

基于机器学习模型的 TC4 钛合金疲劳寿命预测

赵鹏程¹, 李凯尚², 苏庆³, 车伟¹, 李昌¹, 王冬振¹, 韩贵生¹, 郎连林³

(1. 陕西天成航空材料股份有限公司, 陕西 咸阳 712023)

(2. 华东理工大学, 上海 200237)

(3. 中国人民解放军 93147 部队某军事代表室, 贵州 贵阳 550000)

摘要: 分析了 Al、V、O、Fe 元素含量对 TC4 钛合金低周疲劳和高周疲劳寿命的影响规律, 并基于机器学习模型对 TC4 钛合金的低周疲劳和高周疲劳寿命进行预测。研究表明, 在本研究涉及的元素范围内, Al、V 元素含量对 TC4 钛合金的低周疲劳寿命影响较小, Fe 元素含量对 TC4 钛合金的疲劳性能有积极影响, O 元素含量对 TC4 钛合金疲劳寿命的影响较为显著。对于应变控制的低周疲劳, TC4 钛合金的疲劳寿命随着 O 元素含量的增加先增加后降低; 对于应力控的高周疲劳 ($\sigma_{\max} \leq 700$ MPa), TC4 钛合金的疲劳寿命随着 O 元素含量的增加而显著提升。最后, 将 TC4 钛合金元素含量、加载模式和载荷工况作为机器学习的输入变量进行预测, 基于广义回归神经网络的预测结果偏于非保守, 支持向量机回归模型表现出更高的预测精度。本研究为 TC4 钛合金的材料设计与性能优化提供了实验和理论依据。

关键词: 钛合金; 机器学习; 疲劳寿命预测; 低周疲劳; 高周疲劳

中图分类号: TG146.23

文献标识码: A

文章编号: 1009-9964(2025)02-001-08

Fatigue Life Prediction of TC4 Titanium Alloy Based on Machine Learning Models

Zhao Pengcheng¹, Li Kaishang², Su Qing³, Che Wei¹, Li Chang¹, Wang Dongzhen¹, Han Guisheng¹, Lang Lianlin³

(1. Shaanxi Tiancheng Aerospace Co., Ltd., Xianyang 712023, China)

(2. East China University of Science and Technology, Shanghai 200237, China)

(3. Military Representative Office, Unit 93147, People's Liberation Army of China, Guiyang 550000, China)

Abstract: The effects of Al, V, O, and Fe elements content on the low cycle fatigue (LCF) and high cycle fatigue (HCF) lives of TC4 titanium alloy were investigated. The LCF and HCF lives of TC4 titanium alloy were predicted by using machine learning models. The results indicate that Al and V contents have minimal effect on LCF life, and Fe content positively influences the fatigue life of TC4 titanium alloy. The effect of O content on fatigue life of TC4 titanium alloy is significant. For the strain-controlled low cycle fatigue, the fatigue life of TC4 titanium alloy increases and then decreases with increasing O content. For stress-controlled high cycle fatigue ($\sigma_{\max} \leq 700$ MPa), the fatigue life of TC4 titanium alloy significantly increases with increasing O content. Finally, element content, loading mode and loading condition were considered as input variables of machine learning model to predict the fatigue life of TC4 titanium alloy. The predicted life is non-conservative based on generalized regression neural network, while the support vector machine regression shows the highest prediction accuracy. This study provides experimental and

theoretical bases for the material design and performance optimization of TC4 titanium alloy.

Keywords: titanium alloy; machine learning; fatigue life prediction; low cycle fatigue; high cycle fatigue

收稿日期: 2024-11-25

基金项目: 国家自然科学基金青年基金项目 (52105144); 秦创原引用高层次创新创业人才项目 (QCYRCXM-2022-192); 咸阳市“科学家+工程师”队伍项目 (S2024-CXNL-KJRCTD-DWJS-2660); 咸阳市科技创新团队项目 (L2023CXNLCXTD 007); 陕西天成航空材料股份有限公司研发项目 (TC/XM230030)

