

• 极端服役条件用轻质耐高温部件高通量评价与优化设计 •

特邀专栏

High-throughput Evaluation and Optimal Design of Lightweight High-temperature-resistant Components for Extreme Service Conditions

DOI:10.16410/j.issn1000-8365.2025.5175

基于数据增强与机器学习的电子束熔化增材制造 TiAl-4822 合金疲劳寿命高精度预测研究

叶嘉峰¹, 林博超², 鲍伊达³, 陈 玮²

(1. 上海交通大学 材料科学与工程学院, 上海 200240; 2. 中国航空制造技术研究院, 北京 100095; 3. 威斯康星大学斯托特分校, 科学、技术、工程、数学与管理学院, 威斯康辛州 梅诺莫尼市 54751)

摘 要: 电子束熔化(electron beam melting, EBM)增材制造制备的 Ti-48Al-2Cr-2Nb(TiAl-4822)在复杂服役条件下疲劳寿命波动显著, 影响工程可靠性。基于包含 103 个 EBM 制备 TiAl-4822 件的疲劳测试数据, 本文结合数据增强与机器学习(层级神经网络、稳健回归)构建高精度疲劳预测模型(整体误差小于 20%)。该模型首先使用合成少数类过采样技术(SMOTE)增强并且平衡数据, 结合分层神经网络分类模型的判别是否通过疲劳测试(分类准确率达 80%); 随后, 针对未通过疲劳测试件, 采用基于高斯噪声的回归型合成过采样方法(SMOGN)进行数据增强, 结合稳健回归与分层神经网络组成的二阶模型进行疲劳寿命的回归预测(R^2 达到 0.81, 平均百分比误差为 7.3%)。基于 Shapley 值的模型可解释性方法(SHAP)分析, 加载频率、最大应力、温度及应力幅为主要影响因素。研究建立了适用于小样本条件下的 EBM 制备的 TiAl-4822 服役疲劳寿命预测方法, 为该合金在工程服役中的可靠性评估与优化设计提供了可行路径。

关键词: 钛铝合金; 电子束熔化; 疲劳寿命; 数据增强; 机器学习; 分层神经网络; 稳健回归

中图分类号: TG146

文献标识码: A

文章编号: 1000-8365(2025)12-1159-18

High-accuracy Fatigue Life Prediction of Electron Beam Melting Additively Manufactured TiAl-4822 Alloy Based on Data Augmentation and Machine Learning

YE Jiafeng¹, LIN Bochao², BAO Yida³, CHEN Wei²

(1. School of Materials Science and Engineering, Shanghai Jiao Tong University, Shanghai 200240, China; 2. AVIC Manufacturing Technology Institute, Beijing 100095, China; 3. University of Wisconsin-Stout, College of Science, Technology, Engineering, Mathematics & Management, Menomonie 54751, USA)

Abstract: Ti-48Al-2Cr-2Nb (TiAl-4822) materials fabricated via electron beam melting (EBM) additive manufacturing exhibit pronounced variations in fatigue life under complex service conditions, which affects their engineering reliability. To this end, on the basis of fatigue test data consisting of 103 EBM-fabricated TiAl-4822 samples, a high-accuracy fatigue life prediction model (overall error <20%) was developed by combining data augmentation techniques (SMOTE, SMOGN) with machine learning methods (hierarchical neural network, abbreviated as HNN, and Huber regression). The model first employs SMOTE to balance and argument the dataset and then integrates an HNN classifier to determine whether a sample

收稿日期: 2025-08-13

基金项目: 国家重点研发计划(2021YFB3702602)

作者简介: 叶嘉峰, 1993 年生, 博士, 助理研究员. 研究方向为基于数据分析的增材制造过程的成分设计及工艺优化.

Email: yeejf195022@sjtu.edu.cn

通信作者: 鲍伊达, 1990 年生, 博士, 助理教授. 研究方向为机器学习与统计学习方法、数值建模应用于工程制造, 金融定量分析以及医疗生物. Email: baoy@uwstout.edu

陈 玮, 1982 年生, 博士, 研究员. 主要从事增材制造技术研究工作. Email: werner_nju@163.com

引用格式: 叶嘉峰, 林博超, 鲍伊达, 陈玮. 基于数据增强与机器学习的电子束熔化增材制造 TiAl-4822 合金疲劳寿命高精度预测研究[J]. 铸造技术, 2025, 46(12): 1159-1176.

YE J F, LIN B C, BAO Y D, CHEN W. High-accuracy fatigue life prediction of electron beam melting additively manufactured TiAl-4822 alloy based on data augmentation and machine learning[J]. Foundry Technology, 2025, 46(12): 1159-1176.

would pass the fatigue test, achieving a classification accuracy of 80%. For the samples that failed the fatigue test, SMOGN was applied for data augmentation, and a two-stage model combining Huber regression with the HNN was used for fatigue life prediction, leading to an R^2 of 0.81 and a mean absolute percentage error of 7.3%. SHAP analysis based on this model indicates that frequency, maximum stress, temperature, and stress amplitude are the primary influencing factors. A fatigue life prediction approach suitable for small-sample scenarios of EBM TiAl-4822 under service conditions is finally established.

Key words: TiAl alloy; electron beam melting; fatigue life; data augmentation; machine learning; hierarchical neural network; Huber regression

钛铝合金(TiAl),尤其是 Ti-48Al-2Cr-2Nb(TiAl-4822,质量分数,%),以其低密度、高比强度和优异的高温抗氧化性能,被视为极端服役条件下实现轻量化的关键材料^[1-2]。近年来,增材制造(additive manufacturing, AM)中的电子束熔化(electron beam melting, EBM)过程,以其优异的设计自由度以及近净成形能力,为 TiAl-4822 复杂构件(如新一代航空涡轮叶片^[3])的工程化应用带来了新机遇^[1,4-5]。此外,EBM 过程利用真空环境和粉末床整体预热,可有效降低成形温度梯度与热应力,缓解裂纹与层间缺陷^[1,2,4],并提升组织均匀性和力学性能,因此成为 TiAl-4822 复杂构件的主流制备路线^[1-2,4-6]。

尽管 EBM 技术已实现显著的工艺突破,但 TiAl-4822 构件在复杂服役工况(如不同温度、应力及加载频率)下,其疲劳寿命仍呈现出显著的分散性与波动性,这为工程可靠性评估带来了严峻挑战^[7-11]。如 Zhou 等^[11]通过高周疲劳实验指出,AM 制备的 TiAl-4822 在不同服役工况下疲劳极限与寿命呈显著分散性;Cakmak 等^[4]和 Wartbichler 等^[6]揭示了微观组织演变、元素分布、各向异性与缺陷结构等对疲劳寿命的多变量协同调控机制。Chern 等^[7]的综述指出,表面粗糙度、气孔、未熔合缺陷及构件取向共同主导裂纹萌生与寿命分散。虽然机械加工和热等静压可提升寿命并降低数据离散度,但无法完全消除多变量的综合作用。因此,建立能够定量反映复杂服役条件影响的疲劳寿命预测模型,对于 TiAl-4822 构件的可靠性评估至关重要。复杂服役条件影响的疲劳寿命预测模型,将为 TiAl-4822 构件的工程可靠性评估提供有力支撑。

然而现有疲劳寿命预测方法,尤其是基于 $S-N$ 曲线、Basquin 等经典模型的传统物理与统计方法,在应对 TiAl-4822 等多变量耦合、缺陷敏感的脆性合金体系时存在明显局限。这些模型难以同时刻画平均应力、微观缺陷、组织特征和表面状态等多因素的综合作用^[8,10]。Murakami 等^[8]和 Tang 等^[10]系统评述了 $S-N$ 、Basquin 等模型在复杂工程材料、含缺陷材料及变载工况下的局限性,并指出仅依赖曲线拟合

的物理模型难以应对实际服役寿命高度分散的挑战。Chern 等^[7]也指出,虽然统计模型可以定量描述局部寿命分布,但工艺、缺陷、取向、后处理等变量间的多维耦合效应难以用单一物理或统计模型有效表达。

近年来,基于数据驱动的机器学习(machine learning, ML)方法为突破这一困境提供了新思路。ML 可直接利用疲劳寿命实验数据,通过非线性映射建立“服役条件-寿命”关系,绕开内部缺陷、组织各向异性、表面粗糙度和化学成分不均等复杂因素的显式建模^[9,12-17]。因此,基于 ML 的疲劳寿命预测方法已在多种增材制造金属材料体系中得到广泛探索与应用。例如,Zhan 等^[15]以增材制造不锈钢 316L 为材料,基于流体力学模拟和实验数据,训练了神经网络(artificial neural network, ANN)、随机森林(random forest, RF)和支持向量机(support vector machine, SVM)等模型,发现其中 RF 模型能够基于增材制造过程中使用的工艺参数实现制造件的疲劳寿命的精准预测(其中决定系数 R^2 大于 0.9),显著优于传统理论方法。Zhang 等^[16]使用了 ANN 算法,开发了预测激光增材制造不锈钢高周疲劳寿命模型,对比实验值整体误差仅 11%~16%。Shi 等^[9]同样针对激光增材制造制备的 AlSi10Mg 合金,结合插值增强和多种机器学习方法(例如 RF 和 SVM),成功实现了多变量(层厚、应力幅、缺陷尺寸等)下的极限疲劳寿命高效预测,其中 RF 模型表现最佳,预测误差小于 20%。上述研究表明,ML 不仅能整合复杂微观物理、表面特征、工艺与服役变量的非线性耦合,还可在缺乏显式物理机制、实验样本有限情况下获得高精度寿命预测^[9,15-16]。

尽管如此,针对 EBM TiAl-4822 的疲劳寿命预测研究仍十分有限。现有工作主要集中于 Ti-6Al-4V、316L、AlSi10Mg 等韧性合金^[7,9,15-16],而对 TiAl-4822 这一脆性高温轻质合金的系统建模尚未开展。多数研究关注工艺参数(如能量密度、激光功率)对寿命的影响^[10,12,15],而对温度、频率等服役条件对疲劳寿命考虑较少。此外,针对小样本、数据不均衡和极端区间的常用数据增强方法^[9,12]尚未在 TiAl-4822 复杂服

