

# 基于机器学习算法模型的焊接接头疲劳寿命预测

徐梦悦<sup>1</sup>, 齐红宇<sup>1,2</sup>, 李少林<sup>1,2</sup>, 石多奇<sup>1,2</sup>, 杨晓光<sup>1,2</sup>

(1. 北京航空航天大学 能源与动力工程学院, 2. 航空发动机结构强度北京市重点实验室: 北京 100191)

**摘要:** 焊接接头具有非均匀的微观组织和梯度过渡的力学性能及随机分布的焊接缺陷等特征, 相较于其他结构更容易产生疲劳断裂, 特别是焊接接头的疲劳载荷下的强度和寿命问题已成为工程界和学术界的研究热点。为了研究焊接接头的疲劳行为, 开展了基于随机森林(RF)模型的焊接接头疲劳寿命预测模型的全新研究。通过采用 RF 和轻梯度提升机(LightGBM)2 种不同的机器学习算法模型对焊接接头的疲劳数据集进行分析和预测, 从中选择预测性能更优的机器学习模型; 通过比较在不同几何形状下疲劳寿命的预测结果, 评估几何形状对机器学习模型预测性能的影响; 利用 RF 算法对输入条件进行重要度排序, 分析焊接接头疲劳寿命的影响因素; 通过计算模型在不同材料下的疲劳寿命结果验证机器学习模型的泛化能力。结果表明: 机器学习模型对不同几何形状的焊接接头疲劳寿命的预测效果较好, 且可用于预测在不同材料下的焊接接头疲劳寿命。研究结果对焊接结构的强度设计与焊接工艺参数优化等具有重要意义。

**关键词:** 机器学习; 随机森林算法; 轻梯度提升机算法; 焊接接头; 疲劳寿命; 几何形状; 预测模型

中图分类号: V231.95

文献标识码: A

doi: 10.13477/j.cnki.aeroengine.2025.01.014

## Machine-Learning-Based Fatigue Life Prediction Method for Welded Joints

XU Meng-yue<sup>1</sup>, QI Hong-yu<sup>1,2</sup>, LI Shao-lin<sup>1,2</sup>, SHI Duo-qi<sup>1,2</sup>, YANG Xiao-guang<sup>1,2</sup>

(1. School of Energy and Power Engineering, Beihang University,

2. Beijing Key Laboratory of Aero-Engine Structure and Strength: Beijing 100191, China)

**Abstract:** Welded joints are characterized by non-uniform microstructure, gradient transitions in mechanical properties, and randomly distributed welding defects, which are more prone to fatigue fracture than other structures. Therefore, studying the strength and life of welded joints (especially under fatigue loading) has become a hot research topic in engineering and academia. A new study of a fatigue life prediction model for welded joints based on a random forest model was carried out to study the fatigue behavior of welded joints. To select a machine learning model with better prediction performance, the fatigue data set of welded joints was analyzed and predicted using two different machine learning algorithm models, the Random Forest Model, and LightGBM. The random forest algorithm was used to rank the importance of the input conditions to analyze the factors influencing the fatigue life of welded joints; The fatigue life results of the model were calculated with different materials to verify the generalization ability of the machine learning model. The results show that the machine learning model performs well in predicting the fatigue life of welded joints with different geometries and can be used to predict the fatigue life of welded joints with different materials. The results are of great importance for the strength design of welded structures and the optimization of welding process parameters.

**Key words:** machine learning; random forest algorithm; LightGBM (Light Gradient Boosting Machine) algorithm; welded joints; fatigue life; geometry; prediction model

## 0 引言

焊接工艺广泛应用于机械、土木、航空航天、船舶等工程领域。然而, 在焊接接头中所存在的裂纹、气孔、夹杂、未熔合、未焊透等缺陷已成为整个焊接结构

中最薄弱的环节。对于承受交变载荷的焊接结构, 其中 90% 以上的失效均属于疲劳问题。因此, 针对焊接接头开展疲劳寿命预测研究, 制定安全评估及健康管理决策, 实现焊接接头利用的最大化, 可大大降低经济损失和减少人员伤亡。研究焊接接头的疲劳行为

收稿日期: 2023-07-04 基金项目: 国家自然科学基金(51975027)资助

作者简介: 徐梦悦(2000), 女, 在读硕士研究生。

引用格式: 徐梦悦, 齐红宇, 李少林, 等. 基于机器学习算法模型的焊接接头疲劳寿命预测[J]. 航空发动机, 2025, 51(1): 96-102. XU Mengyue, QI Hongyu, LI Shaolin, et al. Machine-learning-based fatigue life prediction method for welded joints[J]. Aeroengine, 2025, 51(1): 96-102.