通信作者: 李凯尚 (1993—), 男, 博士后。

TC4 钛合金被广泛应用于航空、航天和船舶领域, 其疲劳性能直接影响结构件的服役寿命^[1-2]。研究表明, 元素含量对钛合金的疲劳行为有显著影响。Al 元

素是钛合金的主要合金元素之一，具有改善合金强度和抗氧化性的作用。添加 Al 元素通常能提高合金的抗氧化性和耐高温性能，但 Al 含量过高可能导致合金脆化。刘木垚等^[3]发现随着 Al 含量的增加，钛合金的屈服强度和抗压强度增大，压缩率呈现先增大后减小的趋势。V 元素是钛合金中添加的另一种重要元素，对钛合金的强度和韧性具有积极影响。研究表明，V 元素能够优化合金的微观结构，尤其是细化晶粒，从而提高低周疲劳性能^[4]。但是，V 含量过高可能导致应力集中，在高周疲劳条件下会加速裂纹的形成和扩展。随着 Fe 含量的增加，钛合金的屈服强度和抗拉强度先提高后保持稳定，而断后延伸率先提升后降低^[5]，此外，Fe 含量的增加对钛合金的低周疲劳性能有积极作用^[6-7]。O 也是钛合金中的重要元素，其含量对合金的疲劳性能有显著影响。尽管 O 元素在钛合金中作为杂质存在时通常会降低其某些性能，但适量的 O 元素有时能够提升其疲劳寿命，主要是由于 O 元素对钛合金微观结构的影响作用^[8]。例如，O 元素与钛合金中的其他元素（如 Al）发生相互作用，形成细小的强化相，这些强化相能够阻碍裂纹的扩展。

通过上述文献发现，钛合金的元素含量对其疲劳寿命具有显著影响。因此，发展考虑钛合金元素含量的疲劳寿命预测模型可以为材料疲劳性能的优化提供理论依据。目前已被应用的模型主要包括宏观模型^[9-10]、微观模型^[11-12]和机器学习模型^[13-14]。宏观疲劳寿命预测模型侧重于宏观力学行为，通常基于材料的应力-应变关系，例如 Coffin-Manson 低周疲劳模型和 Basquin 高周疲劳模型等，这些模型能够预测在给定载荷条件下钛合金的疲劳寿命。微观疲劳模型注重材料内部的微观结构演化，晶体塑性模型是常用的微观模型，该模型可以考虑晶粒分布、元素含量以及相变等因素对钛合金疲劳寿命的影响规律，因此利用晶体塑性有限元方法可以精准预测钛合金在不同微观组织下的疲劳寿命。近年来，随着数据科学和机器学习技术的发展，基于机器学习模型的疲劳寿命预测方法逐渐成为研究的新方向^[15-16]。机器学习模型能够处理复杂的材料特性与外部条件之间的非线性关系，通过大量实验数据进行训练，从而实现钛合金疲劳寿命的精确预测。与传统的模型相比，机器学习模型不仅能够提高预测精度，还能减少对材料微观结构的依赖性，使得疲劳寿命预测更加高效和灵活。

本研究通过开展大量疲劳试验，探究了 Al、V、O、Fe 含量对 TC4 钛合金低周和高周疲劳性能的影响，基于机器学习方法建立了一种考虑 TC4 钛合金元素含量、加载模式和载荷工况的疲劳寿命预测模

型，以准确预测该合金在不同工况下的疲劳寿命。本研究的开展不仅能够提高对 TC4 钛合金疲劳寿命的预测能力，而且可以为材料优化及安全评估提供理论和技术支撑。

1 实 验

1.1 实验材料

实验材料为 TC4 钛合金，其制备方法如下：首先按照所设计的不同元素含量配比进行配料，再经 2 次真空自耗电弧熔炼获得质量约为 10 kg 的铸锭，随后进行多次锻造，得到尺寸为 300 mm×60 mm×30 mm 的锻坯；对锻坯进行热处理（955 ℃保温 120 min，随后升温至 1000 ℃保温 40 min，空冷；730 ℃时效 130 min，空冷）。对热处理后的 14 块 TC4 钛合金锻坯进行元素含量测量，主要元素含量见表 1。