役场景中得到充分验证。因此,亟需面向真实服役条件、适用于小样本且具备高预测精度的机器学习预测模型。

综上,本文聚焦于 EBM 工艺制备的 TiAl-4822 合金,系统采集其在不同服役条件(包括最大应力、(测试)温度、频率、应力比等)下的疲劳寿命数据,结合数据增强与机器学习建模方法,建立高精度疲劳寿命预测模型,并对模型的预测性能与工程适用性进行定量评估。该研究为 TiAl-4822 构件服役情况下可靠性设计与寿命预测提供了理论基础和方法工具,也为数据驱动的服役性能建模在复杂脆性合金体系中的工程应用提供了参考。

1 实验材料与方法

1.1 实验材料以及疲劳测试条件

研究采用的 Ti-48Al-2Cr-2Nb(TiAl-4822)合金粉末通过电极感应熔炼气雾化(electrode induction melting gas atomization, EIGA)法制备,粒径分布为 45~150 μm 。其化学成分如表 1 所示。

表1 EBM TiAl-4822粉末化学成分

Tab.1 Chemical composition of the EBM TiAl-4822 alloy (mass fraction/%)

Al	Cr	Nb	O	C	N	H	Ti
31.5	2.3	5.0	0.10	0.01	0.01	0.002	Bal.

所有样品在 Arcam A2X 型电子束熔化设备上成形,主要工艺参数包括:成形温度1 050 $^{\circ}\text{C}$ 、层厚 90 μm 、电子束电流 10 mA、扫描速度 600 mm/s。制备样品为圆棒形状,所有构件按统一参数成形,如图 1 所示。




图1 通过 EBM 制备的垂直打印的 TiAl-4822 件^[1]

Fig.1 Schematic of vertically built TiAl-4822 parts fabricated by EBM^[1]

实验获取的数据均围绕影响 EBM 制备的 TiAl-4822 合金服役性能的核心因素展开。原始实验数据包含 6 项主要输入特征,分别为最大应力(max stress)、测试温度(temperature)、应力比(R)、加载频率(frequency)和粉末来源(source)。其中最大应力反映了试样在疲劳加载过程中的受力极限,是影响疲劳

裂纹萌生与扩展的关键参数。温度变量记录了疲劳测试所处环境的服役温度,能够有效揭示 TiAl-4822 合金在高温条件下的组织稳定性和性能变化。应力比定义为最小应力与最大应力之比,反映了载荷循环过程的对称性和非对称性,对于疲劳损伤的积累机制有重要影响。加载频率则用于描述试验过程中循环加载的速率,不同频率条件下材料可能出现应变速率效应或热积累现象,从而影响寿命表现。粉末来源用于标记不同供应批次的合金粉末(国产粉末或者来自 Acram),考虑到微量杂质含量和粒径分布等细节差异,能够解释部分材料性能的离散性。

在数据整理与预处理阶段,所有数值型变量(如最大应力、温度、频率等)均采用线性归一化或 Z-score 标准化方法,消除量纲和取值范围对模型训练的影响。Z-score 标准化的计算公式为:

$$z = \frac{x - \mu}{\sigma} \quad (1)$$

式中, x 为原始变量值; μ 为该变量在全部样本中的均值; σ 为标准差。以温度变量为例,设第 i 个样本的测试温度为 T_i ,所有样本温度的均值为 $\bar{T}$,标准差为 σ_T ,则该样本温度的标准化取值为:

$$z_{\text{temperature}} = \frac{T_i - \bar{T}}{\sigma_T} \quad (2)$$

同理,其他数值型变量如最大应力、加载频率等也采用相同方法进行标准化处理。经过 Z-score 标准化后,所有变量的均值为 0、标准差为 1,从而消除了量纲与取值区间对模型训练的影响,有助于提升机器学习模型的训练效率和预测精度,并保证不同特征之间在建模过程中的可比性和合理性。分类型变量(如粉末来源)通过独热编码转换为数值型输入,确保模型能够有效利用所有变量信息。此外,为保证数据的科学性和后续分析的可靠性,研究过程中对原始数据进行了系统性的缺失值补全与异常值剔除,严格筛查实验异常点或不符合规范的测量结果。最终获得的数据集样本完整,变量描述充分,能够为后续的机器学习建模和性能评估提供坚实基础。

在分类任务中,疲劳寿命以对数形式 $\log(N)$ 表示,并以 $\log(N)=7$ 作为判定样本“通过”疲劳测试的阈值(即 $N=10^7$)。该阈值的设定具有明确的工程意义:在金属材料疲劳研究领域, 10^7 次循环通常被认为是高周疲劳(high cycle fatigue)寿命的典型界限,亦即传统 S-N 曲线中的“耐久极限”或“无破坏寿命”阈值。材料在实际服役中,若能够承受 10^7 次以上的循环载荷而不断裂,则被视为满足典型工程构件的服役要求。因此,将 $\log(N)=7$ 作为分类模型的标签

划分标准,既符合国际疲劳标准(如 ASTM E466、ISO 1099 等^[18])的惯例,也便于与既有文献及工程应用对标,有助于模型结果在实际工程中的解释与推广。

1.2 基于机器学习的疲劳预测模型

考虑到实验数据中材料疲劳寿命的分布特征,即因疲劳测试的上限为能够承受 10^7 次以上的循环载荷而不断裂,通过疲劳测试的样品疲劳寿命统一记录为 10^7 ,未通过疲劳测试的样品则记录其断裂时实际疲劳寿命。针对这一数据特性,采用“分步建模”思路对服役寿命进行预测:首先,使用分类模型对不同测试环境下的样本进行“是否通过疲劳服役要求”的判别;随后,仅针对未通过疲劳标准的样本,进一步利用回归模型定量预测其疲劳寿命。该流程一方面能够避免单一回归模型在寿命数据极端分布区的误差放大,提升整体建模的稳健性;另一方面也更契合实际工程寿命评估的操作流程,使模型输出具备更高的实用性与解释性。

如图 2 所示,本文提出了一种结合数据生成、分布对齐与层级建模的基于机器学习的 EBM 制备 TiAl-4822 疲劳预测模型。该模型整体分为两大阶段:分类预测阶段(是否通过疲劳测试)与回归预测阶段(实际疲劳寿命预测)。首先,依据疲劳寿命的工程要求与实际数据结构,构建以 $\log(N)=7$ 为阈值的两类分类(classification)模型,用于判断材料是否满足 10^7 次以上的循环寿命标准。主要考虑到原始数据中通过与未通过样本在分布上可能存在不均衡,以及数据样本偏少导致机器学习模型准确率较低的情况,采用合成少数类过采样技术(synthetic minority over-sampling technique, SMOTE)^[12,19],进行使用样本生成的数据增强。对于生成数据,使用最大平均差异法(maximum mean discrepancy, MMD)与 Kolmogorov-Smirnov(KS)测试^[20]等统计学方法,确保新生成数据在高维特征空间中与原始数据分布一致。为充分挖掘复杂变量之间的非线性关系,本文采用了基于神经网络的分类建模方法。相较于传统神经网络对所有输入特征的简单全连接处理,进一步引入分层神经网络(hierarchical neural network, HNN)结构,将变量按照物理和工程属性进行分组,分层提取各级特征后再全局融合。该结构不仅能够提升分类模型对于通过/未通过疲劳寿命判别的准确性,还能更好地反映多源异质信息对疲劳行为的综合影响。

针对通过分类模型区分出不满足寿命标准的失效样本,即 $\log(N)<7$,使用了基于高斯噪声的回归型合成过采样方法(synthetic minority over-sampling technique for regression with gaussian noise, SMOGN)

用以增多样本。针对预测疲劳寿命数据噪声较大的实际情况,本文设计了一种二阶建模方法。首先采用稳健回归(huber regression)对主要趋势进行建模,以兼顾对整体数据的拟合能力和对异常值的鲁棒性;随后,在稳健回归的基础上,HNN 对回归残差进行二次建模,进一步捕捉非线性和高阶特征信息。该稳健回归结合 HNN 的二阶模型能够有效提升疲劳寿命预测的准确性和泛化能力,尤其适用于复杂小样本场景。

1.2.1 是否通过疲劳测试分类预测模型

针对疲劳寿命二分类问题,构建基于多种特征的机器学习分类模型。输入变量包括最大应力、温度、应力比、加载频率、数据来源等,标签 $Y=(y_1, y_2, y_3 \dots y_i)$, 其中 i 为数据样本数目)定义如下:

$$y_i = \begin{cases} 1, & \text{当 } \log(N_i)=7 \\ 0, & \text{当 } \log(N_i)<7 \end{cases} \quad (3)$$

式中, N_i 为第 i 个样本的疲劳寿命。该标签划分方式符合国际标准(如 ASTM E466、ISO 1099)及工程实践要求。考虑到由于原始数据中正负样本比例不均衡,容易导致分类模型偏向多数类,影响模型的泛化能力,以及数据样本数较少,导致分类模型准确率较低。为提升模型性能,本节采用 SMOTE 等数据增强方法,结合 HNN 分类模型实现高准确率判定。

1.2.1.1 分类模型的数据增强:SMOTE 算法

在本研究的疲劳寿命分类建模中,试验数据总体样本量有限,且不同类别(通过与未通过)之间样本数量存在一定差异。为有效提升模型的泛化能力,克服数据稀疏及类别分布不均所带来的影响,本文在分类模型训练阶段引入了 SMOTE 数据增强方法^[12,19]。SMOTE 算法不仅能够扩充少数类样本数量,缓解类别不平衡问题,更重要的是通过在特征空间中插值合成新样本,丰富了训练数据的多样性与分布形态,有助于提升模型对复杂边界与稀疏区间的判别能力。

