



基于物理信息神经网络的 结构寿命预测研究

许云飞¹, 彭 畅^{1,2}, 王光君¹

(1. 中车青岛四方机车车辆股份有限公司, 山东 青岛 266111;
2. 运营主动安全保障与风险防控铁路行业重点实验室, 北京 100044)

摘要: 高速列车作为现代交通的重要组成部分, 其结构材料的完整性与安全性对列车运行和乘客安全至关重要。随着列车长时间运行与外部环境的动态变化, 结构材料易出现多种损伤, 其中疲劳裂纹是常见的失效模式。因此, 研发一种高效、准确的结构健康监测技术, 对预防列车事故、延长设备使用寿命具有重要意义。文章聚焦于结构材料的损伤监测与寿命预测, 针对传统深度学习方法在寿命预测中普遍存在的可解释性不足问题, 提出一种基于物理信息神经网络 (PINN) 的结构寿命预测新方法。首先, 通过分析 Lamb 波信号, 结合归一化能量损伤因子, 构建疲劳裂纹扩展观测模型, 有效实现了裂纹损伤信息的定量化表征; 其次, 根据观测数据与 Paris 裂纹扩展公式, 建立物理经验退化模型, 并将其融入 PINN 框架, 最终形成具有高度可解释性的结构寿命预测模型。该模型不仅突破了传统神经网络“黑箱”模型的局限, 而且借助物理信息约束显著提升预测结果的准确性与可信度。试验结果表明, 文章提出的 PINN 模型在疲劳裂纹扩展监测及结构材料剩余寿命预测方面表现优异, 为结构健康监测领域提供了新的研究思路与方法。

关键词: 物理信息神经网络; Lamb 波; 结构健康监测; 剩余寿命预测; 高速列车; 人工智能; 神经网络

中图分类号: U292.91⁴; U270.4 **文献标志码:** A **文章编号:** 1000-128X(2025)05-0052-11

0 引言

随着现代交通运输业的快速发展, 高速列车、大型客机交通装备对安全性与可靠性的要求持续提升。这些装备的关键承载结构多采用高强度铝合金等先进材料, 其结构完整性直接关系到运行安全与乘客生命财产安全^[1]。然而, 在长期服役过程中, 结构材料不可避免地承受着循环载荷、环境腐蚀及振动冲击等多重作用, 易引发疲劳裂纹萌生和扩展, 严重时可能导致灾难性失效事故。因此, 研发高效、准确的结构健康监测 (structural health monitoring, SHM) 技术, 实现对材料损伤状态的实时监测和剩余寿命的精确预测, 对保障交通安全、降低维护成本具有重要的理论意义

与工程价值^[2-3]。

基于 Lamb 波的损伤检测技术具有检测效率高、可复用性强的优势, 适用于大型结构的表面与内部损伤快速排查^[4]。该技术无须移动换能器, 能耗低、损伤敏感性强, 可实现在线监测, 因此在结构健康监测领域备受关注。文献[5]基于二次谐波 Lamb 波的飞行时间, 研发出五阶段闭合微裂纹定位技术, 实现板状结构材料中闭合微裂纹的定位。文献[6]提出一种以具有共同趋势的时间序列为 Lamb 波分析数据的方法, 可在温度变化或传播模式互相干扰的条件下实现结构损伤监测。文献[7]将 Lamb 波损伤监测技术与概率加权成像算法结合, 改善了因传感器位置分布导致的损伤检测效率下降问题。文献[8]从板结构厚度出发, 将 Lamb 波与变分模态相结合, 实现转向架损伤的高精度定位与成像,

基金项目: 国家重点研发计划项目 (2022YFB4300601)

通信作者: 许云飞, 男, 硕士, 主要从事轨道车辆结构健康监测、故障诊断与预测及工程化应用方面的研究; E-mail: xuyunfei@cqsf.com

引用格式: 许云飞, 彭畅, 王光君. 基于物理信息神经网络的结构寿命预测研究[J]. 机车电传动, 2025(5): 52-62.DOI:10.13890/j.issn.1000-128X.2025.05.006.

Citation: XU Yunfei, PENG Chang, WANG Guangjun. Research on structural life prediction based on physics-informed neural network[J]. Electric drive for locomotives, 2025(5): 52-62.DOI:10.13890/j.issn.1000-128X.2025.05.006.

同时验证了该技术在转向架应用中的可行性。文献[9]提出基于 Lamb 波时间场法的损伤检测技术, 完成转向架与钢轨裂纹损伤的定位。文献[10]利用基于 Lamb 波的损伤检测技术实现了损伤的识别与定位。然而, 现有研究多聚焦于损伤识别阶段, 针对疲劳裂纹扩展及剩余寿命预测的研究仍较为缺乏, 该方向亟待进一步深入探索。

寿命预测是 SHM 的重要环节, 其目的是通过对实时监测数据进行外推或映射, 确定设备距离失效的剩余使用时间。目前常用的预测方法主要包括基于断裂力学、物理模型、统计模型及人工智能的剩余寿命预测方法^[11], 以及基于应力/应变、能量、临界面、损伤力学与累积损伤理论的预测方法^[12]。文献[13]提出一种基于伽马过程的动态剩余使用寿命 (remaining useful life, RUL) 预测和最优维修时间确定方法, 可降低随机波动对 RUL 预测的影响, 有助于制定基于状态的实时维护策略。文献[14]则构建了一种面向多传感器系统的 RUL 预测与不确定性管理框架, 并利用无迹卡尔曼滤波进行 RUL 预测。近年来, 机器学习 (machine learning, ML) 作为典型的人工智能问题处理方法, 在材料科学和工程领域的剩余寿命预测研究中受到高度重视, 并已取得诸多成果。文献[15]提出了一种融合遗传算法、支持向量回归 (support vector regression, SVR) 与威布尔比例风险模型 (Weibull proportional hazards model, WPHM) 的集成 RUL 预测方法。文献[16]提出一种新型权重跟踪相关向量机 (weight tracking relevance vector machine, WTRVM) 模型, 并结合自适应顺序最优特征选择方法筛选最优特征, 避免模型过拟合。随着不断优化与发展, 相关研究不仅在寿命预测方法上取得了显著进展, 而且加深了对 ML 方法的理解, 同时该方法体系的构成日趋丰富。然而, 传统 ML 通常需要使用户从复杂数据集中提取信息特征, 这依赖于丰富的领域知识与专业经验, 在一定程度上限制了其在某些复杂场景中的应用。相比之下, 深度学习可自主从已有数据中学习并提取相关特征, 无须过多人工干预^[17], 因此逐渐成为剩余寿命预测与分析的主流选择。

