

# 数据驱动的高温结构强度与寿命评估:进展与挑战\*

杨晓光<sup>1</sup>, 谭龙<sup>1</sup>, 郝文琦<sup>1</sup>, 石多奇<sup>1</sup>, 范永升<sup>2</sup>

(1. 北京航空航天大学 能源与动力学院, 北京 102206;

2. 北京航空航天大学 航空发动机研究院, 北京 102206)

**摘要:** 本文旨在分析数据驱动思维方法和研究范式在高温结构强度与寿命评估中的应用现状、发展趋势以及存在的问题和挑战。重点关注高温结构服役微观组织演化的图像数据处理和定量识别、多因素耦合作用下的材料/结构寿命预测和本构建模方法。总结了数据驱动方法典型的4种应用方式, 即完全代替现有理论方法、耦合驱动已有方法的改进、挖掘变量之间潜在规律和定性认识量化。最后, 指出了数据驱动方法面临的诸如泛化能力不强、外推能力差以及与物理机制关联弱的问题, 探讨了未来研究的潜在方向, 以期能够推进数据驱动新范式在高温结构完整性领域的交叉应用。

**关键词:** 高温结构; 数据驱动; 图像处理; 寿命预测; 本构建模; 微观组织; 综述

**中图分类号:** V231.1 **文献标识码:** A **文章编号:** 1001-4055 (2023) 05-2304020-18

**DOI:** 10.13675/j.cnki.tjjs.2304020

## Data-Driven Structural Strength and Life Assessment of High Temperature Structure: Progresses and Challenges

YANG Xiao-guang<sup>1</sup>, TAN Long<sup>1</sup>, HAO Wen-qi<sup>1</sup>, SHI Duo-qi<sup>1</sup>, FAN Yong-sheng<sup>2</sup>

(1. School of Energy and Power Engineering, Beihang University, Beijing 102206, China;

2. Research Institute of Aero-Engine, Beihang University, Beijing 102206, China)

**Abstract:** The paper aims to analyze the current application status, development trends, and existing problems and challenges of data-driven methodologies and investigation paradigms in high-temperature structural strength and life assessment. In particular, it emphasizes on data processing and quantitative identification of images, the prediction of material/structure life under the coupling effect of multiple factors and the constitutive modeling method for microstructure evolution of high-temperature structures in service. It summarizes four typical application modes of data-driven methods, namely, the complete replacement of existing theoretical methods, the improvement of coupling-driven existing methods, the exploitation of potential regularities between variables and the quantification of qualitative understanding. Lastly, it points out the current shortcomings of data-driven methods, including weak generalization ability, poor extrapolation ability and weak correlation with physical mechanisms. Furthermore, the potential directions for future research are explored with a view of promoting the cross-application of data-driven new paradigms in the field of high-temperature structural integrity.

\* 收稿日期: 2023-04-05; 修订日期: 2023-04-18。

基金项目: 国家科技重大专项 (2019-IV-0017-0085); 国家自然科学基金 (12172021; 52205139); 博士后科学基金面上项目 (2022M710288)。

作者简介: 杨晓光, 博士, 教授, 博士生导师, 研究领域为航空发动机结构完整性。

通讯作者: 范永升, 博士后, 研究领域为航空发动机高温结构强度与寿命。E-mail: fanys@buaa.edu.cn

引用格式: 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): 2304020. (YANG Xiao-guang, TAN Long, HAO Wen-qi, et al. Data-Driven Structural Strength and Life Assessment of High Temperature Structure: Progresses and Challenges [J]. *Journal of Propulsion Technology*, 2023, 44(5): 2304020.)

**Key words:** High-temperature structure; Data driving; Image process; Life prediction; Constitutive modelling; Microstructure; Review

## 1 引言

高温结构是航空发动机和燃气轮机等国防重大装备中工作环境最为恶劣和严重的部件。这也导致高温结构的耐久性成为了制约重大装备安全服役的关键因素<sup>[1-5]</sup>。因此,开展高温结构的损伤分析和寿命评估对高温结构的科学合理设计和长寿命高可靠性安全服役至关重要。经典的结构强度寿命理论经过长久的发展,已经在材料复杂载荷下的变形行为建模<sup>[6]</sup>、损伤分析检测和寿命预测<sup>[7-10]</sup>等方面取得了十足的发展和进步。然而,基于经典物理机制和唯象的强度寿命方法在面向多变载荷环境、制造工艺、材料特性以及结构特征等复杂因素影响时,模型逐渐趋于复杂化,面向问题单一化。极端服役复杂环境下的高温结构强度、损伤与寿命的评估需要交叉固体力学、材料冶金与失效以及环境化学等多个学科,而各个方面相互之间又会产生复杂的相互作用。这就导致成熟的理论框架和“实验观察-理论分析-数学建模”式的研究方法会产生实验能力不足、物理认知缺乏以及建模考虑要素不全等局限。

随着人工智能理论和技术的不断发展和完善,数据驱动方法在结构设计、服役和运维的各个方面展现出巨大的应用潜力<sup>[11-13]</sup>。这种方法以数据为基础和知识输入,通过模拟人脑理性思考和分析的独特建模思路,为工程关键结构的损伤分析和寿命评估提供了一种新的科学研究范式,也为克服以往研究中的客观障碍提供了有效的解决技术。数据驱动研究范式与传统强度破坏理论在复杂影响要素中抽取主要矛盾,进而建立少量自变量与因变量之间因果关系的思维方式存在显著差异<sup>[14-16]</sup>。它更多关注数据样本之间的关联与相关性、样本的多样性与有效性,将影响要素和数据样本映射到高维空间,进而寻找潜在的规律与关联关系。这种直接通过数据描述和认识物理世界的方式减少了人为认知的不确定性,通过数据驱动减小了经验模型误差,进而提高了预测精度和对问题的解释能力,如采用敏感性分析和不确定性评估方法进一步挖掘输入与输出变量的内在关系,为复杂因素影响下的问题研究提供了有效思路。

近年来,数据驱动方法在新材料开发与制备、材料微观组织与宏观性能之间定量关联、多物理场耦

合作用下材料/结构复杂变形行为和寿命预测、大型装备的结构健康监测等方面近些年来吸引了很多学者的关注和研究。但是,也应当注意到,数据驱动方法在结构强度与破坏研究中的应用仍旧存在一些局限性和挑战,如有效数据的稀疏性与依赖性,模型与真实物理场景和机制的欠关联,模型方法的外推能力与泛化能力弱等。针对上述问题,本文聚焦数据驱动方法在高温结构宏观构-性关联、寿命预测以及本构建模三个方面的应用,重点综述和分析了当前研究的进展、现状、存在的问题和挑战。最后总结了数据驱动方法在高温结构强度与寿命评估中的几种典型应用形式,探讨了未来研究的潜在方向,旨在推进数据驱动新范式在高温结构完整性领域的交叉应用。

## 2 基于图像数据的微观组织特征识别与定量表征

构筑材料微观结构特征与宏观力学性能的定量关联关系一直是材料优化设计和多尺度固体力学的研究前沿与热点。而高温结构在极端环境下服役,内部的微观组织也不可避免地出现各种演化行为,影响结构和装备的安全服役。近年来,随着图像处理算法以及数据驱动方法的进步,使得对材料微观图像的定量化描述成为了可能,也为构筑材料宏观的构-性关联提供了关键的方法手段。从大量的材料微观图像数据中,使用数据来识别各种微观结构特征,并利用图像处理算法或者机器学习算法来挖掘上述特征与所关注的材料宏观力学特性。当前,利用数据驱动方法处理材料微观组织主要有2种方式:一种是直接利用机器学习算法来对图像进行处理,通过编码和解码最终得到图像的特征数据,用于后续的特征、重构以及力学建模;另外一种则是通过设计具体的图像处理算法,对微观统计特征进行提取和分析,利用数据降维的方式实现微观状态的定量表征。两种方式都是采用定性图像-高维空间映射-低维空间表征的思路,如图1所示,但是在具体的处理过程中存在一定的不同。

### 2.1 基于机器学习的微观特征识别表征

在微观特征识别与表征中,机器学习算法主要用于识别图像微观组织特征,提取和计算材料微观组织的各类结构特征参数以及关键微观组织重构。

早期的机器学习图像处理方法包括贝叶斯分类器<sup>[17]</sup>、支持向量机<sup>[18-20]</sup>、随机森林<sup>[21]</sup>、决策树<sup>[22]</sup>以及人工神经网络<sup>[23-25]</sup>等。在微观特征提取方面,Albuquerque等<sup>[26]</sup>采用多层感知器和自组织图拓扑从铸铁样品金相图像中分割珠光体和铁素体,对60个铸铁样品比较发现,两种神经网络对珠光体和铁素体面积分数的识别误差为2.72%;在辅助微结构重建方面,Fu等<sup>[27]</sup>利用含微观特征的非均质材料图像训练人工神经网络,进而引导重建程序生成统计等效的微观组织。然而,人工神经网络存也存在一定局限性:首先,人工神经网络对图像分辨率敏感,图像分辨率过高或过低都将导致神经网络预测失败<sup>[28]</sup>,分辨率过低会导致特征无法识别,分辨率过高导致模型陷入“维数灾难”<sup>[29]</sup>;其次,人工神经网络以单个像素点作为输入,模型具有空间依赖特征,即不能识别图像的平移、旋转和对称等操作<sup>[30]</sup>。

卷积神经网络引入滤波器对图像进行卷积处理,代替了人工神经网络的矩阵乘法运算,使得卷积神经网络具备稀疏交互、参数共享和等变表示3个优势<sup>[29-31]</sup>,弥补了人工神经网络在图像处理领域的不足,被广泛用于微结构特征分割<sup>[32-33]</sup>、识别与分类<sup>[28,34]</sup>、特征量化<sup>[32]</sup>和微结构重建<sup>[35-36]</sup>。在特征识别方面,Menasche等<sup>[37]</sup>利用卷积神经网络成功从LSHR镍基高温合金计算机断层扫描图像中分割出裂纹特

征。Mishra等<sup>[38]</sup>利用卷积神经网络对高熵合金、高温合金、铝合金和铜合金的柱状晶、枝晶等6种微观金相图片进行分类。模型展现出良好的泛化能力和分类精度,预测准确率达到94.89%。Warmuzek等<sup>[34]</sup>将卷积神经网络用于多相合金微观组织特征识别与图像分类,建模流程如图2所示。卷积神经网络可以区分相似的形态特征,例如树枝状和“之”字状结构,有效避免了定量图像分类时的模糊逻辑问题。在辅助构筑材料的宏微观定量关联关系方面,卷积神经网络可以将高维图像特征进行特征编码,得到图像的低维量化表征,继而将卷积神经网络的输出作为力学性能模型的微观信息输入。Liu等<sup>[39]</sup>基于PoreSpy生成的孔隙微结构,利用有限元仿真计算得到生成图像的弹性变形数据,将微观图像作为输入进行建模,训练得到的卷积神经网络可以高效地预测不同微观结构特征的宏观弹性模量。Heidenreich等<sup>[40]</sup>利用两个平行卷积神经网络分别检测和提取不同尺度的微观组织图像的相关特征,将生成的多孔微结构图像100×100像素的几何信息减少到10个特征。Wang等<sup>[41]</sup>首次利用卷积神经网络从大面积扫描电镜图像中自动分割高温合金 $\gamma'$ 相微结构,依据提取的几何参数建立了 $\gamma'/\gamma$ 相枝晶干组织硬度与显微组织形貌之间的关联模型,有效预测了不同微观组织状态下合金的硬度。

