

基于机器学习的钢结构节点疲劳寿命预测

曹杰帆

华侨大学土木工程学院, 福建 厦门 361000

摘要: 针对钢结构节点疲劳寿命难以精准预测的问题, 本文构建了一种基于机器学习的预测模型。通过采集实验与仿真数据, 提取多维结构特征, 分别训练 SVR、RF、XGBoost 和 ANN 模型, 并采用交叉验证和参数优化提升预测性能。结果表明, XGBoost 模型在精度与稳定性方面表现最优, R^2 为 0.927, 预测误差控制在 $\pm 7\%$ 以内。与传统 S-N 曲线法相比, 该模型更能适应复杂工况, 具有更高的工程适用性。研究表明, 机器学习可为钢结构疲劳寿命预测提供有效手段。

关键词: 钢结构; 疲劳寿命; 机器学习; XGBoost; 预测模型

引言

钢结构因其强度高、自重轻、施工周期短等优点, 已被广泛应用于桥梁工程、高层建筑、城市轨道交通、海洋平台等大型工程结构体系中。在这些结构中, 节点作为连接各构件的重要部位, 其受力复杂, 易产生应力集中, 是结构疲劳破坏的薄弱环节。随着服役时间的增长与荷载循环次数的积累, 钢结构节点面临的疲劳损伤问题日益突出, 成为影响工程结构安全性与可靠性的重要因素。尤其是在高速列车、高频荷载或特殊环境作用下, 节点疲劳损伤不仅影响结构寿命, 还可能引发安全事故。因此, 对钢结构节点疲劳寿命进行精准预测, 对于延长结构使用年限、优化维护策略、降低运维成本具有重要工程意义。

一、理论基础与方法

(一) 钢结构节点疲劳破坏机理

钢结构节点因其承担力的传递与构件连接功能, 常成为疲劳破坏的关键部位。在交变荷载长期作用下, 节点区域材料内部首先会在应力集中区域出现微裂纹, 随后裂纹在加载循环中逐步扩展, 最终导致

结构失效^[1]。该过程包括三个阶段: 裂纹萌生、稳定扩展与最终断裂。其中, 焊缝质量对裂纹萌生具有决定性影响, 气孔、夹渣、未熔合等焊接缺陷易成为裂纹起始源。同时, 节点几何构造(如刚性角接、槽型接头等)所导致的应力集中, 以及残余应力和材料不均匀性, 也显著影响疲劳寿命。工程实践中, 由于节点形式多样, 受力状态复杂, 疲劳寿命呈现出高度的不确定性和非线性规律, 使传统基于单一应力幅-寿命关系的模型难以满足高精度预测需求^[2]。

(二) 机器学习原理概述

机器学习是一类利用已有数据样本构建映射模型以预测目标变量的方法, 具有自适应、非线性建模和强泛化能力。在疲劳寿命预测中, 机器学习可将节点特征、应力信息等高维输入映射至寿命输出, 从而替代或补充传统物理模型^[3]。支持向量回归(SVR)在处理小样本回归问题中表现稳健; 随机森林(RF)通过集成多个决策树建模非线性关系并具备特征重要性评估能力; XGBoost、GBDT 等梯度提升算法则兼具高精度与高效性, 适合处理结构

疲劳的复杂数据分布。模型训练前，需进行数据预处理，包括归一化、缺失值填充、异常点剔除等操作。随后，实施特征工程以筛选对疲劳寿命具有解释力的变量，如节点类型、应力幅值、加载频率、构件尺寸等，并通过相关性分析或主成分分析（PCA）降维以优化模型输入。最终，通过交叉验证与误差评价指标（如 MSE、 R^2 、MAE）训练模型并评估其性能^[4]。

（三）模型构建思路与框架设计

本研究构建了一套基于机器学习的钢结构节点疲劳寿命预测框架，如图 1 所示。模型主要包括四个阶段：数据采集、特征工程、模型训练和寿命预测。在数据采集

阶段，结合实验测试、有限元仿真和实测监测等多源数据，提取与节点疲劳寿命相关的输入特征，如应力幅值、节点构造形式、循环加载次数、材料等级等。在特征工程阶段，采用归一化与相关性分析剔除冗余变量，确保特征代表性与模型稳定性。随后选择 SVR、RF、XGBoost 等典型回归模型，输入上述变量并训练预测模型^[5]。模型训练阶段采用 K 折交叉验证与网格搜索优化超参数，提升泛化能力。在寿命预测阶段，模型可输出钢结构节点在特定工况下的疲劳寿命估值，并与实测值对比以验证模型效果。通过这种数据驱动方法，可实现钢结构疲劳寿命的高效预测，为智能维护提供支持。