综上所述, 近年来可解释性研究多集中于故障诊断领域, 在剩余寿命预测方面虽有探索, 但大多从样本特征等角度切入, 少有研究深入融合物理机理以增强网络预测模型的可解释性。融合机理知识的网络模型虽能实现其内部可解释性, 但在结构材料寿命预测领域缺乏相关研究。基于上述分析, 本文针对传统深度学习方法在结构寿命预测中可解释性不足的问题, 提出一种基于物理信息神经网络 (physics-informed neural networks, PINN) 的结构寿命预测新方法。本文的主要工作和创新点如下:

①构建基于 Lamb 波归一化能量损伤因子的疲劳裂

纹观测模型。通过对比分析 3 种损伤因子的特性, 选择单调性好、重复性强的归一化能量损伤因子作为疲劳裂纹损伤信息的定量化表征, 建立 Lamb 波信号与裂纹扩展之间的稳定映射关系。

②建立融合 Paris 公式的 PINN 模型。将经典的 Paris 疲劳裂纹扩展公式作为物理约束嵌入神经网络, 构建具有强物理可解释性的 PINN 模型, 有效解决传统“黑箱”神经网络模型在寿命预测中缺乏可解释性的问题。

③实现结构材料剩余寿命的高精度预测。通过结合观测数据驱动与物理机理, 提升预测模型的准确性与可信度, 为 SHM 提供新的技术手段。

本文在理论层面提出了融合物理信息与深度学习的新思路, 为可解释性人工智能在工程领域的应用提供有效范例; 在实践层面, 为高速列车等交通装备的 SHM 和预防性维护提供技术支撑, 对提升交通安全性具有重要价值。研究成果为铝合金材料的健康监测提供了可推广的方法框架。

1 物理信息嵌入的神经网络寿命预测方法

1.1 基于 Lamb 波的裂纹诊断模型构建

在高速列车等交通装备的实际服役过程中, 难以通过频繁停机开展健康监测与设备检查, 而 Lamb 波监测系统可在装备正常运行状态下进行连续健康监测, 满足实时预警需求。此外, 传统目视检测难以覆盖结构内部及目视不可及区域的隐蔽裂纹损伤, 且裂纹长度往往无法直接测量, 通过 Lamb 波提取相关损伤特征以反映损伤水平, 可提升监测的灵敏度与准确率, 为预防性维护预留更长的预警时间。

利用 Lamb 波进行结构材料损伤监测时, 材料对波的吸收会导致传播过程中能量损失。当 Lamb 波传播至疲劳裂纹区域时, 除了能量吸收, 还会出现信号反射、散射及模式转换等现象, 引起 Lamb 波信号的明显变化, 而这些变化反映了疲劳裂纹的损伤信息。基于该原理, 可从接收的 Lamb 波信号中提取相关信息, 进而对疲劳裂纹扩展进行定量分析。

损伤因子是建立裂纹尺寸与 Lamb 波响应信号特征之间定量关联的核心媒介, 可定量化分析 Lamb 波对裂纹损伤的响应与监测规律。受疲劳裂纹损伤影响, Lamb 波响应信号在时域上主要表现为幅值与相位的变化, 因此本文从相位和幅值两个维度选取 3 种损伤因子, 研究 Lamb 波对裂纹损伤信息的定量化表征。

能量差损伤因子表达式为

$$D_1 = \frac{\int_{t_1}^{t_2} |u_i(t)| dt - \int_{t_1}^{t_2} |u_0(t)| dt}{\int_{t_1}^{t_2} |u_0(t)| dt} \quad (1)$$

式中： t_1 和 t_2 分别为直达波包络的起止时刻； u_0 和 u_i 分别为健康状态与损伤状态下在结构材料中采集到的Lamb波信号。

该损伤因子反映了响应信号能量随裂纹尺寸的变化规律，通过对比健康状态与损伤状态下结构材料中Lamb波的能量差异，可实现损伤程度的量化评估。该参数对结构损伤具有较高的敏感性，基于Lamb波进行损伤检测是实现量化损伤信息的有效方法之一。

归一化能量损伤因子表达式为

$$D_2 = \sqrt{\frac{\int_{t_1}^{t_2} |u_i(t)| dt - \int_{t_1}^{t_2} |u_0(t)|^2 dt}{\int_{t_1}^{t_2} |u_0(t)|^2 dt}} \quad (2)$$

该损伤因子反映了损伤散射信号能量随裂纹尺寸变化的规律。其中，损伤散射信号通过对比结构损伤前后的Lamb波信号差异获得。

互换性损伤因子表达式为

$$D_3 = \sqrt{\frac{\left\{ \int_{t_1}^{t_2} |u_i(t)| dt \right\}^2}{\int_{t_1}^{t_2} u_0^2(t) dt \int_{t_1}^{t_2} u_i^2(t) dt}} \quad (3)$$

