

DOI:10.16356/j.1005-2615.2024.06.017

基于 SVR 的 2195 铝锂合金 FSW 接头 疲劳裂纹扩展寿命预测

魏岩¹, 王芳丽^{1,2}, 陈吉昌¹, 聂小华^{3,4}, 常亮^{3,4}, 童明波¹

(1. 南京航空航天大学航空学院, 南京 210016; 2. 金陵科技学院机电工程学院, 南京 211169; 3. 中国飞机强度研究所强度与结构完整性全国重点实验室, 西安 710065; 4. 中国飞机强度研究所结构冲击动力学航空科技全国重点实验室, 西安 710065)

摘要: 为了对搅拌摩擦焊 (Friction stir welding, FSW) 焊接结构进行快速准确的裂纹扩展寿命预测, 提出了一种基于支持向量回归 (Support vector regression, SVR) 的 2195 铝锂合金 FSW 接头疲劳裂纹扩展寿命预测方法。首先, 通过疲劳裂纹扩展试验和有限元仿真得到 Paris 裂纹扩展模型常数及裂纹尖端应力强度因子数据集; 然后基于 SVR 模型建立应力强度因子预测模型, 并采用粒子群优化 (Particle swarm optimization, PSO) 算法优化 SVR 模型的超参数; 最后, 基于构建的应力强度因子预测模型和 Paris 模型进行裂纹扩展寿命预测。结果表明: 优化后的 PSO-SVR 模型能够快速、准确地预测裂纹尖端应力强度因子, 在测试集上的决定系数 R^2 可以达到 0.999 5, 高于未优化 SVR 模型的 0.954; 该方法裂纹扩展寿命预测结果与有限元仿真结果进行对比, 最大误差小于 5%, 验证了方法的准确性。

关键词: 2195 铝锂合金; 搅拌摩擦焊; 支持向量回归; 裂纹扩展; 寿命预测

中图分类号: O346.1

文献标志码: A

文章编号: 1005-2615(2024)06-1134-09

Prediction of Fatigue Crack Propagation Life of 2195 Aluminum-Lithium Alloy FSW Joints Based on SVR

WEI Yan¹, WANG Fangli^{1,2}, CHEN Jichang¹, NIE Xiaohua^{3,4}, CHANG Liang^{3,4}, TONG Mingbo¹

(1. College of Aerospace Engineering, Nanjing University of Aeronautics & Astronautics, Nanjing 210016, China;

2. School of Mechanical and Electrical Engineering, Jinling Institute of Technology, Nanjing 211169, China;

3. National Key Laboratory of Strength and Structural Integrity, Aircraft Strength Research Institute of China, Xi'an 710065, China; 4. Aviation Key Laboratory of Science and Technology on Structural Impact Dynamics, Aircraft Strength Research

Institute of China, Xi'an 710065, China)

Abstract: In order to efficiently and accurately predict the crack propagation life of friction stir welding (FSW) welded structures, a fatigue crack propagation life prediction method for 2195 aluminum-lithium alloy FSW joints based on support vector regression (SVR) is proposed. Firstly, the Paris crack propagation model constants and the crack tip stress intensity factor dataset are obtained by the fatigue crack growth test and the finite element simulation. Then a stress intensity factor prediction model is established based on the SVR model, and the hyperparameters of the SVR model are optimized by the particle swarm optimization (PSO) algorithm. Finally, the crack propagation life is predicted based on the stress intensity factor prediction model and the Paris model. The results show that the optimized PSO-SVR model can effectively predict the crack

基金项目: 航空科学基金项目 (20230009052004)。

收稿日期: 2024-07-14; **修订日期:** 2024-10-11

通信作者: 童明波, 男, 教授, 博士生导师, E-mail: tongw@nuaa.edu.cn。

引用格式: 魏岩, 王芳丽, 陈吉昌, 等. 基于 SVR 的 2195 铝锂合金 FSW 接头疲劳裂纹扩展寿命预测[J]. 南京航空航天大学学报, 2024, 56(6): 1134-1142. WEI Yan, WANG Fangli, CHEN Jichang, et al. Prediction of fatigue crack propagation life of 2195 aluminum-lithium alloy FSW joints based on SVR[J]. Journal of Nanjing University of Aeronautics & Astronautics, 2024, 56(6): 1134-1142.

tip stress intensity factor, and the determination coefficient R^2 on the test set can reach 0.999 5, which is higher than 0.954 of the unoptimized SVR model. The prediction results of crack propagation life by the proposed method are compared with those by the finite element simulation. The maximum error is less than 5%, verifying the accuracy of the method.

Key words: 2195 aluminum-lithium alloy; friction stir welding (FSW); support vector regression (SVR); crack propagation; life prediction

铝锂合金是一种将金属锂作为合金材料添加到铝中的合金,其中2195铝锂合金具有高比强度、高比模量、良好的耐腐蚀性能和卓越的超塑性等综合性能成为当前航空航天工业中最具有竞争力的金属结构之一^[1-2]。

