

引用格式: 王璟怡, 张悦, 钟斌, 等. 基于机器学习的航空材料疲劳寿命预测研究进展[J]. 航空材料学报, 2026, 46(3): 1-17.

WANG Jingyi, ZHANG Yue, ZHONG Bin, et al. Progress on fatigue life prediction of aeronautical materials based on machine learning[J]. Journal of Aeronautical Materials, 2026, 46(3): 1-17.

基于机器学习的航空材料疲劳寿命预测研究进展

王璟怡^{1,2,3}, 张悦^{1,2,3}, 钟斌^{1,2,3}, 何玉怀^{1,2,3}, 许巍^{1,2,3*}

(1. 中国航发北京航空材料研究院, 北京 100095; 2. 航空材料检测与评价北京市重点实验室, 北京 100095; 3. 中国航空发动机集团材料检测与评价重点实验室, 北京 100095)

摘要: 航空装备材料对安全性与可靠性要求极高, 而疲劳性能是其核心性能指标之一。传统的疲劳预测方法依赖大量实验, 成本高、周期长, 难以满足现代航空工程对高效、精准评估的需求。近年来, 机器学习在航空材料疲劳寿命预测中展现出显著潜力。本工作系统综述该领域研究进展, 重点涵盖主流模型与建模流程, 梳理纯数据驱动方法与融合物理机制方法的核心思路与关键成果, 聚焦物理信息嵌入对提升模型精度、可信度与可解释性方面的作用, 并评述数据层面、复杂失效机制的信息挖掘不足、模型可解释性与工程应用信任度不足和复杂工况适应性不足的局限性, 未来需重点突破构建标准化、高可信度的疲劳数据集, 建立面向任务的物理知识自动融合机制, 推动面向复杂工况和结构件层级疲劳预测等研究方向。

关键词: 航空材料; 疲劳性能; 机器学习; 数据驱动; 物理信息融合

doi: 10.11868/j.issn.1005-5053.2025.000140

CSTR: 32420.14.j.issn.1005-5053.2025.000140

中图分类号: V250.2

文献标识码: A

文章编号: 1005-5053(2026)03-0001-17

Progress on fatigue life prediction of aeronautical materials based on machine learning

WANG Jingyi^{1,2,3}, ZHANG Yue^{1,2,3}, ZHONG Bin^{1,2,3}, HE Yuhuai^{1,2,3}, XU Wei^{1,2,3*}

(1. AECC Beijing Institute of Aeronautical Materials, Beijing 100095, China; 2. Beijing Key Laboratory of Aerospace Materials Testing and Evaluation, Beijing 100095, China; 3. AECC Key Laboratory of Aerospace Materials Testing and Evaluation, Beijing 100095, China)

Abstract: Aerospace equipment materials demand an ultra-high level of safety and reliability, with fatigue performance being one of their core performance metrics. Traditional fatigue prediction methods rely heavily on extensive experimental tests, which are associated with high costs and long development cycles, thus failing to meet the requirements of modern aerospace engineering for efficient and accurate performance evaluation. In recent years, machine learning has exhibited remarkable potential in the fatigue life prediction of aerospace materials. This work presents a systematic review of the research progress in this field, with a focus on mainstream models and modeling workflows. It clarifies the core ideas and key research findings of both pure data-driven methods and physics-integrated approaches, and centers on the role of physical information embedding in enhancing model accuracy, credibility, and interpretability. Moreover, the paper critically discusses the existing limitations, including insufficient information mining in terms of data dimensions and complex failure mechanisms, inadequate model interpretability and low trustworthiness for engineering applications, as well as poor adaptability to complex service conditions. Finally, key research directions for addressing these limitations are highlighted, such as constructing standardized and highly reliable fatigue datasets, establishing a task-oriented automatic fusion mechanism for physical knowledge, and advancing fatigue life prediction at the level of structural components under complex service conditions.

Key words: aeronautical material; fatigue property; machine learning; data-driven; physics-informed fusion

航空装备的服役条件极为严苛,需要在高温、高速旋转、高负载、高循环应力等极端工况下长期运行,这对材料的综合性能提出极高要求,尤其是其抗疲劳性能,直接关系到装备的可靠性与飞行安全。同时,航空装备的服役环境较其他机械设备更为复杂,包括起飞和降落时冲击载荷、飞行中气动载荷、发动机的振动载荷等^[1],这些载荷导致材料内部的微观损伤逐步累积,最终导致疲劳失效,这意味着材料必须具备良好的抗疲劳性能,以应对高速飞行、长时服役、极端温度条件等挑战^[2]。此外,航空装备的服役环境还具有高度不确定性和变异性。例如飞行过程中遇到的突发气象条件、不规则的飞行路径、不同的飞行任务等,都会对材料的疲劳性能产生影响。因此,准确预测航空材料的疲劳寿命对于确保航空装备的服役安全至关重要^[3-4]。值得关注的是在工程应用中发现^[4-5],飞机机翼、直升机螺旋桨叶、航空发动机叶片等航空装备关键构件的失效通常发生在高周(10^7 次循环)甚至超高周疲劳($10^8 \sim 10^9$ 次循环)状态,高周疲劳失效会导致航空装备性能下降甚至结构件断裂,对飞行安全构成严重威胁^[6]。

鉴于上述复杂性,航空装备研制过程的强度校核、质量评估以及故障排查,需要关注航空材料疲劳性能,并对疲劳寿命预测精度提出更高要求。传统的航空材料疲劳性能预测方法主要依赖疲劳性能测试数据和预测方程,如常规轴向疲劳测试、高频振动疲劳测试^[7]、超声疲劳测试等。这些方法通

过测试获取材料在不同应力水平下的疲劳寿命数据,然后利用这些数据拟合出疲劳寿命方程,如Basquin方程^[8]。然而,疲劳测试过程耗时耗力,成本高昂。特别在需要获取大量数据以覆盖不同工况和材料状态时,时间和经济成本投入更为显著。需要特别关注的是疲劳预测方程通常考虑的影响因素简单有限,而实际服役中,材料微观结构、表面状态、环境及载荷的复杂性都会对疲劳寿命产生显著影响,而传统方法难以同时考虑这些因素^[9-10]。

近年来,随着航空装备的研制对于材料性能数据需求日益提高,航空材料性能数据库,特别是疲劳性能数据库得到极大丰富,这为机器学习(machine learning, ML)的应用提供可靠的数据基础,提升机器学习模型的应用价值。与传统方法相比,机器学习具有处理和分析材料特性、微观结构、服役载荷等大量复杂数据的能力,还具备识别数据中潜在关系的独特优势,从而可以对航空材料的疲劳性能进行更精准和高效的预测^[11-14]。可靠的预测模型还能够分析不同耦合因素对疲劳寿命的影响,为材料设计与研发提供指导。航空材料服役条件的特殊性与机器学习的技术优势相互匹配,为航空材料疲劳性能预测提供更有效的新途径^[15-18],如图1所示。

机器学习在疲劳性能预测领域已取得一定进展,但其应用仍处于发展阶段,目前面临诸多亟待解决的问题。其中模型的“黑箱”特性限制了机器学习预测结果的可信度,使其与传统测试方法存

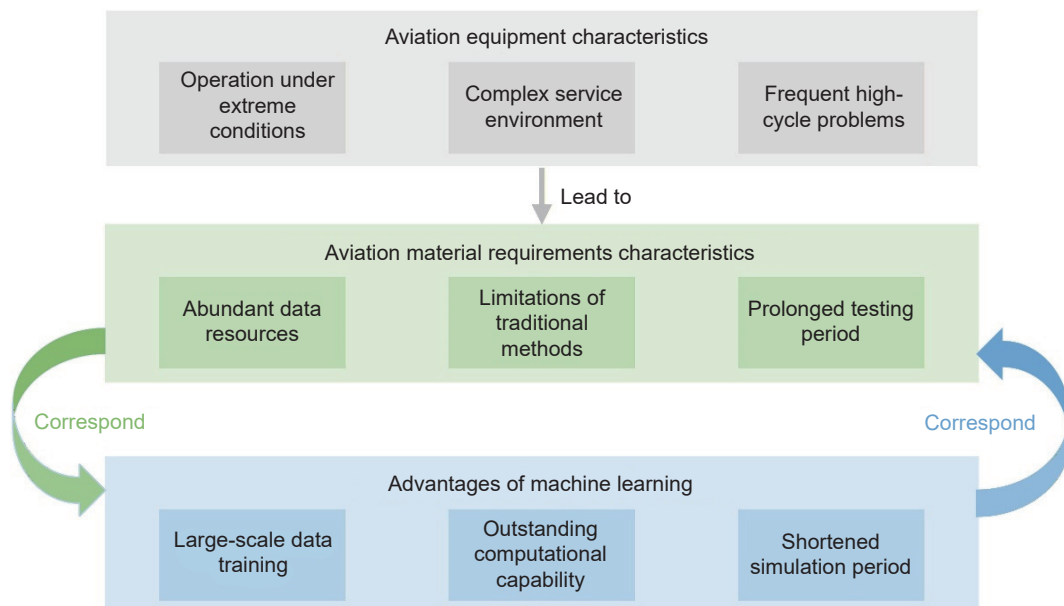


图1 航空材料的特殊性及其对机器学习的适应性

Fig. 1 Specificity of aeronautical materials and their adaptability to machine learning

在差距^[19-20]。此外,研究人员所用原始数据特征量和研究材料不同导致模型的泛化程度低。为了提高模型精度和泛化性,内嵌物理知识的计算方法应运而生^[21]。

本工作基于机器学习方法,分析航空材料疲劳性能预测的研究进展,探讨机器学习应用在航空材料疲劳寿命预测的发展,重点关注物理知识与机器学习数据驱动相结合,达到提高机器学习模型精度和泛化能力的目标,进而推动机器学习在航空材料疲劳性能预测中的广泛应用。

1 疲劳性能机器学习预测模型及流程

1.1 模型介绍

在机器学习领域,随机森林(random forest, RF)、极致梯度提升(extreme gradient boosting, XGBoost)

和神经网络(artificial neural network, ANN)这几种模型在预测任务中表现优异而成为研究者的首选模型。

随机森林是一种集成学习方法,通过并行构建多棵决策树并输出平均结果,提高预测的准确性和稳定性^[22-23]。在材料疲劳性能预测中,它能够处理大量特征并捕捉复杂非线性关系,具有较强的抗过拟合能力,因此被广泛应用^[24]。与之类似,极致梯度提升基于梯度提升框架,通过串行迭代优化损失函数逐步构建决策树,每步尝试修正前一步误差,从而提升模型性能^[25-26]。XGBoost训练效率高,可以处理复杂数据结构,但参数较多,对噪声敏感,需要通过正则化和调参控制过拟合。总体来看,RF通过并行训练降低过拟合风险,适合大规模数据集且调参简单,模型可解释性较好;而XGBoost拟合能力更强,但对噪声敏感,需要精细调参。图2