该损伤因子实现了对直达波波达时刻延迟与信号幅值变化的量化表征。根据上述分析，下文将构建基于损伤因子的疲劳裂纹损伤量化诊断模型。

1.2 基于物理知识的经验退化模型

在断裂力学中，Paris公式是定量分析结构材料疲劳裂纹扩展行为的经典模型，由Paris等人于1963年提出。该公式建立了疲劳裂纹扩展速率与裂纹尖端应力强度因子范围之间的定量关系，适用于表征结构材料在循环载荷作用下的裂纹扩展规律，其基本形式可表示为

$$\frac{da}{dN} = C(\Delta K)^m \quad (4)$$

式中： a 为疲劳裂纹扩展长度； N 为循环应力加载循环次数； $\frac{da}{dN}$ 为疲劳裂纹随循环次数变化的扩展速率； C 为与试验材料、裂纹几何形状及试验环境因素相关的参数，常称为Paris常数，一般通过试验测定； ΔK 为应力强度因子范围，即一次循环中最大与最小应力因子之差，反映了裂纹尖端应力场的强弱； m 为材料相关参数，同样通过试验确定，其反映了疲劳裂纹扩展速率与应力强度因子范围之间的关系。

疲劳裂纹的扩展过程通常分为3个阶段：第1阶段为裂纹萌生或短裂纹阶段，第2阶段为稳定扩展或长裂纹阶段，第3阶段为失稳快速扩展直至断裂阶段。其中，第2阶段是疲劳裂纹扩展分析与寿命预测的主要研究对象，在该阶段中裂纹扩展速率与应力强度因子范围呈现函数关系，这正是Paris公式所描述的力学行为。

在断裂力学理论中，基于Paris公式的剩余寿命预

测方法在工程实践中得到广泛应用。然而，该公式也存在明显局限性：其一，适用范围较窄，仅适用于线弹性材料疲劳裂纹扩展的第2阶段；其二，Paris公式通常基于恒定应力比建立，而实际工程中疲劳载荷的应力比参数 R 往往存在波动，影响其预测准确性；其三，部分材料在疲劳裂纹扩展过程中扩展速率会发生变化，导致材料参数 m 波动，进而降低公式的适用性和预测精度。为克服这些不足，研究者提出了多种修正模型，以适应不同情况下疲劳裂纹的扩展规律，其中Walker模型与Forman模型是应用较为广泛的代表性模型。

Walker模型是对Paris公式的改进，通过引入应力比参数 R ($R = \sigma_{\min}/\sigma_{\max}$)，能够更准确地描述变幅载荷作用下的疲劳裂纹扩展行为，其表达式为

$$\frac{da}{dN} = C_w \left[\frac{\Delta K}{(1-R)^{1-\gamma}} \right]^{m_w} \quad (5)$$

式中： m_w 为裂纹扩展速率指数，它决定了双对数坐标图中的斜率，其意义与Paris公式中的 m 类似； C_w 为裂纹扩展系数，反映了裂纹扩展曲线位置在双对数坐标系中的截距参数； γ 为Walker模型的核心材料常数，用于表征应力比 R 对裂纹扩展速率的影响程度。

Forman模型则考虑了接近断裂韧性时裂纹的快速拓展特性，其表达式为

$$\frac{da}{dN} = \frac{C_f(\Delta K)^{m_f}}{(1-R)K_c - \Delta K} \quad (6)$$

式中： m_f 为裂纹扩展速率指数，其作用与Paris公式中的 m 类似，影响双对数坐标下疲劳裂纹扩展曲线的斜率； C_f 为裂纹扩展系数，是与材料相关的常数； K_c 为材料的断裂韧性系数，表示材料抵抗裂纹失稳扩展（即快速断裂）的能力。

当带裂纹构件的应力强度因子 K 达到 K_c 时，裂纹将发生失稳扩展并导致构件瞬时断裂。

考虑到模型与PINN融合的复杂度，同时为在有限试验数据条件下确保参数的可获取性，本文以传统Paris公式为基础，建立其与神经网络的融合框架，并开展相应的PINN模型训练与收敛优化。

基于Paris公式构建经验退化模型，应力强度因子范围与裂纹长度的关系为

$$\Delta K = \mathfrak{A} \sqrt{a} \quad (7)$$

式中： $\mathfrak{A}$ 为与构件材料有关的参数，其值可通过试验测定。

合并式(4)和式(7)可得

$$\frac{da}{dN} = C \mathfrak{A}^m a^{m/2} \quad (8)$$

简化模型，令 $C \mathfrak{A}^m = \alpha$ ， $\frac{m}{2} = \beta$ ，可得

$$\frac{da}{dN} = \alpha a^\beta \quad (9)$$

若以式(9)作为经验退化公式, 则需明确 $\frac{da}{dN}$ 与 a 的函数关系, 涉及求导运算, 因此需转化公式并进行变量分离, 可得

$$a^{-\beta} da = \alpha dN \quad (10)$$

按照积分法则对等式两边同时积分可得

$$\frac{1}{-\beta+1} a^{-\beta+1} = \alpha N + c \quad (11)$$

式中: c 为常数项。

通过指数变换得到裂纹长度与循环次数的关系式为

$$a = \left[(-\beta+1)(\alpha N + c) \right]^{\frac{1}{-\beta+1}} \quad (12)$$

为便于后续计算和拟合, 对式(12)进行简化, 仅保留 N 的最高阶幂和常数项, 表达式为

$$a = \alpha_1 N^{\beta_1} + c_1 \quad (13)$$

由式(13)可知, 疲劳裂纹长度 a 与循环次数 N 呈幂函数关系。在获得简化后的物理表达式后, 从实际观测数据中抽取部分样本对式(13)进行拟合, 利用非线性最小二乘法求解经验退化模型中的参数。得到式(13)后, 进一步通过求导运算即可得到与本次试验数据对应的 Paris 公式。将该 Paris 公式作为经验物理规律嵌入 PINN 模型的训练过程中, 能近似反映结构材料疲劳裂纹扩展的退化过程, 从而增强 PINN 模型可解释性与物理一致性。