在本节分类建模中,每个样本的特征向量 x_i 包括最大应力、测试温度、应力比、加载频率以及粉末来源,具体表示为:

$$x_i = [\text{max stress}_i, \text{temperature}_i, R_i, \text{frequency}_i, \text{source}_i] \quad (4)$$

在 SMOTE 算法实现过程中,首先需为每个待增强样本 x_i 在同类别样本集合 S 内,基于 k 近邻(k -nearest neighbors, KNN)算法选取个最近邻。具体而言,通过计算 x_i 与 S 中其它样本 $x_j, j \neq i$ 之间的欧氏距离(Euclidean distance) d :

$$d(x_i, x_j) = \sqrt{\sum_{m=1}^M (x_{i,m} - x_{j,m})^2} \quad (5)$$




图2 本文开发的基于机器学习的EBM制备TiAl-4822疲劳寿命预测模型
Fig.2 Schematic of the developed ML-based fatigue life prediction model for the EBM-fabricated TiAl-4822 parts

式中, x_{im} 表示 x_i 的第 m 个特征, M 为特征总数。根据距离从小到大排序, 选取 x_i 最近的 k 个样本, 构成其最近邻集合 N_i 。SMOTE 随后会从中随机选择一个邻居(记为 x_{iNN}), 用于与 x_i 进行插值生成新样本($x_i^1, x_i^2, x_i^3 \cdots x_i^l$), l 为生成的样本数。SMOTE 的核心插值公式如下:

$$x_i^l = x_i + \lambda \cdot (x_{iNN} - x_i) \quad (6)$$

式中, 随机数 $\lambda \in [0, 1]$ 。

对于本文中不同类型变量(连续变量和类别型变量)的插值方式如下:

(1)连续变量(如温度):

$$\text{Temperature}_i^l = \text{Temperature}_i + \lambda \cdot (\text{Temperature}_{iNN} - \text{Temperature}_i) \quad (7)$$

(2)类别变量(如粉末来源):

$$\text{Source}_i^l = \arg \min_{c \in C_{\text{Source}}} |\text{Source}_i + \lambda (\text{Source}_{iNN} - \text{Source}_c)| \quad (8)$$

式中, $c \in C_{\text{Source}}$ 为粉末来源可以取的类别集合。新样本的标签 y_i 与插值起点一致。

通过上述 SMOTE 增强策略, 不仅能够平衡不同类别的样本数量, 缓解训练过程中的类别偏置, 还可以有效扩展训练数据的特征空间覆盖度, 提升模型在小样本和复杂工况下的鲁棒性与泛化能力。

1.2.1.2 分类模型的数据分布检测

在利用 SMOTE 等方法进行数据增强后,有必要对增强后数据集的分布与原始样本分布进行一致性检验,以确保新生成样本在统计特性上与原始数据保持良好的一致性,避免因分布偏移导致模型性能下降。为此,本文在分类任务中引入了 MMD 与 KS 检验,对原始样本与增强样本的数据分布进行定量分析。

MMD 是一种基于核函数的非参数分布距离度量方法,可用于检验两个样本集在高维特征空间中的分布差异。具体地,设原始样本集为 $S=\{s_1, s_2, s_3, \dots, s_i\}$, 其中 $s_i=(x_i, y_i)$, 经过 SMOTE 方法生成的数据样本为 $S'=\{s'_1, s'_2, s'_3, \dots, s'_i\}$, 则 MMD 的计算公式如下:

$$\begin{aligned} \text{MMD}^2[S, S'] = & \frac{1}{n(n-1)} \sum_{i=1}^n \sum_{j \neq i}^n k(s_i, s_j) \\ & + \frac{1}{m(m-1)} \sum_{i=1}^m \sum_{j \neq i}^m k(s'_i, s'_j) \\ & - \frac{2}{nm} \sum_{i=1}^n \sum_{j=1}^m k(s_i, s'_j) \end{aligned} \quad (9)$$

式中, $k(s'_i, s'_j)$ 为核函数, 常用高斯径向基核(RBF 核)。MMD 表示增强数据与原始数据的整体分布越接近。若最大均值差异趋近于 0, 说明两组数据在高维特征空间中的分布基本一致。

KS 检验用于衡量两组一维样本在某一特征上的分布差异。对于每一个特征变量(如第 k 维), 分别计算原始样本 S 和 S' 增强样本在该维上的经验分布函数 $F_n^{(k)}(x)$ 与 $G_m^{(k)}(x)$, KS 统计量定义为:

$$D_{n,m}^{(k)} = \left| \sup_x F_n^{(k)}(x) - G_m^{(k)}(x) \right| \quad (10)$$

式中, $D_{n,m}^{(k)}$ 为第 k 个特征之间的 KS 统计量, $\sup$ 表示在所有 x 处取最大绝对值。KS 值越小, 说明增强样本在该特征上的分布越接近原始数据。工程实际中, 通常对所有特征逐一进行 KS 检验, 以全面评估增强样本在各维度的分布一致性。

通过 MMD 与 KS 检验, 可以定量判断 SMOTE 等数据增强方法是否保持了数据集原有的统计特征, 避免分布偏移, 提高数据增强的科学性和工程适用性。采用 MMD 和 KS 检验对原始样本与增强样本的分布进行分析, 确保增强过程不会损害数据的代表性, 为后续分类模型的可靠性和泛化能力提供保障。

1.2.1.3 HNN 模型分类预测

结合 SMOTE 增强与分布一致性检测后, 本文采用 HNN 进行疲劳寿命的二分类预测。HNN 模型针对本课题样本量有限、多变量交互显著、特征分布复杂等特点, 通过分层特征提取与结构化信息融合, 显著提升了模型对高阶非线性关系与不同物理层次特征的学习能力。

如图 3 所示, HNN 模型整体结构包括输入层、分层特征提取层、特征融合层和输出判别层。输入层按物理意义将原始特征向量划分为三级特征组(如最大应力、温度、应力比, 频率和来源分别单独分组), 体现变量的层级相关性。分层特征提取层(图中 $L1, L2, L3$ 分支)分别对不同特征组进行低阶特征变换, 通过局部感知与非线性激活, 如 ReLU(Rectified Linear Unit)、Sigmoid 等, 实现分组特征的初步抽象。特征融合层将所有分支输出进行拼接和高阶组合, 学习变量间的复杂交互和耦合关系。输出层经过全连接与 Softmax 函数判别, 输出每个样本通过/未




图 3 对于 EBM 制备的 TiAl-4822 样本进行疲劳寿命分类的 HNN 模型的结构
Fig.3 Structure of the HNN model used to classify the EBM-fabricated TiAl-4822 samples

通过疲劳寿命判据的概率,最终实现二分类结果。

HNN 的前向传播过程可表示为:

$$z_g^{(l)} = \sigma_g^{(l)} (W_g^{(l)} x_g^{(l-1)} + b_g^{(l)}) \quad (11)$$

式中, g 代表分组; l 为当前层; σ 为激活函数。多分支特征经过融合后,综合成统一高阶特征向量 z_{fusion} ,最终经输出层判别概率:

$$p(y_i'=1|x_i') = \text{softmax}(W_{\text{out}} z_{\text{fusion}} + b_{\text{out}}) \quad (12)$$

HNN 模型的训练目标为最小化交叉熵损失:

$$\mathcal{L}_{\text{CE}} = -\frac{1}{m} \sum_{i=1}^m [y_i' \log(\hat{p}_i') + (1-y_i') \log(1-\hat{p}_i')] \quad (13)$$

与传统全连接神经网络不同,HNN 模型的分层结构有效引入了“局部-全局”特征融合机制,一方面突出不同物理层级变量的信息表达,另一方面提升了模型对特征子空间的自适应能力。结合 SMOTE 生成的高多样性数据,HNN 可更充分学习复杂边界与极端样本分布,实现对疲劳寿命“通过/未通过”更为稳健和高效的分类判别(如图右侧的判别输出所示)。

综上所述,本节系统构建了面向疲劳寿命二分类的机器学习预测方法,提出了涵盖数据增强、分布一致性检验与 HNN 建模的完整流程。首先,通过 SMOTE 算法扩充训练样本数量、平衡类别分布,有效缓解了小样本和类别不均带来的建模局限。随后,采用最大 MMD 和 KS 检验等统计方法,对增强后数据集的分布特征进行严格定量分析,确保数据增强过程的科学性和代表性。最后,基于高质量的输入数据,利用 HNN 模型充分挖掘各层级特征之间的复杂耦合关系,通过合理的超参数设置和结构设计,显著提升了疲劳寿命分类模型的预测精度和泛化能力。整体方案不仅提升了模型在复杂、多变量工程数据下的应用价值,也为实际构件寿命评估、失效风险判定及优化设计提供了可复制、可推广的智能分析范式和方法论基础。

1.2.2 未通过疲劳测试样品回归预测模型

针对未通过疲劳测试样品,即 $\log(N) < 7$ 的样本,构建基于多特征输入的疲劳寿命回归预测模型。考虑到未通过样品数量有限,且寿命分布在数值空间存在稀疏区间,传统建模容易受小样本与分布不均影响而出现预测不准。为此,本文采用 SMOGN 算法进行数据增强,通过对原始样本及其近邻插值并叠加高斯噪声,显著扩充了训练集的多样性和稀疏区间的代表性。随后,结合 MMD 和 KS 检测等方法对增强前后数据分布进行严格一致性检验,确保数据增强过程的合理性与科学性。

在模型构建方面,采用稳健回归与 HNN 两阶段组合建模思路:首先利用稳健回归方法捕捉主趋势关系,随后通过 HNN 对回归残差进行进一步学习与校正,从而提升回归模型对复杂非线性模式的预测能力与工程泛化性。采用该二阶模型策略,主要是因为在实际数据中,未通过样品数量有限且分布复杂,单一回归模型往往难以兼顾全局趋势与局部稀疏区域的预测精度。通过“主趋势结合残差修正”模式,不仅能够有效提升整体建模性能,还能显著缓解样本分布极端所带来的高误差风险,为疲劳寿命短板样品的精准预测和服役风险评估提供更有力的数据支撑。