图 1 基于机器学习的钢结构节点疲劳寿命预测流程图

二、数据集构建与特征分析

（一）实验数据与仿真数据采集

为了构建高质量的钢结构节点疲劳寿命预测模型，首先需要获取具有代表性和多样性的数据集。本研究的数据来源包括两部分：一是来源于标准疲劳试验平台的

实验数据，二是通过有限元软件对典型节点构型进行建模与模拟得到的仿真数据。实验数据以实际钢结构节点试件为基础，在恒幅或变幅加载条件下记录其应力响应与疲劳寿命，具有较高的工程参考价值；而仿真数据则用于补充难以实验覆盖的边界条件与参数组合，为模型训练提供更广

泛的特征空间。所采集的数据项主要包括节点构造形式（如角接、T 型、K 型）、材料等级（如 Q345、Q390）、应力幅值（单位 MPa）、加载频率（Hz）、几何参数（如板厚、焊缝角度、腹板宽度）、循环次数（即寿命）等变量，这些特征共同决定了节点疲劳行为的复杂演化过程。

（二）数据预处理方法

原始数据往往存在重复记录、缺失项或测量误差，为提升模型训练的有效性与鲁棒性，必须进行系统的数据预处理。首先，在数据清洗阶段，对存在明显异常的样本（如寿命小于 10^2 或大于 10^7 的极端值）进行识别与剔除，避免模型拟合偏移。对少量缺失值样本采用均值插补或 KNN 插补策略进行修复，确保特征维度完整性。随后，所有特征变量统一进行归一化处理，将其缩放至 $[0, 1]$ 区间，消除量纲差异对模型权重学习的干扰。此外，针对部分高度偏态分布的变量（如焊缝角度、循环次数），采用对数变换进行正态化处理，以改善模型对尾部样本的识别能力。

上述操作在保留数据结构特性的同时，有效提升了样本质量，为后续特征工程打下基础。

2.3 特征选择与工程处理

为减少输入冗余、降低计算复杂度并提升模型泛化能力，本研究在特征构建阶段实施了系统性的特征筛选与降维处理。首先，通过皮尔逊相关系数计算各变量与目标值（疲劳寿命）之间的线性关系，并结合方差膨胀因子（VIF）分析多重共线性，剔除冗余性强、共线性大的变量。其次，基于 Lasso 回归的正则化机制进一步筛选出具有代表性的重要特征，同时控制模型复杂度。此外，为进一步压缩输入空间维度并捕捉变量间的协同信息，采用主成分分析（PCA）对输入特征进行降维处理，并保留累计解释方差超过 95% 的主成分用于建模训练。

为更清晰呈现各变量的特性，表 1 展示了部分核心特征的分布统计情况与标准化后的均值、标准差等参数。

表 1 常用输入特征统计特性一览

特征名称	类型	最小值	最大值	均值	标准差
应力幅值（MPa）	连续变量	80	280	145.3	45.7
节点类型	类别变量	T/K/角	-	-	-
材料等级	类别变量	Q345~Q460	-	-	-
焊缝角度（°）	连续变量	30	80	52.4	11.2
循环次数（次）	连续变量	2e3	1e7	6.5e5	1.2e6
腹板厚度（mm）	连续变量	6	20	11.8	3.1

从表 1 可以看出，应力幅值、焊缝角度与腹板厚度等变量在样本中具有较高的分布广度，为模型识别不同疲劳响应提供了有效判别基础。同时，节点类型与材料

等级作为结构分类信息，将通过 One-Hot 编码转换为可训练的特征输入。总体来看，该特征集涵盖了材料、构造与加载等关键疲劳影响因素，具有较强的解释力与建模

价值。接下来将基于该特征集开展回归模型训练与寿命预测工作。

3 疲劳寿命预测模型构建

3.1 模型选型与比较

为了实现对钢结构节点疲劳寿命的高效预测，本研究构建了多种典型的监督式回归模型，分别包括支持向量回归(SVR)、随机森林回归(RF)、梯度提升回归树(XGBoost)以及人工神经网络(ANN)。各模型代表了不同的机器学习建模思想：SVR 适用于高维小样本问题，RF 具有较强的抗噪能力和特征解释能力，XGBoost 因