1.3 基于 PINN 的结构材料寿命预测

本文采用的 PINN 模型由全连接网络模块和物理信息层构成, 其中全连接模块包含 3 个线性连接层, 实现网络输出预测。在网络训练过程中, 总损失 L_{total} 函数由实际样本损失 L_{real} 和经验物理样本损失 L_{phy} 两部分组成, 表达式为

$$L_{\text{total}} = \delta L_{\text{real}} + (1 - \delta) L_{\text{phy}} \quad (14)$$

式中: δ 为平衡参数, 可通过 δ 调节两部分损失权重。

经验物理样本损失 L_{phy} 又包含预测损失和退化特征损失。需要注意的是, 在疲劳裂纹扩展过程中, 若无外部干预, 试件的损伤状态仅随疲劳裂纹增长持续累

积, 直至最终断裂, 因此从裂纹出现到断裂, 其退化率始终为正值。基于此物理约束, 经验物理样本损失函数为

$$L_{\text{phy}} = \mu L_{\text{phy, model}} + (1 - \mu) L_{\text{phy, character}} \quad (15)$$

$$L_{\text{phy, model}} = \left(\Delta x_{\text{phy}} - \hat{\Delta x} \right)^2 \quad (16)$$

$$L_{\text{phy, character}} = \text{ReLU} \left(-\hat{\Delta x} \right) \quad (17)$$

式中: $L_{\text{phy, model}}$ 为预测损失; $L_{\text{phy, character}}$ 为退化特征损失, 用于在网络输出退化率为负数时, 对网络参数进行惩罚; μ 为权重系数, 用于调节两部分损失的权重; Δx_{phy} 为模型样本标签; $\hat{\Delta x}$ 为全连接网络预测值。

在 PINN 网络模型训练时, 首先将训练集的裂纹长度特征 x 输入网络, 计算得到 x 对应的输出 $\hat{\Delta x}$; 随后, 利用该输出计算物理知识模型损失, 将其代入式(16)和式(17), 求解物理模型的预测损失与退化特征损失; 其次, 将式(15)计算得到的物理知识模型损失与实际样本的预测损失相加, 得到网络训练的总损失; 最后, 利用反向传播算法完成模型参数学习。通过上述流程, 物理规律以软约束融入神经网络, 增强了模型的内部可解释性。后续若需进一步优化网络时, 可通过调整嵌入的内部物理信息方程实现。

通过极小化网络损失完成模型训练后, 本节开展网络测试以完成试件剩余寿命预测。首先, 将当前循环次数对应的特征裂纹长度输入已训练的网络, 得到当前退化率预测值; 然后, 将该预测值与当前裂纹特征相加, 计算得到下一次循环的对应特征, 如式(18)。

$$a_{i+1} = a_i + \hat{\Delta x} \quad (18)$$

式中: a_i 表示第 i 次循环下的损伤退化率。

通过不断迭代, 可模拟预测试件断裂前的特征变化趋势。当网络预测值达到材料或构件的断裂阈值时, 停止迭代, 当前循环次数与初始测试循环次数的差值即为剩余寿命, 至此完成预测。

综上所述, 本文提出的基于 PINN 的结构寿命预测方法的总体技术路线如图 1 所示。具体流程如下: 通过疲劳拉伸试验采集 Lamb 波信号, 并基于断裂力学理




图1 总体技术路线

Fig. 1 Technology roadmap

论，以 Paris 公式为起点进行应力强度因子建模和经验退化模型推导，建立对应物理约束方程；其次，在损伤因子分析阶段，分别计算能量差、归一化能量和互相关性 3 种损伤因子，通过对比分析选择表征效果最优的归一化能量损伤因子，并利用多项式拟合优化建立观测模型；随后，设计融合观测数据和物理约束的神经网络架构，构建多目标损失函数，通过权重参数调节完成模型训练与验证；最后，基于训练好的 PINN 模型进行退化率预测，采用迭代预测策略实现裂纹扩展预测和剩余寿命计算。

2 数据分析

2.1 疲劳拉伸试验平台及参数设置

Al 6061 型铝合金已广泛应用于高铁车辆配件制造领域，因此本文选取该材料制备疲劳拉伸试验件。如图 2 所示，共制备 6 块试验铝板，编号为 T1 ~ T6，尺寸均为 240 mm×45 mm×4 mm。为控制裂纹的起裂位置

与扩展方向，在每块铝板中心一侧采用线切割方法预制长度约 2 mm 的初始裂纹。不考虑温度影响，试验在室温 25 °C 环境下进行，每块铝板表面设置两个 PZT 传感器，沿铝板中心线对称等距分布。同侧传感器间距为 60 mm，其连线与预制裂纹平齐，且传感器至铝板中心线的距离相等。试件尺寸与传感器布置示意如图 3 所示。Al 6061 铝板力学性能参数如表 1 所示，PZT 传感器型号及参数如表 2 所示。




图2 铝板实物图与预制裂纹

Fig. 2 Picture of aluminum plate with precracks




图3 试件尺寸与传感器布置示意

Fig. 3 Specimen size and sensor layout

表1 铝板力学性能参数

Table 1 Mechanical property parameters of aluminum plate

参数项目	材料	密度/(kg·m ⁻³)	弹性模量/GPa	泊松比
参数值或说明	Al 6061	2 750	68.9	0.33

表2 PZT 传感器型号及参数

Table 2 Model and parameters of Piezoelectric sensor

参数项目	PZT 传感器 型号	直径/mm	厚度/mm	密度/(g·cm ⁻³)
参数值或说明	SM412	8	0.2	7.80

本文开展 Al 6061 试件的单边疲劳裂纹扩展试验，并结合 Lamb 波进行在线监测，试验平台如图 4 所示。试验系统由疲劳试验机 (MTS Landmark)、SHM 扫查系统和显微镜组成，采用 Lamb 波透射信号监测裂纹扩展，其中 PZT1 为信号激励端，PZT2 为信号接收端。