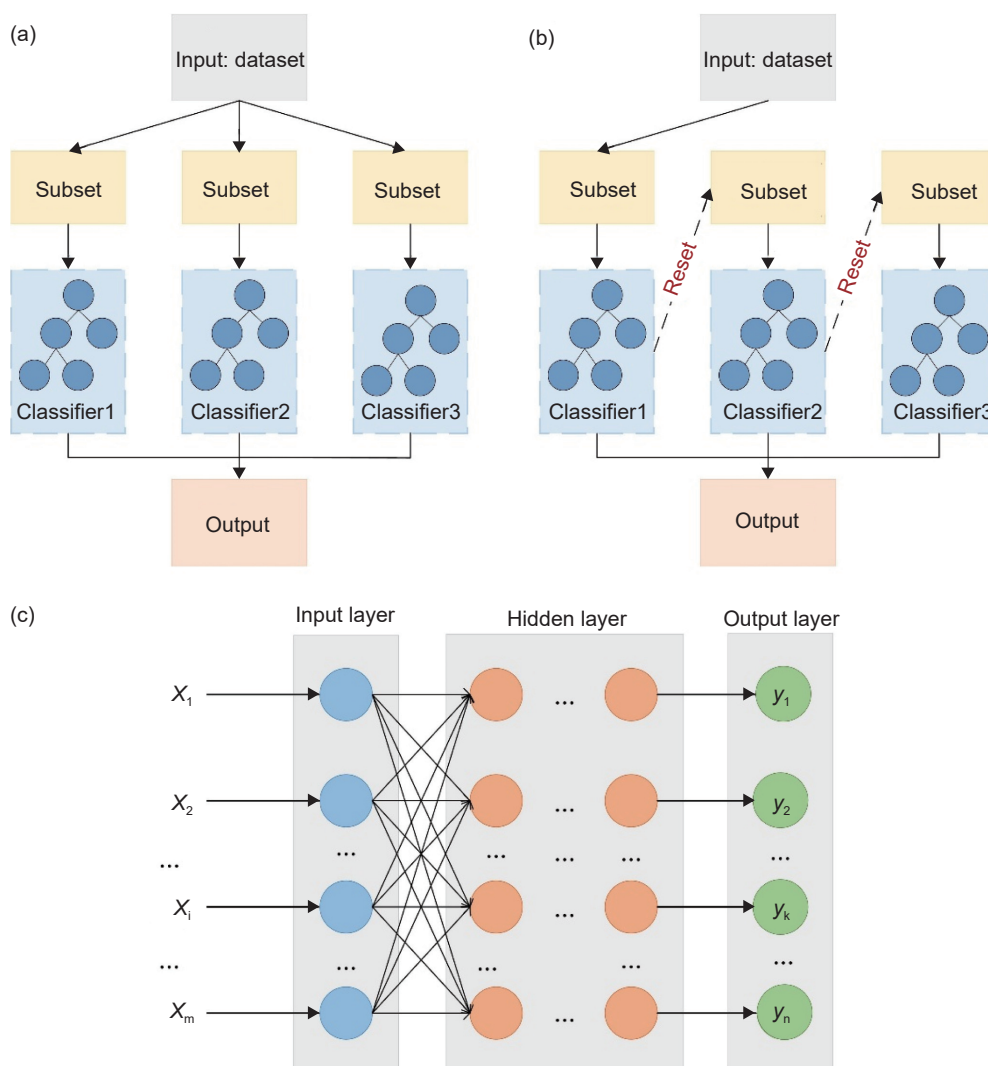


图2 不同机器学习算法结构示意图 (a)随机森林;(b)极致梯度提升;(c)神经网络

Fig. 2 Structural schematic diagrams of different machine learning algorithms (a) RF; (b) XGBoost; (c) ANN

(a)、(b)分别为随机森林和极致梯度提升方法结构示意图。

近年来,神经网络,特别是深度学习模型,广泛应用于疲劳性能预测^[27-28]。ANN通过模拟神经元的加权求和及非线性激活函数处理信息,能够学习输入特征与疲劳寿命之间复杂关系,该方法适用于处理大规模、高非线性数据集^[18,29]。典型神经网络包括输入层、隐藏层和输出层,其中输入层接收外部数据 $X=(x_1, x_2, \dots, x_m)$,隐藏层对输入进行加权处理,提取特征并传递至输出层,实现疲劳寿命预测。图2(c)为简单的神经网络结构示意图,它由输入层、隐藏层和输出层组成,蓝色、橙色和绿色节点分别表示输入层、隐藏层和输出层神经元,隐藏层神经元负责接收来自输入层的信号并计算处理,存在一层或多层。对于隐藏层的第 j 个神经元,其输入 Z_j 是输入层神经元输出的加权和,表示如下^[30]:

$$Z_j = \sum_{i=1}^m w_{ij}x_i + b_j \quad (1)$$

式中: w_{ij} 是输入层第 i 个神经元到隐藏层第 j 个神经元的权重; b_j 是隐藏层第 j 个神经元的偏置。隐藏层神经元通过激活函数 f 对 Z_j 进行处理,输出结果 h_j , 表示如下^[30]:

$$h_j = f(Z_j) = f\left(\sum_{i=1}^m w_{ij}x_i + b_j\right) \quad (2)$$

常见的激活函数有 Sigmoid 函数 $f(x) = \frac{1}{1 + e^{-x}}$ 、ReLU 函数 $f(x) = \max(0, x)$ 等^[31-33]。输出层接收隐藏层的信号,直接给出预测结果,对于输出层的第 k 个神经元,其输入 u_k 是隐藏层神经元输出的加权和,表示如下^[30]:

$$u_k = \sum_{j=1}^{n_h} w_{jk}h_j + b_k \quad (3)$$

式中: w_{jk} 是隐藏层第 j 个神经元到输出层第 k 个神经元的权重; n_h 是隐藏层神经元的数量; b_k 是输出层第 k 个神经元的偏置。输出层根据任务类型选择合适的激活函数得到最终输出 y_k 。在航空材料疲劳寿命预测中,输出一般为疲劳寿命 N_f , 研究人员也通过预测寿命的均值与标准差来代替直接进行寿命预测^[34], 以更好地反映疲劳寿命真实分布特征。

1.2 预测流程

机器学习应用于疲劳性能预测,关键在于数据集构建,它由多个样本组成,每个样本包含描述材料特性、载荷条件和环境因素的特征,以及对应的

疲劳寿命标签^[35]。数据应广泛来源于文献、实验和模拟,涵盖材料成分、微观结构、力学性能、载荷类型与参数、疲劳寿命等关键信息。然而,原始数据常存在异常值、重复值和缺失值(图3(a)), 这些问题会影响分析准确性,因此需要进行严格清洗以保证数据质量^[36]。在清洗完成后,应对数据进行标准化、均一化处理,并可将其转化为接近正态分布形式(图3(b)), 以适应机器学习模型的计算要求并提升性能。随后开展特征工程^[37], 从清洗后的数据中挑选或构造与疲劳寿命高度相关的关键特征,以提高模型预测精度和泛化能力。

在预处理阶段,将数据集按一定比例(通常为4:1)划分为训练集和测试集,用于模型训练与性能验证,为疲劳寿命预测提供高质量和标准化的数据基础。随后,用损失函数评估模型性能,包括均方根误差(root mean square error, RMSE)、决定系数 R^2 和平均绝对误差(mean absolute error, MAE), 表示如下^[38-39]:

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2} \quad (4)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y}_i)^2} \quad (5)$$

$$\text{MAE} = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (6)$$

式中: y_i 表示疲劳测试测得的实际疲劳寿命; \hat{y}_i 表示预测的疲劳寿命; \bar{y}_i 表示真实疲劳寿命的平均值。这些指标用于量化模型预测值与实际值的差异,评估模型准确性和拟合度。

根据损失函数的反馈结果选取最合适的预测模型,并对其进行超参数调试。这一过程旨在找到最佳模型配置,以提升模型预测精度。以神经网络为例,模型构建过程中需调整多种超参数,包括网络层数、每层神经元数量、激活函数类型、正则化参数、学习率、迭代次数等,以优化整体性能。Jia 等^[40] 在预测激光粉末床熔合 Ti-6Al-4V 合金高周疲劳性能时发现,在 DBN-BP 模型中,第一个隐藏层节点数为 10 时, R^2 从 0.63 迅速提升至接近 1; 第二隐藏层节点数为 7 时, R^2 缓慢升至 1, 而后续隐藏层对模型性能影响较小(图3(c)^[39])。RMSE 和 MAE 呈现类似趋势,说明合理的超参数调节对于提升模型预测精度至关重要。

最后,为直观展示预测精度,可将预测值与真实值分别绘于横纵坐标,并添加两倍或三倍标准差的分散带,以反映预测的不确定性(图 3(d)^[41]),从而清晰地呈现模型预测与实际观测之间差异。

