

基于物理信息神经网络的金属多轴疲劳寿命预测进展

张颢利¹ 孙兴悦² 陈旭²

(1. 中海油能源发展装备技术有限公司 工业防护工程中心, 天津 300457)

(2. 天津大学 化工学院, 天津 300350)

摘要: 材料的多轴疲劳寿命预测研究是保证部件结构完整性的关键要素之一。近年来机器学习尤其是神经网络在疲劳寿命预测领域得到了广泛应用。然而,疲劳数据的不足阻碍了神经网络在疲劳预测中的进一步应用。为了解决这一问题,考虑疲劳先验物理知识的物理信息神经网络逐渐受到关注。首先,概述了机器学习算法的分类及神经网络模型在多轴疲劳寿命预测中的应用。随后,重点对基于物理信息神经网络的材料疲劳寿命预测研究进行了深入探讨。最后,从基于物理信息的输入特征、基于物理信息的损失函数构建和基于物理信息的网络框架开发等3个方面对物理信息神经网络模型的发展进行介绍。相关研究表明,在材料多轴疲劳寿命预测过程中,物理信息神经网络可以表现出更好的物理一致性和预测性能。

关键词: 物理信息神经网络; 多轴疲劳; 寿命预测; 机器学习

中图分类号: TH114; O346.2 **DOI:** 10.16579/j.issn.1001.9669.2025.02.006

0 引言

在工程实践中,机械结构的疲劳失效是一个常见的问题,据统计,大约80%~90%的工程构件断裂都与疲劳有关^[1]。因此,深入研究疲劳现象对于确保机械结构在服役期间的可靠性至关重要。自1854年“疲劳”这一概念首次被提出以来,关于疲劳的研究已形成了一个全面的研究体系^[2]。疲劳寿命预测是疲劳研究的重要组成部分,主要关注机械结构在受到循环载荷作用下的性能变化和寿命预估,涉及多个学科领域,包括力学、材料科学、统计学等。

疲劳寿命的预测研究经历了4个显著的发展阶段,如图1所示^[3-4]。在第一阶段,即17世纪之前,预测材料的疲劳寿命主要依赖于经验和实验数据。由于当时的科学和技术水平有限,人们通常只能通过反复实验和观察来积累对材料疲劳特性的认识^[5]。进入第二阶段,即从17世纪到20世纪50年代之前,理论科学范式逐渐占据主导地位。科学家们开始尝试通过理论分析和数学建模来揭示材料疲劳的机制和规律。一些重要的定理和模型相继被提出,为后续的疲劳寿命预测研究奠定了理论基础^[6]。第三阶段是从20世纪50年代到21世纪初,计算机科学范式的崛起标志着预测技术的重大进步。随着计算机技术的飞速发

展,人们开始将理论科学范式与计算机相结合,利用数值计算和仿真分析等方法来预测材料在复杂情况下的疲劳寿命。这种方法不仅提高了预测的准确性和效率,还为解决复杂的疲劳问题提供了有力的工具^[7]。到了第四阶段,即2000年至今,数据驱动范式逐渐成为疲劳寿命预测研究的新趋势。在这一时期,人们将理论与计算机技术相结合,并通过大数据分析和机器学习等技术手段来优化预测模型^[8]。这种基于数据驱动的预测方法能够充分利用实验数据和监测信息,提高预测的准确性和可靠性,为工程实践提供更加有效的支持。

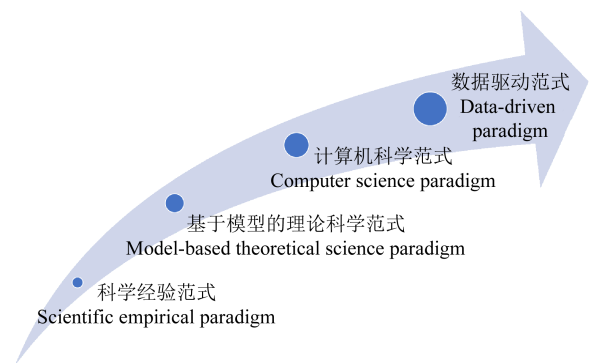


图1 材料疲劳寿命预测发展阶段

Fig. 1 Development stage of fatigue life prediction

收稿日期: 2024-04-23 修回日期: 2024-06-20

基金项目: 国家自然科学基金项目(12302098); 国家资助博士后研究人员资助计划项目(GZB20230508)

作者简介: 张颢利,男,1978年生,天津人,硕士,经济师; 主要研究方向为海洋石油设备设施腐蚀防护与腐蚀治理; E-mail: Zhangzh12@cnooc.com.cn。孙兴悦(通信作者),男,1995年生,河南洛阳人,博士,助理研究员; 主要研究方向为基于数据驱动的材料多轴疲劳寿命预测; E-mail: xysun7230@tju.edu.cn。

引用格式: 张颢利, 孙兴悦, 陈旭. 基于物理信息神经网络的金属多轴疲劳寿命预测进展[J]. 机械强度, 2025, 47(2): 44-52.

ZHANG Zhuanli, SUN Xingyue, CHEN Xu. Development in metal multiaxial fatigue life prediction based on physics-informed neural networks [J].

Journal of Mechanical Strength, 2025, 47(2): 44-52.