相较于传统的TIG、MIG熔化焊,采用搅拌摩擦焊(Friction stir welding, FSW)焊接的铝合金性能更高,且不会产生气孔、夹杂等缺陷,更能满足航空航天领域的焊接结构性能要求^[3-5]。FSW在焊接时,焊接接头受到摩擦热、机械搅拌以及轴间挤压的作用,导致焊缝区域内部的组织呈非均匀分布,同时在焊缝前进侧和后退侧出现钩状缺陷^[6]。在裂纹扩展过程中,接头受力会形成较大的应力集中,进而影响材料的裂纹扩展寿命。因此,众多学者对FSW接头的疲劳裂纹扩展进行了研究。Tra等^[7]研究了AA6063-T5铝合金FSW接头的疲劳裂纹扩展行为,发现非均匀的微观结构对裂纹扩展行为影响显著。Dai等^[8]研究了AA6N01铝合金FSW接头不同区域的裂纹扩展速率,发现焊核区的疲劳裂纹扩展速率最高。Sivaraj等^[9]研究了AA-7075-T651铝合金FSW接头的疲劳裂纹扩展行为,发现FSW焊接接头的疲劳寿命明显低于母材。王磊等^[10]研究了2024-T4铝合金FSW接头的疲劳裂纹扩展行为,并通过有限元仿真建立了不同区域的裂纹扩展寿命预测模型,结果验证了FSW接头分区建模的合理性与准确性。

利用有限元仿真建立FSW接头裂纹扩展寿命预测模型是目前主流的研究方法,然而该方法存在计算效率低,预测速率达不到实际需求等问题。随着人工智能技术的快速发展,由数据驱动的机器学习算法被广泛应用于裂纹扩展的研究中。Raja等^[11]利用低温轧制的2014铝合金的疲劳裂纹扩展试验数据,采用多项式曲线拟合法与机器学习方法中的反向传播算法BPNN、极限学习机ELM算法研究了 da/dN 与 ΔK 之间的关系,结果表明ELM在训练时间上最优,BPNN具有最佳的局部优化能力。廖贞等^[12]采用遗传小波神经网络对疲劳短裂纹扩展规律进行分析,在两种加载频率下进行试验,并进行试样有效短裂纹密度和主导有效短裂纹扩展速率计算,结果表明遗传小波神经网络应用于

疲劳短裂纹演化行为研究具有合理性和有效性。梅金娜等^[13]基于TPE-XGboost算法研究应力强度因子幅 ΔK 、屈服强度、温度、裂纹扩展方向等因素对裂纹扩展速率 da/dN 的影响,最终建立了多维数据关联的镍基600合金腐蚀疲劳裂纹扩展速率预测模型。

综上所述,大多数学者还是利用试验数据作为机器学习模型的训练集。虽然这有利于获得较高精度的模型,但FSW焊接接头的疲劳裂纹扩展试验难度大、成本高等问题导致试验数据量少,难以准确预测FSW焊接结构的寿命。为了对FSW焊接结构进行快速准确的裂纹扩展寿命预测,有必要提出一种成本更低的寿命预测方法,这对于航空航天设备的可靠性评估、损伤容限设计等具有重要的工程应用价值。因此,本文借助于SVR模型优秀的数据拟合能力提出了一种融合试验数据和仿真数据的2195铝锂合金FSW接头疲劳裂纹扩展寿命预测方法。首先,通过疲劳裂纹扩展试验结果得到Paris裂纹扩展速率模型常数;然后利用仿真结果训练SVR模型得到裂纹尖端应力强度因子预测模型,为了提高预测精度,采用PSO算法优化SVR模型的超参数;最后通过Paris机理模型和机器学习模型实现疲劳裂纹扩展寿命的高精度、低成本预测效果。

1 构建疲劳裂纹扩展预测模型

1.1 支持向量回归

支持向量机(Support vector machine, SVM)^[14]是一种解决可分离二分问题的机器学习方法,该算法通过核函数将低维非线性数据映射到多维线性空间,在该多维空间里构建一个最优超平面,对特征空间的所有样本进行划分,离最优超平面最近的样本点称为支持向量,通过支持向量可以计算最优超平面两侧的超平面 α_1 、 α_2 。 α_1 、 α_2 之间的距离越大,分类效果越可靠。

SVM应用于回归问题时又称为支持向量回归(Support vector regression, SVR),该算法的目的是寻找一个离所有样本点最近的回归超平面。SVR仅需较少的样本数据就能获得最佳预测效果,一定程度上解决了过拟合和局部极值等问题,

广泛应用于模式识别、图像处理、故障检测等领域。SVR根据任务类型又分为线性回归和非线性回归,以下对非线性回归的原理进行详细的阐述。

对于给定样本训练集: $T = \{(x_1, y_1), (x_2, y_2), \dots, (x_N, y_N)\}$, N 为训练样本个数, x_i 和 y_i 分别对应第 i 个样本的样本点和响应值, SVR通过一个非线性映射函数 $\phi(x)$, 将样本点 x 映射到一个高维线性空间, 该过程表达式如下

$$f(x) = \omega\phi(x) + b \quad (1)$$

式中: $f(x)$ 为回归超平面; ω 为回归超平面的权重系数; b 为偏置系数。

由于 ω 过大会造成回归超平面出现过拟合现象, 引入 Euclidean 范数约束 ω 系数后, 寻找最佳回归超平面 $f(x)$ 的过程就可以表示为如下所示的凸二次规划问题

$$\min \frac{1}{2} \|\omega\|^2 \quad (2)$$

$$\text{s.t.} \begin{cases} y_i - (\omega\phi(x_i) + b) \leq \epsilon \\ (\omega\phi(x_i) + b) - y_i \leq \epsilon \end{cases}$$