的分散带,以反映预测的不确定性(图 3(d)^[41]),从而清晰地呈现模型预测与实际观测之间差异。

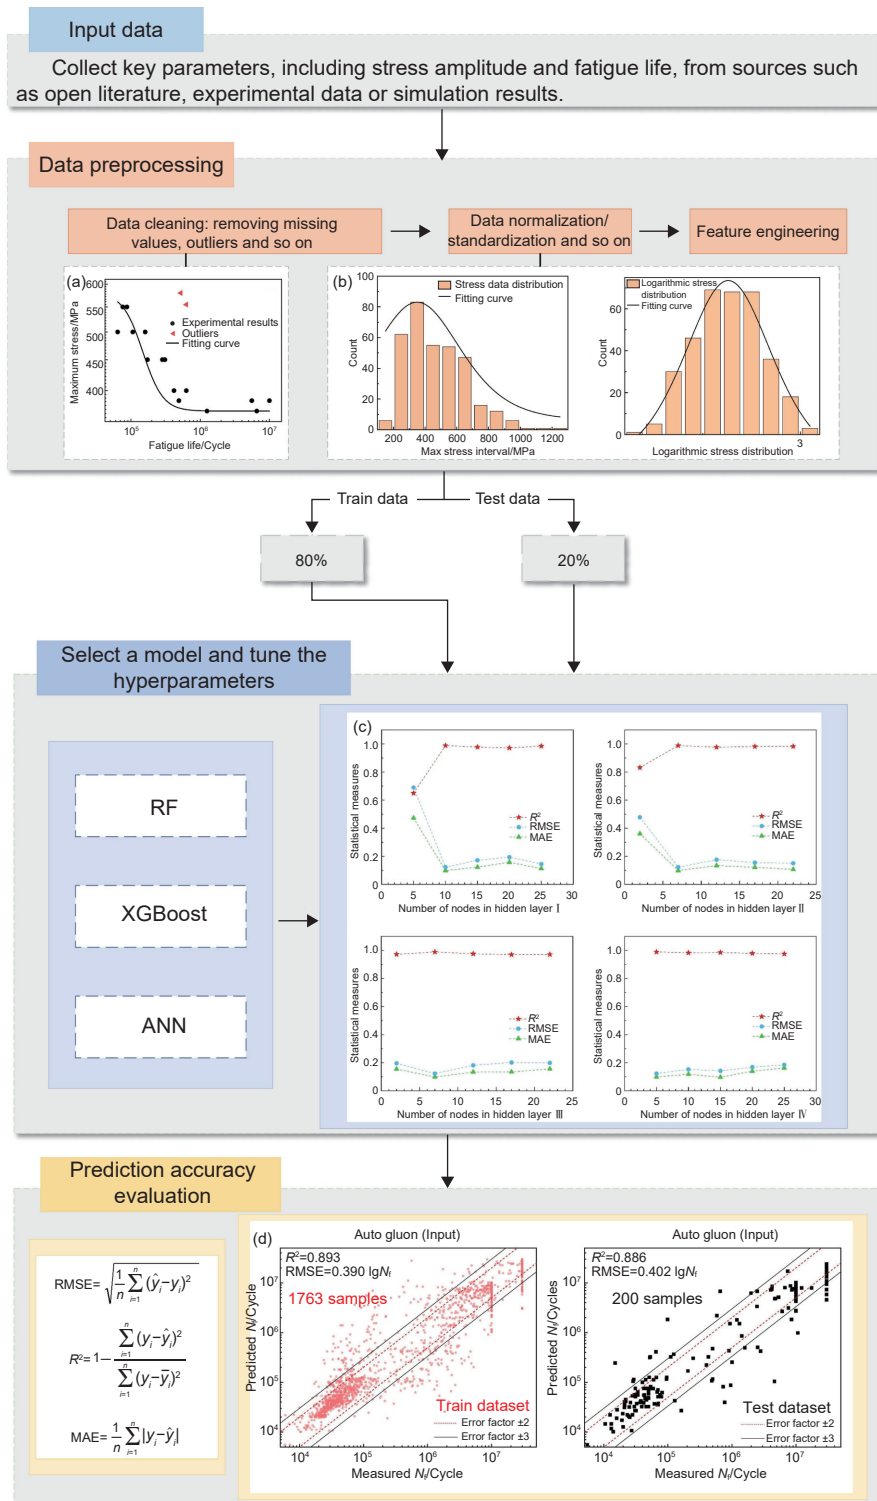


图 3 机器学习预测疲劳寿命一般流程 (a)异常值处理;(b)数据标准化;(c)超参数优化^[39];(d)模型评估^[41]

Fig. 3 General process of predicting fatigue life using machine learning (a) outlier treatment; (b) data normalization; (c) hyperparameter optimization^[39]; (d) model evaluation^[41]

模型训练完成后,为提升黑箱模型的可信度与可解释性,采用多种后验解释方法。典型做法之一是引入 Shapley 值分析,该方法基于合作博弈论思

想,能够定量评估各输入特征对模型预测结果的边际贡献,从而揭示模型的决策依据并识别主导性特征。此外,还可以开展敏感性分析,通过系统地

扰动输入变量并观察输出变化,量化模型对不同特征的响应程度,从而为模型行为提供直观的解释。除了后验方法外,进一步在模型层面引入物理机制约束也是提升可解释性的有效途径。通过在神经网络训练过程中融入物理规律,不仅能够保证预测结果符合物理原理,还能降低过拟合风险,提高模型在外推条件下的泛化能力,从而增强模型在工程应用中的可靠性与学术价值。

2 疲劳寿命机器学习预测模型:从纯数据驱动到物理融合

2.1 纯数据驱动方法及其局限性

基于纯数据驱动的疲劳性能预测在国内外开展较为广泛。例如:Liu等^[42]收集173组高强钢实验数据训练机器学习模型,通过敏感性系数分析,确定夹杂尺寸和最大应力是与疲劳寿命相关性最强的参数,结果表明,ML模型的预测精度优于Murakami模型,在 $10^6 \sim 10^{10}$ 次疲劳循环范围内,ML模型的预测精度最高;Jia等^[40]针对激光粉末床熔融Ti-6Al-4V合金,开发了一种深度信念网络结合反向传播模型,这一研究通过预训练和微调过程,显著提高超高周疲劳寿命的预测精度;Shi等^[43]通过插值法预测AlSi10Mg合金的疲劳寿命,研究采用最邻近插值算法、线性插值算法和结合高斯混合模型的线性插值算法来扩充数据集以增加预测精度,这些插值方法有助于在不生成新像素的情况下增加图像像素大小,从而扩大数据集并保持数据间内在关系;Zhu等^[41,44]分别用Auto Gluon和图神经网络多种算法研究航空用钛合金疲劳寿命,在数据和特征量都很丰富的情况下进行测试,为钛合金疲劳寿命提供指导。可以看出,研究人员通常通过选择不同预测模型或以各类方式扩展数据量来提升预测精度。除此之外,也有部分研究人员选择用少量数据进行预测,Srinivasan等^[45]采用XGBoost算法对AlSi10Mg合金疲劳寿命进行预测,研究基于27组实验数据。结果表明,模型在测试集上的决定系数可达0.7。然而,由于数据量有限,模型的泛化能力受到显著限制,难以有效避免过拟合现象。事实上,该研究也表明,过拟合可能导致模型在训练集上的 R^2 值异常升高至0.9,从而掩盖模型在未知数据的真实表现。这一现象表明,在小样本数据条件下,模型的性能评估需谨慎对待,以确保其在独立测试集上的可靠性和普适性。表1列举纯数据驱动疲劳性能预测的部分研究

进展^[39,41-51]。

纯数据驱动方法在疲劳寿命预测领域展现出显著的精度与计算优势,尤其在处理多变量问题和实现实时控制方面表现突出。由表1可以发现,基于纯数据驱动的机器学习方法普遍存在数据量不足的问题。大多数研究的原始数据规模不足300组,即便是少数研究数据量达到千级,但相较于机器学习对大规模数据的需求而言,仍然显得相对有限。这种小样本特征不仅限制模型的泛化能力,也使得模型的预测结果容易产生过拟合,从而难以保证在复杂服役条件下的可靠性。

为缓解这一问题,研究人员尝试多种数据扩展手段。例如,Qian等^[46]基于蒙特卡洛模拟生成大量随机样本,以丰富输入空间的覆盖范围;Liu等^[47]利用参数化模型对有限实验数据进行推算扩展;Song等^[49]采用生成对抗网络与变分自动编码器两种生成式数据增强技术,针对68组超高周疲劳原始实验数据,生成100~500组合成数据。这是因为在机器学习中,数据是决定算法性能的核心要素。任何算法,无论随机森林、XGBoost,还是神经网络,其有效性均严重依赖于数据的支撑。各类算法虽然各有其适用领域(例如,基于决策树的集成算法通常在处理结构化数据时表现优异,而神经网络则在处理图像、文本等非结构化数据方面更具优势),但它们之间并不存在绝对的优劣之分,其适用性取决于与特定数据特征及问题目标的匹配程度。当数据规模不足时,模型的泛化能力和鲁棒性将受到严重制约,此时,无论采用何种算法均难以获得可靠的预测结果。因此,数据扩充已成为弥补数据局限性、提升模型性能的重要手段。

然而,虽然上述方法在一定程度上提升训练数据集规模,但这些“扩充数据”往往缺乏与实验结果等价的物理真实性,存在一定偏差风险。同时,数据驱动模型本身存在“黑箱”特征,缺乏对预测过程的可解释性,这使得扩展数据的不确定性与模型不透明性叠加,进一步加剧结果可信度的挑战。

2.2 物理机制嵌入路径分类

为弥补纯数据驱动方法的不足,结合物理机制的数据驱动方法应运而生,这种方法通过将物理理论融入数据驱动模型,旨在发挥物理知识和数据优势的协同效应,它不仅一定程度上增加机器学习的可解释性,也为数据量不足的问题提供切实可行的解决方案,结合物理知识的机器学习(physics-informed machine learning, PIML)逐渐成为必要且

表 1 基于纯数据驱动疲劳性能预测的研究进展
Table 1 Research progress in fatigue prediction based on purely data-driven approaches

No.	Material	Application	Algorithm	Original data/sets	Extended data	Extended dataset/sets	Reference
1	Titanium alloy	High-temperature components in engines	RF, SVR, AG	2492	None	2492	[41]
2	Titanium alloy	High-temperature components in engines	Graph neural network	571	None	571	[44]
3	High-strength steel	Some connectors, drive shafts	RF, XGBoost, GB	173	None	173	[42]
4	Epoxy polymer	Support structure	XGBoost	81	None	81	[45]
5	Ti60	Turbine blades, compressor blades and so on	Neural network	171	Monte carlo	500/1000	[46]
6	GCr15	Rolling bearings	SVM, ANN, PINN	15	Z parameter	70/110	[47]
7	Hastelloy X	Combustor casing	DNN, SVM	85	None	85	[48]
8	Inconel718	Turbine blades	ANN, RF, SVR	9	GAN, VAE	150	[49]
9	AlSi10Mg	Non-load-bearing parts	ANN, SVR, RF	45	Interpolation method	1222/645/816	[43]
10	Stainless steel 316L	Fuel pipes, cooling systems	Neural network	139	None	139	[50]
11	Ti-6Al-4V	Compressor blades, casings, connecting sections and so on	DBN-BP	250	None	250	[39]
12	Ti-6Al-4V	Compressor blades, casings, connecting sections and so on	RF	27	None	27	[51]

Note: Due to the differences in data scale and distribution, R^2 and RMSE values lack horizontal comparability, so direct comparison of R^2 values from different studies is not conducted.