1.2.2.1 回归模型的数据增强:SMOGN 算法

针对未通过疲劳测试样品的回归预测任务,样本数量有限且寿命分布存在显著稀疏区间。为提升回归模型对稀疏区域的拟合能力,本文引入了 SMOGN 数据增强方法。SMOGN 基于回归任务特点,结合插值与高斯噪声扰动,可有效扩展训练数据的数量和分布多样性,增强模型对少见寿命区间的学习能力。

具体而言,对于未通过样品的特征向量 x_j ,及其寿命标签 $y_j = \log(N_j)$,SMOGN 首先基于 k 近邻算法,从同类别样本中为每个 x_j 选取一个最近邻 $x_{j,\text{NN}}$, $y_{j,\text{NN}}$,并按如下方式生成新样本 $x_{j,\text{NN}}^*$ 和 $y_{j,\text{NN}}^*$:

$$x_j^* = x_j + \lambda \cdot (x_{j,\text{NN}} - x_j) \quad (14)$$

$$y_j^* = y_j + \lambda \cdot (y_{j,\text{NN}} - y_j) + \varepsilon_j \quad (15)$$

式中,随机数 $\lambda \in [0, 1]$, $\varepsilon_j \sim N(0, \sigma^2)$ 。连续变量采用线性插值,类别变量则插值后投影到最近类别。

需要指出的是,所有经 SMOGN 生成的新数据,在用于后续回归建模前,均需经过 MMD 和 KS 等统计方法的分布一致性检验,以确保增强样本在统计特性上与原始样本保持良好一致性。通过上述 SMOGN 及分布检验,能够为回归模型提供更加丰富且科学的数据基础,提升模型对极端及稀疏区间的预测能力和工程适用性。

1.2.2.2 结合稳健回归和 HNN 的二阶疲劳预测模型

在未通过疲劳测试样品的寿命回归预测建模中,线性回归模型因其结构简洁、系数具备直接物理意义而被广泛应用。线性回归的每一回归系数均能量化输入变量对疲劳寿命的线性贡献,具有良好的可解释性^[19, 21-23]。这为后续开展变量敏感性分析、工艺优化与科学决策提供了理论基础和实践价值。

然而,传统最小二乘法回归对异常值与极端点高度敏感,容易导致模型拟合失真,尤其在疲劳寿命数据中,极端或离群样本较为常见。为克服这一局限,进一步引入稳健回归,通过引入分段损失函数,

在残差较小时采用平方损失、残差较大时采用线性损失。

$$L_{\delta}(r)=\begin{cases} \frac{1}{2}r^2, & \text{if } |r| \leq \delta \\ \delta\left(|r| - \frac{1}{2}\delta\right), & \text{if } |r| > \delta \end{cases} \quad (16)$$

式中, $L_{\delta}(r)$ 为模型预测值 $\hat{y}_j^{\text{Robust}}$ 与真实值 y_j 的残差, δ 为阈值参数。稳健回归能够兼顾常规样本的高效拟合和极端点的抗干扰能力, 有效提升模型鲁棒性, 同时仍保留了对变量影响的物理可解释性。

为进一步提升模型对非线性和高阶特征耦合的刻画能力, 采用 HNN 模型对稳健回归的残差进行二阶建模修正。与前述分类任务中的 HNN 模型相比, 回归型 HNN 的主要不同体现在两个方面: ① 输出层结构: 回归任务中, HNN 的输出层为线性单元, 直接输出寿命对数预测值 $\log(N_j)$, 而分类任务则采用 Softmax 或 Sigmoid 函数输出是否通过疲劳测试的判定。② 损失函数: 回归型 HNN 通常采用均方误差或稳健损失, 而分类 HNN 采用交叉熵损失。

其整体流程为: 首先利用稳健回归模型拟合主趋势, 输出初步预测值 $\hat{y}_j^{\text{Robust}}$, 然后将残差 $L_{\delta}(r)$ 作为 HNN 模型预测的目标, 基于特征向量 x_j 学习和拟合残差项 $\hat{r}_j$, 最终回归输出为:

$$\hat{y}_j^{(\text{最终输出})} = \hat{y}_j^{(\text{Robust})} + \hat{r}_j \quad (17)$$

这种“稳健回归结合 HNN 残差修正”的二阶建模思路, 既充分发挥了线性模型的可解释性与稳健性, 又利用 HNN 结构优势深度挖掘数据中的复杂非线性和高阶关系。经过 SMOGN 数据增强与分布一致性检验后, 组合模型能有效缓解未通过样品数据稀疏对回归建模的影响, 显著提升极端寿命区间的预测精度与泛化能力。整体流程为疲劳寿命风险评估与材料服役性能智能预测提供了坚实的数据支撑与方法基础。

针对样本量有限、类别分布不均及寿命区间稀疏等工程实际问题, 首先引入 SMOTE 和 SMOGN 等数据增强方法, 分别扩充分类与回归任务中的训练样本数量, 丰富了特征空间和目标变量的分布多样性。随后, 采用 MMD 和 KS 检验等统计方法, 对增强前后样本的分布一致性进行严格定量分析, 确保数据增强过程科学合理、不会引入显著分布偏移。

在建模阶段, 针对分类任务, 结合数据增强样本, 提出了 HNN 为核心的疲劳寿命通过/未通过判别模型, 通过分层特征提取与融合机制, 有效提升了对复杂边界和变量高阶关系的学习能力。针对回归

任务, 采用“稳健回归结合 HNN 残差修正”的二阶建模框架, 既发挥了线性模型的物理可解释性和抗干扰能力, 又进一步利用 HNN 对非线性与极端区间的残差进行校正优化, 从而实现了未通过样品寿命的高精度回归预测。

综上, 提出的各类方法不仅显著提升了模型对小样本、多变量、复杂分布工程数据的适应能力, 也为后续疲劳寿命风险判定、服役性能分析和优化设计奠定了坚实的数据和方法基础。下一节将基于上述建模流程, 详细展开模型性能的实验结果分析与工程应用讨论, 进一步验证所提方法的有效性与实际价值。

2 实验结果及讨论

2.1 疲劳数据特征与变量相关性分析

为确保后续建模工作的科学性与工程解释性, 首先有必要对疲劳数据的基础分布特征及主要变量间的相关关系进行系统分析, 旨在明确数据集的整体特征、各变量的物理意义及其分布规律, 为后续分类和回归模型的构建与性能评价奠定坚实的数据基础。

2.1.1 数据总体描述与样本分布

为验证实验数据的工程代表性, 图 4a 展示了 103 组样本在温度-最大应力-频率空间中的分布情况。样本依据服役工况划分为室温组 (25 °C) 和高温组 (650~800 °C), 其中室温组主要覆盖 450~500 MPa 的最大应力区间, 频率固定为 100 Hz; 高温组则在 350~500 MPa 应力范围内, 结合 100、110 和 120 Hz 三挡频率进行组合设计, 形成具有典型正交特征的多变量样本结构, 覆盖范围集中于实际工程关注的高温-高应力区间, 具备良好的代表性。

图 4b 显示了样本疲劳寿命 $\log(N)$ 的分布特征。寿命以对数形式记录, 分界标准设定为 $\log(N)=7$ 。统计结果显示, 通过样本共 55 条, 占比略高于 50%, 反映出在本实验条件下材料整体疲劳性能较好; 未通过样本 48 条, 寿命分布区间较宽, 其中部分样本在极低循环次数下即发生失效 ($\log(N) \approx 0$), 表现出明显的早期断裂行为, 也存在寿命接近 7 的临界样本。这种“双峰+离散”的分布特征揭示了疲劳响应的显著不均质性, 为后续分类与回归建模带来了类别不平衡、局部稀疏等挑战。

2.1.2 变量相关性与物理机制分析

基于皮尔逊线性相关系数, 对主要输入变量及疲劳寿命之间的相关性进行了系统分析。相关性矩阵见图 5。




图4 EBM 制备 TiAl-4822 样本的实验设计与疲劳寿命分布:(a) 不同温度-最大应力-频率下的样本分布,颜色表示频率;(b) 疲劳寿命对数分布,共 103 个样本,其中未通过疲劳测试为 48 组(红色),通过测试为 55 组(蓝色)

Fig.4 Distribution of fatigue life for EBM-fabricated TiAl-4822 samples: (a) sample distribution under different temperature-maximum stress-frequency conditions, with frequency indicated by color; (b) $\log(N)$ distribution, including 103 samples in total. Among these, 48 samples (red) failed the fatigue test, and 55 samples (blue) passed the test




图5 主要输入变量与疲劳寿命 $\log(N)$ 之间的皮尔逊线性相关性矩阵

Fig.5 Pearson correlation matrix between the main input variables and the fatigue life $\log(N)$

结果显示,最大应力与温度之间存在较强的负相关(相关系数为 -0.77),与应力比 R 呈中等正相关(0.51),与频率呈弱负相关(-0.24)。温度与频率之间表现出较高的正相关性(0.68),说明试验工艺参数设置上温度和频率存在耦合关系。应力比与最大应力、频率也有一定相关性,但与温度的线性相关较弱。各变量与疲劳寿命的直接线性相关性整体偏弱;最大应力与寿命呈负相关(-0.36),符合疲劳理论中高应力降低寿命的物理规律;温度与寿命呈弱正相关(0.20),应力比和频率与寿命的相关性更弱。

上述结果表明,虽然部分变量之间存在中等相关性,但整体而言,单一输入变量与寿命的线性相关度有限,尤其是对疲劳寿命的直接预测能力较弱。这一现象揭示了 TiAl-4822 疲劳寿命受多因素复杂耦合影响,传统线性建模难以充分挖掘其本质机制,需要更为灵活的非线性建模方法进一步提升预测精度和工程泛化能力。