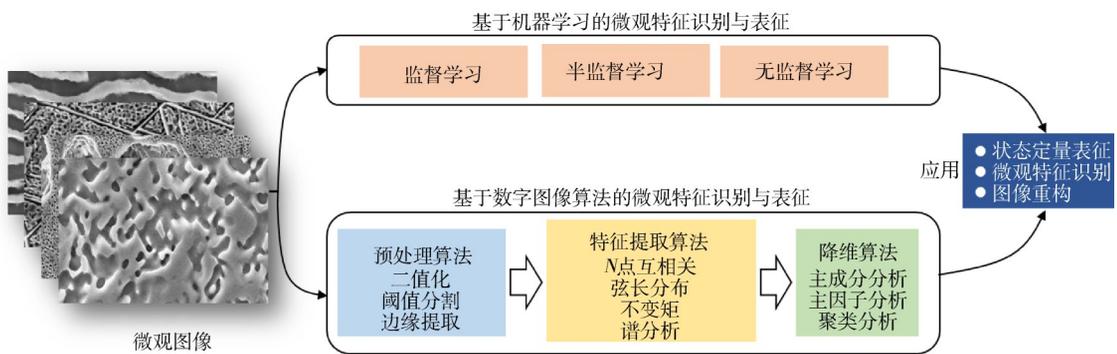


Fig. 1 Data-driven based process of material microstructure recognition and characterization method

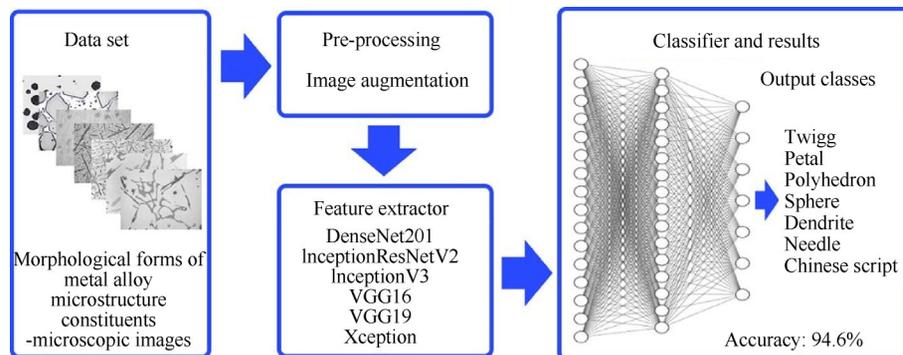


Fig. 2 Framework of convolutional neural network for recognition of metal alloys microstructure constituents<sup>[34]</sup>

## 2.2 基于数字图像算法的微观特征识别表征

基于数字图像算法的材料微观特征定量提取与表征起源较早,可以追溯到早期朴素的金相观察与数据分析方法。该方法应用时,首先对采集到的图像进行预处理,主要有图像的二值化,阈值分割以及边缘特征提取等;然后针对所关注的微观特征如第二相粒子体积分数、形貌、尺寸和分布等设计需要的统计提取算法;得到特征统计样本数据后利用降维算法就可以实现材料微观特征的定量表达,从而应用于后续的研究。

当前,在高温结构材料设计和强度评估领域中应用较为广泛的有 $N$ 点互相关( $N$ -Point Correlation)理论和提取组织特征几何参数的弦长分布算法。Fullwood等<sup>[42-43]</sup>最早根据材料的微观结构特征定义了微观特征函数并开展空间相关性分析,使得互相关算法应用于材料微观结构特征的提取成为了可能。Kirka<sup>[44]</sup>针对CMSXS-4/8以及CM247LC-DS高温合金利用基于互相关算法对 $\gamma'$ 相尺寸进行了统计和提取。利用互相关算法进行于镍基合金的组织特征提取时,首先需要将合金的微观SEM图像进行二值化和灰度翻转处理并进行互相关运算,就可以得到两种图片相关性的空间域分布图谱,如图3所示。在图像

的纹理分析中,相关性图谱可以提供许多特征,如图像的纹理形貌、平均尺寸、粗糙度和取向特征等信息<sup>[45-46]</sup>。弦长分布(Chord length distribution, CLD)描述了在微观结构中找到指定长度弦长截距的概率,这个概率值与材料中的微结构特性、变形历史和热处理流程等因素的特性密切相关<sup>[47]</sup>。这种方法在单相组织特征如裂纹长度、多晶合金晶粒信息的测量统计提取中已经得到了广泛的应用。Latypov等<sup>[48]</sup>针对不同类型多晶合金织构特征开发了一种耦合旋转CLD算法和主成分分析(Principal Component Analysis, PCA)的定量降维表征方法,并利用Dream软件生成的微观图像数据进行了分析和验证。Caccuri等<sup>[49]</sup>基于线段截距法发展了一种单晶合金微观参数如 $\gamma'$ 相尺寸的统计提取方法,并将其应用于材料为微观组分组构张量基础参数的获取。基于数字图像算法的微观组织表征能够获得大量的高维度统计数据,这使得从大数据和信息角度构建材料服役历程、微观状态以及力学行为的定量关联成为了可能。

Fan等<sup>[50]</sup>针对航空发动机涡轮叶片服役微观组织演化及其带来的强度评估和大修判废问题,发展了适用于两相组织材料的旋转弦长分布(TP-CLD)算法,综合利用图像互相关和主成分分析方法实现

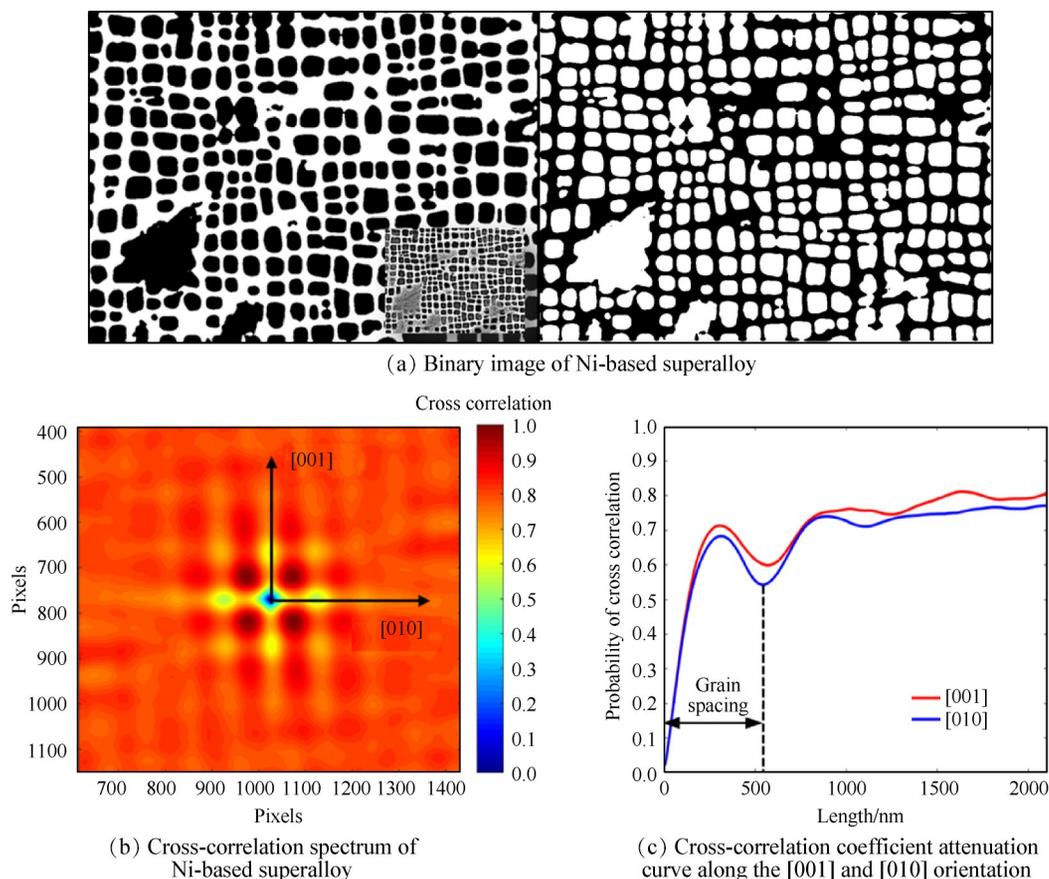


Fig. 3 Extraction and quantification of microstructure features of Ni-based superalloy via cross-correlation algorithm

了涡轮叶片服役微观组织状态的定量表征,构建了服役历程与微观状态演化的支持向量回归(Support Vector Regression, SVR)机器学习模型,同时建立了叶片服役微观状态与其剩余疲劳寿命的关联关系,形成了服役历程-微观状态-剩余寿命(Service Process-Microstructure-Residual Properties, PSP)的一体化评估框架,如图4所示,推动了数据驱动方法在高温结构强度与寿命评估的应用。

### 3 基于机器学习的寿命预测方法

#### 3.1 机器学习寿命建模的一般流程

基于机器学习方法的寿命建模过程如图5所示,主要包括数据收集、数据预处理、特征筛选、模型选择与训练、模型评估和模型应用6个步骤:

(1)数据收集指收集与研究对象相关的试验数据或仿真数据。

(2)数据预处理指按照模型训练要求对收集的原始数据进行特定的表示,例如空缺数据填补、研究对象的属性量化处理、图像量化表征。此外还包括数据归一化、无量纲化、正则化、标准化等处理和数据的异常检测、降噪等。

(3)特征筛选是指从研究对象的属性中提取敏感特征,从而去除多余特征,提高模型训练效率和成

功率,如数据相关性分析、特征敏感性分析等。

(4)模型选择与训练包括:将筛选后的特征按照需求分为训练集、验证集和测试集,选择适合的模型进行训练。

(5)模型评估指采用确定性指标和不确定性评估方法分别对模型的预测精度和稳定性进行评价,如均方根误差(MSE),标准差(SD),决定系数( $R^2$ )

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_{i\_pred} - y_{i\_exp})^2 \quad (1)$$

$$SD = \sqrt{\frac{1}{n-1} \sum_{i=1}^n \left( \left| \frac{y_{i\_pred} - y_{i\_exp}}{y_{i\_exp}} \right| - \frac{1}{n} \sum_{i=1}^n \left( \left| \frac{y_{i\_pred} - y_{i\_exp}}{y_{i\_exp}} \right| \right) \right)^2} \quad (2)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_{i\_pred} - y_{i\_exp})^2}{\sum_{i=1}^n (y_{i\_exp} - \overline{y_{i\_exp}})^2} \quad (3)$$