可行的解决方案。PIML 通过整合物理理论和数据驱动模型,实现两者的优势互补,增强机器学习模型对疲劳损伤过程物理机制的深入理解,从而提高模型的透明度、可解释性、分析能力和响应速度。这种混合模型不仅弥补了传统物理模型在数据不完整性和理想化假设上的局限,也克服了机器学习模型在小样本情况下泛化能力不足的问题,并通过引入物理约束,增强模型的物理一致性,使得模型预测结果更加可靠可信。

结合物理知识的机器学习理念可以追溯至 2015 年 Owhadi 的研究^[52],该工作通过贝叶斯数值分析强调先验知识的关键作用。2018 年, Raissi^[53]首次提出了一种方法论,在算法层面,通过深度神经网络直接近似偏微分方程的解,定义一个深度隐藏物理模型。通过自动微分技术来获取神经网络的导数,这种方法在计算导数时比数值或符号微分更准确高效,这为物理知识结合机器学习应用于疲劳性能预测奠定坚实的基础^[54]。

在疲劳性能的背景下,结合物理知识的机器学习基础是将材料的疲劳行为物理定律,如应力-寿命($S-N$)关系、缺口效应理论等与机器学习模型相

结合。这种方法利用有限的实验数据和深入的物理解,通过在模型训练中引入这些物理约束,使得学习的模型不仅能够准确预测材料在各种加载条件下的疲劳寿命,而且能够保持与物理现象的一致性,从而在数据稀缺的情况下提高预测的准确性和可靠性,并为工程设计提供有力支持。

目前主流的物理知识融入机器学习模型的方法主要包括 3 种方式^[36]:第一,将物理知识融入数据集,即在数据预处理阶段引入物理量或基于物理特征,通过扩展数据量或扩展数据特征量提升预测精度;第二,将物理知识融入模型的中间层,在设计网络结构时考虑物理过程,例如控制神经网络的权重和偏置符号使模型的内部直接与物理现象相关联;第三,将物理知识融入损失函数,通过在训练过程中加入物理定律作为约束,引导模型学习结果与物理规律保持一致。以上 3 类“物理知识融入”路径既可单独使用,也可组合使用。近期研究也提出一些新尝试,例如, Abiria 等^[55]将部分训练后的 ANN 输出引入 3 个并行分支:其一, Basquin 分支采用基于 Basquin 定律激活函数,用于刻画高周疲劳中应力幅值与寿命的关系;其二, Paris 分支引入

修正的 Paris 定律激活函数,并结合 Murakami 模型中缺陷尺寸与裂纹扩展的关系,以反映裂纹扩展的物理机理;其三,非负性分支通过 ReLU 激活函数保证寿命预测结果的物理有效性。通过这种设计,物理约束可直接用于网络输出,既避免传统物理信息神经网络中复杂物理损失函数的构造难题,又确保预测结果与基本力学规律的一致性。

2.2.1 物理知识融入数据集

当前研究中,将物理知识融入数据集主要存在两种有效方式:其一为借助物理知识构造全新的特征量;其二为运用物理知识对数据集进行扩展。

在特征构造领域,Hao 等^[56]在原始特征量(即力学性能、缺口几何参数以及加载条件参数)的基础上,引入了4种物理驱动参数。其中,通过 Basquin 模型从 $S-N$ 曲线获得的无缺口试样参考疲劳寿命 N_{fsd} 表示为:

$$\sigma_{nmax} = \sigma'_f (2N_{fsd})^b \quad (7)$$

式中: σ_{nmax} 为缺口试样的标称最大应力; σ'_f 为疲劳强度系数; b 为疲劳强度指数。此外,基于 Neuber 规则得到的 σ_{rmax} 被选定为第二类物理驱动参数。为充分考量平均应力对相关结果的影响,缺口根部应力比 R_{ro} 也被引入,表示为:

$$R_{ro} = \sigma_{rmin} / \sigma_{rmax} \quad (8)$$

式中: σ_{rmin} 为缺口根部的最小应力。最后,引入 Smith-Watson-Topper (SWT) 能量损伤参数作为第四个物理驱动参数:

$$SWT = \sigma_{rmin} \Delta \epsilon_{rt} / 2 \quad (9)$$

式中:SWT 为损伤参数,用于衡量材料在循环载荷下的疲劳损伤程度; $\Delta \epsilon_{rt}$ 为缺口根部的总应变范围。将上述4种物理驱动参数作为特征量嵌入数据驱动模型中,增强模型预测精度。

Zhang 等^[57]同样使用物理知识构造新的特征量,他们在原始特征量(如加载温度和化学元素)的基础上,通过查阅 ASMEIII-NH 标准,获取 316SS 材料在特定温度下屈服强度值,对于两个特定温度点之间的屈服强度,采用线性插值法计算屈服强度;同时,借助经验公式计算层错能 (stacking fault energy, SFE) 作为物理驱动参数之一,如式(10)所示:

$$\begin{aligned} \gamma_{SFE} = & \gamma^0 + 1.59m_{Ni} - 1.34m_{Mn} + 0.06m_{Mn}^2 - 1.75m_{Cr} + \\ & 0.01m_{Cr}^2 + 15.21m_{Mo} - 5.59m_{Si} - 60.69(m_C + 1.2m_N)^{1/2} + \\ & 26.27(m_C + 1.2m_N) \cdot (m_{Cr} + m_{Mn} + m_{Mo})^{1/2} + \\ & 0.61[m_{Ni} \cdot (m_{Cr} + m_{Mn})]^{1/2} \end{aligned} \quad (10)$$

式中: γ_{SFE} 是室温下的 SFE 值; γ^0 是室温下纯奥氏体铁的 SFE 值,相当于 39 mJ/m^2 ; m_{Ni} 、 m_{Mn} 、 m_{Cr} 、 m_{Mo} 、 m_{Si} 、 m_C 和 m_N 分别为 Ni、Mn、Cr、Mo、Si、C、N 合金元素的质量分数。从 ASMEIII-NH 标准中收集 316SS 材料疲劳设计曲线,考虑调整因子(应力/应变因子为 2,寿命因子为 20),去除其影响后,得到真实疲劳设计曲线,进而确定应变范围与疲劳寿命的关系,如式(11)所示:

$$\Delta \epsilon = A \cdot N^n + B \quad (11)$$

式中: $\Delta \epsilon$ 为应变范围; N 为循环次数; A 、 B 和 n 为材料常数。由此计算得到纯疲劳寿命作为第三类物理驱动特征量。从 ASMEIII-NH 标准中收集 316SS 材料在给定温度下的蠕变断裂曲线,采用 Larson-Miller 模型计算目标温度下的持久断裂寿命,如式(12)所示:

$$P_{LM} = T \cdot (C + \lg t_r) = a \cdot (\lg S)^2 + b \cdot \lg S + c \quad (12)$$

式中: P_{LM} 为拉森-米勒参数; T 为温度; t_r 为蠕变断裂时间; S 为应力; C 为参数,对于 316 奥氏体不锈钢,通常等于 $20^{[58]}$; a 、 b 和 c 为拟合参数。由于数据来自应变控制实验,需要采用拉伸曲线将实验应变幅度转换为应力,以获取蠕变断裂时间作为最后一个物理驱动特征量。将上述这4种特征量作为原始数据输入到经典(如 RF)算法中,其精度均显著高于仅输入纯数据的情况,有力地证明扩展特征量的优势。

除了将物理知识融入特征量以生成新的输入数据外,运用物理知识对原有数据量进行扩展同样是提升模型精度的有效途径。研究表明,除应力振幅和缺陷尺寸外,夹杂位置同样会对结构疲劳寿命产生影响^[59],为此引入参数 D 来描述临界夹杂的相对深度,表示如下:

$$D = \frac{d - d_{inc}}{d} = 1 - \frac{d_{inc}}{d} \quad (13)$$

式中: d 为试样直径; d_{inc} 为夹杂物与试样表面的最短距离。由于 d_{inc} 值范围在 0 至 0.5 之间,因此参数 D 的可能值为 0.5~1。进一步结合参数 D ,提出了参数 Z ,用于描述夹杂物的相对位置在超高周疲劳状态下对疲劳寿命的影响:

$$Z = \sigma_a \left(\sqrt{S_{area}} \right)^{1/6} D^\beta \quad (14)$$

式中: σ_a 为应力振幅; S_{area} 为夹杂物面积; β 为材料常数。

Zhu 等^[60]考虑夹杂物的形状,引入形状因子 Y (取值范围在 0~1 之间)对式(14)进行如下改进:

$$Z = Y\sigma_a(\sqrt{S_{\text{area}}})^{1/6} D^\beta \quad (15)$$

该团队进一步采用 Z 参数结合应力幅值、夹杂物尺寸、夹杂物相对深度及材料常数 β 来表征夹杂物相对位置对疲劳寿命的影响,以丰富原始数据^[61]。具体方法为在原始数据测试中温度和应力比恒定的情况下,运用变量控制法,每次仅改变应力幅值、夹杂物尺寸(以 $\sqrt{S_{\text{area}}}$ 表示)和 D 中一个变量,依据改进后的疲劳寿命函数,在实验数据的取值区间内进行计算,得到相应的疲劳寿命值,从而扩展得到 70 组数据。之后,基于这 70 组数据,在相同区间内再次扩展,得到 110 组数据。通过计算皮尔逊相关系数(Pearson correlation coefficient, PCC)并绘制相关系数矩阵热图,对比原始数据集和两个扩展数据集不同疲劳寿命相关参数间的相关性,验证扩展数据的可靠性,为后续机器学习模型的建立提供有效数据。

2.2.2 物理知识融入模型

物理知识也可以通过神经网络的中间层来纳入模型结构,通过控制神经网络内权重和偏差的符号或引入特定的网络层与节点来表示物理过程。

Chen 等^[34] 提出概率物理引导神经网络(probabilistic physics-guided neural network, PPgNN)。在网络架构上,对 PPgNN 进行创新设计,在输出层设置两个神经元,其中一个负责预测疲劳寿命的均值,另一个用于预测标准差,以此更全面地描述疲劳寿命的分布特征。同时,为了确保模型结果符合物理规律,即疲劳寿命标准差通常随应力降低而增大、 $S-N$ 曲线曲率随应力降低而减小的特性,PPgNN 对权重和偏差施加约束,让模型在训练过程中严格遵循这些物理规律,有效避免不合理的预测结果,如图 4(a)所示。经过多种金属和复合材料的疲劳数据集验证,PPgNN 在预测疲劳寿命均值和方差方面表现卓越,能够精准绘制 $P-S-N$ 曲线,并且大部分数据点位于 95% 置信区间(confidence interval, CI)内,如图 4(b)所示,充分证明其良好的效果。

同样地,Chen 等^[62] 对 PPgNN 进行针对性改进,引入选择性神经元,将其应用于选区激光熔化(selective laser melting, SLM) Ti-6Al-4V 合金疲劳性能分析中。考虑到实际收集的数据集中超过半数存在数据缺失的情况,每个选择性神经元由一个具有 \tanh 激活函数的隐藏神经元、一个指示输入是否有效的输入神经元 r_k 以及一个乘数组成。当

输入数据 r_k 存在时, $r_k=1$, 该选择性神经元会积极参与网络输出的计算;当 r_k 缺失时, $r_k=0$, 该神经元如同输入不存在一样,其连接的权重和偏差不会被更新,如图 4(c)所示。通过这种方式,充分利用所有可用数据,有效解决了传统神经网络对数据完整性的依赖问题。他们收集大量实验数据,这些数据涵盖不同扫描速度、激光功率、间距、层厚、热处理温度和时间等工艺参数条件下的实验结果。经过对改进后的 PPgNN 模型进行严格验证,结果显示该模型在预测 SLM 的 Ti-6Al-4V 合金疲劳寿命方面表现出色,能够合理量化疲劳寿命的均值和分布情况,如图 4(d)所示。