表 1 TC4 钛合金元素含量(wt%)
Table 1 Element contents of TC4 titanium alloy

No.	Chemical composition	Element
SF-1	5.00Al-4.14V-0.051Fe-0.110O	Al
SF-2	6.85Al-4.31V-0.055Fe-0.109O	Al
SF-3	5.73Al-4.24V-0.050Fe-0.115O	Al
SF-4	4.58Al-4.19V-0.051Fe-0.116O	Al
SF-5	6.06Al-3.69V-0.061Fe-0.171O	V
SF-6	6.00Al-4.66V-0.065Fe-0.168O	V
SF-7	6.15Al-4.30V-0.052Fe-0.188O	Fe
SF-8	6.09Al-4.26V-0.155Fe-0.174O	Fe
SF-9	6.12Al-4.24V-0.330Fe-0.170O	Fe
SF-10	6.13Al-4.09V-0.073Fe-0.074O	O
SF-11	6.12Al-4.11V-0.077Fe-0.138O	O
SF-12	5.93Al-3.98V-0.066Fe-0.185O	O
SF-13	5.94Al-4.00V-0.064Fe-0.240O	O

1.2 高低周疲劳试验

按图 1 所示，采用数控机床加工疲劳试样，并对其表面进行打磨和抛光处理。分别按照 GB/T 26077—2021《金属材料疲劳试验 轴向应变控制方法》和 GB/T 3075—2021《金属材料 疲劳试验 轴向力控制方法》对 TC4 钛合金试样进行低周疲劳和高周疲劳试验，所有疲劳试验均在室温下进行。低周疲劳试验采用应变控制加载模式，载荷波形为三角波，试验速率为 0.01 s⁻¹，应变比为-1，应变幅值分别为±0.8%、±0.6%、±0.45%，每个应变水平测试 4 个有效数据点以保证试验数据的准确性。高周疲劳试验采用应力控制的加载模式，载荷

波形为正弦波，加载频率为 10 Hz，应力比为 0.1，最大应力值分别为 800、700、600 MPa，每个应力水平测试 4 个有效数据点以保证试验数据的准确性。




图 1 疲劳试样尺寸示意图

Fig.1 Schematic diagram of fatigue specimen dimension

2 疲劳试验结果

2.1 Al 含量对 TC4 钛合金疲劳寿命的影响

图 2 给出了不同 Al 含量对 TC4 钛合金低周疲劳

和高周疲劳寿命的影响。从图 2 可以看出，Al 含量对 TC4 钛合金的低周疲劳和高周疲劳寿命均有一定影响。如图 2a、2b 所示，随着 Al 含量的增加，低周疲劳寿命在不同应变幅下表现出明显差异：在较高的应变幅（ $\varepsilon_a=0.8\%$ ）下，Al 含量不同的 TC4 钛合金疲劳寿命接近；在较低的应变幅（ $\varepsilon_a=0.45\%$ ）下，该合金的疲劳寿命随着 Al 含量的增加先提升后降低，在 Al 含量为 5.73% 时表现出优异的疲劳寿命。图 2c、2d 为不同 Al 含量下 TC4 钛合金的应力控高周疲劳寿命分布。在高应力水平（ $\sigma_{\max}=800$ MPa）下，不同 Al 含量的合金疲劳寿命差异较小，但 Al 含量较高的合金（如 SF-2）表现出更优的疲劳寿命。在低应力水平（ $\sigma_{\max}=600$ MPa）下，Al 含量对疲劳寿命的影响更加显著，Al 含量为 6.85% 时，TC4 钛合金（SF-2）的疲劳寿命最优，说明适当增加 Al 含量有助于提升 TC4 钛合金的高周疲劳寿命。




图 2 Al 含量对 TC4 钛合金疲劳寿命的影响

Fig.2 Effect of Al content on fatigue life of TC4 titanium alloy: (a, b) low cycle life; (c, d) high cycle life

2.2 V 含量对 TC4 钛合金疲劳寿命的影响

图 3 给出了 V 含量对 TC4 钛合金低周疲劳和高周疲劳寿命的影响。如图 3a、3b 所示，在应变控加载模式下，V 含量对 TC4 钛合金的低周疲劳寿命影响较小。在低应变幅（ $\varepsilon_a=0.45\%$ ）下，V 含量较高的 TC4 钛合金（SF-6）表现出更高的疲劳寿命，但是在较高应变幅（ $\varepsilon_a=0.6\%$ 和 0.8% ）下，V 含量较低的 TC4 钛合金（SF-5）疲劳寿命更高。如图 3c、3d 所示，在高应力