式中 ϵ 为不敏感损失因子。为了控制式(2)中的其他不可行约束引入惩罚因子 C 和松弛变量 ξ_i, ξ_i^* , 式(2)则变为

$$\min \frac{1}{2} \|\omega\|^2 + C \sum_{i=1}^N (\xi_i + \xi_i^*) \quad (3)$$

$$\text{s.t.} \begin{cases} y_i - (\omega\phi(x_i) + b) \leq \epsilon + \xi_i \\ (\omega\phi(x_i) + b) - y_i \leq \epsilon + \xi_i^* \\ \xi_i, \xi_i^* \geq 0; i = 1, 2, \dots, N \end{cases}$$

为了便于计算, 引入拉格朗日乘子将式(3)转换为其对偶问题

$$\max -\frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N (\alpha_i - \alpha_i^*) (\alpha_j - \alpha_j^*) K(x_i, x_j) - \epsilon \sum_{i=1}^N (\alpha_i + \alpha_i^*) + \sum_{i=1}^N y_i (\alpha_i - \alpha_i^*) \quad (4)$$

$$\text{s.t.} \sum_{i=1}^N (\alpha_i - \alpha_i^*) = 0 \quad \alpha_i, \alpha_i^* \in [0, C]$$

式中: α_i, α_i^* 为拉格朗日乘数参数, $K(x_i, x_j)$ 为核函数。

通过对该对偶问题进行求解, $f(x)$ 在高维线性空间内可被表示为

$$f(x) = \sum_{i=1}^N (\alpha_i - \alpha_i^*) K(x, x_i) + b \quad (5)$$

本文选取对非线性数据处理能力好, 应用广泛的径向基核函数(Radial basis function, RBF)作为核函数, 函数形式如下

$$K(x, x_i) = \exp(-\gamma \|x - x_i\|^2) \quad (6)$$

式中: $\gamma = 2\sigma^{-2}$ 为核参数, σ 为带宽参数。

在SVR模型中, 惩罚因子 C 、不敏感损失因子 ϵ 和核参数 γ 是影响其回归精度的主要超参数。合理的参数选择才能获得高精度的SVR模型, 因此本文采用粒子群算法对这3个参数进行寻优。

1.2 PSO超参数优化

超参数优化是机器学习建模的核心步骤。超参数是指在模型训练前需要设置的一类变量, 对模型的性能和行为起关键性作用。目前对SVR参数进行优化的方法主要有试凑法、网格搜索法和智能优化算法。试凑法依赖于个人经验, 具有很强的主观性; 网格搜索本质上是对参数空间所有组合方式的一种穷举法, 容易陷入局部最优解; 智能优化算法中使用较多的是遗传算法, 遗传算法在处理高维数据时有一定的限制, 算法的预测精度和收敛速度会随着维度的增加而产生较大的影响。相较于其他算法而言, 粒子群算法操作简单、所需参数少、收敛速度快, 且具有很强的全局搜索能力。综上所述, 本文采用粒子群优化(Particle swarm optimization, PSO)算法为SVR模型进行超参数优化, 改善模型的预测精度。

PSO算法是依据鸟类捕食行为提出的一种全局随机智能搜索算法, 其利用群体中个体粒子的信息共享, 使整个群体的运动将无序发展转变到有序发展, 最终找到问题的最优解^[15]。PSO算法的每个粒子都有位置、速度和适应度3个参数, 在每一轮迭代过程中, 粒子通过自身历史最佳位置 p_{best} 和群体的历史最佳位置 g_{best} 来更新当前的速度和位置, 直至收敛到最优解。在本文中, 粒子位置为SVR模型中的惩罚因子 C 、不敏感损失因子 ϵ 和核参数 γ ; 粒子适应度为该位置坐标下SVR模型的精度; 粒子速度决定了该粒子飞行的方向和距离。

假设 $X = (X_1, X_2, \dots, X_N)$ 表示大小为 N 的种群, $X_i = (x_{ic}, x_{ie}, x_{iy})$ 和 $V_i = (v_{ic}, v_{ie}, v_{iy})$ 分别表示第 i 个粒子的位置和速度, 则粒子的速度和位置的更新公式如下

$$\begin{cases} V_i^{k+1} = \omega V_i^k + c_1 r_{i1}^k (p_{\text{best}, i}^k - X_i^k) + c_2 r_{i2}^k (g_{\text{best}}^k - X_i^k) \\ X_i^{k+1} = X_i^k + V_i^{k+1} \end{cases} \quad (7)$$

$$i = 1, 2, \dots, N$$

式中: V_i^{k+1} 表示第 $k+1$ 次迭代时第 i 个粒子的速度, 粒子的初始化速度为0; ω 为惯性权重, 用于控制全局搜索和局部寻优能力; c_1 为个体加速度常数, 用于模拟个体本身的加速度, 一般取 $[0, 4]$ 之间; c_2 为种群加速度常数, 用于模拟个体对种群跟随的加速度, 一般也取 $[0, 4]$ 之间; r_{i1}^k 和 r_{i2}^k 为正态分布的随机数, 范围为 $[0, 1.0]$, 用于增加粒子速度的随机性, 避免陷入局部最优解; $p_{\text{best}, i}^k$ 为截止到第

k 次迭代,第 i 个粒子的历史最佳位置; g_{best}^k 为截止到第 k 次迭代,种群的历史最佳位置; X_i^k 为第 k 次迭代时第 i 个粒子的位置。