进一步考虑线性相关性分析结果,尽管所有输

入变量与疲劳寿命的直接线性相关性均不高,但最大应力和温度作为外加载工况与环境影响的主控变量,历来被认为是决定金属疲劳寿命的核心物理因素。为了更直观地揭示这两项变量对样本通过率的具体影响规律,图 6a 和 b 分别展示了不同最大应力区间和不同温度档位下的通过/未通过比例堆叠柱状图。

如图 6a 所示,最大应力对通过率影响的趋势更加清晰。应力低于 390 MPa 时,通过率为 71%;在 390~420 MPa 区间,下降至 46%;高于 420 MPa 时,通过率下降至仅 32%。这一结果符合疲劳物理机制的基本规律,即高应力状态下材料更容易发生失效,但也进一步提示,仅以应力一项仍难以精确区分所有试样的服役表现,尤其是在各应力区间内通过与未通过样本均有分布,体现出多因素耦合作用下的失效复杂性。如图 6b 所示,温度对 TiAl-4822 试样通过率的影响呈现复杂的非线性趋势。25、750 和 800 °C 条件下,通过率均在 53%左右,而 650 和 700 °C 档的通过率相对较低,分别为 47%和 35%。这说明温度变量不仅表现出简单的单调作用,700 °C 附近的通过率最低,提示该温区可能存在材料组织或高温失效机制的特殊敏感性,反映了温度对疲劳寿命的深层影响。

综上,图 6a 与 b 所示堆叠柱状图不仅直观反映了最大应力和温度对疲劳寿命通过率的作用特征,也再次说明单一变量难以独立判定失效风险。这一发现为后续多变量特征联合的分类建模提供了理论依据,强调了将最大应力、温度等关键变量与其他特征综合输入分类模型的重要性。2.2 节将基于上述发现,系统开发和评估多特征联合的分类预测模




图 6 TiAl-4822 试样通过/未通过比例堆叠柱状图:(a) 不同最大应力区间;(b) 不同温度

Fig.6 Stacked bar chart of pass/fail proportions for TiAl-4822 samples: (a) under different maximum stresses; (b) at different test temperatures

型, 以进一步提升工程判据下的预测准确率和泛化能力。

2.2 分类模型结果与分析

本章将通过系统的实验结果, 对前文提出的疲劳寿命分类预测模型框架进行全面评估。我们将围绕特征重要性分析、数据增强方法与分类模型表现三个维度, 结合具体的准确率、混淆矩阵以及分布一致性检验等多项指标, 验证各环节对模型效果的实际提升。通过不同变量组合、数据增强策略和模型结构的对比, 本章旨在明确模型优化的关键要素及其工程适用性, 并为后续的可解释性分析与回归任务提供数据和理论基础。

2.2.1 特征重要性分析

在开展疲劳寿命分类模型构建之前, 科学合理地筛选输入特征, 不仅能够提升模型的预测性能, 也有助于增强结果的物理可解释性。针对原始数据中所包含的多项材料与工艺参数, 本文首先通过置换特征重要性分析(permutation feature importance, PFI)方法, 对全部候选变量的实际贡献进行了定量评估。PFI 能够在模型已拟合好的情况下, 通过依次打乱每个变量的取值, 考察模型准确率的下降幅度, 从而反映出各变量对于最终分类任务的“真实重要性”^[14, 24]。

结合本项目的疲劳测试条件和数据结构, 除了直接测量的最大主应、(测试)温度、(加载)频率应力比、粉末来源以外, 进一步引入了两项具有明确物理含义的衍生变量: 应力幅(stress amplitude)表示一个加载循环内的最大主应力变化范围, 和平均应力(mean stress), 反映循环加载过程中的平均主应力水平。其计算公式如下:

$$\text{Stress amplitude} = \text{Max stress} \times \frac{(1-R)}{2} \quad (18)$$

$$\text{Mean stress} = \text{Max stress} \times \frac{(1-R)}{2} \quad (19)$$

理论和实验研究均表明, 应力幅和平均应力往往是影响金属材料疲劳寿命的主控因素, 因此有必要将其作为候选变量纳入建模体系^[25]。

如图 7 所示, PFI 分析结果显示, 应力幅、最大主应力和温度在全部变量中排名最前, 说明它们对于疲劳寿命分类具有核心判别力。平均应力、粉末来源以及加载频率的贡献相对较低但为正值。值得注意的是, 应力比的 PFI 为负, 这与其在样本数据中几乎恒定(绝大多数为 0.1, 仅极少数为 0.06)的分布有关。缺乏区分度的变量不仅对模型预测无帮助, 反而可能引入噪声和误导。因此, 在后续 HNN 建模中, 剔除了应力比, 保留了具备显著物理意义和统计贡献的其他特征, 并将应力幅和平均应力作为单独一层, 进一步强化模型的物理解释能力。




图 7 各输入变量的 PFI 分析结果
Fig.7 PFI analysis of all the input variables

综上, 通过结合 PFI 特征重要性分析和物理知识, 对输入变量进行系统性分层筛选, 既提升了分类模型的预测能力, 也为后续分层结构的科学设计与可解释性分析奠定了坚实基础。

2.2.2 分类模型结果与分析

为全面评价各类分类模型在疲劳寿命判别任务中的性能, 本文采用准确率(accuracy)作为主要评估指标。准确率指的是模型预测正确的样本数占总样本数的比例, 能够直接反映模型在“通过/未通过”二

分类任务中的整体判别能力。为确保评估结果的稳健性和代表性,所有模型均采用5折交叉验证方法,即将样本集随机划分为5个子集,每次选取其中1个子集作为验证(validation)集,其余4个子集作为训练(training)集,轮流训练与测试。最终准确率取自5个验证集结果(拼接为一个整体数据)来最大程度反映模型在全部样本上的实际分类能力。

为了验证本文所提出的 SMOTE 数据生成结合 HNN 分类模型的在使用数据上的有效性,本文还使用了其他常用的分类模型,如包括逻辑回归(logistic regression),随机森林(random forest, RF)、支持向量机(support vector machine, SVM)、神经网络(artificial neural network, ANN)作为比较。值得说明的是在模型训练与优化过程中,除逻辑回归(logistic regression, LR)采用最大似然估计方法学习模型系数外,其余所有机器学习模型(包括决策树、随机森林、支持向量机、神经网络和 HNN)均采用 Python 中的 Optuna 库^[26]实现的贝叶斯优化算法,在预设的超参数空间内自动搜索最优参数组合,以进一步提升模型的泛化能力和预测准确率。以 HNN 模型为例,需要优化的超参数包括隐藏层单元数(neurons),最终融合层的单元数,激活函数(activation function),学习率(learning rate),每次迭代的样本批量大小(batch size)。

在分类建模中,原始数据集中未通过样本为 48 条,通过样本为 55 条(样本共计 103 条),存在一定程度的类别不均衡。为保证后续模型训练的公平性与泛化能力,采用 SMOTE 对原始数据集进行增强和平衡处理,最终两个类别样本数均达到 79 条(样本共计 158 条)。SMOTE 生成数据原始数据的最大均值差异仅为 0.012,代表生成数据和原始数据分布高度一致^[20]。生成数据与原始数据各个特征的 KS 测试结果如表 2 所示。

表2 SMOTE增强样本与原始样本在各主要特征维度的KS检验结果

Tab.2 KS test results of the SMOTE-generated samples versus the original samples for each feature

Features	KS test P-values	Results
Max stress	0.35	Pass
Temperature	0.39	Pass
Frequency	0.98	Pass
Source	0.71	Pass
Stress amplitude	0.34	Pass
Mean stress	0.35	Pass

Note: $p > 0.05$ indicates passing, showing high distributional consistency between augmented and original data

表 2 结果显示,所有特征的 KS 检验 p 值均大于 0.05,均通过分布一致性检验。这表明 SMOTE 增

强生成的样本在各主特征维度上与原始样本分布高度一致,未引入明显分布漂移,为后续模型训练提供了可靠的数据基础。此外,本文还是用了降维可视化(t -distributed stochastic neighbor embedding, t -SNE)方法来直观比较原始数据和生成数据的空间分布一致性(图 8)。从图像上看,SMOTE 新生成样本(红色)与原始样本(蓝色)在 t -SNE 空间内高度重叠且分布趋势一致,未出现明显的类别分割或异常离群点,说明数据增强过程未引入严重的分布偏移或人工异常。这进一步验证了基于分布一致性约束的 SMOTE 增强策略的有效性,为后续建模提供了坚实的数据基础。




图 8 t -SNE 降维对比原始样本(蓝色)与 SMOTE 生成样本(红色)的分布一致性

Fig.8 t -SNE visualization comparing the distributions of the original samples (blue) and SMOTE-generated samples (red)

表 3 对比了不同机器学习模型在原始数据集(103 条样本)与 SMOTE 增强后的平衡数据集(158 条样本)上的 5 折交叉验证分类准确率。可以看出,在原始样本集上,传统机器学习模型以及 HNN 模型准确率均未超过 0.71,且模型间差距较小;其中 HNN 略优于其它方法,表现为 0.71。在数据增强后,RF、ANN 以及 HNN 模型的准确率均有明显提升,尤其 HNN 准确率达到 0.80。因此,整体来看,数据增强(SMOTE)和(HNN 模型)协同作用是提升小样

表3 各机器学习分类模型在原始样本和SMOTE增强样本下的5折交叉验证准确率对比

Tab.3 Comparison of 5-fold cross-validation accuracies for different machine learning classification models on the original and SMOTE-augmented datasets

Machine learning models	Accuracy (acquired through 5-fold CV)	
	Original data (103 samples)	SMOTE-augmented data (158 samples)
Logistic regression	0.66	-
Random forest	0.69	0.73
Support vector machine	0.68	-
Artificial neural network	0.70	0.76
Hierarchical neural network	0.71	0.80