式中  $y_{i\_pred}$  为模型预测值,  $y_{i\_exp}$  为试验值,  $n$  为训练数据量。

(6)模型应用指将训练的模型用于新对象,如用于新数据集的预测、载荷外推预测等。

机器学习数据来源主要包含仿真生成数据和收集的实验数据。从数据科学的角度来讲,收集的数据有95%的可能性包含缺失的值<sup>[51]</sup>。一方面,随意舍弃不完整的数据会造成巨大的数据资源浪费。另

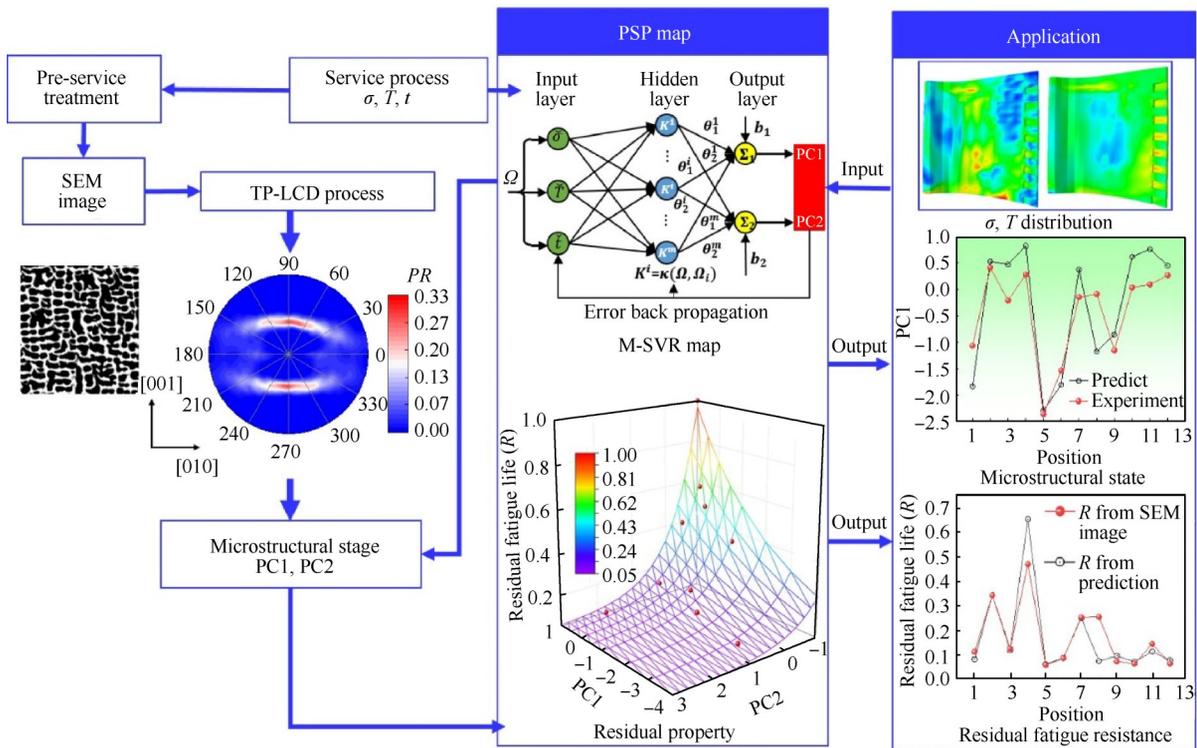


Fig. 4 Integrated evaluation framework for Service History-Microstructure State - Residual Life(PSP) for high temperature components based on image data-driven method<sup>[50]</sup>

一方面,在寿命建模中丢失的数据往往不是随机的,即丢失的数据和数据集中的其他值之间存在某种关系。如果直接舍弃缺值样本或特征,则会丢失大量信息,使不完全观测数据与完全观测数据间产生系统差异。因此需要在数据预处理时采用特定的方法进行数据集的“空缺数据填补”<sup>[51]</sup>。

“空缺数据填补”的常用方法主要包括人工填写、特殊值填充、平均值填充、期望最大化方法、模型插补<sup>[52]</sup>。人工填写是指让最了解数据的用户自身去人为填充缺失值,此方法往往产生的数据偏离最小,但数据规模大、缺失值多的时候并不可行;特殊值填充是指将缺失值直接填充为 0,1 或归一化后的数据代表值,因此有可能导致严重的数据偏离;平均值填充是指采用全局或局部的特征平均值来填充缺失值,全局平均值也可以采用众数替代,局部平均值可采用  $K$  最近距离邻法进行层次聚类后,使用距离缺失值最近的  $K$  个样本的加权平均来估计缺失值;期望最大化方法基于贝叶斯估计,通过期望步和极大化步的交替迭代计算缺失值的极大似然估计;模型插补主要依赖决策树模型的固有属性,先以不考虑缺失值开始分裂,再将缺失值代入子节点计算信息增益,整体信息增益较大处即为最佳填补值。上述几种方法中,期望最大化方法和模型插补法都是在寿命建模中较好的处理方法<sup>[53]</sup>。

### 3.2 机器学习寿命预测研究进展

按照所用模型类型通常可以将机器学习寿命预测方法划分为 3 类:基于经典机器学习模型的、基于人工神经网络的和融合物理信息的机器学习

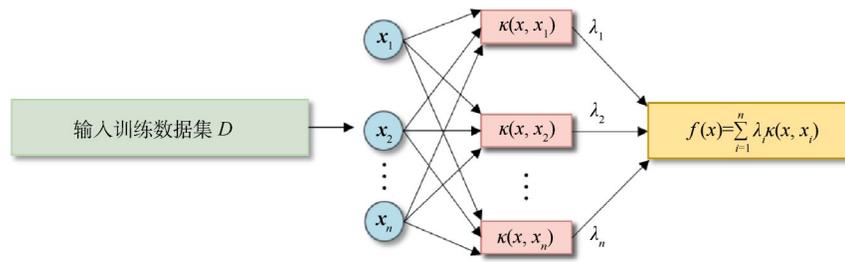
模型。其中经典机器学习模型以统计学习方法为基础,将数据映射到高维空间建立数据间的回归或分类关系,最终建立输入到输出的映射,如图 6(a)所示;而神经网络模型则以网络结构为基础,建立神经元之间的复杂连接,给出输入和输出数据的关联关系,如图 6(b)所示;融合物理特征的机器学习方法是在机器学习模型的输入变量或者模型的架构上引入传统唯象理论或者物理知识,以提高模型预测能力。

#### 3.2.1 经典机器学习方法

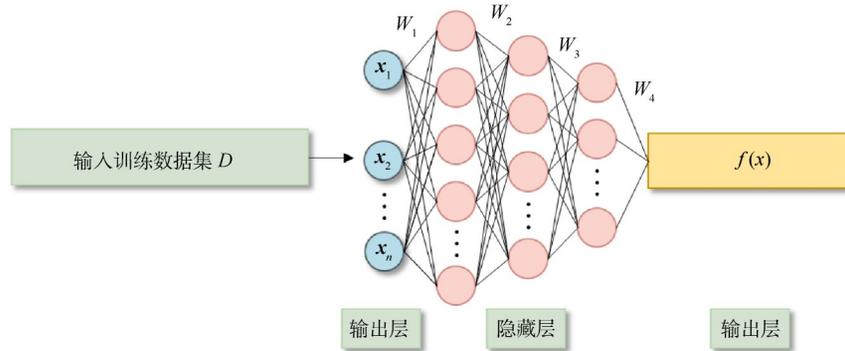
经典的机器学习模型结构简单,建模效率高<sup>[54-55]</sup>,适合小样本问题的分析和建模。Zhang 等<sup>[56]</sup>利用荧光法测得的 5 组循环周次下的裂纹扩展图片对支持向量机、 $K$  近邻、决策树等经典机器学习模型进行训练,预测了疲劳裂纹扩展路径和长度。结果表明决策树在小样本裂纹扩展长度和扩展路径预测最为有效,裂纹长度测量精度达到 0.6mm。Teixeira 等<sup>[57]</sup>针对超高周疲劳实验中的间歇加载效应采用极端梯度增强模型进行建模预测,基于 22 组原始实验数据训练了机器学习模型,模型预测的回归系数达到 0.98。影响材料/结构寿命因素众多,诸如材料组分、制造工艺、服役载荷和环境等。可以预想,当足够多的影响因素被考虑并被量化,有望为材料设计、工艺流程制定与质量控制、寿命评估提供更合适的解决思路。Gan 等<sup>[58]</sup>考虑到平均应力对疲劳寿命的影响,将材料的单拉、循环属性参数和循环的应力应变响应作为输入特征,使用随机森林预测了应力比不为零的疲劳寿命。Liu 等<sup>[59]</sup>设计了一种分类自适



Fig. 5 Machine learning based life prediction process



(a) Statistical machine learning framework, e.g. support vector machine



(b) Neural network framework, e.g. artificial neural network ( $W_i$  is the weight matrix of the ANN hidden layer)

Fig. 6 Machine learning based life prediction framework

应蠕变寿命预测模型,对材料成分、热处理参数、微观结构影响因素和试验条件的27个变量进行了特征重要性分析,推断出了与蠕变性能最为相关的5个微观参数。

### 3.2.2 神经网络方法

近年来,人工神经网络<sup>[60-61]</sup>、深度信念网络<sup>[62-63]</sup>、循环神经网络<sup>[64]</sup>、卷积神经网络<sup>[65-66]</sup>、生成对抗网络<sup>[67-68]</sup>等已经在疲劳寿命建模中得以广泛应用。Gao等<sup>[60]</sup>结合负反馈神经网络和高斯回归过程开发了一种数据驱动的方法来预测多轴疲劳寿命并量化寿命的不确定性。Zhang等<sup>[69]</sup>利用深度信念网络来拟合铝合金的裂纹扩展试验数据,成功高精度预测了合金的裂纹扩展寿命。Yang等<sup>[64]</sup>通过分析多轴载荷的加载模式、加载水平、加载路径和疲劳状态,提出了一种基于循环神经网络的多轴疲劳寿命预测模型,预测寿命基本在±1.5倍误差带内。Bartošák<sup>[62]</sup>采用长短期记忆网络和浅层人工神经网络结合构建了合金钢的等温低周疲劳和热机械疲劳寿命预测模型,结果表明所提出的基于机器学习的损伤模型能够合理预测复杂热机械载荷下的寿命。Li等<sup>[70]</sup>使用改进的埃尔曼神经网络模型预测合金钢的蠕变-疲劳寿命,模型的最大误差为19.2%,更好地描述了保载时间与蠕变-疲劳寿命之间的非线性关系。Seifi等<sup>[65]</sup>采集了增材制造钛合金的实时热成像图,利用卷积神经网络实时提取增材制造的缺陷特征,效提