其集成策略和正则化机制在结构性能预测领域表现优异，而 ANN 可拟合复杂非线性函数关系，适合捕捉高阶特征交互。模型训练时需进行合理的超参数配置，其中 SVR 需设定核函数类型、惩罚系数 C 与 ϵ 损失边界；RF 模型需确定树的数量、最大深度与最小叶节点样本数；XGBoost 需调整学习率、树的最大深度、子样本采样比率等；而 ANN 则需配置网络层数、激活函数与学习率等关键参数。为便于比较不同模型的基础配置，表 2 汇总了各模型的核心参数设定。

表 2 各回归模型参数设置概览

模型名称	核心参数1	核心参数2	核心参数3
SVR	kernel = 'rbf'	$C = 10$	$\epsilon = 0.2$
RF	n_estimators = 200	max_depth = 10	min_samples_leaf = 5
XGBoost	learning_rate = 0.05	max_depth = 8	subsample = 0.8
ANN	hidden_layer_sizes = (50,30)	activation = 'relu'	learning_rate = 0.001

从表 2 可以看出，各模型参数的设定基于初步网格搜索与经验值调整，旨在兼顾预测精度与训练稳定性。参数配置的合理性为后续模型性能优化与泛化能力提升提供了基础保障。

3.2 模型训练与优化

在模型训练阶段，原始数据集首先按 8:2 的比例划分为训练集与测试集，确保模型在未知数据上的验证能力。同时，为减少数据划分带来的偶然性，采用五折交叉验证(5-fold CV)进行训练与评估。交叉验证过程中，模型在五个子集之间轮流作为验证集，其余部分作为训练集，在充分利用样本数据的同时抑制过拟合风险。针对每种模型的关键超参数，分别采用网格搜索与贝叶斯优化算法进行自动调参。

网格搜索通过遍历预设参数组合进行穷举试验，适合参数量小、搜索空间离散的模型如 SVR 与 RF；贝叶斯优化则通过概率模型预测目标函数分布并选择最优采样点，适用于 XGBoost 和 ANN 等高复杂度模型的高效优化。整个训练与优化过程在 Scikit-learn 与 XGBoost 库中实现，模型训练后输出最佳参数组合与预测结果。

3.3 模型结果分析

模型训练完成后，分别在测试集上计算均方误差(MSE)、平均绝对误差(MAE)与决定系数(R^2)等性能指标，量化模型的预测精度与稳定性。表 3 展示了各模型在标准测试集上的评价结果，从中可直观对比不同方法的预测性能。

表 3 不同模型在疲劳寿命预测中的性能比较

模型名称	MSE ($\times 10^5$)	MAE ($\times 10^3$)	R ²
SVR	6.32	5.41	0.873
RF	4.97	4.12	0.901
XGBoost	3.88	3.45	0.927
ANN	4.51	3.82	0.913

从表 3 可以看出，XGBoost 在三个关键指标中均表现最优，表明其在捕捉复杂特征交互关系、提升模型精度方面具有显著优势。RF 和 ANN 模型次之，也具有良好的预测性能和泛化能力。相对而言，SVR 在本研究数据集下略逊一筹，主要由于其在高维大样本条件下的表达能力有限。综合对比结果表明，基于集成学习的 XGBoost 模型更适合用于钢结构节点疲劳寿命的精准预测。在下一章节中，将基于最优模型展开工程案例验证，并进一步探讨预测结果的应用价值。

4 案例分析与模型验证

4.1 工程案例介绍

为验证所构建的疲劳寿命预测模型在实际工程中的有效性与适用性，本文选取某市轨道交通桥梁结构中的六个典型钢结构节点作为案例研究对象。该桥梁采用

Q345 钢材，节点形式为 T 型焊接连接，长期承受列车荷载的高频往复应力，属于疲劳风险较高部位。通过在节点表面布设应变计，连续监测其服役应力状态，结合现场几何尺寸、焊接工艺及材料等级等数据，构建完整特征集。为获取真实的疲劳寿命，采用超声波探伤等手段定期检测裂纹萌生情况，并以裂纹初始出现前的循环次数作为寿命标准值。上述实测数据作为外部测试集输入至训练完成的 XGBoost 模型中，用于检验其在非训练样本上的泛化预测能力。