水平（ $\sigma_{\max}=800$ MPa）下，V 含量较高的 TC4 钛合金（SF-6）表现出更高的疲劳寿命；在较低应力水平（ $\sigma_{\max}=600$ MPa）下，这种趋势更为明显，V 含量更高的合金高周疲劳寿命被显著提升。总体来看，V 含量的增加能够在一定程度上提高 TC4 钛合金的低周疲劳和高周疲劳寿命。

2.3 Fe 含量对 TC4 钛合金疲劳寿命的影响

Fe 含量对 TC4 钛合金微观组织和力学性能的影响




图3 V含量对TC4钛合金疲劳寿命的影响

Fig.3 Effect of V content on fatigue life of TC4 titanium alloy: (a, b) low cycle life; (c, d) high cycle life

响尤为显著^[17]。图4给出了不同Fe含量试样在应变变控和应力变控下的低周疲劳和高周疲劳寿命。从图4a、4b可以看出,在低应变幅($\epsilon_a=0.45\%$)下,TC4钛合金的低周疲劳寿命随着Fe含量的增加而增大,而在高应变幅下Fe含量对TC4钛合金的疲劳寿命影响不大。

从图4c、4d可知,在低应力水平($\sigma_{max}=600\text{ MPa}$)下,Fe含量对TC4钛合金的高周疲劳寿命具有显著影响;在高应力水平($\sigma_{max}\geq 700\text{ MPa}$)下,当Fe含量达到0.155%后,其对合金的疲劳寿命影响不大。综上所述,Fe含量对TC4钛合金的低周疲劳和高周疲劳性能




图4 Fe含量对TC4钛合金疲劳寿命的影响

Fig.4 Effect of Fe content on fatigue life of TC4 titanium alloy: (a, b) low cycle life; (c, d) high cycle life

均有显著影响，增加 Fe 含量有助于提高合金的疲劳寿命。

2.4 O 含量对 TC4 钛合金疲劳寿命的影响

O 含量对 TC4 钛合金疲劳寿命的影响规律如图 5 所示。从图 5a、5b 所示应变控低周疲劳寿命分布来看，随着 O 含量的增加，TC4 钛合金的疲劳寿命先增加后降

低。从图 5c、5d 所示应力控高周疲劳寿命分布来看，在低应力水平 ($\sigma_{\max} \leq 700$ MPa) 下，试样的疲劳寿命随着 O 含量的增加而增加，尤其在最大应力为 600 MPa 时，O 含量为 0.240% 的试样 (SF-13) 表现出优异的疲劳寿命。这种现象可能与 O 元素在钛基体中的固溶强化作用有关，增加了 TC4 钛合金的抗疲劳损伤能力。




图 5 O 含量对 TC4 钛合金疲劳寿命的影响

Fig.5 Effect of O content on fatigue life of TC4 titanium alloy: (a, b) low cycle life; (c, d) high cycle life

通过上述疲劳试验发现，Al、V、O、Fe 元素的含量均对 TC4 钛合金的疲劳性能具有显著影响。为了确定最优元素含量组合，分别从图 2~5 中选取每种元素含量最佳的 TC4 钛合金进行疲劳寿命对比，结果如图 6 所示。从图 6a、6b 可以看出，在应变控低周疲劳条件下，O 含量对 TC4 钛合金的疲劳寿命影响较大，特别是 O 含量较高的 SF-12 试样表现出更加优异的低周疲劳寿命。此外，当 TC4 钛合金中 Al、V、O、Fe 元素含量较高时，试样 (SF-9) 低周疲劳寿命显著提升。从图 6c、6d 可以看出，在应力控高周疲劳条件下，O 含量较高的 SF-9 及 SF-13 试样均表现出较为优异的高周疲劳性能。

3 基于机器学习的疲劳寿命预测

3.1 机器学习模型

BP 神经网络 (backpropagation neural network, BPNN) 是一种具有前馈结构的多层神经网络模型，通常由输入层、一个或多个隐藏层和输出层组成，用于处理非线性和复杂数据的预测建模^[18]。在预测 TC4 钛