本材料疲劳判别任务准确率的核心。传统浅层模型在小样本和不平衡分布下难以获得足够的泛化能力;而通过数据均衡和深层模型结构,可以充分挖掘数据特征,实现更高的判别性能。

为进一步验证模型在具体判别上的表现,图9展示了HNN模型在SMOTE增强数据集上5折交叉验证的混淆矩阵。可以看到,模型对“未通过”(Fail)样本共预测正确64例,误判为“通过”15例;对“通过”(Pass)样本则预测正确62例,误判为“未通过”17例。整体来看,两类样本的识别率较高且分布均衡,模型对短寿命高风险样本的识别能力尤为突出。该结果体现了HNN模型在类别均衡样本下的良好判别能力和实际工程应用价值。




图9 HNN模型在SMOTE增强数据集上的5折交叉验证混淆矩阵

Fig.9 Confusion matrix of the HNN model with 5-fold cross-validation on the SMOTE-augmented dataset

为进一步揭示模型判别的物理合理性与科学解释力,本文结合基于Sharpley值的模型可解释性增强方法(sharpley additive explanations, SHAP),对HNN模型的判别过程进行了可解释性分析。通过量化不同输入特征对模型输出的边际贡献,不仅能够

识别主导疲劳寿命判别的核心变量,还可以直观展示各特征在不同取值区间对判别结果的推动方向和机制。这一分析有助于深入理解模型的“决策逻辑”,并为工程应用中的参数调控和优化提供理论支持。

图10a给出了各输入特征的平均SHAP值条形图,用以反映不同变量对模型判别输出的整体贡献。可以看到,最大应力的平均SHAP值最高,表明其在模型判别材料疲劳寿命通过与否时具有主导作用。紧随其后的是频率和温度,说明除最大应力外,这两个变量对寿命判别也有重要影响。平均应力和应力幅作为辅助变量,对判别结果有一定修正作用,但整体贡献相对较低。粉末来源几乎未对模型输出产生显著影响,这也与其较低的信息量和实际工程意义相符。

图10b的SHAP特征重要性汇总从全局和局部揭示了各输入特征在不同取值区间对模型判别结果的具体作用机理。以最大应力为例,绝大多数高应力(红色)样本的SHAP值显著为负,清晰反映出模型将高应力视为降低疲劳寿命通过概率的主导因子。这一判别规律与材料疲劳破坏的物理本质完全一致,即应力升高极大提升了发生失效的风险。而对于低应力(蓝色)样本,其SHAP值明显为正,表明此类工况下模型更倾向于判定材料能够通过疲劳寿命标准,进一步强化了对“应力-寿命”主控关系的物理一致性验证。

在频率和温度特征上,泡泡图揭示出更为复杂的非线性和交互行为。对于频率,一方面,部分高频率(红色)样本的SHAP值表现为正,意味着高频加载条件下疲劳寿命通过概率提升;但另一方面,部分高频下又出现负向SHAP值,显示高频不总是对通




图10 使用SHAP解释预测模型:(a)各输入特征的平均SHAP值条形图,反映了每个变量对模型输出的整体贡献;(b)SHAP特征重要性汇总图展示了各特征在不同取值下对单个样本判别结果的边际影响

Fig.10 Using SHAP to explain the prediction model: (a) bar plot of the mean SHAP values for each input feature, illustrating the overall contribution of each variable to the model output; (b) SHAP summary plot visualizing the marginal effect of each feature at different values on individual predictions

过有利。类似地,温度特征在中低温区间(蓝色/青色)多数 SHAP 值为正,高温区间(红色)则负向作用更为显著。上述现象说明,模型已经“学会”不同变量的作用并非单调线性,其影响取决于具体工况及与主控变量的交互关系。例如,温度对寿命的影响可能随应力水平、频率等条件发生转向(如高应力结合高温工况下寿命极易下降),体现了疲劳损伤的多物理耦合本质。

衍生变量(应力幅与平均应力)在 SHAP 特征重要性汇总图中的分布也同样表现出“局部主导性”,在某些取值区间对判别结果产生较大拉动,但全局贡献略低于主控变量。这反映了模型判别边界的“柔性”调节机制:在主变量已无法完全区分样本时,辅助变量通过微调 SHAP 值实现样本的最终归类,从而进一步提升了模型的实际工程判别能力和泛化性。

综上所述,本节系统评估了不同特征选择、数据增强及分类模型结构对材料疲劳寿命预测准确率的实际影响。结果表明,物理主控变量(如最大应力、温度、应力幅)在模型判别中起到核心作用,而通过 PFI 分析进一步验证了变量选择的科学性与模型的可解释性。SMOTE 增强在样本不均衡情形下显著提升了模型的泛化能力和分类准确率,HNN 结构优化与深度学习策略的协同应用,使分类性能进一步提升至工程可用水平。混淆矩阵、KS 检验和 t -SNE 可视化均表明数据增强过程未引入分布漂移或异常。SHAP 可解释性分析不仅揭示了主要变量的判别机制,还反映出多变量之间复杂的非线性和交互效应。整体来看,所提出的建模框架有效提升了疲劳寿命短板判别能力,为后续回归预测和机理挖掘奠定了坚实基础。

2.3 回归模型结果与分析

在完成对材料疲劳寿命是否通过的分类判别之后,本节进一步针对所有未通过样本,开展疲劳寿命的定量回归预测分析。回归模型的输入特征体系完全沿用 2.2 节分类建模中的核心变量,包括最大主应力、温度、频率、粉末来源、应力幅与平均应力等,确保模型输入具有高度物理相关性与工程一致性。

在建模策略上,针对原始数据量有限、样本分布偏态以及复杂非线性关系的特点,本文首先采用了 SMOGN 数据增强策略确保训练集覆盖更全面的数据分布。回归建模则采用了稳健回归与 HNN 二阶组合模型:首先利用稳健回归对疲劳寿命的主趋势进行稳健拟合,再由 HNN 针对回归残差部分进

行非线性校正,从而兼顾模型的抗异常能力与复杂模式的刻画能力。为提升回归模型的泛化性与鲁棒性。

在将 SMOGN 数据增强结果用于回归建模之前,本文首先对生成样本与原始样本在特征空间的分布一致性进行了系统验证。一方面,通过最大均值差异评价,SMOGN 生成数据与原始样本在主要变量维度上的最大均值差异值低至 0.007 6,说明两者全局分布高度重合。另一方面,对各主特征(如最大主应力、温度、频率、应力幅、平均应力及数据来源)分别进行 KS 检验,所有特征的 p 值均大于 0.6(表 4),显著通过分布一致性检验。类似于分类模型, t -SNE 降维可视化也直观显示增强样本与原始样本在低维空间内高度重叠(图 11),未见异常漂移。上述结果共同表明,SMOGN 增强样本在统计分布上与原始实验数据保持高度一致,为后续回归模型的训练与泛化能力提升奠定了坚实基础。

表4 原始数据与SMOGN数据的KS检验:各特征均无显著差异($p>0.05$)

Tab.4 KS tests between SMOGN-augmented and original data with all features $p>0.05$

Features	KS test P-values	Results
Max stress	0.96	Pass
Temperature	0.63	Pass
Frequency	1.00	Pass
Source	1.00	Pass
Stress amplitude	0.91	Pass
Mean stress	0.96	Pass




图 11 t -SNE 降维可视化对比回归任务中原始样本(蓝色)与 SMOGN 增强样本(红色)的分布一致性

Fig.11 t -SNE visualization comparing the distributions of the original samples (blue) and SMOGN-generated samples (red) for regression modelling

为系统评价各类回归模型在疲劳寿命预测任务中的性能,本文以判定系数 R^2 和平均绝对百分比误差(mean absolute prediction error, MAPE)^[27]为核心评价指标,全面衡量模型的拟合优度和预测误差水平。建模过程中,除稳健回归与 HNN 两阶段组合建模

外,还选取了随机森林、高斯过程回归、支持向量回归等常用机器学习回归方法作为对比,采用统一的数据增强与5折交叉验证策略,系统评估各模型的泛化能力和鲁棒性。本节将展示各回归模型在原始与增强数据集上的主要评价指标结果,并结合残差分布、预测-实际对比图等典型分析,对比不同建模策略的优势与不足,进一步明确最优模型的选取逻辑及其工程应用价值。

表5系统比较了多种回归模型在原始数据集(46条)与SMO GN增强数据集(166条)上的疲劳寿命预测性能。结果显示,传统的线性回归和高斯过程回归(GPR)在原始小样本下表现极差(R^2 仅0.12和0.06,MAPE高达89.09%和95.56%),几乎无法捕捉复杂的疲劳寿命-特征关系。随机森林和稳健回归对性能有一定提升(R^2 分别为0.34和0.31,MAPE约19.89%和18.84%),但预测精度仍有限。单独的HNN模型在小样本下同样表现不佳(R^2 仅0.03),反映深层模型对样本量较小的数据集存在过拟合风险。

表5 各类回归模型在原始数据(46条样本)与SMO GN增强数据(166条样本)下的5折交叉验证性能对比

Tab.5 Comparison of 5-fold cross-validation performance of different regression models on the original dataset (46 samples) and SMO GN-augmented dataset (166 samples)

Machine learning models	Original data (46 samples)		SMO GN-augmented data (166 samples)	
	R^2	MAPE/%	R^2	MAPE/%
Linear regression	0.12	89.09	-	-
Random forest	0.34	19.89	0.54	13.88
Gaussian process regression	0.06	95.56	-	-
Huber regression	0.31	18.84	0.53	14.56
HNN	0.03	26.56	-	-
Huber regression+RF	0.44	16.60	0.79	7.4
Huber regression+HNN	0.50	15.70	0.81	7.3