本文总结了机器学习、神经网络在金属多轴疲劳寿命预测领域的应用,重点介绍了物理信息神经网络的分类及其在金属多轴疲劳领域的应用。本文的框架组织如下:第 1 节介绍了机器学习的分类及神经网络在疲劳预测中的应用;第 2 节将物理信息神经网络进行分类并介绍了基于物理信息神经网络的材料疲劳寿命预测应用;第 3 节进行了全文总结。

1 机器学习算法分类及应用

1.1 机器学习算法分类

根据学习方式和算法特性的不同,机器学习算法可以划分为多个主要类别,如监督学习、无监督学习、半监督学习、强化学习等^[9],如图 2 所示。监督学习是最为常见的机器学习模型之一。它依赖于带有已知标签的训练数据集。通过训练模型来识别输入数据中的特征,并学习如何将数据映射到相应的标签。常见的监督学习可以分为传统机器学习和神经网络。传统机器学习模型有支持向量机^[10-13](Support Vector Machine, SVM)、随机森林^[14-15](Random Forest, RF)、极限梯度提升(eXtreme Gradient Boosting, XGBoost)树^[16-17]、高斯过程回归(Gaussian Process Regression, GPR)^[18]、K 近邻(K-Nearest Neighbor, KNN)^[19]等多种算法。

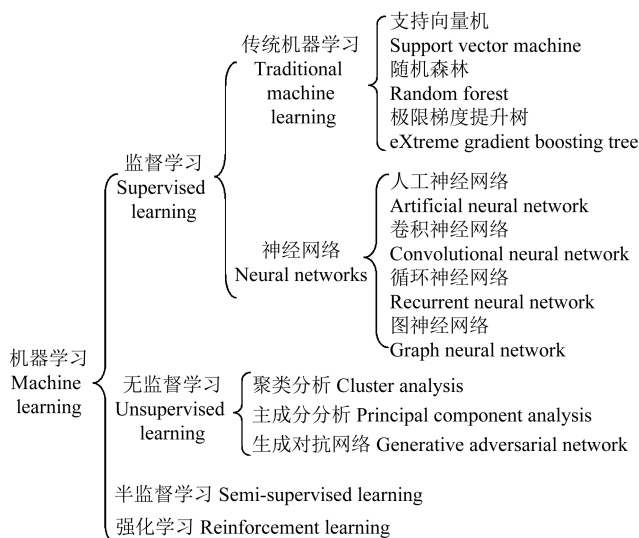


图 2 机器学习算法分类

Fig. 2 Classification of machine learning algorithm

与传统机器学习方法相比,神经网络有着更高的复杂度和更强大的数据处理能力。它由大量神经元连接,模拟人脑神经系统的结构和功能,实现了对数据的非线性映射和预测。神经网络模型包括人工神经网络(Artificial Neural Network, ANN)、卷积神经网络(Convolutional Neural Network, CNN)、循环神经网络(Recurrent Neural Network, RNN)等算法。其一大特点是采用自动学习的方式进行训练,通过反向传播算法自动调整模型的参数,主要步骤为前向传播、计算损失、反向传播、参数更新,如图 3 所示。

图 3 神经网络训练主要步骤




图 3 神经网络训练主要步骤

Fig. 3 Main steps of neural network training

与监督学习不同的是,无监督学习和半监督学习主要用于分类和聚类问题。其中,无监督学习指在没有标签的情况下对数据进行分类^[20]。这类方法通常用于发现数据的内在结构和模式。无监督学习包括聚类分析^[21-22]、主成分分析^[23]、生成对抗网络(Generative Adversarial Network, GAN)^[24-25]等。而半监督学习是监督学习与无监督学习相结合的一种学习方法。这种方法在许多实际应用中特别是在处理大规模、高维、不完全标记的数据集时具有显著优势^[26-27]。

强化学习是一种通过智能体与环境互动来学习最优行为的机器学习方法。它的核心原理是“奖励最大化”,即智能体通过不断尝试不同的行为,观察环境反馈的奖励或惩罚,并以此为依据来调整策略,从而找到一种行为序列,使得在反复执行该序列时能够获得最大的累积奖励^[28]。

1.2 神经网络算法应用

人工神经网络是最为简单和常用的神经网络算法之一。ANN 模型主要由输入层、隐藏层和输出层 3 部分构成^[29-30],结构如图 4 所示。输入层是 ANN 的第 1 层,负责接收数据,一般为与输出相关的特征。隐藏层位于输入层和输出层之间,是 ANN 中最重要的部分。隐藏层的数量并不固定,其作用是负责提取输入数据的特征,并将其转换为对解决问题有用的表示。输出层是 ANN 的最后一层,负责产生神经网络的最终输出。早在 2003 年,就有研究将 ANN 模型应用于 316L 不锈钢的疲劳寿命预测中。近年来,它仍然广泛应用于不锈钢^[31-32]、各种合金^[33]、橡胶^[34]等材料的疲劳寿命预测中。在蠕变-疲劳交互的寿命预测中,ANN 也展现出优于传统模型的预测性能^[35]。

与 ANN 不同的是,卷积神经网络的输入特征一般为图片。SUN 等^[36-37]使用滞环图像作为输入,CNN 模型进行图片特征提取,应用于不锈钢材料、各向异性材料的多轴疲劳以及多轴蠕变-疲劳交互、多轴变幅疲

劳预测中,提高了神经网络模型在疲劳预测上的泛化能力。除了滞环图像,CNN模型还用于微观图像的语义分割中^[38]。此外,CNN模型还具备强大的特征提取能力。XIAO等^[39]应用CNN网络对多变量时间序列样本和相应的性能退化量进行特征提取,较为准确地预测了风电机组剩余使用寿命。