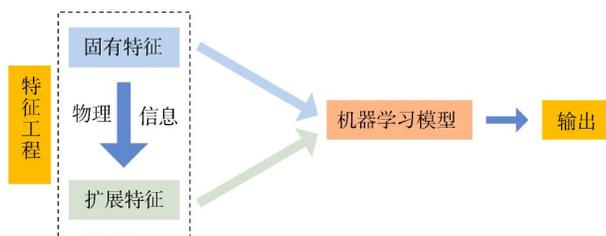
高了合金的疲劳性能评价以及增材制造工艺验证的效率。

### 3.2.3 融合物理信息的机器学习方法

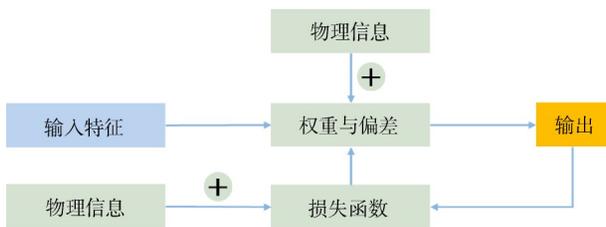
经典机器学习方法“黑箱”式的建模方法不能揭示材料和结构失效内在的机制,缺乏物理认知<sup>[71]</sup>。而物理约束的引入使得模型建模所需数据量降低,为小样本疲劳寿命预测提供了可行的解决方案,另一方面,融合物理信息的机器学习模型融入了先验知识,使得模型的外推能力较机器学习模型更高,进一步提高了预测精度和模型可解释性。按照物理信息的引入方式,融合物理信息的机器学习寿命预测模型主要分为2种:模型输入变量引入物理信息和模型训练过程引入物理信息,分别如图7(a)和(b)所示。

模型输入变量引入物理信息主要有2种策略:(1)将试验观测或经典理论推断得到的物理信息作为补充输入变量引入机器学习模型,从而使机器学习模型更好地模拟研究系统。例如,在含缺陷增材制造材料的疲劳寿命预测中,Wang等<sup>[71]</sup>将含增材制造参数的CDM损伤模型疲劳寿命预测结果作为额外输入,将增材制造参数隐式引入到机器学习模型中相较于无物理信息约束的寿命预测模型,有物理信息输入约束机器学习疲劳寿命模型预测能力显著提高。(2)利用经典物理模型作为约束,对输入变量进行筛选,保留输入变量的关键物理特征,这种方法亦

可以作为小样本机器学习模型的一种训练策略。Gan 等<sup>[72]</sup>根据 Ye-Wang 损伤模型对金属两级加载剩余寿命关键输入变量进行标定,保留了信息量最大的输入特征,降低了机器学习模型输入特征维度,成功用于铝合金、不锈钢等多种金属材料的两级加载剩余寿命预测。Lian 等<sup>[73]</sup>将经验公式引入机器学习框架,利用经验公式获得的物理信息(估计特征)和猜测的关键物理特征(猜测特征)作为输入变量训练了梯度上升回归机器学习模型,成功预测了 7 个系列铝合金的疲劳寿命。



(a) Physical information introduced via model input variables

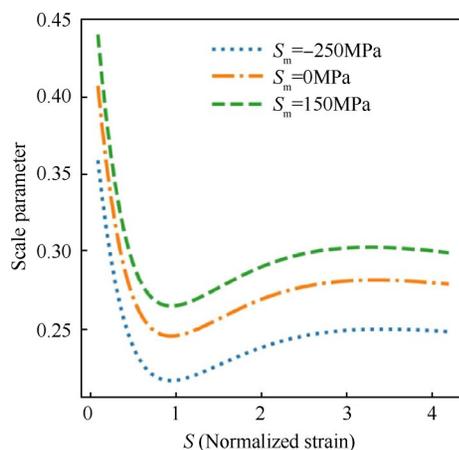


(b) Physical information introduced via model modeling process

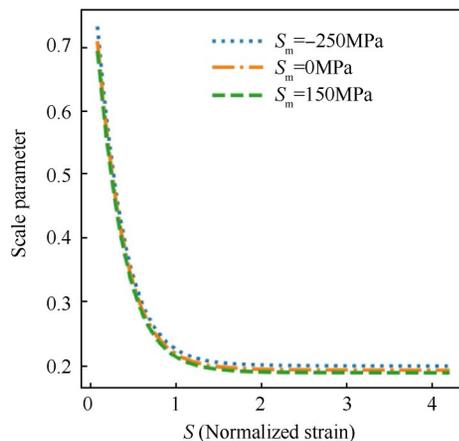
**Fig. 7 Physics-informed machine learning framework**

模型结构引入物理约束的主要通过修改机器学习模型的约束方程或单元连接方式。例如,通过适当限制神经网络的偏差和权重、将物理约束引入损失函数等。研究表明有物理信息指导的信息模型可以较快地收敛,且预测精度高于缺乏物理信息指导的机器学习模型。Zhang 等<sup>[74]</sup>将预测值与试验值均方误差和均方根误差作为物理约束引入 Relu 损失函数,构建融合物理的人工神经网络,预测了 316 不锈钢的蠕变-疲劳寿命。上述方法中的物理信息亦可来自于物理模型,即把物理模型预测值与机器学习模型预测值作为预测误差,指导机器学习模型训练<sup>[72]</sup>。神经网络主要通过调整神经元连接的权重和偏置对数据进行挖掘,因此可以将物理信息直接引入神经网络结构中的权重项和偏置项,使得机器学习模型的预测逻辑与物理先验逻辑相一致。Chen 等<sup>[75]</sup>将高应力下寿命分散性小的先验知识引入神经网络结构中的权重项和偏置项中,强制约束了寿命分散性与载荷大小的关系,抑制了反常结果的

发生。预测结果如图 8 所示,其中  $S_m$  为平均应力。由图 8(a)可知,当归一化应变大于 1 时,未融合物理信息的机器学习模型在出现了寿命分散性随应变增加而增加的反常行为;而融合物理信息的机器学习模型预测寿命分散性符合物理规律认知,如图 8(b)所示。Karolczuk 等<sup>[76-77]</sup>采用符合物理守恒原理的高斯回归过程模型来预测多轴载荷下的疲劳寿命,成功预测了概率疲劳寿命。Zhan 等<sup>[78]</sup>构建了一个基于连续损伤力学的机器学习框架,并验证了随机森林和神经网络在增材制造合金的疲劳寿命预测中的适用性。



(a) Without introduction of physical information



(b) With introduction of physical information

**Fig. 8 Machine learning predicted result of the variance-strain diagram<sup>[75]</sup>**

### 3.3 机器学习寿命建模的主要挑战

机器学习方法的引入在一定程度上弥补了经典理论模型在高温结构强度与寿命研究中的不足<sup>[79-81]</sup>。如机器学习模型在材料和载荷条件适用范围<sup>[62,74,82]</sup>、多因素耦合影响<sup>[60,83]</sup>、影响因素量化与评价<sup>[84-85]</sup>方面显著优于经典理论方法。但是也存在以下挑战:

(1)如何建立面向多材料体系和载荷模式的统一预测方法

材料在不同载荷模式作用下的失效模式和寿命相差巨大。例如,镍基高温合金受位错运动机理的影响,不同试验温度下变形行为有显著区别。如何发挥机器学习方法的优势,建立跨材料体系、多载荷模式和宽载荷条件下统一的材料强度与寿命评估模型,是未来研究要点之一。

Tan等<sup>[86]</sup>从高温结构强度与寿命需求出发,对跨材料体系、多载荷模式、宽载荷条件疲劳寿命建模提出了一种解决策略:为了使模型具备跨材料体系、多载荷模式和宽载荷条件下的预测能力,在构建模型训练数据时采用材料固有属性参数对输入特征进行无量纲化,去除输入样本的材料属性。模型的输入了包含材料属性和载荷特征的17维向量,基于支持向量回归模型,建立了多种不同类型镍基高温合金统一寿命预测模型,建模流程如图9所示。

(2)给定条件下模型的泛化外推能力如何提高

基于机器学习的模型训练需要大量的数据,且尽可能涵盖所研究模型的数据边界,以使模型尽可能学习到适用于所有潜在样本的普遍规律。然而,由于机器学习模型学习能力过于强大,通常会导致模型“过拟合”<sup>[16]</sup>。过拟合现象将导致模型在“陌生的”测试集上的预测性能较差,而模型在外推时的精度和稳定性可能会更低。提高模型泛化能力的方法多种多样,例如降低模型复杂度、提高数据数量、数据正则化、凸优化等。Hao等<sup>[87]</sup>考虑引入物理机制的方法降低模型的数据依赖性,提出了一种简单、高效、高精度的基于物理信息的机器学习疲劳寿命统一预测方法。对比了未融合物理信息的模型预测结果(图10(a))和融合物理信息的机器学习模型(图10(b)),可以发现融合物理信息的机器学习模型有效抑制了“坏点”(图10(a)中红圈所示)的出现。同时,将训练得到的融合物理信息模型用于新材料,由于结合物理信息带来泛化能力的提升,对新数据

的高低周疲劳寿命预测精度达到±3倍分散带,如图10(c)所示。

(3)基于简单条件面向未知复杂条件的预测模型如何建立

高温材料结构强度与寿命领域存在一些无法通过试验直接得到的破坏规律认识或者实验成本很高。例如旋转件裂纹扩展速率与行为、热机械疲劳行为与寿命规律。如何利用数据驱动方法从简单实验数据推断未知复杂载荷或者真实服役条件下的寿命与性能,也是当前面临的重要挑战之一。

### 4 数据驱动的本构建模研究进展

#### 4.1 数据驱动本构建模的特点与应用方式

获取准确的变形响应是对结构进行寿命评估的关键基础。经典本构模型引入内变量和状态空间,建立演化方程或具有记忆特征的定律来模拟试验条件下的变形行为<sup>[88-89]</sup>。复杂的微观变形机制和载荷条件导致模型方程形式愈发复杂。此外,模型参数依赖试验获取,参数识别质量直接决定了模型的精确度<sup>[90-91]</sup>。

机器学习模型为变形行为预测提供了辅助和替代方案。特别是具有记忆特征人工神经网络的出现,为具有记忆效应的变形行为预测提供了强有力的工具。例如递归神经网络、长短时记忆神经网络和门控制循环单元等可将历史时间步的数据信息选择性的输入当前时间步,给神经网络赋予了“记忆”特征。而这种记忆特征恰好迎合了具有典型的变形历史依赖性的本构行为建模需求。

基于机器学习模型的材料变形行为预测建模流程与寿命预测类似。需要注意的是,寿命预测是“点到点”的映射关系,而材料变形行为由于具有路径和历史依赖性,是“线到点”的映射关系。反映在建模流程上主要有以下2点区别:(1)机器学习变形行为预测的输入格式是序列,是具有特定排列顺序的一串有序数字或向量,而寿命预测所采用的输入数据格式为随机数字或随机向量;(2)机器学习变形行为