以及预测其疲劳寿命,具有重要意义和工程价值。

王晓锋等<sup>[1]</sup>进行的研究表明,焊接接头的疲劳性能不仅受焊缝形状、接头类型、焊接残余应力等因素的综合影响,还受载荷、焊接缺陷、应力循环次数等因素的影响;Lee 等<sup>[2]</sup>研究了焊缝几何形状对疲劳寿命的影响,表明疲劳寿命受焊后角和焊趾半径的影响较大,而受焊喉厚度的影响较小;Guha<sup>[3]</sup>针对 3 种不同接头类型的试样进行疲劳试验,发现受拉十字型接头试样由于其约束因子最大,疲劳性能也最差;Chiocca 等<sup>[4]</sup>通过数值建模和微观结构分析研究残余应力对焊接接头疲劳评估的影响,表明残余应力会降低焊接接头的疲劳寿命。

焊接接头的疲劳寿命预测方法主要有 4 种:(1)基于名义应力的方法<sup>[5]</sup>;(2)基于局部应力的方法<sup>[6]</sup>;(3)基于断裂力学的方法<sup>[7-8]</sup>;(4)基于损伤力学的方法<sup>[9]</sup>。基于名义应力的模型在工程应用中简单,但却忽略了焊接接头中的重要细节,预测结果无法在不同类型的焊接接头之间传递;局部模型通常采用在疲劳过程初始阶段评估的点和场参数只能预测在这些参数控制的区域内的疲劳裂纹萌生和短裂纹扩展的寿命<sup>[10]</sup>;基于断裂力学的模型从某种程度上可以避免上述方法的不足,但只能预测在结构中具有微小初始缺陷的裂纹扩展,而无法分析裂纹萌生问题;基于损伤力学的模型可以描述焊接接头的疲劳损伤演化,但需要建立焊接接头在不同子区域的本构模型和参数识别,并需考虑材料不均匀性的残余应力场。

机器学习通过采用特定的算法进行科学数据分析,从而为复杂的工程问题提供最优的方案,已用于疲劳寿命预测。Tan 等<sup>[11]</sup>采用支持向量回归(Support Vector Regression, SVR)的监督机器学习方法,用于识别和训练镍基高温合金的疲劳寿命;Li 等<sup>[12]</sup>将机器学习方法应用于激光熔化的 Ti-6Al-4V 合金的超高周疲劳(Very High Cycle Fatigue, VHCF)寿命预测分析;Braun 等<sup>[13]</sup>采用机器学习技术,对小尺寸的焊接接头试样的疲劳失效循环次数和失效位置进行了预测。

本文基于随机森林(Random Forest, RF)模型和轻梯度提升机(Gradient Boosting Machine, LightGBM)模型,对在不同几何形状和不同材料下不同机器学习模型疲劳寿命预测结果进行比较分析。

## 1 机器学习模型理论框架

目前,机器学习已形成较为科学和完整的开发流程,面对应用场景和数据特征差异,需采取不同的方案进行研究<sup>[14]</sup>。对于本文的焊接接头的机器学习预测模型,主要包括数据采集及预处理、特征工程、预测模型选定、模型训练、模型测试、模型评估、模型优化等步骤。机器学习的开发流程如图 1 所示。

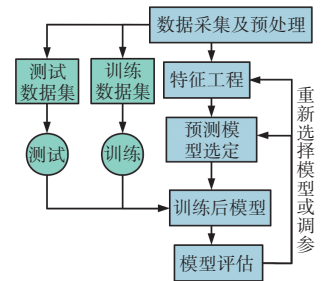


图 1 机器学习的开发流程

### 1.1 数据采集及预处理

在建立模型前,首先要进行数据采集,为避免机器学习模型中的过拟合或欠拟合结果,应在数据集中收集到尽可能多的疲劳数据。在收集焊接接头疲劳数据的过程中,不仅要收集疲劳寿命,还需要收集焊接接头的几何特性和疲劳试验中的应力状态作为输入,如应力幅、应力比、应力集中系数 $K_t$ 、焊接试验的加载方式试件的材料刚度等。对于不同条件影响下的疲劳性能试验结果,其收集到的特征因素也不相同,考虑接头几何形状对接头疲劳性能影响的数据集中会引入焊接接头的接头类型的物理量;考虑焊缝形状对接头疲劳性能影响的数据集则会引入焊趾半径尺寸的物理量;考虑焊接残余应力对接头疲劳性能影响的数据集可能会引入残余应力强度因子或裂纹尺度的物理量<sup>[15]</sup>。试样几何形状和样本 ID 如图 2 所示。部分原始数据<sup>[16]</sup>见表 1。