合金元素含量、加载工况与疲劳寿命关系的研究中，BPNN 因其强大的非线性映射能力和自学习特性，能够从实验数据中提取元素含量和加载工况对疲劳寿命的影响规律，从而在一定程度上替代传统的经验公式进行寿命预测。BPNN 的计算过程首先是前向传播，即从输入层经过隐藏层到达输出层的计算过程。对于每一个隐藏层节点 j ，其输出可以表示为：

$$z_j^{(l)} = \sum_i W_{ij}^{(l)} a_i^{(l-1)} + b_j^{(l)} \quad (1)$$

式中： $W_{ij}^{(l)}$ 为连接节点 i 和节点 j 的权值， $a_i^{(l-1)}$ 为前一层节点的激活值， $b_j^{(l)}$ 为该层节点的偏置值。隐藏层和输出层的每个节点将其输入 $z_j^{(l)}$ 通过激活函数 $f(\cdot)$ 进行非线性变换，得到输出为：

$$a_j^{(l)} = f(z_j^{(l)}) \quad (2)$$

常用的激活函数包括 Sigmoid 函数、ReLU 函数等，本研究采用 Sigmoid 函数，其形式为：

$$f(z) = \frac{1}{1 + e^{-z}} \quad (3)$$




图 6 不同元素含量 TC4 钛合金的疲劳寿命分布

Fig.6 Fatigue life distribution of TC4 titanium alloy with different element contents: (a, b) low cycle life; (c, d) high cycle life

广义回归神经网络 (generalized regression neural network, GRNN) 是一种基于径向基函数的前馈神经网络, 适合处理小样本且具有较强非线性和不确定性的预测问题^[19]。GRNN 能够通过对小样本试验数据的学习, 用于预测不同元素含量对材料性能的影响规律, 例如预测钛合金中不同元素含量对其疲劳寿命的影响。GRNN 主要包括 4 个层次, 分别是输入层、模式层、求和层和输出层。输入层用于接收输入变量, 即 TC4 钛合金各元素含量 (Al、V、O、Fe) 以及加载工况。每个模式层节点对应一个训练样本, 计算输入向量与训练样本的欧氏距离, 表达式为:

$$D_i = \|X - X_i\| \quad (4)$$

式中: X 是当前输入向量, X_i 是第 i 个训练样本。求和层包括 2 个节点, 分别计算加权求和分子和加权求和分母。分子和分母计算公式分别为:

$$S = \sum_{i=1}^N Y_i \exp\left(-\frac{D_i^2}{2\bar{\omega}^2}\right) \quad (5)$$

$$G = \sum_{i=1}^N \exp\left(-\frac{D_i^2}{2\bar{\omega}^2}\right) \quad (6)$$

式中: Y_i 是第 i 个样本的输出值 (即疲劳寿命), $\bar{\omega}$ 为平滑参数, 用于控制径向基函数的扩展程度。输出层用于计算预测值, 表达式为:

$$\hat{Y} = \frac{S}{G} \quad (7)$$

式中: $\hat{Y}$ 为 GRNN 预测的输出值, 即 TC4 钛合金的疲劳寿命。

支持向量机回归 (support vector regression, SVR) 适用于处理非线性、高维度和小样本的数据回归问题^[20]。SVR 可以将输入数据映射到高维空间, 通过找到一个最优的超平面或非线性边界, 使模型能够以更小的误差对数据进行预测。对于预测 TC4 钛合金不同元素含量对疲劳寿命的影响, SVR 能够在非线性回归的场景下取得良好的预测效果。SVR 的目标是找到一个最优函数 $f(x)$, 使其能够在允许的误差范围内逼近数据。其回归模型可以表示为:

$$f(x) = [w, \phi(x)] + b \quad (8)$$

式中: $\phi(x)$ 是将输入数据映射到高维特征空间的非线性映射函数, w 和 b 分别是权重向量和偏置。SVR 通过以下优化问题来实现回归模型的训练:

$$\min_{w, b, \xi, \xi^*} \frac{1}{2} \|w\|^2 + C \sum_{i=1}^N (\xi + \xi_i^*) \quad (9)$$