1.3 裂纹扩展预测模型的建立

依据本文构建的裂纹扩展预测模型可基于疲劳裂纹扩展试验所得的Paris模型,以及ABAQUS和FRANC3D联合仿真所得的裂纹尖端应力强度因子数据集,来预测2195铝锂合金FSW焊接接头的裂纹扩展寿命。因此建立的模型如图1所示,由裂纹扩展试验、有限元仿真和构建机器学习模型3个部分组成。

第一步,预制裂纹后开展疲劳裂纹扩展试验,获取试验数据,通过试验数据和其对应的裂纹应力强度因子理论解拟合得到Paris裂纹扩展模型常数。

第二步,在ABAQUS软件中建立与MT试验件对应的仿真模型。考虑到FSW焊缝区域和母材区的不同,对MT试验件进行分区建模并添加材料属性。还要建立接触和绑定关系、划分网格、设置约束和载荷的添加。再导入到FRANC3D中插入裂纹、重新划分网格、计算应力强度因子、扩展裂纹,收集应力强度因子作为数据集用于训练代理模型。

第三步,提取不同载荷加载下裂纹扩展仿真得到的数据,数据包括两个输入量(载荷大小 P 、裂纹长度 a)与一个输出量(应力强度因子 K),其中输出

结果 K 应根据裂纹扩展形式选择不同的应力强度因子。采用式(8)将数据标准化,以消除不同量级的特征数据对模型训练的影响。

$$X_i = \frac{x_i - \bar{x}}{\sigma(x)} \quad (8)$$

式中: \bar{x} 为特征数据的均值; $\sigma(x)$ 为特征数据的标准差, X_i 为标准化后的数据。

将标准化后的数据随机选择75%作为模型训练集,剩下的25%作为模型测试集,将其导入初始化后的机器学习模型进行训练。在训练过程中,通过超参数优化算法不断改变机器学习模型的参数以获得最优应力强度因子预测模型。

第四步,将前面得到的裂纹扩展速率模型和应力强度因子预测模型进行融合,得到最终的2195铝锂合金FSW焊接接头疲劳裂纹扩展寿命预测模型。进行裂纹扩展时,首先将裂纹扩展数据初始化后插入初始裂纹;然后由应力强度因子预测模型根据载荷大小、裂纹长度计算出相应的裂纹尖端应力强度因子;再利用Paris公式计算出裂纹扩展速率,并通过式(9)进行裂纹扩展,直到应力强度因子达到断裂韧度为止;最后得到完整的裂纹扩展寿命。

$$\begin{cases} a_k = a_{k-1} + \Delta a \\ N_k = N_{k-1} + \frac{\Delta a}{da/dN|_{a_{k-1}}} \end{cases} \quad (9)$$

式中: a_k 为第 k 个裂纹扩展步下的裂纹长度; Δa 为裂纹扩展增长步长; N_k 为第 k 个裂纹扩展步下的疲劳寿命; $da/dN|_{a_{k-1}}$ 为 a_{k-1} 下的裂纹扩展速率。

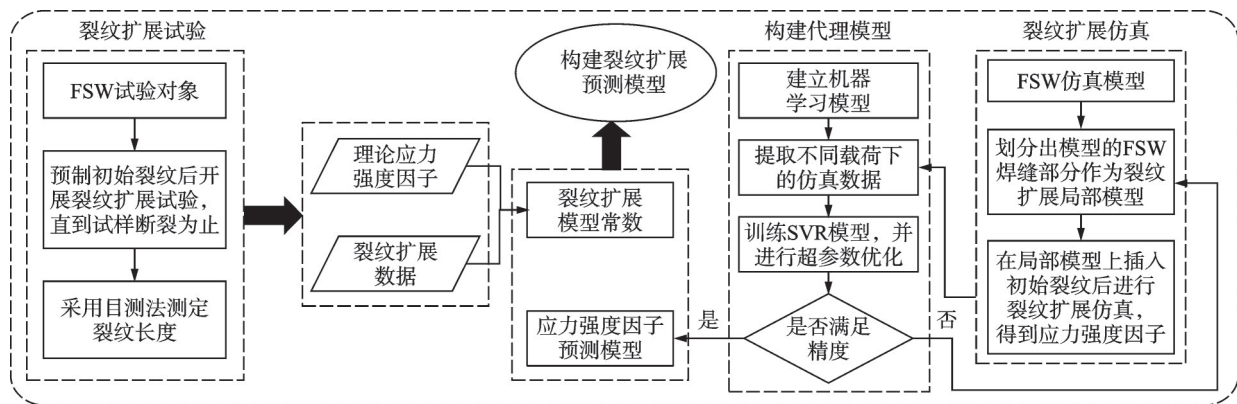


图1 2195铝锂合金FSW接头疲劳裂纹扩展寿命预测模型构建流程

Fig.1 Construction process of fatigue crack propagation life prediction model for 2195 Al-Li alloy FSW joints

1.4 模型评估标准

在建立2195铝锂合金FSW焊接接头裂纹扩展预测模型后,使用模型评估标准来评估该模型的预测能力。本文采用均方误差(Mean squared error, MSE)和决定系数 R^2 作为模型全局预测精度的评估标准。

$$MSE = \frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2 \quad (10)$$

$$R^2 = 1 - \frac{\sum_{i=1}^N (y_i - \hat{y}_i)^2}{\sum_{i=1}^N (y_i - \bar{y})^2} \quad (11)$$