图 2 试样几何形状和样本 ID<sup>[16]</sup>

### 1.2 异常值及缺失值处理

样本数据的质量对预测模型的预测性能产生很大影响,同时对最终预测模型的质量造成严重的影响。因此,需要在采集数据后对原始的数据进行预处理,原始寿命数据的丢失、噪声、离群值等问题,可以利用数据清理技术对“脏数据”进行检测和处理,并将

表1 部分原始数据

样本ID	接头类型*	试件厚度/mm	$K_t$	应力比 $R_1$	应力比 $R_2$	加载方式**	应力幅/MPa	疲劳寿命/次循环
Dic1	3	24	2.1	0	0	2	262	274419
Sta1	1	20	2.9	0.1	0.1	1	369	63780
Haa2	4	8	3.7	0.1	0.1	2	303	39617
Wan2	3	8	1.6	0	0.1	2	384	38862
Wan1	4	8	2.7	0	0.1	2	151	597465
Ped1	1	6	2.0	0.1	0.1	1	644	25682
Gal2	1	6	2.0	0.1	0.1	1	383	195611
Man1	2	12.5	2.7	0.1	0.1	2	303	71573
Oht2	2	20	3.0	0	0.5	2	101	1691502
Lif4	4	8	3.9	0.2	0.2	2	222	75272
Lop1	4	12	3.8	0	0	2	251	60773
Haa1	1	20	2.8	0.1	0.1	1	227	1185270
Nak1	3	20	2.0	0	0	2	107	3631089
Lif3	4	8	3.4	0.2	0.2	2	69	1686128
Wan2	3	8	1.6	0	0.1	2	150	1899042
Nak1	3	20	2.0	0	0	2	142	897763
Lif2	3	8	1.6	0.2	0.2	2	251	1132566
Lif1	2	8	2.4	0.2	0.2	2	212	923787
Lif4	4	8	3.9	0.2	0.2	2	69	1306996
Dim1	4	12.7	3.6	0.1	0.1	2	95	1494625
Lif1	2	8	2.4	0.2	0.2	2	250	388136

注:接头类型\*:1为T型接头,2为双面横向接头,3为对接接头,4为双面纵向接头;加载方式\*\*:1为拉伸试验,2为弯曲试验。

其转化为“干净数据”,从而改善了数据的质量。其中包含对缺失值和异常值的处理。本研究选用的数据集没有缺失值,只对异常值进行处理,处理方式为此条数据删除。

### 1.3 机器学习模型

机器学习中的算法模型很多,按照模型的数量和性质的不同,可将机器学习模型划分为单一模型和集成模型。所谓单一模型,是只由1个模型组成的机器学习模型,以某种模型单独对其进行训练和验证,其中包括了线性回归、逻辑回归、近邻、决策树、感知机、神经网络、支持向量机等。而集成模型指的是将多个单模型进行合并,形成1个强模型,该强模型可以获得所有单模型的优点,从而获得相对最佳的性能。在集成模型中,单一模型可能属于同种类别,也可能属于不同类别。目前研究的集成模型有2大类:Boosting和Bagging,其中主要包括了自适应提升机(Adaptive Boosting, AdaBoost)、梯度提升决策树(Gradient Boosting Decision Tree, GBDT)、极端梯度提升机(eXtreme Gradient Boosting, XGBoost)、轻梯度提升机(LightGBM)、以及随机森林(RF)等模型。

由于集成模型中的RF和LightGBM 2种算法模型

可以灵活处理各种类型的数据,且预测准确性较高,考虑到焊接疲劳数据之间非线性的关系,本文主要选取这2种算法模型进行建模预测并进行详细介绍。

#### 1.3.1 随机森林(RF)模型

RF模型是基于随机决策的一种通用集成方法。该方法可用于建立分类和回归问题的预测模型<sup>[7]</sup>,如图3所示。RF<sup>[18]</sup>是指一系列树结构分类器 $\{h(x, \theta_k), k=1\}$ 的集合,其中 $\{\theta_k\}$ 是独立的同分布随机向量,每棵树对输入 $x$ 的最受欢迎的类别进行单位投票。用户需要指定随机选择的变量数量 $m$ ,以便在每个节点