已有研究表明，相较于其他特征参数，分析 Lamb 波中对称模式波 (S0) 和反对称模式波 (A0) 在裂纹处的特性变化，可显著提升损伤检测准确度；同时，考虑到 Lamb 波的色散特性，为避免模式叠加，需根据




图4 试验装置

Fig. 4 Experimental setup

板厚与激励频率的乘积对信号参数进行合理约束。因此，本试验选取激励和接受信号中的 S0、A0 模式波作为分析对象，先提取信号中的损伤敏感特征，再对比健康和损伤状态下特征的变化规律，从而识别结构损伤程度与位置。

试验采用正弦拉伸疲劳载荷，试验载荷的加载频率为 10 Hz，最大加载载荷为 32 kN，疲劳应力范围为 8

~80 MPa。受试件尺寸限制, 为减少不同模式Lamb波之间的相互干扰, 激励信号频率需靠近中心频率, 因此将Lamb波的信号频率设定为140 kHz。SHM扫查系统的监测信号长度记录为3 000点, 采样频率设为10 MHz。

拉伸疲劳试验开始后, 按预设疲劳加载次数间隔暂停拉伸过程, 通过显微镜及液压疲劳试验机连接的计算机测量并记录当前裂纹长度; 重复上述操作, 直至达到预设的最大加载次数或试件断裂, 并记录对应

加载次数。对6块试件均执行相同的试验流程, 全程记录试件断裂前的加载次数、对应裂纹长度及Lamb波信号。

2.2 基于Lamb波的裂纹诊断模型

试验共获取6块试件在不同裂纹长度下对应的Lamb波信号, 图5为试件T1在不同裂纹长度下的Lamb波信号。




图5 Lamb波信号

Fig. 5 Lamb wave signal

根据损伤因子计算公式, 分别求解6块试件对应的3种损伤因子, 对Lamb波信号的分析结果如图6所示。




图6 各试件3种损伤因子随疲劳裂纹扩展的变化

Fig. 6 Variations of three damage factors with fatigue crack propagation for each specimen

3种损伤因子在表征损伤信息方面各具特点与局限。通常而言, 能量差损伤因子反映健康与损伤状态下Lamb波的能量差异, 具有较高的损伤敏感性, 但易受环境噪声和传播路径变化的影响, 在部分试件中呈现非单调性; 互相关性损伤因子能综合反映波达时间与幅值变化, 物理意义清晰, 但对信号质量要求较高, 且在裂纹扩展初期敏感性不足; 归一化能量损伤因子通过归一化处理降低了系统误差影响, 在所有试件中均表现出良好的单调递增特性与重复性。

通过对3种损伤因子的分析发现, 归一化能量损伤因子在单调性、递增稳定性以及重复性方面均优于其

他两种因子。因此, 本文选用该因子对Lamb波信号进行疲劳裂纹损伤的定量表征。为验证该方法的可行性, 采用多项式对归一化能量损伤因子与裂纹长度之间的关系进行拟合。

通过对3种损伤因子的分析发现, 信号归一化能量损伤因子的单调性、递增稳定性和重复性均优于其他两种因子, 因此, 本文选用该因子对Lamb波信号进行疲劳裂纹损伤的定量化表征。为验证该方法的可行性, 采用多项式对其进行拟合, 计算公式为

$$f(x) = w \cdot x^3 + p \cdot x^2 + q \cdot x + m \quad (19)$$

式中: w 、 p 、 q 、 m 均为自变量系数; x 为函数的输入变量。

将试件T6作为测试件, 利用试件T1~T5的损伤因子进行多项式拟合, 拟合结果如图7所示, 多项式参数如表3所示。




图7 试件T1~T5损伤因子及其拟合曲线

Fig. 7 Damage factors of T1-T5 and their fitted curves

表3 多项式参数

Table 3 Polynomial parameters

参数名称	w	p	q	m
参数值	$-6.844\ 919\times 10^{-5}$	$2.791\ 579\times 10^{-3}$	$9.906\ 345\times 10^{-3}$	$5.187\ 824\times 10^{-3}$

基于试件 T1 ~ T5 的损伤因子拟合曲线，绘制 T6 的损伤因子分布图，如图 8 所示。从图 8 可以看出，T6 的损伤因子分布在拟合曲线附近，其随裂纹长度增加的变化趋势与拟合曲线基本一致。




图 8 T6 的观测值与拟合曲线对比

Fig. 8 Comparison of observations with fitted curve for T6

上述结果表明，通过 Lamb 信号提取试件的归一化能量损伤因子，可量化表征结构材料疲劳裂纹的扩展过程，由此建立观测方程具备良好的可行性。

2.3 疲劳寿命预测结果分析

利用试件 T1 ~ T5 疲劳裂纹扩展阶段的裂纹长度 a 和循环次数 N 的观测数据，绘制 a - N 关系曲线，如图 9 所示，图 9 曲线直观反映了疲劳裂纹扩展趋势。进一步利用该组观测数据进行经验物理模型拟合，得到符合 a - N 关系的方程式为

$$a=8.02322\times 10^{-10}N+0.5033 \tag{20}$$

在此基础上，利用求导法则可得到最终的经验退化方程为

$$\frac{da}{dN}=5.666\times 10^{-10}(a-0.5033)^{0.54} \tag{21}$$




图 9 试件 a - N 曲线

Fig. 9 Specimen a - N curve

式(20)可准确描述疲劳裂纹随着应力循环次数增加的扩展过程，对其通过求导公式运算得到式(21)，其物理含义为疲劳裂纹长度随应力循环次数增加的扩展速率，即结构材料的退化率。理论上，式(21)在一定程度上可反映退化阶段疲劳裂纹长度的扩展趋势，从而较好地表征疲劳裂纹的扩展过程；该式定量描述了训练试件的退化过程，为具有相似退化规律的试件提供了基于准确物理知识的解释。尽管受噪声信号和环境因素影响，部分试件的退化过程存在差异，但多数具有相似规律的试件仍符合该物理方程，因此可将式 (21) 作为先验物理知识融入神经网络，用于后续疲劳寿命预测。