4.2 模型验证效果分析

模型预测结果与实测寿命进行逐点对比，分析其精度与误差分布。表 4 列出了六个节点的应力幅值、关键几何参数、实测疲劳寿命、模型预测寿命及相对误差情况。

表 4 节点疲劳寿命实测值与模型预测结果对比

节点编号	应力幅 (MPa)	板厚 (mm)	节点类型	实测寿命 ($\times 10^4$)	预测寿命 ($\times 10^4$)	相对误差 (%)
N1	145	10	T型	52.1	49.3	-5.38
N2	172	12	T型	38.7	36.2	-6.46
N3	132	8	T型	60.4	64.1	+6.13
N4	158	14	T型	43.5	41.0	-5.75
N5	149	10	T型	50.8	47.6	-6.30
N6	137	11	T型	56.3	58.5	+3.91

从表 4 可以看出，XGBoost 模型预测值与实测寿命整体吻合良好，所有节点样本的相对误差均控制在 $\pm 7\%$ 以内，表现出较强的精度与鲁棒性。误差可能来自应力采集时的测量不确定性、裂纹检测的滞后

性，或个别特征未充分表达（如残余应力等）导致的信息不完整。尤其在 N3 与 N6 节点上略有高估，说明模型在处理低应力幅、长寿命节点时可能存在略微偏差，但整体仍保持稳定预测能力。

4.3 与传统方法对比分析

为进一步评估模型的优势，将 XGBoost 模型的预测结果与传统的 S-N 曲线法进行对比。采用《钢结构设计规范》

推荐的 S-N 数据，根据各节点实测应力幅对寿命进行估算，并对比其与实测值的误差。表 5 呈现了两种方法在相同节点上的预测结果和误差情况。

表 5 XGBoost 模型与 S-N 曲线法预测结果对比

节点编号	实测寿命($\times 10^4$)	S-N法预测($\times 10^4$)	误差(%)	XGBoost预测($\times 10^4$)	误差(%)
N1	52.1	44.2	-15.16	49.3	-5.38
N2	38.7	32.3	-16.55	36.2	-6.46
N3	60.4	55.7	-7.79	64.1	+6.13
N4	43.5	37.6	-13.56	41.0	-5.75
N5	50.8	42.9	-15.55	47.6	-6.30
N6	56.3	48.0	-14.75	58.5	+3.91

表 5 结果显示，S-N 法普遍存在寿命低估问题，误差集中在-13%至-17%区间，说明其难以充分反映节点构造细节和实际服役状态的复杂性。而 XGBoost 模型的预测结果更为接近实测值，误差显著缩小，在效率方面也具备极大优势，可快速处理大规模节点寿命评估任务。由此可见，基于机器学习的预测模型不仅在精度上优于传统方法，在适应性和工程应用潜力方面也展现出较大优势，具有较高的推广价值。

5 结论

本文围绕钢结构节点疲劳寿命预测问题，基于实际工程数据和仿真样本，构建了一套融合特征工程、模型训练与误差评

估的机器学习预测框架。通过引入 SVR、RF、XGBoost 和 ANN 等多种算法进行对比，结果表明 XGBoost 模型在各项误差指标上表现最优，具有较高的预测精度与鲁棒性。在工程验证环节，模型预测值与实测寿命高度吻合，误差控制在 $\pm 7\%$ 以内，远优于传统 S-N 曲线法。研究表明，机器学习方法可有效挖掘复杂、多维度疲劳影响因素之间的非线性关联，适用于应对多工况、多节点形式下的寿命评估任务。本文模型不仅提升了疲劳寿命预测的科学性与效率，也为钢结构智能运维和寿命管理提供了可行的技术路径。未来可结合实时监测系统和数字孪生平台，进一步拓展模型的在线适应能力与应用范围。

参考文献

- [1] 甘磊, 吴昊, 仲政. 数据驱动的金属疲劳寿命模型研究进展[J]. 力学进展, 2025, 55(01): 30-79.
- [2] 刘妍, 王茂岑, 张令心. 从 18WCEE 看基于 ML 的结构地震响应预测和损伤评估研究进展[J]. 世界地震工程, 2025, 41(01): 72-89.
- [3] 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(02): 44-52.
- [4] 李荣强, 连小锋, 朱睿, 等. 基于机器学习的飞机起落架着陆载荷预测模型[J]. 科学技术与工程, 2023, 23(18): 801-807.

[5]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(01):1-33.