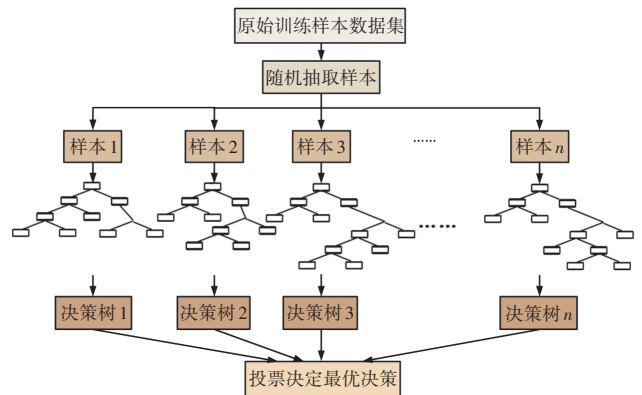


图3 RF算法

上搜索出最佳分割结果。使用该节点随机选择的预测变量子集中的最佳节点进行拆分。最大的树是生长的,不进行修剪。森林中每棵树的根节点都包含来自原始数据的引导样本作为训练集。不在训练集中的观测值被称为“袋外”观测值。

分类器  $h_k(x)$  的袋外试例为  $O_k(x)$ 。  $Q(x, y_j)$  为根据输入  $x$  和  $P(h(x)=y_j)$  的近似值投票选出的类别  $y_j$  的“袋外”比例<sup>[19]</sup>

$$Q(x, y_j) = \frac{\sum_{k=1}^K I(h_k(x) = y_j, (x, y) \in \Theta_k)}{\sum_{k=1}^K I(h_k(x), (x, y) \in \Theta_k)} \quad (1)$$

式中:以  $I(\cdot)$  形式出现的函数为指标函数。

树木分类器森林的泛化误差取决于森林中单个树木的强度以及他们之间的相关性。计算边距函数以找到正确类  $y$  的平均票数超过任何其他类的平均票数的程度。

$Q(x, y)$  和  $Q(x, y_j)$  用于估计函数。预期余量称为强度,根据整个训练集的平均值计算

$$s = \frac{1}{n} \sum_{i=1}^n \left( Q(x_i, y) - \max_{j \neq y} Q_{j-1}^c(x_i, y_j) \right) \quad (2)$$

由于单棵树未经修剪,终端节点只能包含少量观测数据。训练数据在每棵树上运行。如果观测值  $i$  和  $j$  最后都出现在同一个终端节点,则  $i$  和  $j$  之间的相似度会增加 1。在森林构建结束时,相似度会被对称化,并除以树的数量<sup>[20]</sup>。

### 1.3.2 LightGBM 模型

LightGBM 模型是一种快速高效的梯度提升决策树(GBDT)算法,主要通过直方图算法和具有深度限制的逐叶策略来对决策树进行改进<sup>[21]</sup>,包括以下几种。

(1)直方图算法。直方图算法的核心思想是把连续的浮点数的特征值离散成  $k$  个整数,通过这些特征值构造宽度为  $k$  的直方图,在遍历数据中,以离散值作为指标,在直方图中累积统计量。在遍历 1 次数据后,累积得到直方图所需的统计量,然后再对直方图上的分叉点的离散值重新进行遍历,从而找到最佳的分割点。该过程如图 4 所示。




图 4 直方图遍历过程

(2)有深度限制的 Leaf-wise 生长策略。GBDT 和

XGBoost 模型在叶子的生长策略上采取的是 Level-wise 分裂。由于 Level-wise 分裂算法没有对每层叶子进行区别处理,导致每次迭代都必须要通过数据集中的全部数据,使得效率很低。而 Leaf-wise 分裂算法是每次从所有的叶子中找出分裂收益最高的叶子,并对这些叶子进行分裂和循环,其他叶子节点均不会出现分裂。但是,Leaf-wise 分裂算法容易过拟合,LightGBM 在 Leaf-wise 的生长策略上增加了 1 个最大深度限制,以防止过拟合,同时保证高效率<sup>[22]</sup>。Leaf-wise 树叶生长过程如图 5 所示。




图 5 Leaf-wise 树叶生长过程

(3)单边梯度采样算法。单边梯度采样算法(Gradient-based One-Side Sampling, GOSS)基于减少样本的角度,将权重小的样本剔除,仅计算剩余样本的信息增益。