图4 神经网络基本框架

Fig. 4 Framework of artificial neural network

循环神经网络由于序列数据上优异的特征提取功能,广泛应用于材料的疲劳寿命预测中。RNN可以直接将材料的应力-应变载荷信息作为输入,省略了特征的预处理过程,也减少了在预处理过程中的信息损失。RNN模型主要包括门控神经网络(Gated Recurrent Unit, GRU)和长短时记忆网络(Long Short-Term Memory, LSTM)。在一些较为复杂的情况下,RNN模型能够很好地进行疲劳寿命预测,如恒温条件下的低周疲劳和热机械疲劳的寿命预测^[40]。YANG等^[41]将RNN模型成功应用于不同加载模式、不同加载水平、不同加载路径以及低周和高周疲劳的寿命预测中。针对高周疲劳,WEI等^[42]基于LSTM预测了低合金钢的扭转应力-寿命曲线和旋转弯曲应力-寿命曲线。

2 物理信息神经网络模型

由于实验成本较高,多轴疲劳实验的数据量往往难以满足神经网络对训练样本的需求,导致预测精度不理想。单纯的数据驱动模型也只能根据数据的输入输出关系进行拟合,在数据量有限的情况下难以满足物理一致性,造成模型泛化性能差。通过将物理信息融入神经网络,得到物理-数据驱动模型,可以有效提升小样本条件下神经网络模型的多轴疲劳寿命预测效果。本节将主要从基于物理信息的输入特征、基于物理信息的损失函数构建和基于物理信息的网络框架开发等3个方面对物理信息神经网络模型在金属多轴疲劳寿命预测中的发展进行介绍。

2.1 基于物理信息的输入特征

神经网络根据不同的输入特征值给出相应的回

归预测。因此,恰当的输入特征是神经网络准确预测材料疲劳寿命的关键^[43]。对数据集进行预处理,提取与疲劳寿命强相关的特征,可以大大提高神经网络预测精度。

基于物理知识相关参数筛选输入特征,是一种将物理知识融入神经网络的有效方法。在多轴疲劳预测应用中,机器学习尤其是神经网络模型一般不直接将应变、应力原始序列直接作为输入特征,而是采用预处理后的多轴应力、应变的幅值和峰值等作为输入的特征。基于物理知识选择特征能够提高神经网络的性能,简化神经网络的框架。在多轴疲劳寿命预测中,认为应力、应变峰值和幅值、滞环能以及非比例度等因素是与多轴疲劳寿命强相关的基因特征。将这些特征作为模型的输入,能够实现316L不锈钢多轴疲劳预测的最佳性能^[44]。在更复杂的多轴变幅疲劳预测中,基于物理信息的输入也起着关键作用。ZHOU等^[45]¹⁰⁷⁸⁶⁸进一步结合多轴疲劳寿命预测的临界面模型,计算出临界面上的应力、应变峰值和幅值作为神经网络的输入,将神经网络成功应用于304不锈钢的多轴变幅疲劳寿命预测中,如图5所示^[45]¹⁰⁷⁸⁶⁸。郑战光等^[46]考虑了轴向和扭转方向相位差与加载路径非比例度的关系,构建一种以相位差、正应变幅值和切应变幅值作为输入变量,以疲劳寿命作为输出的神经网络模型,成功实现了对多种钛及钛合金的多轴疲劳寿命预测。相似的,HE等^[47]选择了多轴疲劳寿命预测相关的敏感性特征,即不同方向的应力、应变幅值、滞环能、非比例度等因素进行了特征重要性分析。除了敏感特征,传统多轴疲劳寿命模型计算的多轴损伤参数也被输入至神经网络中。输入特征的选择提高了ANN在多轴寿命预测上的预测性能。除了ANN,贝叶斯神经网络也应用于多轴疲劳寿命预测中,网络的

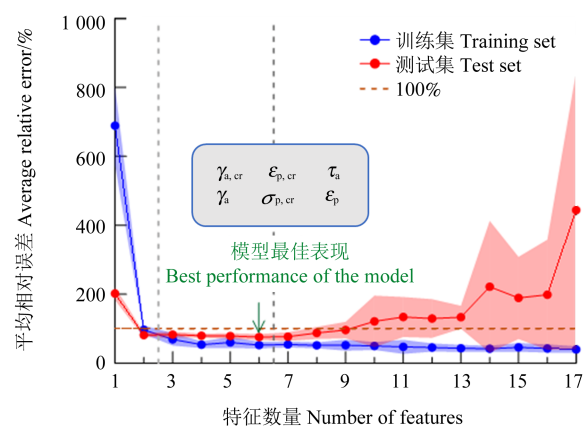


图5 多轴变幅疲劳寿命预测基于知识的基因特征筛选

Fig. 5 Knowledge-based genetic feature selection in multiaxial variable amplitude fatigue life prediction

输入也采用了与多轴疲劳寿命强相关的敏感性特征^[48]。为了使神经网络输入反映更多的加载信息,ZHENG等^[49]选择能反映加载和非比例加载、相位差、加载频率的矢量数据,以及正应变、剪切应变,构造双层特征输入,并基于图像识别和特征提取方法进行回归预测。结果表明,该方法能准确地预测多轴疲劳寿命并具有良好的外推能力,图像识别技术适用于载荷路径的特征提取。