式中: N 表示样本总数; y_i 表示模型的真实值; \hat{y}_i 表示模型的预测值; \bar{y} 表示真实值的均值。MSE反映了模型的预测值与真实值之间的差值,值越接近0表示模型精度越高。 R^2 反映了模型的预测值与真

实值之间的相关性,值越接近1表示模型精度越高。

2 FSW 焊接接头疲劳裂纹扩展寿命预测试验验证

本文采用 2195 铝锂合金 FSW 焊接接头的 MT 试样的疲劳裂纹扩展试验进行方法验证。

2.1 材料与试样

试验材料选用 2195 铝锂合金,采用搅拌摩擦焊具实施焊接,材料的化学成分如表 1 所示。该材料标准件的抗拉强度为 608 MPa、屈服强度为 442 MPa,焊接件的抗拉强度为 568 MPa、屈服强度为 320 MPa。

表 1 2195 铝锂合金化学成分表(质量分数)

Table 1 Chemical composition of 2195 Al-Li alloy (mass fraction) %							
Cu	Li	Ag	Fe	Mg	Zr	Ti	Al
3.52	1.07	0.43	0.29	0.27	0.21	0.11	余量

按照《航空材料力学性能检测》^[16]中的试验标准要求设计和加工疲劳试验试样,铝锂合金标准件疲劳裂纹扩展试验采用标准中心裂纹拉伸(Middle crack tension, MT)试样,选取 MT 试样尺寸为 280 mm × 70 mm × 6 mm。试样的具体尺寸如图 2 所示,其中阴影部分为 FSW 焊缝。




图 2 MT 试样尺寸示意图

Fig.2 Schematic of MT specimen

2.2 疲劳裂纹扩展试验

试验在室温环境下采用 MTS 液压伺服疲劳试验机进行,在正式试验前,疲劳试样先在 10 Hz 频率下预制 1~2 mm 裂纹消除由机械加工而引起的残余应力。预制裂纹结束后,开展正式裂纹扩展试验,试验采用正弦恒幅载荷谱进行加载,应力比 $R=0.1$,频率 $f=10$ Hz,取 2195 铝锂合金搅拌摩擦焊接头屈服强度的 25% 为峰值载荷。使用目测法测定裂纹长度,其裂纹长度 a 和疲劳寿命 N 的 $a-N$ 曲线如图 3 所示。随着循环次数 N 的增长,裂纹的扩展越来越快,当循环次数达到近 50 000 次时,试验件断裂失效,试验结束。

《航空材料力学性能检测》^[16]中规定,中心裂




图 3 裂纹扩展 $a-N$ 曲线

Fig.3 $a-N$ curve of crack propagation

纹拉伸试样的应力强度因子幅 ΔK 的计算公式如式(12)所示,将试验所得到的结果分别采用七点递增多项式法和式(12)进行处理,得到疲劳裂纹扩展速率 da/dN 和应力强度因子幅 ΔK 。

$$\Delta K = (1 - R) K_{I, \max} = (1 - R) \frac{P_{\max}}{B} \sqrt{\frac{\pi a}{2W}} \sec \frac{\pi a}{2} \quad (12)$$

式中: a 为裂纹长度, W 为有效试样宽度,定义 $\alpha = 2a/W$; $K_{I, \max}$ 为交变载荷中最大载荷应力强度因子; R 为应力比; P_{\max} 为试验施加最大载荷; B 为试样厚度。

Paris公式是裂纹扩展分析中应用最为广泛的裂纹扩展速率模型,在该公式中疲劳裂纹扩展速率 da/dN 和裂纹尖端的应力强度因子幅 ΔK 存在如下规律

$$\frac{da}{dN} = C (\Delta K)^m \quad (13)$$

式中 C 和 m 均为材料参数。对式(13)等式两边同时取对数后有

$$\log \left(\frac{da}{dN} \right) = m \log (\Delta K) + \log C \quad (14)$$

将试验所得的 da/dN 和 ΔK 转成对数形式后进行线性拟合,在对数坐标系下裂纹扩展速率曲线如图 4 所示,得到 FSW 焊接接头的 Paris 常数为 $C=7.255 \times 10^{-11}$, $m=2.44$ 。




图 4 疲劳裂纹扩展速率曲线

Fig.4 Fatigue crack propagation rate curves

2.3 应力强度因子数据集

为获取应力强度因子数据集,首先构建MT试样的有限元模型,如图5所示。




图5 MT试样有限元模型

Fig.5 Finite element model of MT specimen

由于FSW焊接区和母材区力学性能不同,因此对有限元模型进行分区处理以赋予母材区和焊接区不同的材料属性。为了节省计算资源,将焊接区作为局部模型导入到FRANC 3D中,并在中心孔两侧缺陷上插入初始裂纹进行裂纹扩展仿真。

裂纹按照位移特点、受力形式分为I型(张开型)裂纹、II型(滑移型)裂纹和III型(撕开型)裂纹,试验采用的MT试样产生的裂纹为I型裂纹,因此本文只考虑I型裂纹尖端应力强度因子 K_I 。FRANC 3D一般采用 M -积分计算应力强度因子,即

$$M^{1,2} = \int_{\Gamma} \left(\sigma_{ij}^1 \frac{\partial u_i^2}{\partial x_i} + \sigma_{ij}^2 \frac{\partial u_i^1}{\partial x_i} \right) \frac{\partial q}{\partial x_j} ds - \int_{\Gamma} (W_s^{1,2} \delta_{ij}) \frac{\partial q}{\partial x_j} ds \quad (15)$$