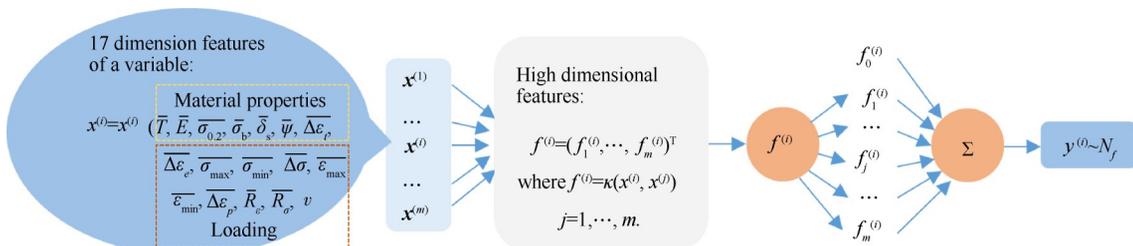
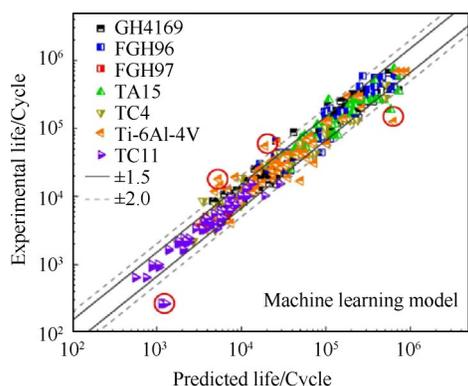
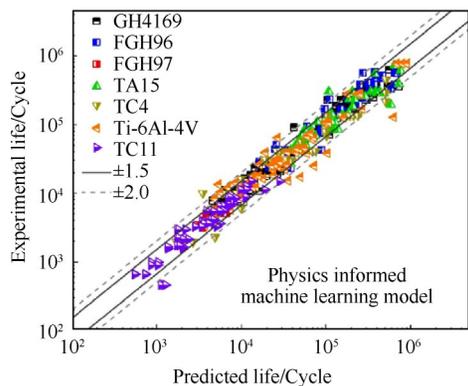


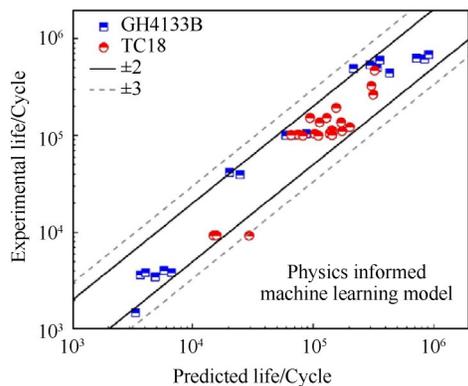
Fig. 9 Supervised machine learning framework for fatigue life prediction of Ni-based superalloy family<sup>[86]</sup>



(a) Prediction results of unintegrating physical information machine learning model



(b) Prediction results of physics-informed machine learning model



(c) Prediction results of unseen material of physics-informed machine learning model

**Fig. 10 Comparison of prediction results of machine learning model with and without physical information for notch fatigue life<sup>[87]</sup>**

预测采用的模型多为具有“记忆”的神经网络。

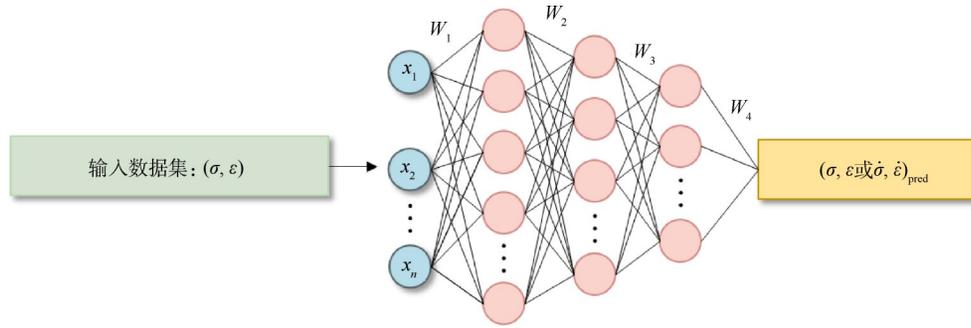
目前数据驱动方法在材料本构建模中的应用策略主要有 3 种：第一种是机器学习模型完全取代经典本构模型如图 11(a)所示。第二种是用机器学习模型结合经典本构模型完成变形行为预测，部分或全部取代经典本构模型的内变量演化方程，如图 11(b)所示。第三种则是利用机器学习模型确识别和优化复杂模型中的材料参数。

#### 4.2 本构模型完全替代

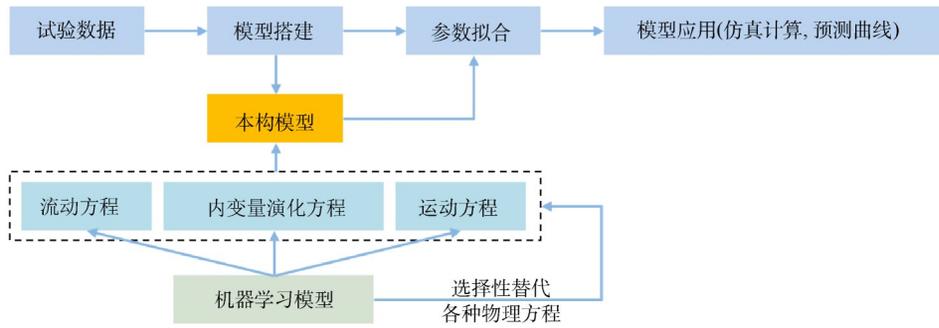
机器学习模型完全取代经典本构模型通常将有应力-应变数据作为输入训练模型，从而输出全量形式应力、应变或者增量形式的应力、应变。Sun 等<sup>[92-93]</sup>利用负反馈神经网络建立了钛合金热压缩变形本构模型，该模型对高通量应力-应变数据进行学习，可以很好的预测流动应力随真应变、应变率和温度的变化规律。与经典本构模型的符号公式不同，基于机器学习的变形行为预测来源于对数据的认知。在这种情况下，通常需要丰富的数据来建立输入输出变量的映射关系。例如 Jang 等<sup>[94]</sup>利用经典本构理论与人工神经网络迭代生成大量训练数据用于本构模型的建立。

#### 4.3 数据驱动方法辅助本构建模

采用机器学习模型部分或全部取代内变量演化方程可以充分发挥机器学习模型基于数据挖掘的优势，又兼顾了经典本构模型的物理机制，具有训练速度快、应用范围广、数据需求量小等优点。Xu 等<sup>[95]</sup>结合人工神经网络，依据位移和外荷载数据预测切线刚度矩阵的 Cholesky 因子，在此基础上以增量形式计算了材料应力-应变。同时在模型训练过程中引入物理约束，如强制切线刚度矩阵对称正定和应力-应变时间一致性，保证了应变能的弱凸性，从而满足路径相关材料变形的 Hill 判据。Masi 等<sup>[96]</sup>基于热力学人工神经网络和内变量理论，重新定义了与内部坐标  $\xi$  相关的内变量  $z$ ，并根据内变量是否已知，给出了两种增量热力学人工神经网络描述内变量随时间连续演化，建立了演化热力学人工神经网络，模型结构如图 12 所示。由于引入了内变量内部坐标描述，增量热力学人工神经网络可以同时描述材料宏观变形响应和微观变形响应。为了搭建微结构形貌与宏观变形之间的桥梁，Weber 等<sup>[97]</sup>提出了一种基于机器学习的参数均匀化晶体塑性模型的多尺度建模框架，并应用于镍基单晶高温合金 Rene 88DT 多尺度本构建模，基本流程如图 13 所示。该模型将镍基单晶高温合金微观  $\gamma/\gamma'$  相的统计信息纳入模型中，并且与宏观晶体塑性本构模型无缝搭接，成为考虑微结构形貌合金本构建模的有力工具。He 等<sup>[98]</sup>提出了一种可测量材料状态的路径相关材料的机器学习物理数据驱动本构建模方法。该方法将热力学第一定律集成到模型中，通过热力学第二定律对网络参数进行约束，以 RNN 预测的内变量、试验条件应变和温度训练 DNN 来预测给定条件下的 Helmholtz 自由能，从而给出路径依赖材料的本构关系。

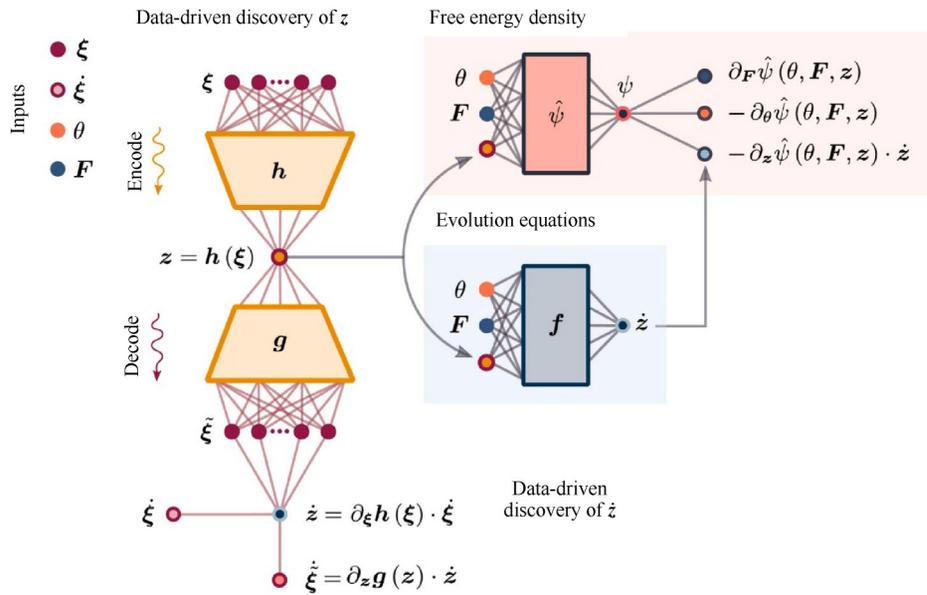


(a) Classical constitutive models completely replaced by machine learning models



(b) Classical constitutive models partially replaced by machine learning models

**Fig. 11 Physics-informed machine learning constitutive model**



$$\underbrace{\|\xi - g(h(\xi))\|}_{\text{reconstruction loss}} + \underbrace{\|\dot{\xi} - \partial_z g(z) \cdot \dot{z}\|}_{\text{loss in } \dot{\xi}} + \underbrace{\|\dot{z} - f(\theta, F, z)\|}_{\text{loss in } \dot{z}} + \underbrace{\|\psi - \hat{\psi}(\theta, F, z)\|}_{\text{loss in } \psi} +$$

$$\underbrace{\|P - \partial_F \hat{\psi}(\theta, F, z)\| + \|\eta + \partial_\theta \hat{\psi}(\theta, F, z)\| + \|d + \partial_z \hat{\psi}(\theta, F, z) \cdot \dot{z}\|}_{\text{loss in grad } \psi} + \underbrace{\lambda_{\text{reg}} \|\{\partial_z \hat{\psi}(\theta, F, z) \cdot \dot{z}\}\|}_{\text{regularization}}$$

**Fig. 12 Evolution thermodynamics artificial neural networks framework for identification evolution of internal variables and of control equations<sup>[96]</sup>**