式中: $\|w\|^2$ 是用于控制模型复杂度的正则项, ξ 和 ξ_i^*

为松弛变量, C 为惩罚参数, 用于控制训练误差与模型复杂度的权衡, N 是训练样本的数量。为了处理非线性回归问题, SVR 引入了核函数 $K(x_i, x_j) = [\phi(x_i), \phi(x_j)]$, 将原始输入空间的数据映射到高维特征空间。本研究使用的核函数为:

$$K(x_i, x_j) = \exp\left(-\frac{\|x_i - x_j\|^2}{2\bar{\omega}^2}\right) \quad (10)$$

3.2 数据集构建及模型训练

本研究用于训练和测试的数据集来自上述 TC4 钛合金的低周疲劳和高周疲劳试验结果。机器学习的输入参数分别为不同元素含量 (Al、V、O、Fe)、载荷工况 (最大应力和应变幅) 和加载方式 (应力控为 1, 应变控为 0), 输出参数为疲劳寿命。考虑到疲劳寿命范围从最低的 359 周次 (低周疲劳) 到最高的 5 125 215 周次 (高周疲劳), 横跨了 4 个数量级, 故考虑先对寿命取以 10 为底的对数处理。在实际的模型训练过程中, 经常会发现机器学习模型对于训练集的拟合程度较好, 一旦应用到测试集上, 其预测精度将会被降低。此外, 如果对训练集和测试集的划分不合理, 则容易出现欠拟合或过拟合现象。为了得到稳定可靠且泛用性更佳的模型, 需要对数据集进行交叉验证。本研究选用了 k 折交叉验证, 首先将全部数据划分为训练集与测试集, 同时在训练集中进一步划分成 k 个子集; 其次, 在每次训练中将一个子集作为验证

集, 其余子集作为训练集; 最后, 通过 k 次训练, 选出验证集表现最佳的模型作为最终采用的模型, 并在测试集上进行验证。在本研究中, k 取 5, 即 5 折交叉验证。

3.3 疲劳寿命预测结果

3 种不同的机器学习模型的预测结果及评价指标如图 7 所示, 其中空心方形点为训练集中的数据及其预测结果, 空心圆点为用来验证模型精度的测试集数据点。从图 7 可以看出, 对于这 3 种模型, 大部分数据分布在 ± 3 倍分散带以内。为了进一步对比这 3 种机器学习模型的预测精度, 本研究使用了概率密度函数 (probability density function, PDF) 量化模型预测误差, PDF 可以写成:

$$P_{\text{error}} = \log_{10}(N_{\text{pre}}) - \log_{10}(N_{\text{exp}}) \quad (11)$$

式中: N_{pre} 和 N_{exp} 分别表示预测疲劳寿命和试验疲劳寿命。从图 7d 可以看出, 基于 GRNN 模型的 PDF 峰值偏离中心线, 表现出非保守的预测结果。对比基于 BP 模型和 SVR 模型的 PDF, 可以发现基于 SVR 模型的 PDF 峰值较高且峰宽较窄, 说明 SVR 模型表现出更高的预测精度。




图 7 基于机器学习模型的 TC4 钛合金疲劳寿命预测结果

Fig.7 Fatigue life prediction of TC4 titanium alloy based on machine learning models:

(a) BP model; (b) GRNN model; (c) SVR model; (d) probability density function

4 结 论

(1) Al、V、O、Fe 元素含量对 TC4 钛合金的低周疲劳和高周疲劳性能具有显著影响, 通过对这 4 种元

素进行合理调配可以实现 TC4 钛合金低周疲劳和高周疲劳寿命的同步提升。

(2) 在本研究的成分范围内, O 含量对 TC4 钛合金的疲劳寿命影响较为显著。对于应变控的低周疲劳,

随着 O 含量的增加, TC4 钛合金的疲劳寿命先增加后降低; 对于应力控的高周疲劳 ($\sigma_{\max} \leq 700$ MPa), TC4 钛合金的疲劳寿命随着 O 含量增加而显著提升。

(3) 通过将元素含量、加载模式和载荷工况作为机器学习的输入变量对 TC4 钛合金进行疲劳寿命预测, 对比发现, 基于支持向量机回归模型的寿命预测精度最高, 大部分预测数据分布在 ± 3 倍分散带以内。