Zhou 等^[63] 受到 Basquin-Coffin-Manson(BCM)方程的启发,提出一种物理引导的神经网络建模方法。在 ANN 模型的最后一个隐藏层设置两个神经元,并对这两个神经元的权重和偏差值符号进行严格约束。具体而言,通过借鉴 BCM 方程中疲劳寿命与应变的关系,将疲劳寿命分布的先验物理知识巧妙引入 ANN 模型,从而构建物理引导的神经网络(physics-informed neural network, PINN)。经过一系列实验验证, PINN 模型在多轴疲劳寿命预测方面表现出优异性能,其平均相对误差和均方根误差明显降低。在预测不规则加载情况下的疲劳寿命时, PINN 模型同样能够取得令人满意的结果,展现良好的泛化能力。

在单晶合金方面, Acharya 等^[64] 使用包含 ε_r 、 $\lg N$ 等多个与镍基高温合金热机械疲劳紧密相关的物理量节点作为输入层,通过不同连线对权重和偏置施加约束,例如,应变范围对应变-寿命曲线二阶导数非负、应变范围对标准差导数非正等物理约束,以此确保模型输出契合镍基高温合金热机械疲劳相关的物理规律。然而,值得注意的是,该研究团队构建的模型仅聚焦于 $\langle 001 \rangle$ 取向的镍基高温合金,对于晶体取向在更广泛范围内对热机械疲劳寿命的影响未能充分考量。为弥补这一不足,后续研究中,研究人员引入归一化弹性模量作为关键输入特征^[65]。镍基高温合金具有显著的弹性模量各向异性,在室温下, $\langle 001 \rangle$ 方向杨氏模量约为 125 GPa,而 $\langle 111 \rangle$ 方向杨氏模量高达 294 GPa,这种差异在不同温度下均有体现。研究人员利用这一特性,构建了 $\langle 001 \rangle$ 方向与加载方向 $\langle hkl \rangle$ 杨氏模量的比值 E_{ratio} , 表示如下:

$$E_{\text{ratio}} = \frac{E_{\langle 001 \rangle}}{E_{\langle hkl \rangle}} \quad (16)$$

式中: $E_{\langle 001 \rangle}$ 和 $E_{\langle hkl \rangle}$ 分别为 $\langle 001 \rangle$ 方向与加载

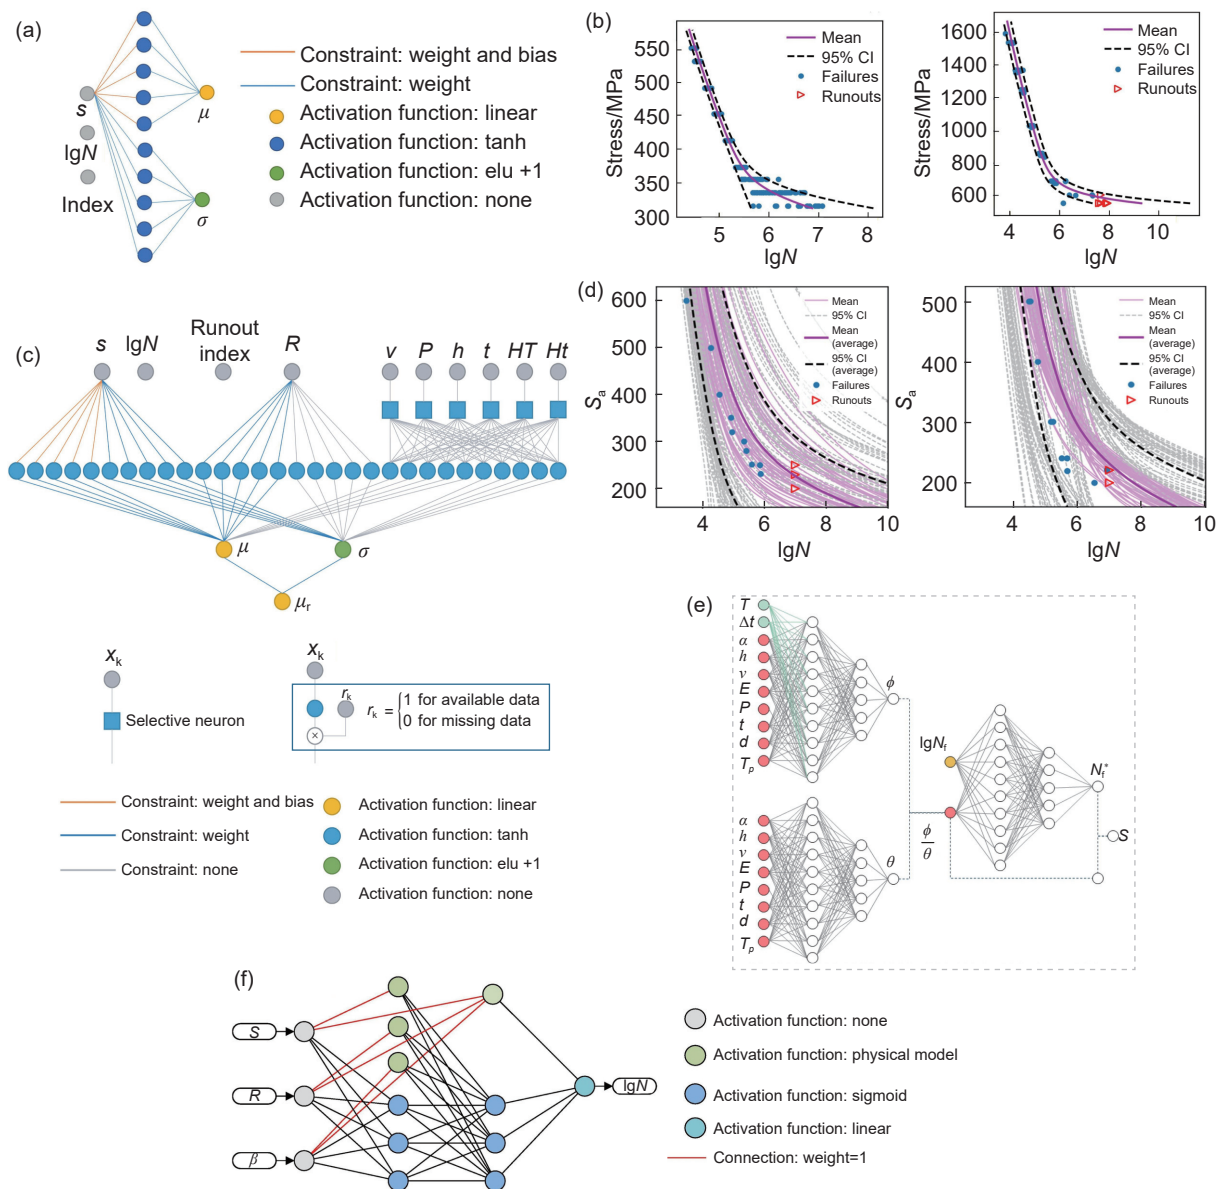


图4 (a)对权重和偏置约束的概率神经网络结构^[34]; (b)采用两种不同材料验证PPgNN^[34]; (c)考虑缺失数据的SLM的Ti-6Al-4V疲劳分析PPgNN^[62]; (d)PPgNN预测的均值及其分布^[62]; (e)PINN结构^[66]; (f)物理先验知识作为激活函数结构图^[67]

Fig. 4 (a) PPgNN structure with weight and bias constraints^[34]; (b) validation of PPgNN using two different materials^[34]; (c) PPgNN-based fatigue analysis of SLM-fabricated Ti-6Al-4V alloy considering missing data^[62]; (d) mean value and its distribution predicted by PPgNN^[62]; (e) PINN structure^[66]; (f) structure diagram of physical prior knowledge as an activation function^[67]

方向 $\langle hkl \rangle$ 杨氏模量。通过该表达式, 能够将晶体取向对疲劳寿命的影响进行量化。以不同取向的单晶为例, 该比值的变化能直观反映出不同取向在相同应变条件下, 因弹性模量不同导致疲劳寿命差异, 为模型提供更具物理意义的输入信息。优化后的模型对预测不同晶体取向和测试条件下镍基高温合金的热机械疲劳寿命表现更为精确。

上述提及的概率物理神经网络, 本质上是通过神经元权重与偏置的调控, 达成契合先验物理知识的目标。除此之外, Ciampaglia等^[66]基于工艺参数主要影响缺陷尺寸和微观结构, 热处理属性主

要影响微观结构进而影响疲劳响应这一物理证据, 设计了一种新型模块化架构。将输入参数(如构建方向、扫描距离、扫描速度、热处理持续时间和温度等工艺参数)分别输入两个独立的神经网络分支。一个分支用于缺陷估计, 预测这些参数对缺陷尺寸的影响; 另一个分支用于微观结构估计, 预测微观结构强度参数, 如图4(e)所示。然后, 根据Murakami方程在自定义层中计算两个分支结果的比值, 并结合疲劳寿命 N_f 相关的函数计算预测疲劳强度 S_a , 从而在中间层实现将工艺参数与微观结构属性的先验关系融入网络, 让网络学习到这些变

量对疲劳曲线形态特征的影响,使模型预测更符合物理规律。

在图4(f)所示的神经网络架构中,Chen等^[67]使激活函数以物理模型的形式加到神经网络中间层。从输入层传来的应力水平 S 、应力比 R 、其他影响因素 β 等数据,进入隐藏层。隐藏层中存在两种神经元,即普通的Sigmoid神经元和嵌入物理模型作为激活函数的物理神经元。物理模型包含Basquin关系、Walker平均应力模型等物理知识。当数据到达物理神经元时,物理模型作为激活函数对输入数据进行处理,例如根据Basquin关系和Walker模型计算应力与疲劳寿命的关系,产生一个基于物理知识的输出结果。这些结果会和Sigmoid神经元的输出一起,继续向后传递到下一层神经元。因此,通过将物理模型作为激活函数嵌入隐藏层神经元,实现在神经网络中间层融入物理知识,进而辅助疲劳寿命预测。

2.2.3 物理知识融入损失函数

在材料疲劳研究领域,将物理知识融入损失函数也是提升模型性能的关键策略,这是研究人员最常采用的方法之一,但选用的具体物理公式往往各不相同。Dong等^[68]利用 M 积分计算等效损伤面积统一表征多缺陷的影响,其疲劳模型表示如下:

$$\frac{dA_D}{dN} = \lambda(\Delta M)^\varepsilon \quad (17)$$

式中: A_D 为等效损伤面积; ΔM 为等效应力强度因子范围; λ 和 ε 表示材料的拟合参数; N 为循环次数。在构建基于断裂力学的物理信息神经网络时,依据该模型构建物理损失函数 L_{FP} 表达如下:

$$L_{FP} = \sqrt{\frac{1}{n} \sum_{i=1}^n \left\{ \lg \frac{N_f^i}{A_0^i} + \lg \left[\lambda(\xi - 1)(\Delta M_0)^\xi \right] \right\}^2} \quad (18)$$