这种在材料多轴疲劳寿命预测中常用的物理信息输入特征构建方法,也经常用于其他复杂条件下的疲劳寿命预测中,为其提供了相关经验^[50-52]。

除了物理知识相关参数,将仿真结果、理论结果作为神经网络的输入特征,是另一种常见的基于物理信息输入,可表达为

$$y_{\text{pre}} = f(x_1, x_2, \dots, x_n, y_{\text{true}}) \quad (1)$$

式中, y_{pre} 为神经网络的寿命预测结果; x_i 为各输入特征,其中, i 为样本个数; y_{true} 为仿真结果或理论结果。

目前这一方法大多应用于不同材料条件下的单轴疲劳寿命预测中,在多轴疲劳寿命预测中应用并不广泛。WANG等^[53]将基于连续损伤力学的寿命预测值输入至机器学习模型中,在增材制造材料的疲劳寿命预测上得到了较好的结果。类似的,WANG等^[54]通过串行集成和并行集成两种方式将增材制造Murakami模型的寿命预测结果集成至机器学习模型中,预测了3种增材制造材料的疲劳寿命,缓解了过拟合问题。在预测金属材料两步加载的剩余寿命上,GAN等^[55]将基于损伤理论的寿命理论值作为机器学习的输入特征,降低了对训练数据的要求。

2.2 基于物理信息的损失函数构建

除了输入特征,损失函数在机器学习中起着关键作用,是神经网络参数优化目标之一。回归预测的损

失函数通常使用均方误差(Mean Square Error, MSE)来表示,能够衡量模型预测结果与真实值之间的差异。而在损失函数中加入物理约束项,能够使模型预测值与真实值误差减小的同时,满足物理一致性。加入物理约束项的损失函数可表达为

$$L_{\text{loss}} = \lambda_{\text{error}} L_{\text{error}} + \lambda_{\text{phy},1} L_{\text{phy},1} + \lambda_{\text{phy},2} L_{\text{phy},2} + \dots \quad (2)$$

式中, L_{loss} 为神经网络的损失函数; L_{error} 为预测值与真实值之间的误差; λ_{error} 为 L_{error} 的权重; $L_{\text{phy},i}$ 为物理约束项; $\lambda_{\text{phy},i}$ 为 $L_{\text{phy},i}$ 的权重。这些权重平衡各个损失项之间的作用。

基于物理信息的损失函数物理约束项最早是将偏微分方程引入神经网络^[56-57]。在疲劳领域,引入的物理约束项主要有两种:预测结果对输入的偏导和物理方程残差。前者常用的物理约束项可表达为

$$L_{\text{phy}} = \max(0, \frac{\partial y_{\text{pre}}}{\partial x}) \quad (3)$$

该约束项表示当输出对输入的偏导大于0时,将偏导值作为物理约束项。这能够促进结果分布规律的物理一致性。根据疲劳寿命对输入特征的偏导关系推导神经网络参数分布规律,将此分布规律应用于构造物理约束项。HALAMKA等^[58]基于此,提出了物理信息混合神经网络,在42CrMo4钢和2024-T3铝合金的多轴疲劳寿命预测中得到验证。根据概率疲劳中疲劳寿命的均值及方差随着载荷应力幅值的增大而减小的经验规律,ZHOU等^[59]¹⁰⁷²³⁴在损失函数中加入物理约束项,提出了概率物理信息神经网络,如图6所示。输入特征为应力幅值,输出为疲劳寿命的均值和方差,以参数化疲劳寿命概率分布。将基于物理知识的规律以权值 λ 添加至损失函数中。结果表明,概率物理信息神经网络给出的疲劳寿命分布有着良好的物理一致性,预测结果更为稳定。

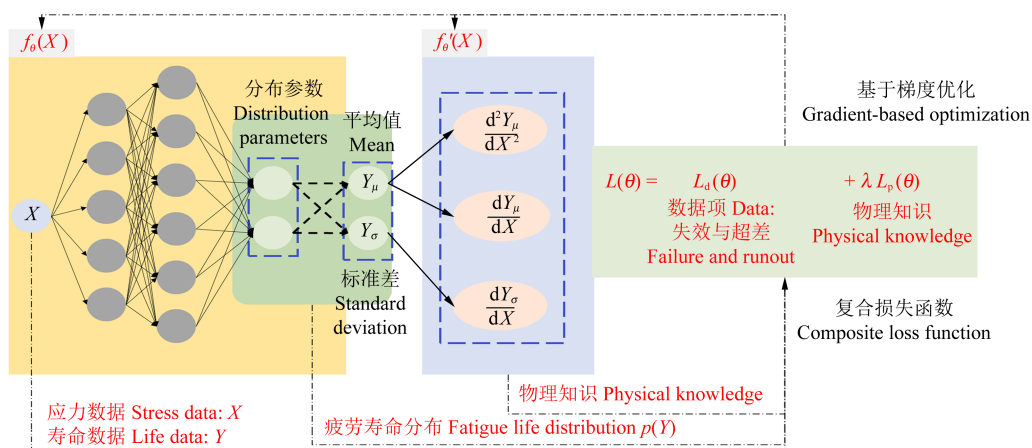


图6 加入输入偏导的概率物理信息神经网络结构示意图

Fig. 6 Probabilistic physics-informed neural network with input deflection of prediction results

基于物理方程残差项的约束项一般表达式可表述为

$$L_{\text{phy}} = [y - f(x)]^2 \quad (4)$$

式中, y 为输出特征; x 为输入特征; $f(x)$ 为根据物理方程 $y=f(x)$ 构造的函数。

当神经网络预测值与输入特征的关系不满足物理方程时, 用物理方程残差构建物理约束项, 使神经网络的预测值接近于物理方程。在材料的多轴疲劳

寿命预测中, SWT (Smith-Waston-Topper) 方程、FS (Fatemi-Socie) 方程以不同形式被引入损失函数, 以构建物理信息神经网络。HE 等^{[60]104889[61]}在选取了疲劳敏感特征的基础上, 先后将传统多轴疲劳预测方程以直接和取对数的形式添加至损失函数, 以提高模型性能。该物理信息神经网络的结构如图 7 所示^{[60]104889}。断裂力学方程也以相似的方式参与神经网络的参数训练。