值得注意的是,二阶组合模型(稳健回归+RF/HNN)在原始数据上表现出更强的拟合与泛化能力, R^2 分别达到0.44和0.50,MAPE降至16.6%和15.7%,表明“主趋势拟合结合残差非线性校正”能够有效提升模型精度。进一步地,在SMO GN增强数据集上,各模型的表现均有大幅提升。RF和稳健回归的提升至0.54和0.53,MAPE降至13.88%和14.56%;而稳健回归结合RF与稳健回归结合HNN组合模型的分别大幅提升至0.79和0.81,MAPE降至7.4%和7.3%。此结果表明,数据增强在提升模型泛化能力、释放复杂模型潜力方面具有关键作用。综合来看,二阶组合模型与SMO GN数据增强

策略,是实现高精度疲劳寿命回归预测的核心技术路径。

为进一步验证回归模型的预测能力,图12展示了SMO GN增强数据集上HNN模型的真实值与预测值对比散点图。图中蓝色点代表原始实验数据,红色点为SMO GN生成的增强样本。黑色对角线为理想预测线,绿色和红色虚线分别对应 $\pm 10\%$ 与 $\pm 20\%$ 误差区间。可以看到,绝大多数样本点均落在 $\pm 20\%$ 误差带以内,且原始数据(蓝色)仅有6个样本超出 $\pm 20\%$ 误差区间。这表明模型不仅在增强样本上具备高精度预测能力,在真实实验数据上的工程适用性和稳健性同样得到了充分体现。




图12 稳健回归结合HNN模型在SMO GN增强数据集上的真实值与预测值对比散点图

Fig.12 Comparison between true and predicted fatigue life values for Huber regression with the HNN model on the SMO GN-augmented dataset

为了进一步揭示二阶组合建模框架中主趋势模型的物理合理性,对稳健回归子模型的线性系数进行了详细分析。由于稳健回归具备较强的鲁棒性,其回归系数能够直观反映各输入特征对疲劳寿命主趋势的实际贡献,有助于理解数据中各变量的主控作用与内在机理。稳健回归拟合直线可得如下:

$$\hat{y}_i^{\text{Huber}} = 0.91 \times \text{Max stress} + 6.09 \times \text{Temperature} - 6.11 \times \text{frequency} - 6.61 \times \text{stress amp} + 6.45 \times \text{mean_stress} - 3.44 \times \text{source} + 5.30 \quad (20)$$

稳健回归主趋势模型的系数可以显示各输入变量对疲劳寿命的边际贡献,体现了明显的多变量回归特征。平均应力(6.45)、温度(6.09)和最大应力(0.91)的系数均为正,在控制其他变量不变的情况下,这些变量的增加会提升疲劳寿命预测值。频率(-6.11),应力幅(-6.61)和粉末来源(-3.44)系数为负,这些变量的增加会降低疲劳寿命预测值。

需要指出的是,这样的回归系数分布,并不意味着“最大应力越大,寿命越长”等直接物理结论,而是反映了多变量回归中变量间高度相关性(多重共线

性)对系数分配的影响。具体而言,最大应力、应力幅和平均应力三者之间存在线性组合关系,主控变量的信息被多个衍生变量分摊,导致最大应力本身的回归系数数值较小甚至符号可能与常规物理经验不符。此时,正系数体现的是“在控制应力幅和平均应力不变时,最大应力增加一单位对寿命的边际影响”,而非单变量情形下的直接物理意义。温度和平均应力的正系数,也需结合具体数据分布和变量构造方式进行理解。

进一步排除多重共线性对回归系数解释的影响,并更准确地揭示各输入变量对疲劳寿命回归预测的实际贡献,本文进一步对第二阶段 HNN 残差回归模型开展了基于 SHAP 方法的特征重要性分析。如图 13 所示,SHAP 值能够量化每个变量对模型输出的平均边际影响,从而更清晰地反映特征对模型预测的全局贡献。分析结果显示,加载频率的 SHAP 绝对均值最高(1.18),表明在 HNN 模型修正主趋势残差时,频率对预测结果的边际影响最大,是模型调整非线性误差的关键变量。最大应力和应力幅的 SHAP 值也较高(0.92 和 0.60),说明主应力水平和应力幅度依然是影响疲劳寿命局部修正的重要物理因素,强化了其在主控变量中的作用。温度、平均应力和粉末来源的 SHAP 值相对较低(0.35、0.27 和 0.23),但在部分样本中仍发挥局部调节和补偿作用。总体来看,SHAP 分析再次突出频率与应力类变量在疲劳寿命高精度建模中的主导性。这表明,模型不仅在整体趋势上依赖于物理主控变量,在复杂误差修正阶段也能有效捕捉其非线性和交互效应,进一步增强了模型的物理合理性和工程解释力。




图 13 二阶段 HNN 残差回归模型各输入特征平均绝对 SHAP 值的条形图

Fig.13 Bar plot of the mean absolute SHAP values for each input feature in the second-stage HNN residual regression model

2.4 结果讨论与局限性

为进一步深化对所提出方法的理解及其在实际工程应用中的价值,现有必要对研究结果进行更高

层次的归纳和反思。基于上述分析,本节将从工程意义、科学启示以及方法局限性等方面展开讨论,为未来相关研究和模型应用提供参考。

2.4.1 工程意义与科学启示

(1)传统的单一机器学习模型(如随机森林、支持向量机和常规神经网络)在 EBM TiAl-4822 合金的小样本数据集上表现有限,难以实现工程要求的预测精度。这主要归因于钛铝系合金本身脆性高、对缺陷敏感性强,疲劳寿命分布在实际测试中呈现显著的不均衡性和高度非线性特点。针对这一特征,本文通过 SMOTE 与 SMOGN 数据增强技术有效扩展了训练数据集,使得模型在小样本和极端区间的预测性能显著提升,特别是极大增强了模型对低寿命、敏感服役条件下的工程预测能力。这一成果提示,后续在工程疲劳寿命预测实践中,应特别强调采用严谨的数据增强策略,并通过 MMD、KS、 t -SNE 等多种统计与可视化方法严格检验数据增强的合理性,以确保预测结果真实可靠,避免出现由数据失真导致的错误工程决策。

(2)本研究中提出的稳健回归与 HNN 组合的二阶段建模策略,体现出了显著的工程适用性和理论优势。钛铝合金因其晶体结构特殊性(如层片状 γ 相和 α_2 相分布)和微观缺陷(如微孔、未熔合缺陷)的广泛存在,导致疲劳数据中常出现异常点或寿命高度离散的情况,传统最小二乘回归和一般神经网络模型对此极为敏感,易受极端值干扰而模型失真。稳健回归通过特殊的分段损失函数(小残差平方项、大残差线性项)能够很好地克服这些问题,表现出对疲劳数据中异常值的高鲁棒性。此外,稳健回归的回归系数能够直观量化各个输入变量(如最大应力、温度、频率等)对疲劳寿命的主趋势贡献,这种物理可解释性对于实际的工艺设计和疲劳寿命控制具有明显的优势和工程指导价值。

在此基础上,HNN 结构更进一步提升了模型的非线性学习能力与工程泛化性。相比于传统神经网络模型简单地对所有变量进行无差别的全连接堆叠,HNN 利用变量的物理属性和工程意义进行明确分组和分层,通过不同层级的特征提取和融合,更高效、更精准地表达了 TiAl-4822 合金复杂非线性疲劳行为。这种模型结构不仅降低了因变量之间高度相关(如最大应力、平均应力、应力幅之间的共线性)造成的特征混淆与模型不稳定风险,也为模型的可解释性提供了结构化的基础,使研究者能够深入分析和理解变量间交互作用的内在机制。

(3)通过 SHAP 特征重要性分析明确揭示,加载频率、最大应力、温度等变量在模型预测中始终发挥着主导作用,而衍生变量如应力幅和平均应力在非线形修正与局部调整中也体现出重要贡献。这一结果与疲劳理论和以往钛铝合金疲劳研究中强调的应力-环境协同效应高度一致。因此,后续 EBM 制备 TiAl-4822 合金服役条件设计和疲劳性能优化,应特别注意频率条件和应力加载方式的精确控制,避免由频率过高或应力幅过大引发的材料早期疲劳损伤或服役失效。

相较于近期其他疲劳预测研究,本研究在不依赖具体缺陷信息或微观组织输入的前提下,实现了可比甚至更优的建模性能。如,Abiria 等^[28]将 Basquin/Paris 定律嵌入神经网络,在增材 Al-Mg-4.5Mn 与 Ti-6Al-4V 合金上实现约 23% 对称平均绝对百分比误差,且 90% 预测寿命总体落入 2 倍因子散布带;Liu 等^[29]通过缺陷统计特征构建 TA15 合金的应力-寿命概率回归模型;Song 等^[30]则利用生成对抗网络增强数据,在疲劳寿命预测中将 R^2 提升约 0.05,误差下降 2%。相比之下,本文提出的 SMOTE/SMOEN 数据增强结合稳健回归与 HNN 架构,在小样本、高非线性疲劳建模中同样表现出优异性能(通过/不通过分类准确率达 0.80,未通过样本寿命预测 $R^2=0.81$,MAPE=7.3%),验证了本方法在复杂工况下的实用性、鲁棒性与广泛适应性。

2.4.2 方法的局限性

尽管本文所提出的建模方法获得了良好的结果(分类准确率达到 80%,回归预测 R^2 达到 0.81,MAPE=7.3%),并在小样本预测中表现出优异的工程适用性,但依然存在一些局限性值得重视:

(1)数据局限性 当前数据均来自实验室环境下制备和测试的标准样本,未涉及实际工程零件尺度和更复杂的真实服役环境(如多轴载荷、环境腐蚀、高低温交变等),数据的代表性和丰富性仍然有限。虽然数据增强方法显著缓解了这一问题,但并不能完全替代真实多样化数据采集。未来研究中应积极扩展数据采集来源和服役条件的广泛性,以进一步提高模型的实际应用范围和泛化能力。

(2)模型机理局限性 本文采用的数据驱动方法虽然在预测精度和泛化性能方面表现突出,但尚未与 TiAl-4822 合金疲劳损伤机理(如晶界裂纹萌生机制、相界滑移行为、微结构演化机制)直接耦合。尽管稳健回归和 HNN 结构提供了模型可解释性,但依然属于统计意义上的可解释性,距离真正机理导向的模型仍有一定距离。后续研究可