式中: N_f^i 为第 i 个样本的预测疲劳寿命; A_0^i 为第 i 个样本的初始等效面积; ξ 为损伤指数; ΔM_0 为初始 M 积分的范围。该函数与数据相关损失函数相结合,以调整神经网络训练,有效反映多缺陷疲劳损伤能量演化,精准引导神经网络训练的梯度下降,提高多缺陷材料疲劳寿命预测的准确性,填补多缺陷材料疲劳评估模型的空白。Feng等^[69]围绕增材制造材料疲劳寿命预测展开,将断裂力学中裂纹与缺陷导致应力集中及疲劳寿命遵循对数正态分布^[70]等物理知识融入损失函数。在多任务物理信息分支神经网络框架里,运用PyTorch自动微分计算疲劳寿命均值和标准差对最大应力的一阶导数,作为物理约束纳入损失函数,表示为:

$$\text{Loss}_{\text{physical},\mu} = \sum_{i=1}^n \sqrt{\max\left(0, \frac{\partial \mu_{\text{pre},i}}{\partial S}\right)^2} \quad (19)$$

式中: $\mu_{\text{pre},i}$ 是神经网络第一阶段预测的平均值; S 为应力。PINN的损失函数一般包括两部分,即神经网络损失和物理损失,这种方式有效处理增材制造零件中微观缺陷引起的疲劳寿命分散问题,提升模型预测的可靠性和准确性,克服传统数据驱动方法的局限性。Liao等^[71]聚焦疲劳裂纹扩展剩余寿命预测,该工作基于线性弹性断裂力学的Paris定律^[72],把裂纹扩展驱动力与疲劳裂纹扩展速率的关系融入损失函数。通过自动微分获取神经网络预测疲劳循环数对裂纹长度的梯度,分别构建包含数据损失和物理知识损失的总损失函数 Loss 和 Loss_p ,表示如下:

$$\text{Loss} = \lambda_1 \text{Loss}_D + \lambda_2 \text{Loss}_p \quad (20)$$

$$\text{Loss}_p = \text{MSELoss} \left(\frac{1}{\frac{\partial NN}{\partial a}}, C(\Delta K)^m \right) \quad (21)$$

式中: Loss_D 为数据损失; Loss_p 为物理损失; λ_1 和 λ_2 均为权重系数,用来平衡数据与物理量的重要性; $\frac{\partial NN}{\partial a}$ 为裂纹扩展速率; ΔK 为应力强度因子范围; C 和 m 为材料常数。这不仅利用物理模型直接约束网络梯度,还在训练中反向识别物理模型参数,提高疲劳裂纹扩展剩余寿命预测的准确性和模型的外推能力,为疲劳裂纹剩余寿命预测提供更可靠的方法。Liu等^[73]收集11种材料(如TC11钛合金、GH4169高温合金等)共99条数据,将Miner模型^[74]、Zhu模型、Yu模型及Liu模型这4种经典的高低周复合疲劳预测物理模型作为约束项嵌入损失函数,使得总损失由两部分构成:一是神经网络寿命预测值与实验观测值的误差,保障模型对数据的拟合能力;二是神经网络预测值与上述物理模型计算结果的误差,并通过权重参数 ω 调控物理约束的强度。结果表明,加入物理知识的机器学习算法预测值主要分布在 ± 2 倍寿命分散带内,而修正的SWT预测值大多偏离该分散带,预测精度相对较低。因此,在疲劳寿命预测中,基于物理知识的机器学习算法优于传统模型。

多数情况下,这3种方法需要结合使用,例如Wu等^[75]引入物理公式作为约束来调整损失函数,将与缺陷相关的物理知识(如缺陷尺寸、位置、形态、取向等影响疲劳寿命的关系)纳入物理信息神

神经网络,定义权重的允许范围,确保训练结果符合物理规律,以此建立3D缺陷与高周疲劳性能的关系。同样地,Huang等^[76]一方面构建包含Walker损失项的疲劳裂纹扩展速率损失函数,将Walker裂纹扩展模型^[77]融入损失函数引入学习偏差;另一方面把物理模型嵌入隐藏层的激活函数,引入归纳偏差,使网络学习与裂纹扩展物理规律相关模式,从而预测铝合金腐蚀疲劳裂纹扩展速率。Jiang等^[27]把与316不锈钢低周疲劳寿命相关的物理知识(如应变幅值、应变率、温度对疲劳寿命的影响关系)以偏导数形式作为物理约束,嵌入到损失函数中,并将堆垛层错能作为输入特征,同时利用Sigmoid函数变换不等式调整权重范围,使模型在训练时遵循物理原理,进而实现对316不锈钢低周疲劳寿命的准确预测。

3 现有研究的局限和不足

近年来,基于机器学习的疲劳寿命预测逐渐成为航空材料领域的热点方向,研究人员试图通过数据驱动方法提升疲劳寿命预测的精度与效率,服务于航空装备的可靠性评估与维护决策。尽管现有研究已取得显著进展,但仍存在局限和不足,制约其在工程实践中的广泛应用。

3.1 数据层面的局限性

航空材料疲劳寿命预测高度依赖多源异构数据(如微观组织图像、宏观力学性能参数、服役载荷谱、环境温湿度等),但现有数据体系存在显著瓶颈。

(1)数据量稀缺且分布不均:疲劳测试(尤其超高周疲劳测试)成本高昂且周期长(可能长达数月甚至数年),导致公开数据库样本量普遍较小(多为数百至数千组),难以覆盖材料在实际服役中可能遇到的复杂工况(如变幅载荷、多轴应力、腐蚀环境等)。小样本场景下,机器学习模型易陷入过拟合,泛化能力受限^[78]。

(2)数据质量参差不齐:不同测试机构的疲劳测试质量控制(如载荷精度、环境控制、试样制备工艺等)存在差异,可能导致数据噪声多、一致性差。例如,高温超高周疲劳测试可能因设备载荷和温度控制精度或操作人员经验不同产生误差,直接影响模型输入的特征可靠性。

(3)关键失效特征的标注缺失:疲劳失效常伴随裂纹萌生-扩展的非线性过程,但现有数据多聚焦于宏观寿命(如断裂时的循环次数),缺乏对微观失效特征(如微裂纹起始位置、初始缺陷、疲劳条

带等)的精细标注,导致模型难以捕捉“黑箱”失效过程的物理本质。

3.2 复杂失效机制的信息挖掘不足

航空材料的疲劳失效涉及多尺度、多物理场耦合机制(如位错运动、晶界滑移、氧化腐蚀、应力集中等),目前机器学习模型依赖设计参数(如应力幅、平均应力、表面粗糙度等),难以全面表征失效过程的关键信息。

(1)多尺度特征的融合难度大:微观尺度(如晶粒尺寸、夹杂物分布等)、细观尺度(如裂纹尖端应力场等)与宏观尺度(如构件几何形状等)的特征需跨尺度关联,但现有技术(如基于图像的卷积神经网络等)多仅针对单一尺度(如宏观断口图像等),缺乏跨尺度特征的深度关联建模能力^[79]。

(2)动态演化特征的捕捉不足:疲劳过程中材料性能(如残余应力、微观结构等)会随循环次数动态退化,但现有模型多基于静态数据训练,难以直接建模“时间序列”或“循环次数”维度的动态变化(如裂纹扩展速率的非线性突变等)。

(3)隐性失效模式的表征缺失:部分失效模式(如氢脆、应力腐蚀等)与环境因素(如湿度、温度波动等)高度相关,但环境参数(如局部微环境等)的实时监测与量化难度大,导致模型难以将环境因素与材料失效建立直接关联^[80]。

3.3 模型可解释性与工程应用信任度不足

航空领域对安全性要求极高,模型的可解释性是工程应用的前提,但现有机器学习模型(尤其深度学习)的“黑箱”特性严重限制其可信度:一些机器学习模型(如全连接神经网络、随机森林等)虽然能够通过高精度拟合数据得到寿命预测结果,但无法清晰解释“哪些特征(如晶粒尺寸、载荷幅值等)主导寿命衰减”、“不同特征的贡献权重如何”等关键问题,导致工程技术人员难以验证模型是否符合经典疲劳理论,机器学习模型与物理机制的融合还存在不足。另外,疲劳寿命预测本质上是概率统计问题,受材料分散性、环境波动等影响,但多数模型仅输出单点预测值,缺乏对预测结果的置信区间(如95%置信度的寿命)估计,无法满足航空工程中对“可靠性评估”的需求。

3.4 复杂工况适应性不足

航空材料实际服役环境复杂(如高温、高压、交变载荷、腐蚀介质等),现有模型对多物理场耦合效应的建模能力有限,多数研究聚焦于单一因素(如机械载荷或温度等)对疲劳寿命的影响,而实际服役中多因素(如“热-力-化学耦合”等)的协同作用

会显著改变材料失效机理(如腐蚀坑加速裂纹萌生),但现有模型难以量化多因素的交互效应。此外,航空装备在服役中可能经历变幅或随机载荷(如起飞-巡航-降落循环)、突发外物冲击(如鸟撞)等动态工况,现有机器学习模型多基于恒定或简单变幅载荷训练,难以实时适应工况突变后的寿命预测需求。

4 结语和展望

本工作综述基于机器学习的航空材料疲劳性能预测的研究进展,重点探讨机器学习在提高预测精度、处理复杂数据和实际应用中的潜力和挑战。通过详细分析纯数据驱动和结合物理知识的机器学习预测模型,展示机器学习技术在航空材料疲劳性能预测领域的广泛应用和显著优势。特别是,结合物理知识的机器学习方法通过整合物理理论和数据驱动模型,不仅提高模型的物理一致性和预测准确性,还增强模型的透明度和可解释性,为解决航空材料疲劳性能预测中的复杂问题提供新思路和新方法。

基于机器学习的航空材料疲劳寿命预测虽已突破传统方法的精度瓶颈,但其发展仍受限于数据、模型、验证等多维度挑战。未来需重点突破多源异构数据(如跨尺度数据融合、小样本学习等)的高效利用、物理约束(如结合连续损伤力学的深度学习)的可解释模型构建、多物理场耦合(如变工况跟踪、环境因素嵌入等)的动态建模等关键技术,并推动工程验证标准的完善,才能真正实现从“实验室研究”到“工程实战”的跨越。基于机器学习的航空材料疲劳寿命预测要实现这一跨越,需围绕数据、模型、验证三大核心痛点,结合多学科交叉技术,重点突破以下研究方向:

(1)构建标准化、高可信度的疲劳数据集。疲劳寿命预测所依赖的算法工具与计算资源日益丰富,疲劳数据本身仍是制约建模质量的关键瓶颈。目前缺乏覆盖多材料、多加载、多尺度条件的高质量疲劳数据集,材料来源、实验标准、数据格式、预处理手段高度异构,难以实现跨材料、跨模型的有效迁移与比较。构建可信、系统、可共享、具备代表性的数据集,有助于提升模型精度与泛化能力,进而促进整个行业疲劳寿命预测能力系统提升。