采用 GOSS 采集数据时,仅保留梯度较大的数据,为了避免丢弃梯度小的数据会对样本分布造成的影响,在计算增益时引入 1 个常量对小梯度样本进行平衡。GBDT 通过决策树将输入空间映射到梯度空间中进行学习。假设训练集中有  $n$  个试例为  $x_1, \dots, x_n$ , 特征维数为  $s$ 。当每次梯度迭代时,用  $g_1, \dots, g_n$  来表示模型数据变量的损失函数的负梯度方向,通过最佳分割点(最大信息增益点)将数据分割成相应的节点<sup>[23]</sup>。

分割特征  $j$  的分割点  $d$  定义为

$$V_{j0}(d) = \frac{1}{n_0} \left( \frac{\left( \sum_{\{x_i \in 0; x_i < d\}} g_i \right)^2}{n_{j0}^l(d)} + \frac{\left( \sum_{\{x_i \in 0; x_i > d\}} g_i \right)^2}{n_{j0}^r(d)} \right) \quad (3)$$

(4)互斥特征捆绑算法。高维度的数据具有高度稀疏、特征间相互排斥的特点,严重影响模型的精度和效率。针对高维度数据的稀疏性问题,提出一种基于互斥特征捆绑算法(Exclusive Feature Bundling, EFB)。在 EFB 算法中,采用复合函数并通过非零的数量对特征进行排序,并且计算碰撞率。

## 2 模型预测结果及讨论

### 2.1 利用机器学习模型对非合金钢进行预测

采集多种几何形状的焊接接头的疲劳寿命数据<sup>[16]</sup>,以及单一几何形状下焊接接头的疲劳寿命数

据,包括对接接头<sup>[24-26]</sup>、T型接头<sup>[27-29]</sup>、双面横型接头<sup>[30-31]</sup>和双面纵向接头<sup>[32-34]</sup>。最终,共获得了409组焊接接头的疲劳寿命数据,每组数据记录了焊接接头的几何特征、试验中的应力条件和疲劳寿命,共涵盖9种类别。此处考虑数据的唯一差异是试样的几何形状。

初始输入特征共有8种,包括样本ID、接头类型、试件厚度、 $K_t$ 、 $R_1$ 、 $R_2$ 、加载方式和应力幅。 $R_1$ 和 $R_2$ 表示应力比区间的最大应力比和最小应力比。然后对采集的数据进行预处理,构建训练集和测试集。通过上述2种模型(RF和LightGBM)算法对非合金钢材料的焊接接头进行疲劳寿命预测。此外,焊接工艺也是焊接接头疲劳性能的影响因素之一,在参考的数据中并未对焊接接头的具体焊接工艺明确解释,因此在初始输入特征中不考虑。机器学习模型预测焊接接头疲劳寿命流程如图6所示。

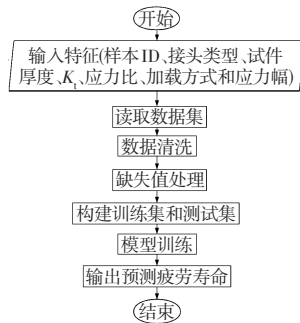


图6 机器学习模型预测疲劳寿命流程

通过将机器学习获得的预测疲劳寿命与测试数据进行比较,以评估不同的机器学习模型在疲劳寿命预测方面的性能。

从测试集获得的输出疲劳寿命与试验寿命间的对比如图7所示。从图7(a)可见,由于存在几何形状对焊接接头的影响,在LightGBM模型的预测结果中有80%的数据点位于3倍分散系数之内,表明LightGBM模型的预测结果具有较大的离散性,是不可接受的。另外,该模型具有明显的预测偏差。以 $2 \times 10^6$ 的实际疲劳试验值为界,LightGBM模型的预测效果具有很大的分散性,仅有少部分的数据点偏差较小。表明了较低的疲劳寿命水平下,LightGBM模型不适用预测焊接接头的疲劳寿命。从图7(b)可见,RF模型具有更好的预测能力,所有点均位于5倍分散系数以内,且88.54%的数据点位于3倍分散系数之内,计算结果与试验数据具有良好的相关性。同时,疲劳数据点均匀分布在 $y=x$ 线的两侧,且无较大的预测偏差。只有当疲劳寿命大于 $4 \times 10^7$ 时,84.85%的焊接接头的疲劳寿命会被低估。以上结果表明RF模型能更好地预测焊接接头在受几何形状影响下的疲劳寿命。