参考文献 References

- [1] 李炳强, 吴超, 李晨昀, 等. TC4 钛合金的多轴高周疲劳损伤及强度退化研究[J]. 稀有金属材料与工程, 2023, 52(5): 1896-1904.
- [2] 聂敬敬, 马平义, 孙京丽, 等. 选区激光熔化 TC4 合金高温力学性能及腐蚀行为研究[J]. 稀有金属材料与工程, 2023, 52(6): 2126-2133.
- [3] 刘木垚. 铝含量对粉末冶金富氧双相钛合金组织与性能影响研究[D]. 湘潭: 湘潭大学, 2021.
- [4] 杨楠. V 元素对激光增材制造 TC4 合金组织及性能的影响[D]. 沈阳: 沈阳工业大学, 2021.
- [5] Liao Y, Bai J H, Chen F W, et al. Microstructural strengthening and toughening mechanisms in Fe-containing Ti-6Al-4V: a comparison between homogenization and aging treated states[J]. Journal of Materials Science & Technology, 2022, 99(10): 114-126.
- [6] 毛成亮, 赵彬, 贾蔚菊, 等. Fe 元素含量对钛合金性能的影响[J]. 钛工业进展, 2019, 36(2): 42-46.
- [7] Xu H F, Ye D Y, Mei L B. A study of the back stress and the friction stress behaviors of Ti-6Al-4V alloy during low cycle fatigue at room temperature[J]. Materials Science and Engineering A, 2017, 700(17): 530-539.
- [8] Luo S D, Song T, Lu S L, et al. High oxygen-content titanium and titanium alloys made from powder[J]. Journal of Alloys and Compounds, 2020, 836(25): 155526.
- [9] Li K S, Gu L H, Wang X R, et al. A unified rule for high-cycle and low-cycle fatigue life prediction in multi-scale framework[J]. International Journal of Fatigue, 2023, 170: 107512.
- [10] Zhang X C, Li H C, Zeng X, et al. Fatigue behavior and bilinear Coffin-Manson plots of Ni-based GH4169 alloy with different volume fractions of δ phase[J]. Materials Science & Engineering A, 2017, 682: 12-22.
- [11] Li D F, Barrett R A, O'Donoghue P E, et al. A multi-scale crystal plasticity model for cyclic plasticity and low-cycle fatigue in a precipitate-strengthened steel at elevated temperature[J]. Journal of the Mechanics and Physics of Solids, 2017, 101: 44-62.
- [12] Li K S, Wang R Z, Yuan G J, et al. A crystal plasticity-based approach for creep-fatigue life prediction and damage evaluation in a nickel-based superalloy[J]. International Journal of Fatigue, 2021, 143: 106031.
- [13] 王海伟, 叶波, 冯晶, 等. 机器学习在钢铁材料研究中的应用综述[J]. 中国材料进展, 2023, 42(10): 806-813.
- [14] 石炜, 钱泓江, 黄志勇, 等. 基于机器学习的 TC17 合金超高周疲劳寿命预测[J]. 燃气涡轮试验与研究, 2024, 37(1): 49-54.
- [15] 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.
- [16] 邓阳, 戴春春, 王瑞金, 等. 疲劳寿命预测的机器学习模型研究进展[J]. 自然杂志, 2024, 46(4): 247-260.
- [17] Sun Y, Alexandrov I V, Dong Y, et al. Optimized low-cycle fatigue behavior and fracture characteristics of Ti-6Al-4V alloy by Fe microalloying[J]. Journal of Materials Research and Technology, 2021, 15: 5277-5287.
- [18] 赵恒章, 杨英丽, 杜宇, 等. 基于 BP 神经网络的 Ti-26 钛合金本构模型[J]. 钛工业进展, 2010, 27(1): 39-43.
- [19] Liu K, Lin T, Zhong T, et al. New methods based on a genetic algorithm back propagation (GABP) neural network and general regression neural network (GRNN) for predicting the occurrence of trihalomethanes in tap water[J]. Science of The Total Environment, 2023, 870(20): 161976.
- [20] Gu H H, Wang R Z, Zhu S P, et al. Machine learning assisted probabilistic creep-fatigue damage assessment[J]. International Journal of Fatigue, 2022, 156: 106677.