在模型训练阶段，将训练数据集中的裂纹长度信息作为网络输入 x ，将通过分段线性拟合得到的近似退化率作为网络输出的真实训练样本 (x, x_{real}) ；同时，将裂纹长度输入经验退化方程，得到物理模型的退化率，作为网络输出的物理模型训练样本 $(x, \Delta x_{\text{phy}})$ 。为获得较为平滑的退化率曲线及准确率较高的预测值，在构建损失函数时需合理平衡真实样本损失与物理模型样本损失的权重，以实现训练误差的最小化。

在网络模型训练过程中，将真实数据样本与通过式(21)计算得到的物理知识样本同时输入网络，利用网络输出分别计算真实样本损失和物理模型损失，进而得到网络总损失；通过参数调优训练，最终获得理想的 PINN 网络模型，训练过程的最终超参数如表 4 所示。

表 4 模型训练参数

Table 4 Model training parameters

参数项目	参数初始化	优化器	学习率	训练次数	损失权重 α
参数值或说明	标准正态分布	Adam	0.001	20 000	0.5

确定最佳权重分配后，通过 PINN 网络模型得到训练试件退化过程的退化率预测数据，同时记录了基于分段线性拟合的真实退化率及物理模型对训练试件退化率的预测结果，退化率预测训练结果如图 10 所示。从图 10 可以看出，退化率曲线平滑性得到显著改善：退化前期，网络模型预测的退化率变化趋势与物理模型相近；而在退化后期，网络模型预测的退化率开始上升，与观测数据所反映的趋势相一致，这表明该网络既遵循了物理规律所描述的整体演变趋势，又有效融合了真实数据样本包含的退化率变化信息。

本文以试件 T6 的观测数据作为测试样本进行网络模型测试，首先利用式(20)对疲劳裂纹的扩展过程进行预测，结果如图 11 所示。观察发现，预测裂纹随应力循环次数的增加持续扩展，其过程呈现明显的 3 阶段特征：在 0 ~ 10 000 次循环内扩展速度缓慢；10 000

~40 000次循环内扩展速度趋于恒定; 40 000次循环后进入快速扩展阶段。结合图9对比可知, 式(20)既符合疲劳裂纹扩展的3个阶段特征, 又能较为准确地预测裂纹的实际扩展过程。




图10 退化率预测训练结果

Fig. 10 Degradation rate predictions in training




图11 测试件 a - N 曲线预测

Fig. 11 Prediction of the a - N curve of the test piece

由式(21)可知, 当疲劳裂纹长度超过0.503 3 mm时可进行退化率预测, 因此从裂纹长度达到该阈值时开始预测, 直至试件断裂, 对退化率进行预测。利用试件T6的观测数据对预测效果进行验证: 将裂纹长度数据输入PINN网络模型, 得到相应的退化率预测数据; 同时, 通过分段线性拟合观测数据得到近似退化率; 并利用式(21)计算物理模型的退化率预测值。采用3种方法所得退化率的对比结果如图12所示。

由图12可知, 裂纹扩展至6 mm前, PINN网络模型预测的退化率变化趋势与物理模型基本一致, 且与实际观测数据差异较小; 当裂纹长度超过6 mm后, PINN网络模型的预测结果逐渐偏离物理模型, 转而趋近实际观测数据, 并呈现急剧上升趋势, 符合裂纹扩展规律。结果表明, PINN网络模型可精准预测疲劳裂纹扩展退化率, 有效表征裂纹扩展过程。

此外, 以退化率预测的首个裂纹长度为基准, 累加后续所有循环次数的单步预测退化率, 得到基于PINN网络模型的疲劳裂纹长度预测结果, 如图13所示。

由图13可知, PINN网络模型预测的疲劳裂纹长度能较好地展现真实数据变化, 直至接近疲劳裂纹扩展阈值。此后, 实际裂纹长度出现突变, 而PINN网络模型未能捕捉到这一急剧变化, 该现象与图12中退化率预测的表现一致。




图12 退化率预测结果

Fig. 12 Degradation rate prediction results




图13 T6裂纹长度扩展预测结果


Fig. 13 Predictions of T6 crack length propagation

在测试过程中, 仅能获取当前循环次数对应的裂纹长度。因此, 本文采用迭代预测策略, 逐步推算后续循环中的疲劳裂纹长度。具体过程如下: 先利用当前疲劳裂纹长度预测其退化率, 再计算下一循环对应的裂纹长度; 将该长度数据作为新的输入, 重复上述步骤, 通过循环迭代最终得到疲劳裂纹的变化趋势。


图14~图17分别展示了起始预测点为10 009次、22 510次、30 020次及38 102次应力循环时, PINN网络模型与物理模型的裂纹长度预测结果。

基于上述对比结果, 进一步计算得到两种模型的结构材料剩余寿命预测值及相应的裂纹误差, 如表5所示。

结合上述图表分析可知, 若以单一起始预测点为准, 无论是PINN网络模型还是物理模型, 在起始点为10 009次和30 020次循环时, 其对裂纹扩展的预测误差相对较小, 这一趋势在相应预测曲线中可直观观察到。在剩余寿命预测方面, 以22 510次循环作为起始预测点时效果最优, 其前期预测结果与真实数据贴合度高, 当试件接近寿命终点时, 两种模型的预测趋势




