20260408.1623.002>.
ZHANG Hongzhe, WANG Depeng, BAO Yongjie, et al. Fracture behavior analysis of TC4 titanium alloy notched parts for aviation based on long-term and short-term memory networks [J/OL]. China industrial economics, 2026 (2026-04-09). <https://link.cnki.net/urlid/23.1390.u.20260408.1623.002>.
- [14] 国家质量监督检验检疫总局, 中国国家标准化管理委员会. 金属材料 疲劳试验 轴向力控制方法: GB/T 3075—2008[S]. 北京: 中国标准出版社, 2009.
General Administration of Quality Supervision, Inspection and Quarantine of the People's Republic of China, Standardization Administration of the People's Republic of China. Metallic materials - fatigue testing-axial-force-controlled method: GB/T 3075—2008[S]. Beijing: Standards Press of China, 2009.
- [15] YI Min, TANG Wei, ZHU Yiqi, et al. A holistic review on fatigue properties of additively manufactured metals[J]. Journal of materials processing technology, 2024, 329: 118425.
- [16] SHEN Xingkeng, DAI Ying, CHEN Xinmin, et al. Fatigue performance testing and life prediction of welded fuel pipes[J]. International journal of fatigue, 2024, 187: 108453.
- [17] 郭宏超, 关晓迪, 王万祯, 等. 高强钢焊接接头疲劳性能及损伤演化规律研究[J/OL]. 建筑钢结构进展, 2026, 1-10 [2026-03-17]. <https://link.cnki.net/urlid/31.1893.TU.20250916.1726.04>.
GUO Hongchao, GUAN Xiaodi, WANG Wanzhen, et al. Research on fatigue properties and damage evolution laws of high-strength steel welded joints [J/OL]. Advances in Building Steel Structures, 2026, 1-10 [2026-03-17]. <https://link.cnki.net/urlid/31.1893.TU.20250916.1726.04>.
- [18] 姚喆赫, 何森峰, 王发博, 等. 基于数据增强的激光增材制造GH4169疲劳寿命预测方法研究[J/OL]. 中国激

- 光, 2026, 1-17 [2026-03-30]. <https://link.cnki.net/urlid/31.1339.TN.20251201.0941.074>.
- YAO Zhehe, HE Miaofeng, WANG Fabo, et al. Research on fatigue life prediction method for GH4169 in laser additive manufacturing based on data augmentation [J/OL]. Chinese Journal of Lasers, 2026, 1-17 [2026-03-30]. <https://link.cnki.net/urlid/31.1339.TN.20251201.0941.074>.
- [19] LI Yunze, DONG Chao, JIANG Chao, et al. Fatigue limit prediction of 7050 aluminium alloy based on experimental and shallow + deep hybrid neural network[J]. Engineering failure analysis, 2025, 167: 108994.
- [20] LEVENBERG K. A method for the solution of certain non-linear problems in least squares [J]. Quarterly of applied mathematics, 1944, 2(2): 164-168.
- [21] 李龙斌. 基于深度学习的裂纹转子剩余寿命预测[D]. 成都: 西南交通大学, 2023.
- LI Longbin. Prediction of residual life of cracked rotor based on deep learning[D]. Chengdu: Southwest Jiaotong University, 2023.
- [22] 张波, 胡昌华, 张浩, 等. 机器学习应用于随机退化设备剩余寿命预测的综述[J]. 哈尔滨工程大学学报, 2024, 45(9): 1783-1790.
- ZHANG Bo, HU Changhua, ZHANG Hao, et al. A review of remaining useful life prediction for stochastic degrading devices based on machine learning[J]. Journal of Harbin engineering university, 2024, 45(9): 1783-1790.
- [23] 赵德望, 李运泽, 尹汉琪, 等. 一种基于自注意力机制的深度学习小样本增量迭代训练的金属疲劳寿命预测方法及系统: CN120449668A[P]. 2025-08-08.
- [24] 裴洪, 张澳, 胡昌华, 等. 考虑阶段划分不确定性的轴承剩余寿命预测方法[J/OL]. 哈尔滨工程大学学报, 1-8 [2026-06-15]. <https://link.cnki.net/urlid/23.1390.U.20260518.1424.002>.
- PEI Hong, ZHANG Ao, HU Changhua, et al. Remaining useful life prediction for bearings considering stage division uncertainty [J/OL]. Journal of Harbin Engineering University, 1-8 [2026-06-15]. <https://link.cnki.net/urlid/23.1390.U.20260518.1424.002>.

本文引用格式:

赵德望, 徐雨帆, 杨文平等. 小样本下基于数据衍生与混合神经网络的7050铝合金高周疲劳强度预测[J]. 哈尔滨工程大学学报, DOI:10.11990/jheu.20260612013.

ZHAO Dewang, XU Yufan, YANG Wenping, et al. High-cycle fatigue strength prediction for 7050 aluminum alloy using data augmentation and hybrid neural network in small sample scenarios[J]. Journal of Harbin Engineering University, DOI:10.11990/jheu.20260612013.