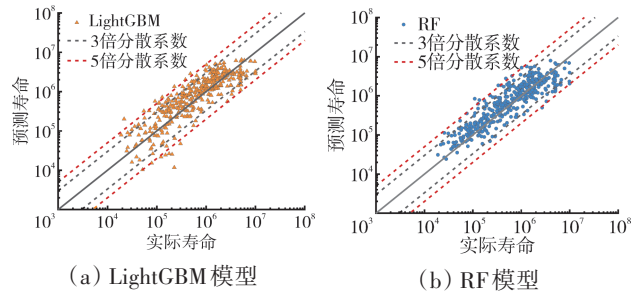


图7 不同机器学习模型下的预测结果

## 2.2 考虑几何形状对预测结果的影响

通过对不同几何形状的疲劳预测寿命相互比较,来评估几何形状对机器学习模型预测性能的影响。4种不同类型试件的RF模型下的疲劳寿命预测结果如图8所示,试验结果来自于文献[13]。

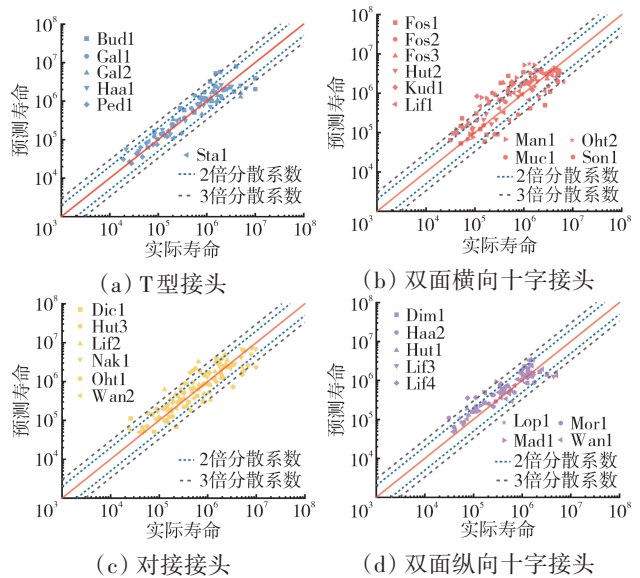


图8 不同焊接接头形式的预测结果对比

从图中可见,双面横向十字接头下的预测结果中有较多位于3倍分散系数以外的数据点(图8(b))。双面纵向十字接头的大部分数据点均位于3倍分散系数范围内(图8(d)),但在疲劳试验值小于 $3 \times 10^6$ 的较低疲劳寿命水平下,预测的疲劳寿命均比实际寿命更高。总之,机器学习模型在不同焊接形式的焊接接头的疲劳寿命预测效果较好且接近,说明机器学习预测模型受焊接接头的几何形状的影响小,可适用于不同焊接形式下的焊接接头疲劳寿命的预测。

## 2.3 影响因素重要度排序

在RF中,每棵树是基于某个特征切分得到的。因此,特征重要性可以通过计算每个特征在所有树中切分样本时的信息增益或减少的不纯度来确定。通过RF算法计算得出焊接接头影响因素重要度排序结果如图9所示。从图中可见,应力幅是影响焊接接头

疲劳寿命最重要的因素,且应力幅值越大,焊接接头的疲劳寿命越低,其次影响疲劳寿命的因素依次为  $K_t$ 、样本 ID、应力比和试件厚度,而受本文数据的限制,在拉伸和弯曲 2 种加载形式下的试验加载方式对疲劳强度的影响较小。其中,样本 ID、 $K_t$ 、试件厚度和接头类型均为与焊接接头几何特征相关的输入特征。




图9 焊接接头影响因素重要度排序

## 2.4 验证预测模型的泛化性能

对 2 种低合金结构钢 E32 和 E36 的焊接接头疲劳数据进行训练和验证<sup>[35]</sup>。预测寿命与实际寿命间的离散关系如图 10 所示。从图中可见,预测结果与试验数据间具有良好的相关性,数据点几乎均位于 2 倍分散系数以内,且均匀地分布在  $y = x$  线的两侧。与非合金钢材料的预测结果相比,低合金钢材料的疲劳寿命预测结果均位于 3 倍误差范围以内,而在非合金钢材料的疲劳寿命预测结果中则有部分数据点位于 3 倍误差范围外。




图10 低合金钢的疲劳寿命预测结果

综上所述表明,本文所建立的基于机器学习的焊接接头疲劳寿命预测模型,对不受接头形状影响的低合金钢的疲劳寿命数据同样适用,可用于不同材料的焊接接头的疲劳寿命的预测。

## 3 结论

(1) 2 种机器学习算法模型对非合金钢的焊接接头疲劳寿命具有良好的预测能力。其中,RF 模型的预测结果更接近试验值。

(2) 机器学习预测模型受焊接接头的几何形状对疲劳寿命的影响小,在不同焊接形式下的疲劳寿命预测结果均较为接近,说明机器学习模型适用于不同几何形状下的焊接接头疲劳寿命的预测。