式中: Γ 为裂纹尖端积分路径; W_s 为应变能密度因子; q 为中间变量; σ_{ij} 为应力; u_{ij} 为位移; δ_{ij} 为应变;1,2表示 x 、 y 方向。

I型裂纹尖端应力强度因子为

$$M^{1,2} = \frac{1 - \nu^2}{E} K_I^1 K_I^2 \quad (16)$$

式中: ν 为泊松比; E 为弹性模量。

为了验证仿真模拟的准确性,将应力强度因子的仿真结果与理论解进行对比,其中MT试样的 K_I 理论解如式(12)所示。由于应力强度因子只和外形、裂纹以及载荷有关,在本文中外形已经确定的情况下选择载荷大小和裂纹长度作为设计变量。其中载荷范围为20~40 kN;初始裂纹长度为8.3 mm,最大裂纹长度为达到断裂韧度时的裂纹长度。采用ABAQUS和FRANC 3D联合仿真计算得到500个样本点,将计算得到的裂纹尖端应力强度因子与理论计算结果进行对比,结果如图6所示。

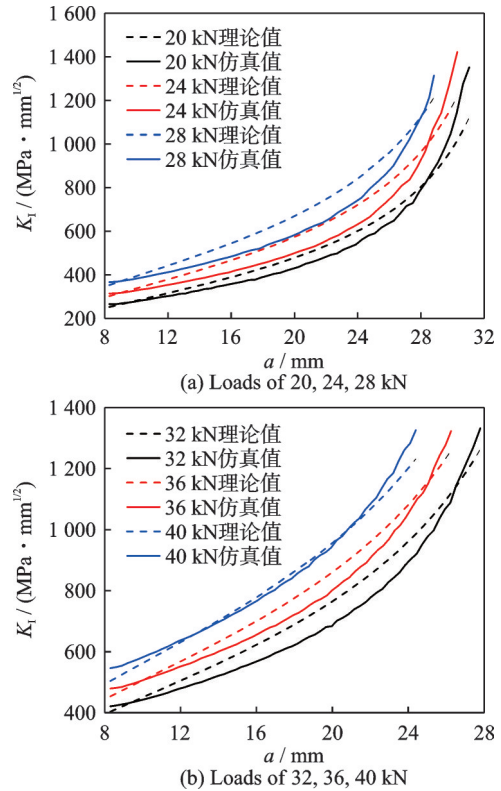


图6 裂纹尖端应力强度因子仿真与理论解比较

Fig.6 Comparison of crack tip stress intensity factors between simulation and theoretical loads

在所有载荷下,理论计算结果和有限元仿真的相对误差基本都在10%以下,处在合理的范围内。造成误差的主要原因是FRANC 3D每次扩展裂纹后都会重新划分局部模型的网格,可能造成裂纹尖端处的网格精度降低、网格单元出现变形。其次理论计算和仿真计算采用了不同的公式,这也在一定程度上产生了误差。但由于理论与仿真结果的相对误差较小,因此可以利用FRANC 3D计算的应力强度因子作为训练机器学习模型的数据集。

2.4 焊接接头裂纹扩展寿命预测

将仿真得到的样本数据按照载荷大小划分为6组,每组划分25%作为测试集,其余数据作为训练集。为了避免发生过拟合现象,将数据进行标准化处理后训练SVR模型。在经过20次迭代优化后,得到应力强度因子预测模型,其中PSO算法参数、未优化的SVR模型及PSO-SVR模型的超参数如表2所示。

采用不同载荷下的测试集分别测试未进行优化的SVR模型和优化后的PSO-SVR模型,图7为优化前后SVR模型预测结果的对比。其中,SVR和PSO-SVR模型在整个测试集上的预测精度分别为 $MSE=3\ 407.91$ 、 $R^2=0.954$ 和 $MSE=36.5$ 、 $R^2=0.999\ 5$ 。

从图7可以看出,经过PSO算法优化后的PSO-SVR模型相较于SVR模型在预测精度上有

表2 PSO和SVR的超参数设置

Table 2 Hyperparameter configuration for PSO and SVR

算法	超参数名称	值
PSO	粒子位置维度	3
	种群数 N	20
	惯性权重 w	1
	个体加速度常数 c_1	2
	种群加速度常数 c_2	2
SVR	惩罚因子 C	2
	不敏感损失因子 ϵ	0.05
	RBF核参数 γ	0.01
PSO-SVR	惩罚因子 C	3 934.21
	不敏感损失因子 ϵ	0.01
	RBF核参数 γ	1.13