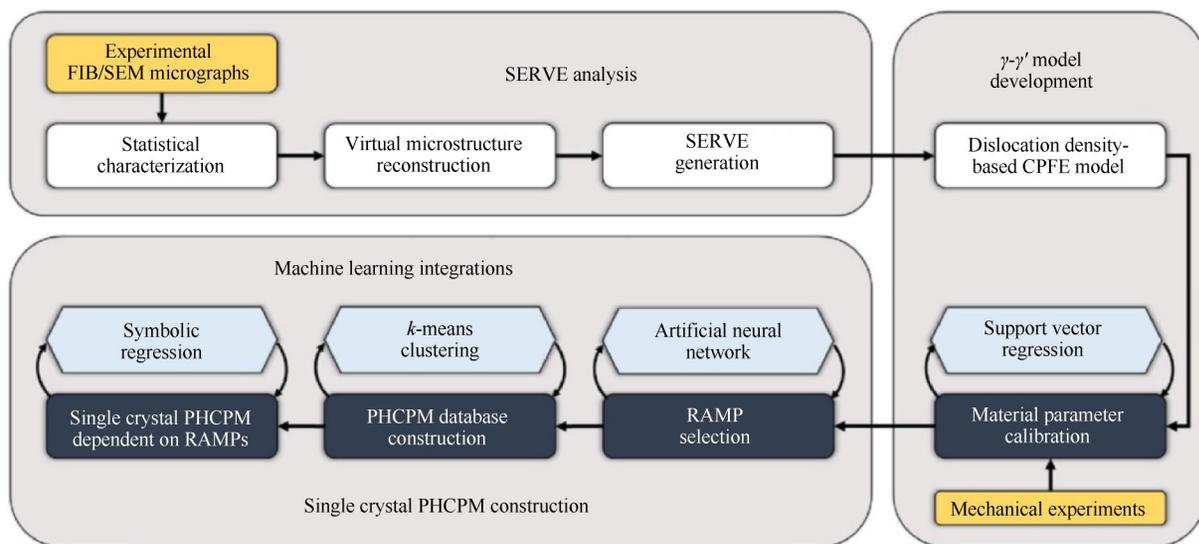


Fig. 13 Machine learning-enabled self-consistent parametrically-upscaled crystal plasticity model framework<sup>[97]</sup>

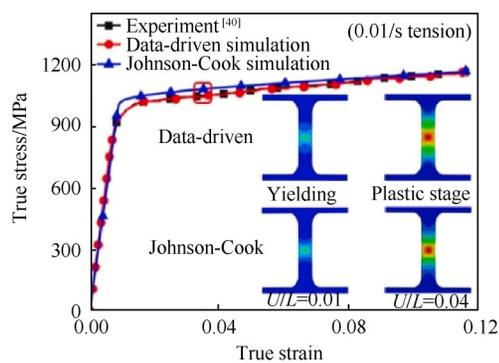
#### 4.4 本构模型参数识别与优化

传统的本构模型参数提取方法主要有两种：均匀应力法和基于全场测量的方法。Guo 等<sup>[99]</sup>总结了上述两种方法的应用范围和优缺点，指出均匀应力假设在颈缩开始后是不成立的，而全场测量方法易受噪声污染。为了克服传统方法的不足，Guo 等<sup>[99]</sup>基于卷积神经网络和长短时记忆神经网络构建了一种本构参数快速识别模型，以各向同性硬化的弹塑性本构模型参数为例，证明了该模型可以识别路径相关的本构参数。Wang 等<sup>[100]</sup>利用高斯过程建立了一种考虑加载历史的本构参数识别方法，该方法采用奇异值分解对应力历史数据进行压缩，提取应力历史数据中的关键信息。Yao 等<sup>[101]</sup>提出了一种基于负反馈神经网络和遗传算法的混合参数识别方法，对耦合损伤的粘塑性本构模型的高度耦合参数进行标定。Ktari 等<sup>[102]</sup>等利用融合机器学习的逆向识别算法对高度耦合的本构参数解耦，从而用于本构参数快速识别。基于机器学习的本构参数识别方法在参数提取效率、鲁棒性等方面优于传统方法<sup>[103]</sup>，且易于与数值算法相结合，材料的复杂变形行为预测方面具有应用潜力。

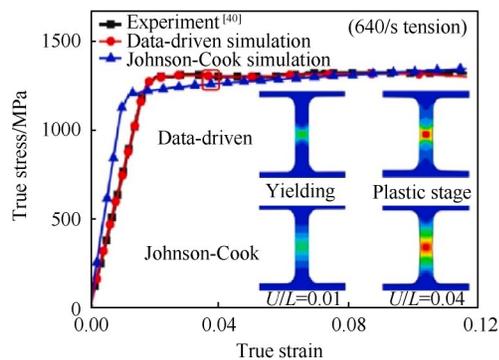
#### 4.5 本构建模案例分析

从上述 4.1~4.4 节的分析来看，数据驱动方法为材料的变形行为预测提供了合适的辅助和替代方案。文献[104]中开发了一个增强型的数据驱动本构模型来预测材料在应变率和温度效应耦合下的弹塑性行为，成功模拟了 Ti-6Al-4V 合金在多种试验温度和加载速率下的应力-应变响应。不仅如此，与传统的 Johnson-Cook 模型相比，对于复杂的非线性应

力-应变响应数据驱动本构模型有更强大的预测能力，对于屈服应力和屈服后的响应都有着很好的模拟，如图 14 所示，数据驱动本构模型在四种应变率下预测结果都优于 J-C 模型。高效、通用和高精度的数据驱动方法在本构建模中展现出巨大的潜力和优势。



(a) Strain rate: 0.01/s



(b) Strain rate: 640/s

Fig. 14 True tensile stress-strain curves and strain distributions simulated using the data-driven model and J-C model<sup>[104]</sup>

## 5 数据驱动方法主要应用方式及存在的问题

### 5.1 主要应用方式

从已有的研究进展可以发现,数据驱动方法在高温结构强度与寿命研究中的应用方式主要有4种:

(1)完全代替现有理论方法。早期的数据驱动方法如机器学习在寿命评估的应用大多数以神经网络来代替载荷因素与寿命之间的复杂非线性关系,以达到更好的预测精度。而在本构建模中则是通过数据驱动方法来建立应力与应变、硬化变量之间的演化规律,从而避免复杂的非线性偏微分方程求解。

(2)耦合和驱动已有模型方法的改进。一方面,为已有的一些模型和方法在提供不确定性量化与修正,如利用神经网络代理模型实现本构模型参数的高效识别、优化以及精简;另一方面,耦合一些已有的唯象或者物理模型来达到更高的预测精度,如耦合连续损伤理论、临界平面方法的结构寿命预测等。

(3)挖掘变量之间潜在规律。数据驱动方法所构建的复杂内部结构能够体现数据之间的相互作用、约束以及影响相关性,通过对数据中稀疏特征的辨识、关联及分析,从而挖掘出隐含的物理规律、甚至是机理模型,完善现有的理论或方法,比如 Nowell 等<sup>[84]</sup>就利用 ANN 网络发现了微动疲劳中接触尺寸与疲劳寿命的转折关系。

(4)定性认识转化为定量可建模数据。金属材料 and 复合材料在服役和研发过程中受到各种热力作用,会形成某些特殊的微观组织和结构,通过机器学习方法或者数字图像处理算法来讲定性的微观图像转化为定量认识,进而产生可用于力学建模的数据输入,突破了传统固体强度与破坏领域中宏微观简单关联或者无法关联的巨大鸿沟。

### 5.2 存在的问题

综合已有各个方面的研究进展,数据驱动方法在结构强度与寿命领域中已经取得了较好的初步应用成果,但是也面临着一些不足与问题,主要表现在:

(1)数据依赖性与获取能力弱。数据驱动方法严重依赖于数据的有效性和充分性,而高温结构的损伤与破坏数据往往是稀疏的,特征有限且多样性不足;此外,由于长期形成的主观经验认识,从业研究人员在数据的收集、分析和管理的上仍存在一定的不足,从而限制了数据驱动方法自身潜力的最大

发挥。

(2)客观物理定律难以引入。自然科学中事物的发展严格遵循这物理客观不变性、守恒律以及耗散不可逆等规律的约束,而数据驱动方法难以对这些客观物理规律进行引入,单纯依赖数据之间的关联,这也导致方法在应用过程中出现欠/过拟合,预测偏差大等问题。

(3)方法的泛化和外推能力弱。当前在结构寿命评估,变形行为预测以及损伤关联研究中,应用机器学习方法大多是内插预测,也即是在模型训练过程中就已经确定好了问题的上下边界,这就导致在面对超出边界的情形时,模型的预测能力存在较大的不确定性,出现外推能力不足的情况;另一方面,由于缺乏问题的统一描述,大多数所建立的数据驱动模型往往只针对某一具体问题和材料有效,导致相同模型的泛化和延拓能力难以提升。

(4)模型构建的客观认识不足。构建数据驱动模型时需要确定一些信息特征,才能够保证模型的有效预测和利用。而实际的过程中由于受到先验认知的影响,导致对具体问题的特征量并不明确,或者明确之后没有获得,无法针对数据提出有意义且可执行的问题。

## 6 总结与展望

数据驱动方法在高温结构微观组织定量化、复杂载荷下材料/结构寿命评估以及多物理场耦合作用下材料的变形行为预测等方面已经取得了较好的初步应用,引起了国内外学者的广泛关注和重视。相比与传统研究思路存在明显的差异,更多关注数据的相关性而不是单一因果律,具有适应问题范围广、能够考虑多因素耦合作用、识别和量化关键因素影响的特点。

数据驱动方法在高温结构强度与寿命的研究中主要存在4中应用方式,分别为:完全代替现有理论方法、耦合和驱动已有模型方法的改进、挖掘变量之间潜在规律和定性认识转化为定量可建模数据。同时,数据驱动方法主要面临着4个方面的不足与挑战,分别是:数据依赖性与获取能力弱、客观物理定律难以引入、方法的泛化和外推能力弱和模型构建的客观认识不足。

为进一步推动数据驱动方法在高温结构强度与寿命评估领域的应用,建议如下:

(1)开发基于小数据样本的数据驱动方法。高温结构强度与寿命试验成本高,试验难度大,可用于

模型训练的试验数据量少。有必要研究基于小样本数据的数据驱动方法建模策略。

(2)发展耦合客观物理规律的数据驱动方法。耦合物理规律的数据驱动方法不仅提高了模型的物理可解释性,更为缩小模型计算量、减少训练数据需求量、提高模型泛化能力等提供了解决方案。在发展数据驱动方法的同时,不应放弃传统基于宏微观物理机制的实验和建模的理性研究,形成“数据+物理”双核驱动的科学研究范式,显著提高解决高温结构在设计服役阶段的各类问题的能力。

(3)发展耦合多物理场信息的数据驱动方法。数据作为信息的载体包含数字、图片、符号、音频等形式。数据驱动方法在识别数据信息时打破了现有理论模型以数字和符号为建模基础的限制,从而可以从数字信息、图像信息、符号信息、音频信息等众多物理场信息中学习失效与破坏规律,或将有助于高温结构强度与寿命评估模型的完善,可以作为未来关注的方向之一。