(3) 从输入条件的重要度排序结果分析,施加在焊接接头上的应力幅对其疲劳寿命的影响最大。此外, $K_t$ 、应力比和试件厚度也会影响疲劳性能。而与

焊接接头几何形状有关的输入条件对疲劳寿命的影响较小。

(4) 本文所建立的机器学习模型适用于非合金钢的焊接接头疲劳寿命预测,在低合金钢的焊接接头疲劳寿命预测工作中也具有较高的准确性,模型的泛化能力较好,可用于预测在不同材料下的焊接接头的疲劳寿命。

尽管如此,本研究仍具有一些局限性。焊接接头的疲劳数据集主要考虑几何形状的差异而不具有广泛性,需广泛地进行疲劳试验,针对焊接接头的特点,应考虑焊接工艺、应力集中、残余应力和尺寸效应因素的影响,以获得更全面的分析结果。此外,也可以采用断裂力学和损伤力学的方法对焊接接头的疲劳寿命数值求解,将计算结果用于机器学习模型的训练,以获得预测性能更优的焊接接头机器学习模型。

### 参考文献:

- [1] 王晓锋,郭长青,李子龙. 循环载荷下钢结构焊接接头的疲劳失效分析[J]. 山西建筑,2009,35(17):63-64.  
WANG Xiaofeng, GUO Changqing, LI Zilong. Fatigue failure analysis of steel structure welded joint under cyclic loading[J]. Shanxi Architecture, 2009, 35(17): 63-64. (in Chinese)
- [2] Lee C, Chang K, Jang G, et al. Effect of weld geometry on the fatigue life of non-load-carrying fillet welded cruciform joints[J]. Engineering Failure Analysis, 2009, 16(3): 849-855.
- [3] Guha B. Effect of specimen geometry on fatigue of welded joints[J]. Engineering Fracture Mechanics, 1993, 46(1): 35-39.
- [4] Chiocca A, Frendo F, Aiello F, et al. Influence of residual stresses on the fatigue life of welded joints. numerical simulation and experimental tests[J]. International Journal of Fatigue, 2022, 162(9): 106901.
- [5] Hobbacher A F. New developments at the recent update of the IIW recommendations for fatigue of welded joints and components[J]. Steel Construction, 2010, 3(4): 231-242.
- [6] Arcari A, Vita R D, Dowling N E. Mean stress relaxation during cyclic straining of high strength aluminum alloys[J]. International Journal of Fatigue, 2009, 31(11): 1742-1750.
- [7] Nasiri S, Khosravani M R, Weinberg K. Fracture mechanics and mechanical fault detection by different methods of artificial intelligence : a review[J]. Engineering Failure Analysis, 2017, 81(11): 270-293.
- [8] Lukić M, Cremona C. Probabilistic optimization of welded joints maintenance versus fatigue and fracture[J]. Reliability Engineering and System Safety, 2001, 72(3): 253-264.
- [9] Yuan D, Cui C, Zhang Q, et al. Fatigue damage evaluation of welded joints in steel bridge based on meso-damage mechanics[J]. International Journal of Fatigue, 2022, 161(8): 106898.
- [10] Kang G Z, Luo L L. Review on fatigue life prediction models of welded