(2)建立面向任务的物理知识自动融合机制。当前物理知识嵌入模型的方式多依赖领域专家经验,需人工选择与任务相关的物理机制,这在一定

程度上限制方法的灵活性与通用性。未来研究应致力于发展具备自适应能力的物理信息融合框架,能够根据不同材料、载荷条件与寿命机制,自动识别并嵌入合适的物理约束或演化规律,从而提升模型的泛化能力与解释能力。这一方向需要在数据驱动学习机制与物理模型间建立有效的桥梁,推动“从物理启发到物理建模”的智能化过渡。

(3)推动面向复杂工况和结构件层级疲劳预测。现阶段大多数研究聚焦于单一工况和材料层面的疲劳寿命预测,尚未充分考虑复杂工况、构件几何结构、应力集中等因素的影响。未来应加强材料-构件-系统一体化建模思路,融合有限元仿真结果、无损检测信息与材料本构模型,实现对复杂构件服役寿命的精细预测与动态更新。这不仅有助于航空产品的服役安全评估与维修优化,也是构建智能化设计-评估-运维闭环体系的核心技术基础。

随着人工智能与大数据技术持续发展,机器学习在航空材料疲劳寿命预测的应用前景将愈加广阔,未来有望为航空装备的可靠性设计和安全评估提供更加坚实的技术支撑。

参考文献:

- [1] 王国荣. 无损检测在航空装备维修中的应用与发展[J]. 模具制造, 2025, 25(4): 234-236.
WANG G R. Application and development of non-destructive testing in aviation equipment maintenance[J]. Die & Mould Manufacturing, 2025, 25(4): 234-236.
- [2] 刘巧沐, 李园春. 航空发动机材料及工艺发展浅析[J]. 航空动力, 2021(6): 9-12.
LIU Q M, LI Y C. Analysis to development of aero engine materials and processes[J]. Journal of Aerospace Power, 2021(6): 9-12.
- [3] 代定强, 周轩, 董雷霆. 数字工程与数字孪生在航空疲劳与结构完整性领域的研究进展与展望[J]. 航空学报, 2025, 46(19): 19-40.
DAI D Q, ZHOU X, DONG L T. Research progress and prospect of digital engineering and digital twin in field of aeronautical fatigue and structural integrity[J]. Acta Aeronautica et Astronautica Sinica, 2025, 46(19): 19-40.
- [4] AVATEFFAZELI M, WEBSTER G, TAHMASBI K, et al. Very high cycle fatigue at elevated temperatures: a review on high temperature ultrasonic fatigue[J]. Journal of Space Safety Engineering, 2022, 9(4): 488-512.
- [5] YANG K, HE C, HUANG Q, et al. Very high cycle fatigue behaviors of a turbine engine blade alloy at various stress ratios[J]. International Journal of Fatigue, 2017, 99: 35-43.

- [6] 陶春虎, 习年生, 钟培道. 航空装备失效典型案例分折[M]. 北京: 国防工业出版社, 1998.
TAO C H, XI N S, ZHONG P D. Typical case analysis of aviation equipment failure[M]. Beijing: National Defense Industry Press, 1998.
- [7] 陈新, 许巍, 何玉怀. 基于 DIC 的超高频振动疲劳试样动态全场应变测量方法[J]. *实验力学*, 2021, 36(5): 677-685.
CHEN X, XU W, HE Y H. Ultra-high frequency vibration fatigue dynamic strain field measurement based on digital image correlation method[J]. *Journal of Experimental Mechanics*, 2021, 36(5): 677-685.
- [8] OH B. The exponential law of endurance tests[C]//Proceeding of the American Society for Testing and Materials. Pennsylvania: American Society for Testing and Materials, 1910, 10: 625-630.
- [9] 魏艳娇, 向清怡. 基于机器学习的焊接接头疲劳寿命预测方法综述[J]. *兵器材料科学与工程*, 2025, 48(3): 183-190.
WEI Y J, XIANG Q Y. Review of machine learning-based fatigue life prediction methods for welded joints[J]. *Ordnance Material Science and Engineering*, 2025, 48(3): 183-190.
- [10] 杨晓光, 谭龙, 郝文琦, 等. 数据驱动的高温结构强度与寿命评估: 进展与挑战[J]. *推进技术*, 2023, 44(5): 1-18.
YANG X G, TAN L, HAO W Q, et al. Data-driven structural strength and life assessment of high temperature structure: progresses and challenges[J]. *Journal of Propulsion Technology*, 2023, 44(5): 1-18.
- [11] 胡雅楠, 余欢, 吴圣川, 等. 基于机器学习的增材制造合金材料力学性能预测研究进展与挑战[J]. *力学学报*, 2024, 56(7): 1892-1915.
HU Y N, YU H, WU S C, et al. Machine learned mechanical properties prediction of additively manufactured metallic alloys: progress and challenges[J]. *Chinese Journal of Theoretical and Applied Mechanics*, 2024, 56(7): 1892-1915.
- [12] 牛昌海, 孙倩, 郑佳, 等. 入水温度和时效参数对 7075 铝合金析出和力学性能的影响[J]. *材料工程*, 2025, 53(4): 35-42.
NIU C H, SUN Q, ZHENG J, et al. Effect of water entry temperature and aging parameters on precipitation and mechanical properties of 7075 aluminum alloy[J]. *Journal of Materials Engineering*, 2025, 53(4): 35-42.
- [13] 祝亚亮, 雍维, 杨杰, 等. 热力学计算与机器学习相结合逆向设计镍基高温合金[J]. *材料工程*, 2024, 52(6): 167-176.
ZHU Y L, YONG W, YANG J, et al. Reverse design of nickel-based superalloys based on thermodynamic calculation and machine learning[J]. *Journal of Materials Engineering*, 2024, 52(6): 167-176.
- [14] 高威, 周希晨, 朱前勇, 等. 面向极端载荷环境用高熵合金的研究进展[J]. *航空材料学报*, 2024, 44(5): 154-173.
GAO W, ZHOU X C, ZHU Q Y, et al. Research progress on high-entropy alloys for extreme loading environments[J]. *Journal of Aeronautical Materials*, 2024, 44(5): 154-173.
- [15] 李桌汉, 有移亮, 赵子华, 等. 人工智能技术在失效分析领域的应用[J]. *航空材料学报*, 2024, 44(5): 1-16.
LI Z H, YOU Y L, ZHAO Z H, et al. Application of artificial intelligence technology in failure analysis[J]. *Journal of Aeronautical Materials*, 2024, 44(5): 1-16.
- [16] 高田创, 高建宝, 李谦, 等. 机器学习驱动难熔高熵合金设计的现状与展望[J]. *材料工程*, 2024, 52(1): 27-44.
GAO T C, GAO J B, LI Q, et al. Current status and prospects in machine learning-driven design for refractory high-entropy alloys[J]. *Journal of Materials Engineering*, 2024, 52(1): 27-44.
- [17] 甘磊, 吴昊, 仲政. 数据驱动的金属疲劳寿命模型研究进展[J]. *力学进展*, 2025, 55(1): 30-79.
GAN L, WU H, ZHONG Z. Advances in data-driven models for fatigue life prediction of metallic materials[J]. *Advances in Mechanics*, 2025, 55(1): 30-79.
- [18] CHEN S N, BAI Y T, ZHOU X H, et al. A deep learning dataset for metal multiaxial fatigue life prediction[J]. *Scientific Data*, 2024, 11: 1027.
- [19] 蔡培, 袁辉, 徐鹤鸣, 等. 基于小样本量的航空发动机材料高低周复合疲劳 $P-S-N$ 曲线优化方法[J]. *材料工程*, 2024, 52(10): 117-126.
CAI P, YUAN H, XU H M, et al. Optimization method of combined high and low cycle fatigue $P-S-N$ curve for aeroengine materials with small size sample[J]. *Journal of Materials Engineering*, 2024, 52(10): 117-126.
- [20] 张聪, 刘杰, 解树一, 等. 高通量计算与机器学习驱动高熵合金的研究进展[J]. *材料工程*, 2023, 51(3): 1-16.
ZHANG C, LIU J, XIE S Y, et al. Research progress in high-entropy alloys driven by high throughput computation and machine learning[J]. *Journal of Materials Engineering*, 2023, 51(3): 1-16.
- [21] MIZUNO Y, HOSOI A, KOSHITA H, et al. Fatigue life prediction of composite materials using strain distribution images and a deep convolution neural network[J]. *Scientific Reports*, 2024, 14(1): 25418.
- [22] HORŇAS J, BĚHAL J, HOMOLA P, et al. Modelling fatigue life prediction of additively manufactured Ti-6Al-4V samples using machine learning approach[J]. *International Journal of Fatigue*, 2023, 169: 107483.
- [23] PARMAR A, KATARIYA R, PATEL V. A review on