致谢:感谢国家科技重大专项、国家自然科学基金、博士后科学基金面上项目的资助。

## 参考文献

- [1] Milne I, Ritchie R O, Karihaloo B. Comprehensive Structural Integrity [M]. Amsterdam: Elsevier Science Ltd, 2003.
- [2] 闫晓军, 聂景旭. 涡轮叶片疲劳[M]. 北京: 科学出版社, 2014.
- [3] Carter T J. Common Failures in Gas Turbine Blades[J]. *Engineering Failure Analysis*, 2005, 12(2): 237-247.
- [4] 李孝堂, 侯凌云, 杨敏. 现代燃气轮机技术[M]. 北京: 航空工业出版社, 2006.
- [5] 陶春虎. 航空发动机转动部件的失效与预防[M]. 北京: 国防工业出版社, 2000.
- [6] 涂善东. 高温结构完整性原理[M]. 北京: 科学出版社, 2003.
- [7] 杨晓光, 石多奇. 粘塑性本构理论及其应用[M]. 北京: 国防工业出版社, 2013.
- [8] 刘金龙. 镍基单晶/定向凝固涡轮叶片铸造模拟及其合金低循环疲劳行为研究[D]. 北京: 北京航空航天大学, 2011.
- [9] 王井科. 镍基高温合金及钛合金缺口疲劳问题研究[D]. 北京: 北京航空航天大学, 2011.
- [10] 谭龙, 杨晓光, 孙燕涛, 等. 考虑服役微结构状态的镍基合金低周疲劳寿命预测方法[J]. *推进技术*, 2022, 43(2): 210531. (TAN Long, YANG Xiaoguang, SUN Yan-tao, et al. Low Fatigue Life Prediction Methods for Ni-Based Superalloys Considering Microstructure State in Service[J]. *Journal of Propulsion Technology*, 2022, 43(2): 210531.)
- [11] Ackoff R L. From Data to Wisdom [J]. *Journal of Applied Systems Analysis*, 1989, 16: 3-9.
- [12] Agrawal A, Choudhary A. Perspective: Materials Informatics and Big Data: Realization of the “Fourth Paradigm” of Science in Materials Science [J]. *APL Materials*, 2016, 4(5): 053208.
- [13] Al-Jarrah O Y, Yoo P D, Muhaidat S, et al. Efficient Machine Learning for Big Data: A Review [J]. *Big Data Research*, 2015, 2(3): 87-93.
- [14] 张晓强, 杨君游, 曾国屏. 大数据方法: 科学方法的变革和哲学思考[J]. *哲学动态*, 2014(8): 83-91.
- [15] 杜子芳. 多元统计分析[M]. 北京: 清华大学出版社, 2016.
- [16] 周志华. 机器学习[M]. 北京: 清华大学出版社, 2016.
- [17] Chowdhury A, Kautz E, Yener B, et al. Image Driven Machine Learning Methods for Microstructure Recognition [J]. *Computational Materials Science*, 2016, 123: 176-187.
- [18] DeCost B L, Holm E A. A Computer Vision Approach for Automated Analysis and Classification of Microstructural Image Data [J]. *Computational Materials Science*, 2015, 110: 126-133.
- [19] Iacoviello F, Iacoviello D, Di Cocco V, et al. Classification of Ductile Cast Iron Specimens Based on Image Analysis and Support Vector Machine [J]. *Procedia Structural Integrity*, 2017(3): 283-290.
- [20] Sundararaghavan V, Zabarar N. Classification and Reconstruction of Three-Dimensional Microstructures Using Support Vector Machines [J]. *Computational Materials Science*, 2005, 32(2): 223-239.
- [21] Bangaru S S, Wang C, Hassan M, et al. Estimation of the Degree of Hydration of Concrete through Automated Machine Learning Based Microstructure Analysis—a Study on Effect of Image Magnification [J]. *Advanced Engineering Informatics*, 2019, 42: 100975.
- [22] Bostanabad R, Bui A T, Xie W, et al. Stochastic Microstructure Characterization and Reconstruction via Supervised Learning [J]. *Acta Materialia*, 2016, 103: 89-102.
- [23] Zhang G, Song Y, Zhao W, et al. Machine Learning-Facilitated Multiscale Imaging for Energy Materials [J]. *Cell Reports Physical Science*, 2022, 3(9): 101008.
- [24] Cang R, Xu Y, Chen S, et al. Microstructure Representation and Reconstruction of Heterogeneous Materials via

- Deep Belief Network for Computational Material Design [J]. *Journal of Mechanical Design*, 2017, 139(7): 071404.
- [25] Mosser L, Dubrule O, Blunt M J. Reconstruction of Three-Dimensional Porous Media Using Generative Adversarial Neural Networks[J]. *Physical Review E*, 2017, 96(4-1).
- [26] de Albuquerque V H C, de Alexandria A R, Cortez P C, et al. Evaluation of Multilayer Perceptron and Self-Organizing Map Neural Network Topologies Applied on Microstructure Segmentation from Metallographic Images [J]. *NDT & E International*, 2009, 42(7): 644-651.
- [27] Fu J, Xiao D, Li D, et al. Stochastic Reconstruction of 3D Microstructures from 2D Cross-Sectional Images Using Machine Learning-Based Characterization [J]. *Computer Methods in Applied Mechanics and Engineering*, 2022, 390: 114532.
- [28] Knaup A, Jernigen J, Curtis M, et al. Application of Deep Learning to Shale Microstructure Classification [J]. *Marine and Petroleum Geology*, 2022, 144: 105842.
- [29] Goodfellow I, Bengio Y, Courville A. Deep Learning [M]. USA: MIT Press, 2016.
- [30] Albawi S, Mohammed T A, Al-Zawi S. Understanding of a Convolutional Neural Network [C]. *Antalya: 2017 International Conference on Engineering and Technology (ICET)*, 2017.
- [31] LeCun Y, Kavukcuoglu K, Farabet C. Convolutional Networks and Applications in Vision [C]. *Paris: Proceedings of 2010 IEEE International Symposium on Circuits and Systems*, 2010.
- [32] Zhao P, Wang Y, Jiang B, et al. A New Method for Classifying and Segmenting Material Microstructure Based on Machine Learning [J]. *Materials & Design*, 2023, 227: 111775.
- [33] Perera R, Guzzetti D, Agrawal V. Optimized and Autonomous Machine Learning Framework for Characterizing Pores, Particles, Grains and Grain Boundaries in Microstructural Images [J]. *Computational Materials Science*, 2021, 196: 110524.
- [34] Warmuzek M, Żelawski M, Jałocha T. Application of the Convolutional Neural Network for Recognition of the Metal Alloys Microstructure Constituents Based on Their Morphological Characteristics [J]. *Computational Materials Science*, 2021, 199: 110722.
- [35] Liu Y, Chen S J, Sagoe-Crentsil K, et al. Large Set Microstructure Reconstruction Mimicking Quantum Computing Approach via Deep Learning [J]. *Acta Materialia*, 2022, 230: 117860.
- [36] Ma B, Xu Y, Chen J, et al. Deep Learning Based Object Tracking for 3D Microstructure Reconstruction [J]. *Methods*, 2022, 204: 172-178.
- [37] Menasche D B, Shade P A, Safriet S, et al. Deep Learning Approaches to Semantic Segmentation of Fatigue Cracking within Cyclically Loaded Nickel Superalloy [J]. *Computational Materials Science*, 2021, 198: 110683.
- [38] Mishra S P, Rahul M R. A Comparative Study and Development of a Novel Deep Learning Architecture for Accelerated Identification of Microstructure in Materials Science [J]. *Computational Materials Science*, 2021, 200: 110815.
- [39] Liu X, Yan Z, Zhong Z. Predicting Elastic Modulus of Porous  $\text{La}_{0.6}\text{Sr}_{0.4}\text{Co}_{0.2}\text{Fe}_{0.8}\text{O}_{3-\delta}$  Cathodes from Microstructures via FEM and Deep Learning [J]. *International Journal of Hydrogen Energy*, 2021, 46(42): 22079-22091.
- [40] Heidenreich J N, Gorji M B, Mohr D. Modeling Structure-Property Relationships with Convolutional Neural Networks: Yield Surface Prediction Based on Microstructure Images [J]. *International Journal of Plasticity*, 2023, 163: 103506.
- [41] Wang C, Shi D, Li S. A Study on Establishing a Microstructure-Related Hardness Model with Precipitate Segmentation Using Deep Learning Method [J]. *Materials*, 2020, 13(5).
- [42] Fullwood D T, Niezgodka S R, Adams B L, et al. Microstructure Sensitive Design for Performance Optimization [J]. *Progress in Materials Science*, 2010, 55(6): 477-562.
- [43] Fullwood D T, Adams B L, Kalidindi S R. Generalized Pareto Front Methods Applied to Second-Order Material Property Closures [J]. *Computational Materials Science*, 2007, 38(4): 788-799.
- [44] Kirka M M. Thermomechanical Behavior of a Directionally Solidified Nickel-Base Superalloy in the Aged State [D]. *Atlanta: Georgia Institute of Technology*, 2014.
- [45] Altschuh P, Yabansu Y C, Hötzer J, et al. Data Science Approaches for Microstructure Quantification and Feature Identification in Porous Membranes [J]. *Journal of Membrane Science*, 2017, 540: 88-97.
- [46] Moore A W, Connolly A J, Genovese C, et al. Fast Algorithms and Efficient Statistics: N-Point Correlation Functions [C]. *Garching: Proceedings of the MPA/ESO/MPPE Workshop*, 2000: 71-82.
- [47] Fromm B S, Adams B L, Ahmadi S, et al. Grain Size and Orientation Distributions: Application to Yielding of