- joint[J]. *Acta Mechanica Sinica*, 2020, 36(3): 701–726.
- [11] 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(17): 108813.
- [12] Li J, Yang Z, Qian G, et al. Machine learning based very-high-cycle fatigue life prediction of Ti-6Al-4V alloy fabricated by selective laser melting[J]. *International Journal of Fatigue*, 2022, 158(5): 106764.
- [13] Braun M, Kellner L, Schreiber S, et al. Prediction of fatigue failure in small-scale butt-welded joints with explainable machine learning[J]. *Procedia Structural Integrity*, 2022, 38(4): 182–191.
- [14] 罗晓牧. 浅谈如何从程序开发的角度入门机器学习[J]. *电子世界*, 2016(8): 34–35.  
LUO Xiaomu. An introduction to machine learning from a program development perspective[J]. *Electronics World*, 2016(8): 34–35. (in Chinese)
- [15] 王业辉. TC4 钛合金超声喷丸强化残余应力数值模拟分析[J]. *航空发动机*, 2019, 45(3): 58–64.  
WANG Yehui. Numerical simulation analysis of residual stress in ultrasonic shot peening of TC4 Titanium alloy[J]. *Aeroengine*, 2019, 45(3): 58–64. (in Chinese)
- [16] Pedersen M M, Mouritsen O, Hansen M R, et al. Re-analysis of fatigue data for welded joints using the notch stress approach[J]. *International Journal of Fatigue*, 2010, 32(10): 1620–1626.
- [17] Toyohide W. Document analysis and recognition[J]. *IEICE Transactions on Information and Systems*, 1999, E82-D(3): 601–610.
- [18] Boinee P, Angelis A D, Foresti G L. Meta random forests[J]. *International Journal of Computational Intelligence*, 2005, 2(3): 138–147.
- [19] Boulicaut J F, Esposito F, Giannotti F, et al. Machine learning: ECML 2004: 15th european conference on machine learning, Pisa, Italy, September 2004, Proceedings [M]. Germany: Springer, 2004: 58–63.
- [20] Lee S L A, Kouzani A Z, Hu E J. Random forest based lung nodule classification aided by clustering[J]. *Computerized Medical Imaging and Graphics*, 2010, 34(7): 535–542.
- [21] Ke G, Meng Q, Finley T, et al. LightGBM: a highly efficient gradient boosting decision tree[C]// In Proceedings of the 31st International Conference on Neural Information Processing Systems (NIPS'17). New York: Red Hook Curran Associates Inc., 2017: 3149–3157.
- [22] Yang S, Zhang H. Comparison of several data mining methods in credit card default prediction[J]. *Intelligent Information Management*, 2018, 10(5): 115–122.
- [23] Yang S. Prediction method of remaining service life of Li-ion batteries based on XGBoost and LightGBM[C]// 2022 2nd International Conference on Algorithms, High Performance Computing and Artificial Intelligence (AHPICAI). Guangzhou: IEEE Press, 2022: 324–327.
- [24] Wang T, Wang D, Huo L, et al. Discussion on fatigue design of welded joints enhanced by ultrasonic peening treatment (UPT) [J]. *International Journal of Fatigue*, 2009, 31(4): 644–650.
- [25] Ohta A, Suzuki N, Maeda Y. Shift of S-N curves with stress ratio[J]. *Welding in the World*, 2003, 47(1): 19–24.
- [26] Kudryavtsev Y, Kleiman J, Lugovskoy A, et al. Rehabilitation and repair of welded elements and structures by ultrasonic peening[J]. *Welding in the World*, 2007, 51(7): 47–53.
- [27] Statnikov E S, Muktepavel V O, Blomqvist A. Comparison of ultrasonic impact treatment (UIT) and other fatigue life improvement methods[J]. *Welding in the World*, 2002, 46(3–4): 20–32.
- [28] Galtier A, Statnikov E S. The influence of ultrasonic impact treatment on fatigue behaviour of welded joints in high-strength steel[J]. *Welding in the World*, 2004, 48(5): 61–66.
- [29] Pedersen M M, Mouritsen O, Hansen M R, et al. Comparison of post-weld treatment of high-strength steel welded joints in medium cycle fatigue[J]. *Welding in the World*, 2010, 54(7): R208–R217.
- [30] Lagerqvist O, Clarin M, Gozzi J, et al. Efficient lifting equipment with extra high-strength steel[J]. *EUR*, 2007, 22569: 1–89.
- [31] Ohta A, Maeda Y, Suzuki N. Residual stress effect on fatigue strength of non-load-carrying cruciform welded joints of SM570Q steel for welded structures[J]. *Welding in the World*, 2002, 46(11): 20–25.
- [32] Martinez L L, Blom A F. Influence of life improvement techniques on different steel grades under fatigue loading[J]. *European Structural Integrity Society*, 1997, 22(1): 175–191.
- [33] Dimitrakis S D, Lawrence F V. Improving the fatigue performance of fillet weld terminations[J]. *Fatigue and Fracture of Engineering Materials and Structures*, 2001, 24(6): 429–438.
- [34] Mori T, Inomata T, Hirayama S. Influence of grinding method on fatigue strength of out-of-plane gusset welded joints[J]. *Steel Construction Engineering*, 2004, 11(42): 55–62.
- [35] 王永达, 谢仕柜. 低合金钢焊接基本数据手册[M]. 北京: 冶金工业出版社, 1998: 19–69.  
WANG Yongda, XIE Shigui. Basic data sheet for welding of low alloy steel[M]. Beijing: Metallurgical Industry Press, 1998: 19–69. (in Chinese)

(编辑: 贺红井)