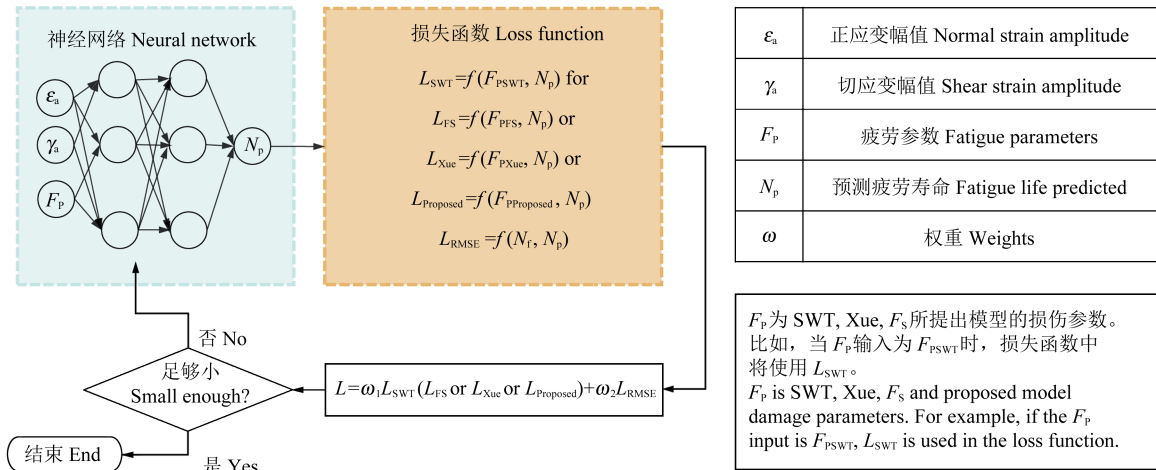


图 7 加入多轴疲劳预测方程残差项的物理信息神经网络

Fig. 7 Physics-informed neural network with residual term of multiaxial fatigue life prediction equation

除此之外, 损失函数中的物理约束项还有其他形式, 引导神经网络的预测满足不同要求。例如物理约束项可以惩罚不符合要求的过大或过小的疲劳寿命预测值, 提高模型在小样本下的泛化性能和预测精度^{[52]108130}。

2.3 基于物理信息的神经网络框架

除了输入特征和损失函数, 神经网络的框架也可以融入物理信息。神经元连接权重是神经网络的重要参数。神经网络的权重和偏置在数据集的训练下进行更新, 使预测结果接近真实值。而神经网络尤其是深度神经网络大量的参数对训练数据的数量提出了较高的要求。缩小参数的搜索空间可以降低训练

数据的要求, 简化训练过程。基于物理信息约束神经网络的参数, 能够在减小搜索空间的同时提高物理一致性, 是构建物理信息神经网络框架的重要方法。

ZHOU 等^{[62]20220392}将疲劳寿命经典预测方程 Basquin-Coffin-Manson 公式约束神经网络的框架和参数, 提出了一种基于物理引导神经网络的多轴寿命预测方法, 模型结构如图 8 所示^{[62]20220392}。该方法基于 Basquin-Coffin-Manson 公式将神经网络权重及偏置符号约束为负, 使网络具备了较好的预测性能和外推性能。YANG 等^[63]根据 Basquin 方程的寿命与加载率和损伤参数的关系进行数学推导, 约束神经网络权重和偏置的符号, 使得神经网络参数在减小的搜索空间内




图 8 Basquin-Coffin-Manson 公式约束的物理信息神经网络

Fig. 8 Physics-informed neural network constrained by Basquin-Coffin-Manson equation

满足输出与输入的关系,提高了 PA6 材料涉及棘轮加载的多轴疲劳寿命预测精度。YANG 等^[64]还通过采用自注意力的神经网络架构来实现对多轴热机械疲劳加载过程中载荷历史效应以及温度变化的特征提取分析,从而表征复杂加载历程和温度历程对疲劳寿命的影响,实现了准确的寿命预测结果。

除了权重和偏置搜索空间约束外,还可以利用稀疏网络在神经网络框架中加入物理知识。稀疏网络是相对于全连接网络提出的。当有物理知识指导输入特征与输出结果的关系,可以采用稀疏连接,以减少神经网络的参数,降低神经网络对数据的要求。CHEN 等^[65]提出了一种预测小样本金属材料疲劳寿命的稀疏连接物理信息神经网络架构。该结构以应力、应力比和简化了其他因素的影响因子为输入、疲劳寿命为输出,基于 Walker 和 Basquin 等物理模型给定的关系,人为地去掉全连接层不必要的连接。除此之外,该模型还提出了一种基于物理理论的激活函数。在基于物理信息的框架下,该模型表现出了物理一致性、良好的准确性和外推性能。

3 结论

对基于物理信息神经网络的金属材料多轴疲劳寿命预测研究进行了全面的回顾,并系统地介绍了机器学习的分类及 3 种物理信息神经网络方法在材料多轴疲劳寿命预测中的应用。相关结论如下:

1) 文献结果表明,各种神经网络广泛应用于多轴疲劳预测中,但由于疲劳数据的不足,神经网络的预测性能和物理一致性需要提高。

2) 为了解决这一问题,物理信息神经网络近年来引起了关注。基于物理信息神经网络的材料疲劳寿命预测研究包括 3 个方面:基于物理信息的输入特征、基于物理信息的损失函数构建和基于物理信息的框架开发。不同形式的物理信息神经网络提高了模型的泛化性能和物理一致性。