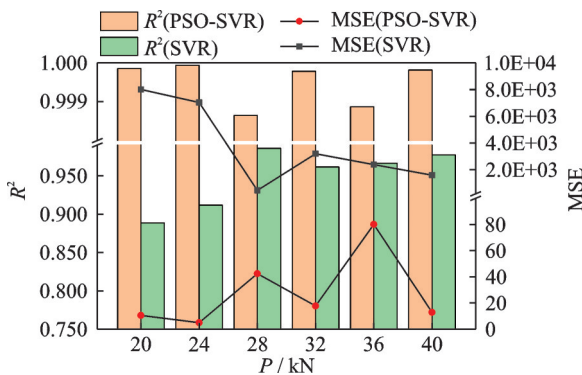



图7 不同载荷下SVR及PSO-SVR的精度对比

Fig.7 Comparison of accuracy for SVR and PSO-SVR under different loads


较大提升。在载荷 $P=24$ kN时,PSO-SVR模型有最高的 R^2 和最低的马塞。

分别采用 PSO-SVR 模型和 SVR 模型构建的应力强度因子预测模型进行疲劳裂纹扩展寿命预测,Paris 模型的参数采用上述试验所得结果。将计算结果与有限元仿真结果进行对比,其中,有限元仿真在计算得到裂纹尖端应力强度因子后采用相同参数的 Paris 模型进行寿命预测。图 8 展示了几种不同载荷加载下 2195 铝锂合金 FSW 接头裂纹扩展 $a-N$ 曲线的两种模型预测值和仿真值。可以看出,采用 PSO-SVR 的裂纹扩展寿命预测模型对 $a-N$ 曲线的捕捉效果很好,在裂纹稳定扩展阶段曲线预测结果十分吻合,进入裂纹快速扩展阶段后,预测值与仿真值对比稍有偏差,但也能准确反映曲线的增长细节。采用未优化 SVR 的裂纹扩展寿命预测模型在裂纹快速扩展阶段与仿真值偏差较大,相对误差在 5%~20% 之间。造成这种情况的主要原因是,在裂纹扩展过程中,需要预测上千次应力强度因子,即使 SVR 模型的预测精度不低,但在上千次预测误差的叠加下,最终得到的裂纹扩展寿命与仿真值也会有不小的误差。由此可以看出,本文提出的裂纹扩展寿命预测方法对应力强度因


子的预测精度有着极高的要求,采用超参数优化技术具有必要性。



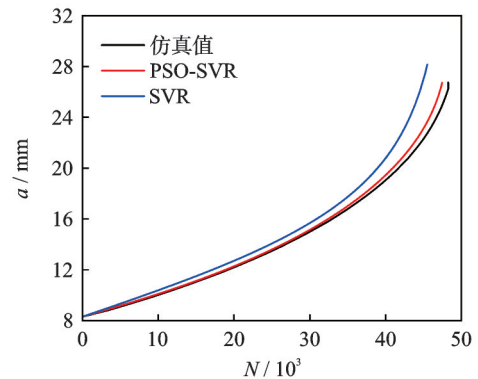
(a) $P=22$ kN, PSO-SVR error=1.53%, SVR error=19.24%



(b) $P=26$ kN, PSO-SVR error=2.87%, SVR error=16.58%



(c) $P=30$ kN, PSO-SVR error=3.34%, SVR error=7.71%



(d) $P=34$ kN, PSO-SVR error=-1.67%, SVR error=-5.74%

图8 PSO-SVR及SVR的 $a-N$ 曲线预测值与仿真值对比

Fig.8 Comparison of predicted and simulated values of PSO-SVR and SVR $a-N$ curves

在得到了具有较高精度的疲劳裂纹扩展寿命预测模型后,为了深入对比本文方法与ABAQUS和FRANC 3D联合仿真结果的预测效果,将两种方法的预测结果与试验结果进行对比。如表3所示,本文方法在裂纹扩展 $a-N$ 曲线上的预测仅耗时0.43 s,而有限元仿真结果的耗时达到了82 min。可以看出,本文方法大幅度提高了2195铝锂合金FSW接头的疲劳裂纹扩展寿命预测的效率。且由于本文方法采用的是试验数据与仿真数据融合的方法进行构建,其成本也远比完全采用试验数据作为训练集的方法更低。

表3 疲劳裂纹扩展寿命预测方法对比

Table 3 Comparison of prediction methods for fatigue crack propagation life

参数	本文方法	ABAQUS+FRANC 3D
设备	AMD R7 6800H	AMD R7 6800H
使用核数	1	12
耗时	0.43 s	82 min

为进一步对比两种方法的预测精度,将两种方法预测的疲劳裂纹扩展寿命结果与试验结果进行比较,结果如图9所示。其中,仿真方法的寿命预测误差为0.5%,本文方法的预测误差为4.9%,精度略低于仿真结果,但仍然能够满足疲劳裂纹扩展寿命的预测精度要求。




图9 疲劳裂纹扩展寿命预测结果对比

Fig.9 Comparison of prediction results of fatigue crack propagation life

3 结 论

(1)为了对FSW焊接结构进行快速准确的裂纹扩展寿命预测,提出了一种融合试验数据和仿真数据的2195铝锂合金FSW接头疲劳裂纹扩展寿命预测方法。首先,通过疲劳裂纹扩展试验结果得到Paris裂纹扩展速率模型;然后利用仿真结果训练SVR模型得到裂纹尖端应力强度因子预测模型,为了提高预测精度,采用PSO算法优化SVR

模型的超参数;通过Paris机理模型和机器学习模型实现疲劳裂纹扩展寿命的高精度、低成本预测效果。

(2)采用ABAQUS和FRANC 3D联合仿真计算所得的裂纹尖端应力强度因子与MT试样的理论解对比,在裂纹长度较小时,仿真结果较低于理论解;但在裂纹长度较大时,尤其是在应力强度因子接近断裂韧度时,仿真结果比理论解更高;由于总体上来说,仿真结果与理论解的相对误差在10%以内,因此可以利用仿真计算的应力强度因子作为训练机器学习模型的数据集。