(a) PINN 迭代预测




(b) 物理模型预测

图 14 起始点为 10 009 次循环 PINN 迭代预测和物理模型预测

Fig. 14 PINN iterative predictions and physical model predictions starting at 10,009 cycles




(a) PINN 迭代预测




(b) 物理模型预测

图 16 起始点为 30 020 次循环 PINN 迭代预测和物理模型预测

Fig. 16 PINN iterative predictions and physical model predictions starting at 30,020 cycles



(a) PINN 迭代预测




(b) 物理模型预测

图 15 起始点为 22 510 次循环 PINN 迭代预测和物理模型预测


Fig. 15 PINN iterative predictions and physical model predictions starting at 22,510 cycles

虽与真实数据变化趋势一致，但数值均出现偏离，导致剩余寿命预测产生一定误差。

通过对比相同起始预测点的结果可知，PINN 网络



(a) PINN 迭代预测



(b) 物理模型预测

图 17 起始点为 38 102 次循环 PINN 迭代预测和物理模型预测

Fig. 17 PINN iterative predictions and physical model predictions starting at 38,102 cycles

模型的预测曲线更接近真实裂纹扩展过程。结合表 5 数据进一步分析表明，无论是在疲劳裂纹扩展预测上还是在剩余寿命预测上，PINN 网络模型的误差均小于物理模型，更贴近实际情况。造成这一差异的主要原因

表5 PINN与物理模型预测对比
Table 5 Comparison between PINN and physical model predictions

类别	起始点	裂纹误差/ mm	预测 RUL/次	真实 RUL/次	RUL 误差/次
PINN	10 009	0.564 2	38 797	36 368	2 429
	22 510	0.790 3	25 694	23 867	1 827
	30 020	0.557 9	19 918	16 357	3 561
	38 102	0.964 7	12 320	8 275	4 045
物理模型	10 009	0.802 6	40 625	36 368	4 257
	22 510	1.235 1	26 621	23 867	2 754
	30 020	0.820 6	22 043	16 357	5 686
	38 102	1.378 0	16 561	8 275	8 286

在于: 物理模型的参数固定, 且仅基于一组训练数据推导, 其预测行为相对单一; 而PINN网络模型在训练中既融入了物理模型作为约束, 又能从多组观测数据中自动提取相关特征, 两者结合使其具有更好的预测效果。

综上所述, PINN网络模型与物理模型均能对疲劳裂纹扩展过程及结构材料剩余寿命进行有效预测。相比之下, PINN网络模型在整体上表现出更优的预测性能与更高的预测精度。

3 结束语

针对结构材料疲劳裂纹损伤监测问题, 本文提出一种基于Lamb波归一化能量损伤因子的疲劳裂纹扩展观测模型。首先, 利用含疲劳裂纹损伤信息的Lamb波信号及损伤因子计算公式, 得到3种随疲劳裂纹长度变化的损伤因子曲线图; 其次, 通过对比分析各损伤因子的特性, 确定单调性好、重复性强的归一化能量损伤因子作为疲劳裂纹的表征信息; 最后, 利用观测数据对归一化能量损伤因子曲线进行拟合并测试其合理性, 验证其作为疲劳裂纹表征信息的有效性, 最终建立观测模型。

针对传统神经网络在疲劳寿命预测研究中可解释性不足的问题, 本文提出一种基于PINN的结构寿命预测方法。首先通过观测数据求解Paris公式的相关参数, 建立经验退化模型; 其次, 将该模型融入神经网络, 构建PINN网络模型; 最后, 通过预测疲劳裂纹扩展退化率与剩余寿命, 系统对比了观测数据、物理模型以及PINN网络模型的预测误差。结果表明, PINN网络模型不仅能够更准确地预测疲劳裂纹剩余寿命, 而且能为预测过程提供可解释性。

本文将基于Lamb波的SHM技术与PINN相结合, 构建了一种数据驱动与物理约束有机融合的寿命预测新方法。与传统的纯数据驱动或物理建模方法不同, 该方法通过将Paris公式等物理知识嵌入神经网络的损失函数, 既保留了深度学习强大的非线性拟合能力,

又赋予模型明确的物理可解释性, 从而有效缓解了传统神经网络“黑箱”模型在工程应用中可信用不足的问题。此外, 通过多损伤因子的对比分析确定了最优观测模型, 建立了Lamb波信号与疲劳裂纹扩展之间可靠的定量映射关系, 为结构材料的在线健康监测和智能化寿命管理提供了新的技术支撑。

参考文献:

[1] 卿新林, 刘琦华, 张雨强, 等. 飞行器复合材料全寿命结构健康监测技术[J]. 厦门大学学报(自然科学版), 2021, 60(3): 614-629.
QING Xinlin, LIU Qijian, ZHANG Yuqiang, et al. Life-cycle health monitoring technology for aircraft composite structures[J]. Journal of Xiamen university(natural science), 2021, 60(3): 614-629.

[2] 张天成. 高速列车制动盘热疲劳裂纹萌生理及磨损性能研究[D]. 长春: 长春工业大学, 2023.
ZHANG Tiancheng. Study on thermal fatigue crack initiation mechanism and wear performance of high-speed train brake disc[D]. Changchun: Changchun University of Technology, 2023.