3) 物理信息神经网络已在金属多轴疲劳寿命预测研究中展现出较大的潜力和广泛的应用前景,但相关研究仍然处于起步阶段。未来基于物理信息神经网络的金属多轴疲劳寿命预测研究可参考单轴疲劳在复杂情况下的疲劳预测研究,将多角度的发展成熟的传统疲劳寿命预测模型以物理信息的方式加入到神经网络的构建和训练过程中。

4) 物理信息的加入方式会朝着多样化发展。随着物理信息神经网络的研究不断丰富,多模态物理信息可以加入至神经网络中,进一步提高物理知识在神

经网络中的引导作用。而计算机算力的提升和算法的优化,也促进机器学习方法和物理信息神经网络应用在更复杂的工况和更广泛的领域,为解决实际工程问题提供更加有效的解决方案。

参考文献(References)

- [1] LI Y, LIU J, HUANG W, et al. Microstructure related analysis of tensile and fatigue properties for sand casting aluminum alloy cylinder head[J]. *Engineering Failure Analysis*, 2022, 136: 106210.
- [2] 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.
- [3] 曹孟杰. 基于机器学习的 304 不锈钢低周疲劳寿命预测研究[D]. 兰州: 兰州理工大学, 2024: 3-7.
CAO Mengjie. Prediction study of 304 stainless steel low-cycle fatigue life based on machine learning[D]. Lanzhou: Lanzhou University of Technology, 2024: 3-7. (In Chinese)
- [4] 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.
- [5] KALAYCI C B, KARAGOZ S, KARAKAS Ö. Soft computing methods for fatigue life estimation: a review of the current state and future trends[J]. *Fatigue and Fracture of Engineering Materials and Structures*, 2020, 43(12): 2763-2785.
- [6] 张明义, 袁帅, 钟敏, 等. 金属材料结构的疲劳寿命预测概率模型及应用研究进展[J]. *材料导报*, 2018, 32(5): 808-814.
ZHANG Mingyi, YUAN Shuai, ZHONG Min, et al. A review on development and application of probabilistic fatigue life prediction models for metal materials and components[J]. *Materials Reports*, 2018, 32(5): 808-814. (In Chinese)
- [7] POST N, CASE S, LESKO J. Modeling the variable amplitude fatigue of composite materials: a review and evaluation of the state of the art for spectrum loading[J]. *International Journal of Fatigue*, 2008, 30(12): 2064-2086.
- [8] CHEN J, LIU Y. Fatigue modeling using neural networks: a comprehensive review [J]. *Fatigue and Fracture of Engineering Materials and Structures*, 2022, 45(4): 945-979.
- [9] FU Y, DOWNEY A R J, YUAN L, et al. Machine learning algorithms for defect detection in metal laser-based additive manufacturing: a review [J]. *Journal of Manufacturing Processes*, 2022, 75: 693-710.
- [10] WANG X, LIU J. Intelligent prediction of fatigue life of natural rubber considering strain ratio effect [J]. *Fatigue and Fracture of Engineering Materials and Structures*, 2023, 46(5): 1687-1703.
- [11] 李有根, 马文生, 李方忠, 等. SVM 方法在某多级离心泵故障诊断中的应用[J]. *机械强度*, 2024, 46(2): 272-280.
LI Yougen, MA Wensheng, LI Fangzhong, et al. Application of SVM method in fault diagnosis of a multi-stage centrifugal pump