- A-Titanium[J]. *Acta Materialia*, 2009, 57(8): 2339-2348.
- [48] Latypov M I, Kühbach M, Beyerlein I J, et al. Application of Chord Length Distributions and Principal Component Analysis for Quantification and Representation of Diverse Polycrystalline Microstructures[J]. *Materials Characterization*, 2018, 145: 671-685.
- [49] Caccuri V, Desmorat R, Cormier J. Tensorial Nature of  $\gamma'$ -Rafting Evolution in Nickel-Based Single Crystal Superalloys[J]. *Acta Materialia*, 2018, 158: 138-154.
- [50] Fan Y S, Yang X G, Shi D Q, et al. Quantitative Mapping of Service Process-Microstructural Degradation-Property Deterioration for a Ni-Based Superalloy Based on Chord Length Distribution Imaging Process[J]. *Materials & Design*, 2021, 203: 109561.
- [51] Little R J A, Rubin D B. Statistical Analysis with Missing Data[M]. *New York: John Wiley & Sons*, 2019.
- [52] Van Buuren S. Flexible Imputation of Missing Data[M]. *London: CRC Press*, 2018.
- [53] Emmanuel T, Maupong T, Mpoeleng D, et al. A Survey on Missing Data in Machine Learning[J]. *Journal of Big Data*, 2021, 8(1): 1-37.
- [54] 王红珂, 刘啸天, 林磊, 等. 机器学习在材料服役性能预测中的应用[J]. *装备环境工程*, 2022(1): 11-19.
- [55] 侯哲哲, 杜彦良, 赵维刚. 基于支持向量机的疲劳应力集中系数预测模型研究[J]. *机械工程学报*, 2012(4): 40-43.
- [56] Zhang L, Wang Z, Wang L et al. Machine Learning-Based Real-Time Visible Fatigue Crack Growth Detection[J]. *Digital Communications and Networks*, 2021, 7(4): 551-558.
- [57] Teixeira M C, Brandão A L T, Parente A P, et al. Artificial Intelligence Modeling of Ultrasonic Fatigue Test to Predict the Temperature Increase[J]. *International Journal of Fatigue*, 2022, 163: 106999.
- [58] Gan L, Wu H, Zhong Z. Fatigue Life Prediction Considering Mean Stress Effect Based on Random Forests and Kernel Extreme Learning Machine [J]. *International Journal of Fatigue*, 2022, 158: 106761.
- [59] Liu Y, Wu J, Wang Z, et al. Predicting Creep Rupture Life of Ni-Based Single Crystal Superalloys Using Divide-and-Conquer Approach Based Machine Learning[J]. *Acta Materialia*, 2020, 195: 454-467.
- [60] Gao J, Wang J, Xu Z, et al. Multiaxial Fatigue Prediction and Uncertainty Quantification Based on Back Propagation Neural Network and Gaussian Process Regression [J]. *International Journal of Fatigue*, 2023, 168: 107361.
- [61] Schneller W, Leitner M, Maier B, et al. Artificial Intelligence Assisted Fatigue Failure Prediction[J]. *International Journal of Fatigue*, 2022, 155: 106580.
- [62] Bartošák M. Using Machine Learning to Predict Lifetime under Isothermal Low-Cycle Fatigue and Thermo-Mechanical Fatigue Loading [J]. *International Journal of Fatigue*, 2022, 163: 107067.
- [63] Chen J, Liu Y. Fatigue Modeling Using Neural Networks: A Comprehensive Review [J]. *Fatigue & Fracture of Engineering Materials & Structures*, 2022, 45(4): 945-979.
- [64] Yang J, Kang G, Liu Y, et al. A Novel Method of Multiaxial Fatigue Life Prediction Based on Deep Learning[J]. *International Journal of Fatigue*, 2021, 151: 106356.
- [65] Seifi S H, Yadollahi A, Tian W, et al. In Situ Nondestructive Fatigue-Life Prediction of Additive Manufactured Parts by Establishing a Process-Defect-Property Relationship[J]. *Advanced Intelligent Systems*, 2021, 3(12): 2000268.
- [66] 李杰, 贾渊杰, 张志新, 等. 基于融合神经网络的航空发动机剩余寿命预测[J]. *推进技术*, 2021, 42(8): 1725-1734. (LI Jie, JIA Yuan-jie, ZHANG Zhi-xin, et al. Remaining Useful Life Prediction of Aeroengine Based on Fusion Neural Network[J]. *Journal of Propulsion Technology*, 2021, 42(8): 1725-1734.)
- [67] Sun X, Zhou K, Shi S, et al. A New Cyclical Generative Adversarial Network Based Data Augmentation Method for Multiaxial Fatigue Life Prediction [J]. *International Journal of Fatigue*, 2022, 162: 106996.
- [68] He G, Zhao Y, Yan C. Application of Tabular Data Synthesis Using Generative Adversarial Networks on Machine Learning-Based Multiaxial Fatigue Life Prediction [J]. *International Journal of Pressure Vessels and Piping*, 2022, 199: 104779.
- [69] Zhang K, Fan C, Li S, et al. Fitting and Prediction for Fatigue Crack Propagation of 7N01 Aluminum Alloy After Long-Term Service Based on Deep Belief Network [J]. *Engineering Fracture Mechanics*, 2021, 258: 107980.
- [70] Li N, Yan W P, Ye F, et al. Creep-Fatigue Interaction Life Prediction for P91 Steel Based on Improved Elman Neural Network Model [C]. *Yangzhou: International Conference on Advanced Engineering Materials and Technology*, 2012.
- [71] Wang H, Li B, Gong J, 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.
- [72] Gan L, Wu H, Zhong Z. On the Use of Data-Driven Machine Learning for Remaining Life Estimation of Metallic Materials Based on Ye-Wang Damage Theory [J]. *International Journal of Fatigue*, 2022, 156: 106666.
- [73] Lian Z, Li M, Lu W. Fatigue Life Prediction of Aluminum Alloy via Knowledge-Based Machine Learning [J]. *International Journal of Fatigue*, 2022, 157: 106716.
- [74] Zhang X, Gong J, Xuan F. A Deep Learning Based Life Prediction Method for Components under Creep, Fatigue and Creep-Fatigue Conditions [J]. *International Journal of Fatigue*, 2021, 148: 106236.
- [75] Chen J, Liu Y. Probabilistic Physics-Guided Machine Learning for Fatigue Data Analysis [J]. *Expert Systems with Applications*, 2021, 168: 114316.
- [76] Karolczuk A, Słowski M. Application of the Gaussian Process for Fatigue Life Prediction under Multiaxial Loading [J]. *Mechanical Systems and Signal Processing*, 2022, 167: 108599.
- [77] Karolczuk A, Skibicki D, Pejkowski A. Gaussian Process for Machine Learning-Based Fatigue Life Prediction Model under Multiaxial Stress-Strain Conditions [J]. *Materials*, 2022, 15(21): 7797.
- [78] Zhan Z, Hu W, Meng Q. Data-Driven Fatigue Life Prediction in Additive Manufactured Titanium Alloy: A Damage Mechanics Based Machine Learning Framework [J]. *Engineering Fracture Mechanics*, 2021, 252: 107850.
- [79] Sun X, Zhou K, Shi S, et al. A New Cyclical Generative Adversarial Network Based Data Augmentation Method for Multiaxial Fatigue Life Prediction [J]. *International Journal of Fatigue*, 2022, 162: 106996.
- [80] 周书蔚, 杨冰, 王超, 等. 机器学习法预测不同应力比 6005a-T6 铝合金疲劳裂纹扩展速率 [J/OL]. 中国有色金属学报, <http://kns.cnki.net/kcms/detail/43.1238.TG.20230310.1324.003.html>, 2023-03-10.
- [81] 王思齐. 基于神经网络的低周疲劳寿命预测方法研究 [D]. 大连: 大连理工大学, 2022.
- [82] Wang Y, Zhu Z, Sha A, et al. Low Cycle Fatigue Life Prediction of Titanium Alloy Using Genetic Algorithm-Optimized BP Artificial Neural Network [J]. *International Journal of Fatigue*, 2023, 172: 107609.
- [83] Lian Z, Li M, Lu W. Fatigue Life Prediction of Aluminum Alloy via Knowledge-Based Machine Learning [J]. *International Journal of Fatigue*, 2022, 157: 106716.
- [84] Nowell D, Nowell P W. A Machine Learning Approach to the Prediction of Fretting Fatigue Life [J]. *Tribology International*, 2020, 141: 105913.
- [85] Gorji M B, de Pannemaecker A, Spevack S. Machine Learning Predicts Fretting and Fatigue Key Mechanical Properties [J]. *International Journal of Mechanical Sciences*, 2022, 215: 106949.
- [86] Tan L, Yang X G, Shi D Q, et al. Unified Fatigue Life Modelling and Uncertainty Estimation of Ni-Based Superalloy Family with a Supervised Machine Learning Approach [J]. *Engineering Fracture Mechanics*, 2022, 275: 108813.
- [87] 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.
- [88] 徐会会, 奥妮, 吴圣川, 等. 金属结构材料腐蚀疲劳寿命预测模型的研究进展 [J]. 固体力学学报, 2023, 44(1): 1-33.
- [89] Fan Y S, Tan L, Yang X G, et al. A Microstructural Rafting State-Based Constitutive Model for Single Crystal Ni-Based Superalloys at Elevated Temperature [J]. *International Journal of Mechanical Sciences*, 2022, 228: 107484.
- [90] Schulte R, Karca C, Ostwald R, et al. Machine Learning-Assisted Parameter Identification for Constitutive Models Based on Concatenated Loading Path Sequences [J]. *European Journal of Mechanics-A/Solids*, 2023, 98: 104854.
- [91] 田静莹, 夏瞳, 杨振宇, 等. 基于纳米压痕试验的塑性本构参数反演方法研究 [J]. 固体力学学报, 2023, DOI: 10.19636/j.cnki.cjasm42-1250/O3.2023.016: 1-15.
- [92] Sun Y, Zeng W D, Zhao Y Q, et al. Development of Constitutive Relationship Model of Ti600 Alloy Using Artificial Neural Network [J]. *Computational Materials Science*, 2010, 48(3): 686-691.
- [93] Sun Y, Zeng W D, Zhao Y Q, et al. Modeling Constitutive Relationship of Ti40 Alloy Using Artificial Neural Network [J]. *Materials & Design*, 2011, 32(3): 1537-1541.
- [94] Jang D P, Fazily P, Yoon J W. Machine Learning-Based Constitutive Model for J2-Plasticity [J]. *International Journal of Plasticity*, 2021, 138: 102919.
- [95] Xu K, Huang D Z, Darve E. Learning Constitutive Relations Using Symmetric Positive Definite Neural Networks

- [J]. *Journal of Computational Physics*, 2021, 428: 110072.
- [96] Masi F, Stefanou I. Evolution Tann and the Identification of Internal Variables and Evolution Equations in Solid Mechanics[J]. *Journal of the Mechanics and Physics of Solids*, 2023, 174: 105245.
- [97] Weber G, Pinz M, Ghosh S. Machine Learning-Enabled Self-Consistent Parametrically-Upscaled Crystal Plasticity Model for Ni-Based Superalloys[J]. *Computer Methods in Applied Mechanics and Engineering*, 2022 402: 115384.
- [98] He X, Chen J. Thermodynamically Consistent Machine-Learned Internal State Variable Approach for Data-Driven Modeling of Path-Dependent Materials[J]. *Computer Methods in Applied Mechanics and Engineering*, 2022, 402: 115348.
- [99] Guo Z, Bai R, Lei Z, et al. Cpinet: Parameter Identification of Path-Dependent Constitutive Model with Automatic Denoising Based on CNN-LSTM [J]. *European Journal of Mechanics-A/Solids*, 2021, 90: 104327.
- [100] Wang J, Li T, Cui F, et al. Metamodeling of Constitutive Model Using Gaussian Process Machine Learning[J]. *Journal of the Mechanics and Physics of Solids*, 2021, 154: 104532.
- [101] Yao D, Duan Y, Li M, et al. Hybrid Identification Method of Coupled Viscoplastic-Damage Constitutive Parameters Based on BP Neural Network and Genetic Algorithm [J]. *Engineering Fracture Mechanics*, 2021, 257: 108027.
- [102] Ktari Z, Leitão C, Prates P A, et al. Mechanical Design of Ring Tensile Specimen via Surrogate Modelling for Inverse Material Parameter Identification[J]. *Mechanics of Materials*, 2021, 153: 103673.
- [103] Zhang B, Endelt B, Lang L, et al. Identification of Constitutive Parameters for Thin-Walled Aluminium Tubes Using a Hybrid Strategy[J]. *Materials Today Communications*, 2021, 28: 102670.
- [104] Xin L, Ziqi L, Yang C, et al. An Enhanced Data-Driven Constitutive Model for Predicting Strain-Rate and Temperature Dependent Mechanical Response of Elastoplastic Materials[J]. *European Journal of Mechanics-A/Solids*, 2023, 98: 104996.

(编辑:梅 瑛)