[3] 王万祯. Q460C钢缺口板的疲劳裂纹萌生寿命计算模型和总疲劳寿命计算[J]. 材料导报, 2024, 38(4): 192-199.
WANG Wanzhen. Calculation model of fatigue crack initiation life and total fatigue life calculation of Q460C steel notched plates[J]. Materials reports, 2024, 38(4): 192-199.

[4] 顾震华. 基于Lamb波的结构疲劳裂纹监测及寿命预测方法研究[D]. 无锡: 江南大学, 2021.
GU Zhenhua. Research on structural fatigue crack monitoring and life prediction based on Lamb waves[D]. Wuxi: Jiangnan University, 2021.

[5] ZHENG Kaihong, SHAO Shixuan, HAMEED M S, et al. Damage detection method based on continuous wavelet transform of second harmonic Lamb waves[J]. Nondestructive testing and evaluation, 2023, 38(6): 1006-1026.

[6] DAO P B. Lamb wave-based structural damage detection: a time series approach using cointegration[J]. Materials, 2023, 16(21): 6894.

[7] 王高平, 陈云, 李波, 等. Lamb波概率加权成像的复合板损伤检测方法[J]. 噪声与振动控制, 2023, 43(4): 149-156.
WANG Gaoping, CHEN Yun, LI Bo, et al. Composite plate damage detection method based on Lamb waves probability weighted imaging[J]. Noise and vibration control, 2023, 43(4): 149-156.

[8] 冯锴. 基于SSA-VMD的Lamb波轨道车辆转向架损伤检测技术研究[D]. 北京: 北京交通大学, 2023.
FENG Kai. Research on rail vehicle bogie damage detection technologies based on SSA-VMD of Lamb waves[D]. Beijing: Beijing Jiaotong University, 2023.

[9] 王琳. 基于Lamb波时间场法的裂纹检测技术及其在轨道交通中的应用[D]. 北京: 北京交通大学, 2021.

- WANG Lin. Crack testing technology based on Lamb wave & time field method and its application in rail transit[D]. Beijing: Beijing Jiaotong University, 2021.
- [10] 王 鸽. 基于 Lamb 波的地铁车辆车轮损伤识别技术研究[D]. 北京: 北京交通大学, 2020.
- WANG Ge. Damage identification of metro vehicle wheels based on Lamb wave[D]. Beijing: Beijing Jiaotong University, 2020.
- [11] 杨筱戡. 具有可解释性的滚动轴承预警和预测方法研究[D]. 武汉: 华中科技大学, 2022.
- YANG Xiaoyu. Research on early warning and prediction method of rolling bearing with interpretability[D]. Wuhan: Huazhong University of Science and Technology, 2022.
- [12] 柏松. 航空发动机涡轮轴高低周复合疲劳寿命预测方法[D]. 成都: 电子科技大学, 2023.
- BAI Song. Life prediction method for the combined high and low cycle fatigue of an aero-engine turbine shaft[D]. Chengdu: University of Electronic Science and Technology of China, 2023.
- [13] WANG Han, LIAO Haitao, MA Xiaobing, et al. Remaining useful life prediction and optimal maintenance time determination for a single unit using isotonic regression and gamma process model[J]. Reliability engineering & system safety, 2021, 210: 107504.
- [14] ZHANG Heng, LIU Enhui, ZHANG Bin, et al. RUL prediction and uncertainty management for multisensor system using an integrated data-level fusion and UPF approach[J]. IEEE transactions on industrial informatics, 2021, 17(7): 4692-4701.
- [15] QIU Guangqi, GU Yingkui, CHEN Junjie. Selective health indicator for bearings ensemble remaining useful life prediction with genetic algorithm and Weibull proportional hazards model[J]. Measurement, 2020, 150: 107097.
- [16] TANG Jian, ZHENG Guanhui, HE Dong, et al. Rolling bearing remaining useful life prediction via weight tracking relevance vector machine[J]. Measurement science and technology, 2020, 32(2): 024006.
- [17] WANG Bofu, WANG Qiang, ZHOU Quan, et al. Active control of flow past an elliptic cylinder using an artificial neural network trained by deep reinforcement learning[J]. Applied mathematics and mechanics, 2022, 43(12): 1921-1934.

Research on structural life prediction based on physics-informed neural network

XU Yunfei¹, PENG Chang^{1,2}, WANG Guangjun¹

(1. CRRC Qingdao Sifang Co., Ltd., Qingdao, Shandong 266111, China; 2. Key Laboratory of Railway Industry for Operational Active Safety Assurance and Risk Prevention and Control, Beijing 100044, China)

Abstract: High-speed trains are an important mode of modern transportation, and the integrity and safety of their structural material are critical to train operation and passenger safety. Subjected to long-term train operation and dynamic changes in external environments, these structural materials are prone to various damage modes, with fatigue cracks among the most common. Therefore, developing an efficient and accurate structural health monitoring approach holds great significance for preventing train accidents and extending equipment service life. This paper focuses on damage monitoring and life prediction for structural materials by proposing a structural life prediction method based on a physics-informed neural network (PINN) to address the limited interpretability of traditional deep learning methods. Firstly, an observation model for fatigue crack propagation was constructed by analyzing Lamb wave signals and combining a normalized energy damage factor. This model allowed for effective quantitative characterization of crack damage. Secondly, a physics-based empirical degradation model was established by combining observation data with the Paris formula, and was then integrated into PINN, to ultimately establish a highly interpretable structural life prediction model. The proposed model not only overcomes the "blackbox" limitations of traditional neural network models but also significantly improves prediction accuracy and credibility by leveraging physics-informed constraints. Experimental results show that the PINN model performs excellently in fatigue crack propagation monitoring and remaining life prediction for structural materials, providing new insights and methods in the field of structural health monitoring.

Keywords: physics-informed neural network; Lamb waves; structural health monitoring; remaining life prediction; high-speed train; artificial intelligence; neural network