(3)采用PSO算法优化后的SVR模型相较于优化前的模型具有更高的拟合精度,两种模型在整个测试集上的预测精度分别为 $MSE=3\ 407.91$ 、 $R^2=0.954$ 和 $MSE=36.5$ 、 $R^2=0.999\ 5$ 。采用两种精度的模型进行裂纹扩展时发现,高精度模型的寿命预测误差小于5%,而较低精度的模型预测误差在5%~20%之间。这一结果表明该方法中应力强度因子的预测效果对裂纹扩展寿命预测精度有较大影响。将本文方法与有限元仿真方法进行对比,该方法计算效率远高于有限元方法的同时其相对误差小于5%,验证了方法的准确性和可靠性。

参考文献:

- [1] RIOJA R J, LIU J. The evolution of Al-Li base products for aerospace and space applications[J]. Metallurgical and Materials Transactions A, 2012, 43(9): 3325-3337.
- [2] GUPTA R K, NAYAN N, NAGASIREESHA G, et al. Development and characterization of Al-Li alloys [J]. Materials Science and Engineering: A, 2006, 420(1/2): 228-234.
- [3] 王森, 李天景, 黄婷婷, 等. 6061铝合金FSW接头组织与耐蚀性能的研究[J]. 热加工工艺, 2024(15): 31-34.
WANG Miao, LI Tianjing, HUANG Tingting, et al. Study on microstructure and corrosion resistance of 6061 aluminium alloy friction stir welded joint[J]. Hot Working Technology, 2024(15): 31-34.
- [4] ZHOU C, YANG X, LUAN G. Fatigue properties of friction stir welds in Al 5083 alloy[J]. Scripta materialia, 2005, 53(10): 1187-1191.
- [5] YOKOYAMA T, NAKAI K, SUKEDAI E, et al. Tensile properties and constitutive modeling of friction stir welded AA6061-T6 butt joints[J]. Journal of Solid Mechanics and Materials Engineering, 2011, 5(12): 780-792.
- [6] YIN Y H, SUN N, NORTH T H, et al. Hook formation and mechanical properties in AZ31 friction stir

- spot welds[J]. *Journal of Materials Processing Technology*, 2010, 210(14): 2062-2070.
- [7] TRA T H, OKAZAKI M, SUZUKI K. Fatigue crack propagation behavior in friction stir welding of AA6063-T5: Roles of residual stress and microstructure [J]. *International Journal of Fatigue*, 2012, 43: 23-29.
- [8] DAI Q, LIANG Z, CHEN G, et al. Explore the mechanism of high fatigue crack propagation rate in fine microstructure of friction stir welded aluminum alloy [J]. *Materials Science and Engineering: A*, 2013, 580: 184-190.
- [9] SIVARAJ P, KANAGARAJAN D, BALASUBRAMANIAN V. Fatigue crack growth behaviour of friction stir welded AA7075-T651 aluminium alloy joints [J]. *Transactions of Non-ferrous Metals Society of China*, 2014, 24(8): 2459-2467.
- [10] 王磊, 李东侠, 回丽, 等. 2024-T4 铝合金 FSW 接头疲劳裂纹扩展行为及寿命预测 [J]. *焊接学报*, 2023(4): 77-83, 133-134.
- WANG Lei, LI Dongxia, HUI Li, et al. Fatigue crack propagation behavior and life prediction of 2024-T4 aluminum alloy FSW joints [J]. *Transactions of the China Welding Institution*, 2023(4): 77-83, 133-134.
- [11] RAJA A, CHUKKA S T, JAYAGANTHAN R. Prediction of fatigue crack growth behaviour in ultra-fine grained Al 2014 alloy using machine learning [J]. *Metals*, 2020, 10(10): 1349.
- [12] 廖贞, 杨冰, 秦亚航, 等. 基于遗传小波神经网络的疲劳短裂纹演变规律研究 [J]. *铁道学报*, 2018, 40(5): 66-72.
- LIAO Zhen, YANG Bing, QIN Yahang, et al. Research on evolution behavior of short fatigue crack based on genetic wavelet neural network [J]. *Journal of the China Railway Society*, 2018, 40(5): 66-72.
- [13] 梅金娜, 王鹏, 韩姚磊, 等. 基于 TPE-XGBoost 算法的镍基 600 合金应力腐蚀裂纹扩展速率预测模型 [J]. *稀有金属材料与工程*, 2021, 50(7): 2399-2408.
- MEI Jinna, WANG Peng, HAN Yaolei, et al. Prediction of stress corrosion crack growth rate of Ni-base alloy 600 based on TPE-XGBoost algorithm [J]. *Rare Metal Materials and Engineering*, 2021, 50(7): 2399-2408.
- [14] CORTES C, VAPNIK V. Support-vector networks [J]. *Machine Learning*, 1995, 20: 273-297.
- [15] POLI R, KENNEDY J, BLACKWELL T. Particle swarm optimization: An overview [J]. *Swarm Intelligence*, 2007, 1: 33-57.
- [16] 郭广平, 丁传富. 航空材料力学性能检测 [M]. 北京: 机械工业出版社, 2017.
- GUO Guangping, DING Chuanfu. *Mechanical properties testing of aeronautical materials* [M]. Beijing: Mechanical Industry Press, 2017.

(编辑:夏道家)