- random forest: an ensemble classifier[C]//International Conference on Intelligent Data Communication Technologies and Internet of Things. Singapore: Springer Singapore, 2018: 758-763.
- [24] GUO J Y, ZAN X P, WANG L, et al. A random forest regression with Bayesian optimization-based method for fatigue strength prediction of ferrous alloys[J]. *Engineering Fracture Mechanics*, 2023, 293: 109714.
- [25] CHEN T. XGBoost: a scalable tree boosting system[D]. New York: Cornell University, 2016.
- [26] CHEN T, HE T, BENESTY M, et al. XGBoost: extreme gradient boosting[J]. *R Package Version*, 2015, 1(4): 1-4.
- [27] JIANG L F, HU Y N, LIU Y X, et al. Physics-informed machine learning for low-cycle fatigue life prediction of 316 stainless steels[J]. *International Journal of Fatigue*, 2024, 182: 108187.
- [28] GOODFELLOW I, BENGIO Y, COURVILLE A. Deep learning[M]. Massachusetts: The MIT Press, 2016.
- [29] YANG J Y, KANG G Z, LIU Y J, et al. A novel method of multiaxial fatigue life prediction based on deep learning[J]. *International Journal of Fatigue*, 2021, 151: 106356.
- [30] MCCULLOCH W S, PITTS W. A logical calculus of the ideas immanent in nervous activity[J]. *The Bulletin of Mathematical Biophysics*, 1943, 5(4): 115-133.
- [31] HAN J, MORAGA C. The influence of the sigmoid function parameters on the speed of backpropagation learning[C]//International Workshop on Artificial Neural Networks. Berlin: Springer-Verlag, 1995: 195-201.
- [32] YIN X, GOUDRIAAN J A N, LANTINGA E A, et al. A flexible sigmoid function of determinate growth[J]. *Annals of Botany*, 2003, 91(3): 361-371.
- [33] CHEN Y P, DAI X Y, LIU M C, et al. Dynamic relu[C]//European Conference on Computer Vision. Cham: Springer International Publishing Switzerland/Springer Nature Switzerland AG, 2020: 351-367.
- [34] CHEN J, LIU Y M. Probabilistic physics-guided machine learning for fatigue data analysis[J]. *Expert Systems with Applications*, 2021, 168: 114316.
- [35] ZHANG X C, GONG J G, XUAN F Z. A deep learning based life prediction method for components under creep, fatigue and creep-fatigue conditions[J]. *International Journal of Fatigue*, 2021, 148: 106236.
- [36] WANG H J, LI B, GONG J G, et al. Machine learning-based fatigue life prediction of metal materials: perspectives of physics-informed and data-driven hybrid methods[J]. *Engineering Fracture Mechanics*, 2023, 284: 109242.
- [37] ZHAN Z X, HU W P, MENG Q C. Data-driven fatigue life prediction in additive manufactured titanium alloy: a damage mechanics based machine learning framework[J]. *Engineering Fracture Mechanics*, 2021, 252: 107850.
- [38] BERGSTRA J, BENGIO Y. Random search for hyperparameter optimization[J]. *The Journal of Machine Learning Research*, 2012, 13(1): 281-305.
- [39] JAMES G, WITTEN D, HASTIE T, et al. An introduction to statistical learning[M]. New York: Springer-Verlag New York, Inc., 2013.
- [40] JIA Y F, FU R, LING C, et al. Fatigue life prediction based on a deep learning method for Ti-6Al-4V fabricated by laser powder bed fusion up to very-high-cycle fatigue regime[J]. *International Journal of Fatigue*, 2023, 172: 107645.
- [41] ZHU S Y, ZHANG Y, CHEN X, et al. A multi-algorithm integration machine learning approach for high cycle fatigue prediction of a titanium alloy in aero-engine[J]. *Engineering Fracture Mechanics*, 2023, 289: 109485.
- [42] LIU X L, ZHANG S Y, CONG T, et al. Very high-cycle fatigue life prediction of high-strength steel based on machine learning[J]. *Fatigue & Fracture of Engineering Materials & Structures*, 2024, 47(3): 1024-1035.
- [43] SHI T, SUN J Y, LI J H, et al. Machine learning based very-high-cycle fatigue life prediction of AlSi10Mg alloy fabricated by selective laser melting[J]. *International Journal of Fatigue*, 2023, 171: 107585.
- [44] ZHU S Y, ZHANG Y, ZHU B C, et al. High cycle fatigue life prediction of titanium alloys based on a novel deep learning approach[J]. *International Journal of Fatigue*, 2024, 182: 108206.
- [45] SRINIVASAN D V, MORADI M, KOMNINOS P, et al. A generalized machine learning framework to estimate fatigue life across materials with minimal data[J]. *Materials & Design*, 2024, 246: 113355.
- [46] QIAN H J, HUANG Z Y, XU Y T, et al. Very high cycle fatigue life prediction of Ti60 alloy based on machine learning with data enhancement[J]. *Engineering Fracture Mechanics*, 2023, 289: 109431.
- [47] LIU Y K, FAN J L, ZHU G, et al. Data-driven approach to very high cycle fatigue life prediction[J]. *Engineering Fracture Mechanics*, 2023, 292: 109630.
- [48] LEI L M, LI B, WANG H J, et al. High-temperature high-cycle fatigue performance and machine learning-based fatigue life prediction of additively manufactured Hastelloy X[J]. *International Journal of Fatigue*, 2024, 178: 108012.
- [49] SONG Z X, PENG J L, ZHU L N, et al. High-cycle fatigue life prediction of additive manufacturing Inconel 718 alloy via machine learning[J]. *Materials*, 2025,

- 18(11): 2604.
- [50] ZHANG M, SUN C N, ZHANG X, et al. High cycle fatigue life prediction of laser additive manufactured stainless steel: a machine learning approach[J]. *International Journal of Fatigue*, 2019, 128: 105194.
- [51] 谢沛东, 谢德巧, 周凯, 等. 基于疲劳源孔隙的增材制造 Ti6Al4V 疲劳寿命预测[J]. *激光与光电子学进展*, 2024, 61(21): 179-187.
- XIE P D, XIE D Q, ZHOU K, et al. Fatigue life prediction of additive manufacturing Ti6Al4V based on fatigue source pore[J]. *Laser & Optoelectronics Progress*, 2024, 61(21): 179-187.
- [52] OWHADI H. Bayesian numerical homogenization[J]. *Multiscale Modeling & Simulation*, 2015, 13(3): 812-828.
- [53] RAISSI M. Deep hidden physics models: deep learning of nonlinear partial differential equations[J]. *Journal of Machine Learning Research*, 2018, 19(25): 1-24.
- [54] RAISSI M, PERDIKARIS P, KARNIADAKIS G E. Physics-informed neural networks: a deep learning framework for solving forward and inverse problems involving nonlinear partial differential equations[J]. *Journal of Computational Physics*, 2019, 378: 686-707.
- [55] ABIRIA I, WANG C, ZHANG Q C, et al. High-cycle and very-high-cycle fatigue life prediction in additive manufacturing using hybrid physics-informed neural networks[J]. *Engineering Fracture Mechanics*, 2025, 319: 111026.
- [56] HAO W Q, TAN L, YANG X G, et al. A physics-informed machine learning approach for notch fatigue evaluation of alloys used in aerospace[J]. *International Journal of Fatigue*, 2023, 170: 107536.
- [57] ZHANG X C, GONG J G, XUAN F Z. A physics-informed neural network for creep-fatigue life prediction of components at elevated temperatures[J]. *Engineering Fracture Mechanics*, 2021, 258: 108130.
- [58] TAMURA M, ABE F, SHIBA K, et al. Larson-miller constant of heat-resistant steel[J]. *Metallurgical and Materials Transactions A*, 2013, 44(6): 2645-2661.
- [59] ZHU M L, XUAN F Z, DU Y N, et al. Very high cycle fatigue behavior of a low strength welded joint at moderate temperature[J]. *International Journal of Fatigue*, 2012, 40: 74-83.
- [60] ZHU M L, JIN L, XUAN F Z. Fatigue life and mechanistic modeling of interior micro-defect induced cracking in high cycle and very high cycle regimes[J]. *Acta Materialia*, 2018, 157: 259-275.
- [61] FAN J L, ZHU G, ZHU M L, et al. A data-physics integrated approach to life prediction in very high cycle fatigue regime[J]. *International Journal of Fatigue*, 2023, 176: 107917.
- [62] CHEN J, LIU Y M. Fatigue property prediction of additively manufactured Ti-6Al-4V using probabilistic physics-guided learning[J]. *Additive Manufacturing*, 2021, 39: 101876.
- [63] ZHOU T G, SUN X Y, CHEN X. A physics-guided modelling method of artificial neural network for multiaxial fatigue life prediction under irregular loading[J]. *Philosophical Transactions of the Royal Society A*, 2023, 381(2260): 20220392.
- [64] ACHARYA R, CAPUTO A N, NEU R W. Predicting creep-fatigue and thermomechanical fatigue life of Ni-base superalloys using a probabilistic physics-guided neural network[J]. *Fatigue & Fracture of Engineering Materials & Structures*, 2023, 46(4): 1554-1571.
- [65] ACHARYA R, CAPUTO A N, NEU R W. Machine learning model for predicting the influence of crystallographic orientation on thermomechanical fatigue of Ni-base superalloys[J]. *International Journal of Fatigue*, 2025, 194: 108832.
- [66] CIAMPAGLIA A, TRIDELLO A, PAOLINO D S, et al. Data driven method for predicting the effect of process parameters on the fatigue response of additive manufactured AlSi10Mg parts[J]. *International Journal of Fatigue*, 2023, 170: 107500.
- [67] CHEN D, LI Y Z, LIU K, et al. A physics-informed neural network approach to fatigue life prediction using small quantity of samples[J]. *International Journal of Fatigue*, 2023, 166: 107270.
- [68] DONG Y X, YANG X F, CHANG D D, et al. Predicting fatigue life of multi-defect materials using the fracture mechanics-based physics-informed neural network framework[J]. *International Journal of Fatigue*, 2025, 190: 108626.
- [69] FENG F, ZHU T, YANG B, et al. Probabilistic fatigue life prediction in additive manufacturing materials with a physics-informed neural network framework[J]. *Expert Systems with Applications*, 2025, 275: 127098.
- [70] SCHIJVE J. *Fatigue of structures and materials*[M]. Dordrecht: Springer Netherlands, 2009.
- [71] LIAO W W, LONG X Y, JIANG C. A physics-informed neural network method for identifying parameters and predicting remaining life of fatigue crack growth[J]. *International Journal of Fatigue*, 2025, 191: 108678.
- [72] PARIS P, ERDOGAN F. A critical analysis of crack propagation laws[J]. *Journal of Basic Engineering*, 1963, 85(4): 528-533.
- [73] LIU H H, DING X, LIU J H, et al. A Physics-informed neural network model for combined high and low cycle fatigue life prediction[J]. *Mechanics of Materials*, 2025,

- 209: 105429.
- [74] MINER M A. Cumulative damage in fatigue[J]. *Journal of Applied Mechanics*, 1945, 12(3): A159-A164.
- [75] WU Z K, WU S C, KRUZIC J J, et al. Critical damage events of 3D printed AlSi10Mg alloy *via in situ* synchrotron X-ray tomography[J]. *Acta Materialia*, 2025, 282: 120464.
- [76] HUANG T H, LI X Y, ZHANG Y Z, et al. Multifactorial prediction of corrosion fatigue crack growth in aluminum alloys using physics-informed neural networks[J]. *Engineering Failure Analysis*, 2025, 174: 109521.
- [77] WALKER K. The effect of stress ratio on fatigue crack growth[C]//*Fatigue Crack Growth Under Spectrum Loads*. Philadelphia: American Society for Testing and Materials, 1970: 225-233.
- [78] XU P, JI X, LI M, et al. Small data machine learning in materials science[J]. *npj Computational Materials*, 2023, 9(1): 42.
- [79] BOSTANABAD R, CHAN Y, AHMED S, et al. Computational microstructure characterization and reconstruction for data-driven materials science: a review[J]. *Progress in Materials Science*, 2022, 129: 100952.
- [80] ZHENG X, LIU J, LUO J, et al. Environment-assisted fatigue and fracture of metallic materials: mechanisms, modeling, and data challenges[J]. *Engineering Fracture Mechanics*, 2023, 289: 109456.

收稿日期: 2025-07-30; 录用日期: 2025-09-03

基金项目: 稳定支持项目(2019-363); 国家科技重大专项(J2019-VIII-0002-0163)

通讯作者: 许巍(1983—), 男, 博士, 研究员, 研究方向为航空发动机材料的力学行为, 联系地址: 北京 81 号信箱 19 分箱(100095), E-mail: wxu621@163.com

(本文责编: 陈 卉)