尝试结合更深入的疲劳损伤理论和微观组织仿真计算,构建更加严谨和机理清晰的数据-物理混合驱动模型。

(3)工程落地的局限性 实际的工程应用环境通常复杂多样,受到制造缺陷、服役条件变动和长时服役损伤累积等因素的综合作用,这些因素的共同作用可能超出目前模型预测的能力范畴。因此,本研究所开发的模型在真实工程应用前,需结合多场景试验验证和可靠性分析,进一步明确模型在更复杂环境下的预测边界条件和适用范围。

综上所述,本研究明确验证了数据增强与稳健回归-HNN 组合建模在 EBM 增材制造 TiAl-4822 合金疲劳寿命预测任务中的优势与可行性,强调了数据增强方法、鲁棒模型结构和明确物理意义变量选择对实际工程预测的巨大价值,同时也反应了方法在数据、机理和工程应用层面的局限性,这为未来相关研究明确了发展方向和需要关注的关键问题。

3 结论

(1)针对疲劳寿命分类任务(以 10^7 循环为界),本文提出的 SMOTE 数据增强与 HNN 分层结构组合模型显著提升了模型的泛化能力,在增强数据集上的 5 折交叉验证准确率达到 80%,实现了精准预测与可靠分类。

(2)在未通过疲劳测试样本的回归预测中,本文设计的二阶建模框架(稳健回归结合 HNN 残差校正)表现突出。通过 SMOEN 数据增强进一步提升了模型精度,最终预测的 R^2 达到 0.81,MAPE 低至 7.3%。真实样本预测误差大部分(约 87%)位于 $\pm 20\%$ 区间内,表明模型具有优异的工程适用性。

(3)SHAP 可解释性分析明确指出,加载频率、最大应力、温度以及应力幅是影响 TiAl-4822 疲劳寿命预测精度的关键因素,提示了后续材料设计、工艺优化及服役条件控制的明确方向。

综上,本文建立了一种数据驱动的 EBM TiAl-4822 合金高精度疲劳寿命预测新方法,为增材制造材料可靠性评估与疲劳性能优化提供了坚实的数据分析工具和理论方法支撑。尽管如此,现有方法在数据多样性、微观机理融合和工程落地等方面仍有改进空间。

参考文献:

- [1] LIN B C, CHEN W, YANG Y, WU F, LI Z Q. Anisotropy of microstructure and tensile properties of Ti-48Al-2Cr-2Nb fabricated

- by electron beam melting[J]. Journal of Alloys and Compounds, 2020, 830: 154684.
- [2] LIN B C, CHEN W. Mechanical properties of TiAl fabricated by electron beam melting - A review[J]. China Foundry, 2021,18(4): 307-316.
- [3] USATEGUI L, LÓPEZ-FERREÑO I, ECHÁNIZ T, SAINZ-MENCHÓN M, MUSI M, CLEMENS H, LÓPEZ G A. Emissivity measurements conducted on intermetallic γ -TiAl-based alloys for aeronautical applications [J]. Journal of Materials Research and Technology, 2023, 27: 3170-3179.
- [4] CAKMAK E, NANDWANA P, SHIND, YAMAMOTO Y, GUSSEV M N, SEN I, HAZAR SEREN M, WATKINS T R, HAYNES J A. A comprehensive study on the fabrication and characterization of Ti-48Al-2Cr-2Nb preforms manufactured using electron beam melting[J]. Materialia, 2019, 6: 100284.
- [5] YOUN S J, KIM Y K, KIM H S, LEE K A. Improvement in the high temperature mechanical properties of additively manufactured Ti-48Al-2Cr-2Nb alloy using heat treatment[J]. Intermetallics, 2023, 153: 107784.
- [6] WARTBICHLER R, CLEMENS H, MAYER S, GHIBAUDO C, RIZZA G, GALATI M, LULIANO L, BIAMINO S, UGUES D. On the formation mechanism of banded microstructures in electron beam melted Ti-48Al-2Cr-2Nb and the design of heat treatments as remedial action[J]. Advanced Engineering Materials, 2021, 23 (12): 2101199.
- [7] CHERN A H, NANDWANA P, YUAN T, KIRKA M M, DEHOFF R R, LIAW P K, DUTY C E. A review on the fatigue behavior of Ti-6Al-4V fabricated by electron beam melting additive manufacturing[J]. International Journal of Fatigue, 2019, 119: 173-184.
- [8] MURAKAMI Y, TAKAGI T, WADA K, MATSUNAGA H. Essential structure of S-N curve: Prediction of fatigue life and fatigue limit of defective materials and nature of scatter[J]. International Journal of Fatigue, 2021, 146: 106138.
- [9] SHI T, SUN J Y, LI J H, QIAN G A, HONG Y S. 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.
- [10] TANG W, TANG Z M, LU W J, WANG S, YI M. Modeling and prediction of fatigue properties of additively manufactured metals [J]. Acta Mechanica Solida Sinica, 2023, 36(2): 181-213.
- [11] ZHOU W L, SHEN C, WANG L, LI Y, ZHANG T, XIN J W, DING Y H, ZHANG D Q, ZHANG Y L, LI F, HUA X. High-temperature tensile and fatigue properties of Ti-48Al-2Cr-2Nb alloy additively manufactured via twin-wire directed energy deposition-arc[J]. Intermetallics, 2025, 184: 109933.
- [12] HOUSER E, SHASHAANIS, HARRYSSON O, JEON Y. Predicting additive manufacturing defects with robust feature selection for imbalanced data[J]. IJSE Transactions, 2024, 56(9): 1001-1019.
- [13] LIU J, YE J F, IZQUIERDO D S, VINEL A, SHAMSAEI N, SHAO S. A review of machine learning techniques for process and performance optimization in laser beam powder bed fusion additive manufacturing [J]. Journal of Intelligent Manufacturing, 2023, 34: 3249-3275.
- [14] POUDEL A, YASIN M S, YE J F, LIU J, VINEL A, SHAO S, SHAMSAEI N. Feature-based volumetric defect classification in metal additive manufacturing [J]. Nature Communications, 2022, 13: 6369.
- [15] ZHAN Z X, LI H. Machine learning based fatigue life prediction with effects of additive manufacturing process parameters for printed SS 316L[J]. International Journal of Fatigue, 2021, 142: 105941.
- [16] ZHANG M, SUN C N, ZHANG X, GOH P C, WEI J, HARDACRE D, LI H. High cycle fatigue life prediction of laser additive manufactured stainless steel: A machine learning approach [J]. International Journal of Fatigue, 2019, 128: 105194.
- [17] BAO Y. Hopfield neural networks: A updated approach for using associative memory to improve matrices [D]. Auburn: Auburn University, 2024.
- [18] PROCHAZKA R, DZUGAN J, KONOPIK P. Fatigue limit evaluation of structure materials based on thermographic analysis[J]. Procedia Structural Integrity, 2017, 7: 315-320.
- [19] DASARI S K, CHEDDAD A, PALMQUIST J, LUNDBERG L. Clustering-based adaptive data augmentation for class-imbalance in machine learning (CADA): Additive manufacturing use case[J]. Neural Computing and Applications, 2025, 37(2): 597-610.
- [20] GRETTON A, BORGWARDT K M, RASCH M J, SCHÖLKOPF B, SMOLA A. A kernel two-sample test[J]. The Journal of Machine Learning Research, 2012, 13: 723-773.
- [21] BATURYNSKA I, MARTINSEN K. Prediction of geometry deviations in additive manufactured parts: Comparison of linear regression with machine learning algorithms[J]. Journal of Intelligent Manufacturing, 2021, 32: 179-200.
- [22] BAO Y D, GAILLARD P. Summarizing some conventional methods to classify a binary target[A]. Proceedings of SESUG 2019 Conference[C]. Williamsburg: SESUG. 2019.
- [23] BAO Y D, HUANG I, LI Q, ZHANG Z, XING Y, HOU D F, YE J F. A framework for modeling county-level COVID-19 transmission [J]. Frontiers in Public Health, 2025, 13: 1608360.
- [24] YE J F, POUDEL A, LIU J, VINEL A, SILVA D, SHAO S, SHAMSAEI N. Machine learning augmented X-ray computed tomography features for volumetric defect classification in laser beam powder bed fusion[J]. The International Journal of Advanced Manufacturing Technology, 2023, 126: 3093-3107.
- [25] BASTENAIRE F A. New method for the statistical evaluation of constant stress amplitude fatigue-test results [M]//HELLER R A. Probabilistic aspects of fatigue. West Conshohocken: ASTM International, 1972: 26.
- [26] AKIBA T, SANO S, YANASE T, OHTA T, KOYAMA M. Optuna: A next-generation hyperparameter optimization framework [A]. KDD '19: Proceedings of the 25th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining[C]. Anchorage: Association for Computing Machinery, 2019. 2623-2631.
- [27] CHICCO D, WARRENS M J, JURMAN G. The coefficient of determination R-squared is more informative than SMAPE, MAE, MAPE, MSE and RMSE in regression analysis evaluation[J]. PeerJ Computer Science, 2021, 7: e623.
- [28] ABIRIA I, WANG C, ZHANG Q C, LIU C M, JIN X. 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.
- [29] LIU Y, GAO X X, ZHU S Y, HE Y H, XU W. Fatigue life prediction of selective laser melted titanium alloy based on a machine learning approach [J]. Engineering Fracture Mechanics, 2025, 314: 110676.
- [30] SONG Z X, PENG J L, ZHU L N, DENG C Y, ZHAO Y Y, GUO Q Y, ZHU A R. High-cycle fatigue life prediction of additive manufacturing Inconel 718 alloy via machine learning[J]. Materials, 2025, 18(11): 2604.

(责任编辑:宫文婧)