- [J]. *Journal of Mechanical Strength*, 2024, 46(2): 272-280. (In Chinese)
- [12] DONG Q, YU Y, XU G. Fatigue residual life estimation of jib structure based on improved V-SVR algorithm obtaining equivalent load spectrum [J]. *Fatigue and Fracture of Engineering Materials and Structures*, 2020, 43(6): 1083-1099.
- [13] DANG L, HE X, TANG D, et al. A fatigue life prediction approach for laser-directed energy deposition titanium alloys by using support vector regression based on pore-induced failures [J]. *International Journal of Fatigue*, 2022, 159: 106748.
- [14] XU L, ZHANG R, HAO M, et al. A data-driven low-cycle fatigue life prediction model for nickel-based superalloys [J]. *Computational Materials Science*, 2023, 229: 112434.
- [15] DAEIL K, AZARIAN M H, PECHT M. Remaining-life prediction of solder joints using RF impedance analysis and Gaussian process regression [J]. *IEEE Transactions on Components, Packaging and Manufacturing Technology*, 2015, 5(11): 1602-1609.
- [16] FENG C, SU M, XU L, et al. Estimation of fatigue life of welded structures incorporating importance analysis of influence factors: a data-driven approach [J]. *Engineering Fracture Mechanics*, 2023, 281: 109103.
- [17] XIAO L, WANG G, LONG W, et al. Fatigue life prediction of the FCC-based multi-principal element alloys via domain knowledge-based machine learning [J]. *Engineering Fracture Mechanics*, 2024, 296: 109860.
- [18] GAO J J, WANG J, XU Z L, 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.
- [19] 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]. *中国有色金属学报*, 2023, 33(8): 2416-2427.
- ZHOU Shuwei, YANG Bing, WANG Chao, et al. Fatigue crack growth rate estimation of 6005A-T6 aluminum alloys with different stress ratios using machine learning methods [J]. *The Chinese Journal of Nonferrous Metals*, 2023, 33(8): 2416-2427. (In Chinese)
- [20] WUEST T, WEIMER D, IRGENS C, et al. Machine learning in manufacturing: advantages, challenges, and applications [J]. *Production & Manufacturing Research*, 2016, 4(1): 23-45.
- [21] PUTRA T E, ABDULLAH S, SCHRAMM D, et al. Wavelet-based feature extraction algorithm for fatigue strain data associated with the k-means clustering technique [C]. 11th International Fatigue Congress, Melbourne, Australia: 2014: 1717.
- [22] CAI W, ZHAO J, ZHU M. A real time methodology of cluster-system theory-based reliability estimation using k-means clustering [J]. *Reliability Engineering and System Safety*, 2020, 202: 107045.
- [23] PERRIN T V E, ROUSTANT O, ROHMER J, et al. Functional principal component analysis for global sensitivity analysis of model with spatial output [J]. *Reliability Engineering & System Safety*, 2021, 211: 107522.
- [24] 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.
- [25] NING L, CAI Z, LIU Y, et al. Conditional generative adversarial network driven approach for direct prediction of thermal stress based on two-phase material SEM images [J]. *Ceramics International*, 2021, 47(24): 34115-34126.
- [26] ZHANG S, HUANG K, ZHU J, et al. Manifold adversarial training for supervised and semi-supervised learning [J]. *Neural Networks*, 2021, 140: 282-293.
- [27] LI Y, WANG Y, YU D J, et al. ASCENT: active supervision for semi-supervised learning [J]. *IEEE Transactions on Knowledge and Data Engineering*, 2020, 32(5): 868-882.
- [28] FAN C, ZENG L, SUN Y, et al. Finding key players in complex networks through deep reinforcement learning [J]. *Nature Machine Intelligence*, 2020, 2(6): 317-324.
- [29] 娄路亮, 李付国. 锻造模具的随机疲劳损伤分析 [J]. *机械强度*, 2002, 24(1): 104-108.
- LOU Luliang, LI Fuguo. Stochastic fatigue damage analysis of the forging die [J]. *Journal of Mechanical Strength*, 2002, 24(1): 104-108. (In Chinese)
- [30] 左旸, 杨蓉萍, 马浩钦, 等. 基于径向神经网络的桥式起重机剩余寿命评估 [J]. *机械强度*, 2021, 43(6): 1450-1455.
- ZUO Yang, YANG Rongping, MA Haoqin, et al. Evaluation for remaining life of bridge crane based on radial basis neural network [J]. *Journal of Mechanical Strength*, 2021, 43(6): 1450-1455. (In Chinese)
- [31] SRINIVASAN V. Low cycle fatigue and creep-fatigue interaction behavior of 316L(N) stainless steel and life prediction by artificial neural network approach [J]. *International Journal of Fatigue*, 2003, 25(12): 1327-1338.
- [32] ZHAN Z, 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.
- [33] BRITO OLIVEIRA G A, FREIRE JÚNIOR R C S, CONTE MENDES VELOSO L A, et al. A hybrid ANN-multiaxial fatigue nonlocal model to estimate fretting fatigue life for aeronautical Al alloys [J]. *International Journal of Fatigue*, 2022, 162: 107011.
- [34] YANG J, KANG G, LIU Y, et al. Life prediction for rate-dependent low-cycle fatigue of PA6 polymer considering ratchetting: semi-empirical model and neural network based approach [J]. *International Journal of Fatigue*, 2020, 136: 105619.
- [35] 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.
- [36] SUN X, ZHOU T, SONG K, et al. An image recognition based multiaxial low-cycle fatigue life prediction method with CNN

- model[J]. *International Journal of Fatigue*, 2023, 167: 107324.
- [37] ZHOU T, SUN X, YU Z, et al. A generalization ability-enhanced image recognition based multiaxial fatigue life prediction method for complex loading conditions [J]. *Engineering Fracture Mechanics*, 2024, 295: 109802.
- [38] TSOPANIDIS S, MORENO R H, OSOVSKI S. Toward quantitative fractography using convolutional neural networks [J]. *Engineering Fracture Mechanics*, 2020, 231: 106992.
- [39] 车畅畅, 王华伟, 倪晓梅, 等. 基于 1D-CNN 和 Bi-LSTM 的航空发动机剩余寿命预测 [J]. *机械工程学报*, 2021, 57(14): 304-312.
- CHE Changchang, WANG Huawei, NI Xiaomei, et al. Residual life prediction of aeroengine based on 1D-CNN and Bi-LSTM [J]. *Journal of Mechanical Engineering*, 2021, 57(14): 304-312. (In Chinese)
- [40] 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.
- [41] 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.
- [42] WEI X, ZHANG C, HAN S, et al. High cycle fatigue S-N curve prediction of steels based on transfer learning guided long short term memory network [J]. *International Journal of Fatigue*, 2022, 163: 107050.
- [43] PENG J, YAMAMOTO Y, HAWK J A, et al. Coupling physics in machine learning to predict properties of high-temperatures alloys [J]. *npj Computational Materials*, 2020, 6(1): 141.
- [44] ZHOU K, SUN X, SHI S, et al. Machine learning-based genetic feature identification and fatigue life prediction [J]. *Fatigue and Fracture of Engineering Materials and Structures*, 2021, 44(9): 2524-2537.
- [45] ZHOU T, SUN X, CHEN X. A multiaxial low-cycle fatigue prediction method under irregular loading by ANN model with knowledge-based features [J]. *International Journal of Fatigue*, 2023, 176: 107868.
- [46] 郑战光, 张剑, 孙腾, 等. 基于多轴载荷相位差的神经网络预测钛合金疲劳寿命 [J]. *中国有色金属学报*, 2023, 33(3): 781-791.
- ZHENG Zhanguang, ZHANG Jian, SUN Teng, et al. Multi-axial fatigue life prediction of titanium alloy based on neural network of load phase difference [J]. *The Chinese Journal of Nonferrous Metals*, 2023, 33(3): 781-791. (In Chinese)
- [47] HE G, ZHAO Y, YAN C. Multiaxial fatigue life prediction using physics-informed neural networks with sensitive features [J]. *Engineering Fracture Mechanics*, 2023, 289: 109456.
- [48] HE G, ZHAO Y, YAN C. Uncertainty quantification in multiaxial fatigue life prediction using Bayesian neural networks [J]. *Engineering Fracture Mechanics*, 2024, 298: 109961.
- [49] ZHENG Z, LI X, SUN T, et al. Multiaxial fatigue life prediction of metals considering loading paths by image recognition and machine learning [J]. *Engineering Failure Analysis*, 2023, 143: 106851.
- [50] 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.
- [51] 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.
- [52] ZHANG X, GONG J, XUAN F. A physics-informed neural network for creep-fatigue life prediction of components at elevated temperatures [J]. *Engineering Fracture Mechanics*, 2021, 258: 108130.
- [53] WANG H, LI B, XUAN F. Fatigue-life prediction of additively manufactured metals by continuous damage mechanics (CDM) informed machine learning with sensitive features [J]. *International Journal of Fatigue*, 2022, 164: 107147.
- [54] WANG L, ZHU S, LUO C, et al. Physics-guided machine learning frameworks for fatigue life prediction of AM materials [J]. *International Journal of Fatigue*, 2023, 172: 107658.
- [55] 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.
- [56] KARNIADAKIS G E, KEVREKIDIS I G, LU L, et al. Physics-informed machine learning [J]. *Nature Reviews Physics*, 2021, 3(6): 422-440.
- [57] NASCIMENTO R G, FRICKE K, VIANA F A. A tutorial on solving ordinary differential equations using Python and hybrid physics-informed neural network [J]. *Engineering Applications of Artificial Intelligence*, 2020, 96: 103996.
- [58] HALAMKA J, BARTOŠÁK M, ŠPANIEL M. Using hybrid physics-informed neural networks to predict lifetime under multiaxial fatigue loading [J]. *Engineering Fracture Mechanics*, 2023, 289: 109351.
- [59] ZHOU T, JIANG S, HAN T, et al. A physically consistent framework for fatigue life prediction using probabilistic physics-informed neural network [J]. *International Journal of Fatigue*, 2023, 166: 107234.
- [60] HE G, ZHAO Y, YAN C. MFLP-PINN: a physics-informed neural network for multiaxial fatigue life prediction [J]. *European Journal of Mechanics-A/Solids*, 2023, 98: 104889.
- [61] HE G, ZHAO Y, YAN C. A physics-informed generative adversarial network framework for multiaxial fatigue life prediction [J]. *Fatigue and Fracture of Engineering Materials and Structures*, 2023, 46(10): 4036-4052.
- [62] ZHOU T, SUN X, CHEN X. A physics-guided modelling method of artificial neural network for multiaxial fatigue life prediction under irregular loading [J]. *Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences*, 2023, 381(2260): 20220392.
- [63] YANG J, KANG G, KAN Q. Rate-dependent multiaxial life

- prediction for polyamide-6 considering ratchetting: semi-empirical and physics-informed machine learning models [J]. *International Journal of Fatigue*, 2022, 163: 107086.
- [64] YANG J, KANG G, KAN Q. A novel deep learning approach of multiaxial fatigue life-prediction with a self-attention mechanism characterizing the effects of loading history and varying temperature [J]. *International Journal of Fatigue*, 2022, 162: 106851.
- [65] CHEN D, LI Y, LIU K, et al. A physics-informed neural network approach to fatigue life prediction using small quantity of samples [J]. *International Journal of Fatigue*, 2023, 166: 107270.

Development in metal multiaxial fatigue life prediction based on physics-informed neural network

ZHANG Zhuanni¹ SUN Xingyue² CHEN Xu²

(1. Industrial Protection Engineering Center, CNOOC Energy Development Equipment Technology Co., Ltd., Tianjin 300457, China)

(2. School of Chemical Engineering, Tianjin University, Tianjin 300350, China)

Abstract: The research on multiaxial fatigue life prediction of materials is one of the critical elements in ensuring the structural integrity of components. In recent years, machine learning, especially neural networks, has been widely applied in fatigue life prediction. However, the scarcity of fatigue data has limited the further application of neural networks in fatigue prediction. To address this issue, physics-informed neural networks that consider prior physical knowledge of fatigue have gradually gained attention. Firstly, provided an overview of the classification of machine learning algorithms and the application of neural-network models in multiaxial fatigue life prediction. Then, it focused on a deep exploration of the research on material fatigue life prediction based on physics-informed neural networks. Finally, the development of physics-informed neural networks was introduced from three aspects: physics-informed input features, the construction of physics-informed loss functions, and physics-informed network frameworks. Relevant studies show that physics-informed neural networks can exhibit better physical consistency and prediction performance in the process of multiaxial fatigue life prediction of materials.

Key words: Physics-informed neural network; Multiaxial fatigue; Life prediction; Machine learning

Corresponding author: SUN Xingyue, E-mail: xysun7230@tju.edu.cn

Fund: National Natural Science Foundation of China (12302098); Postdoctoral Fellowship Program of CPSF (GZB20230508)

Received: 2024-04-23 Revised: 2024-06-20