

# 基于 KBRF 算法的镍基 690 合金应力腐蚀裂纹扩展速率预测模型

梅金娜, 王 鹏, 韩姚磊, 蔡 振, 遆文新, 彭群家, 薛 飞

(苏州热工研究院有限公司, 江苏 苏州 215004)

**摘 要:** 镍基 690 合金广泛用于压水堆核电站核岛主设备关键部件及焊缝, 高温高压水环境应力腐蚀开裂 (SCC) 是其潜在的失效机理。由于 SCC 行为影响因素多达二十余种, 因此存在参数化模型预测精度不高的问题。本研究通过融合随机森林机器学习算法 (random forest, RF) 与基于领域知识的 MRP-386 参数化模型, 建立了镍基 690 合金 SCC 裂纹扩展速率 KBRF (knowledge-based random forest) 预测模型。结果表明, 领域知识的引入增强了 KBRF 模型的鲁棒性, 准确性较 MRP-386 参数化模型和 RF 等机器学习模型显著提高。模型将应用于中国压水堆核电站镍基 690 合金部件及焊缝在反应堆冷却剂中的应力腐蚀裂纹扩展工程预测。

**关键词:** 镍基 690 合金; 应力腐蚀; 裂纹扩展; 机器学习; KBRF

中图分类号: TG146.1<sup>+</sup>5; TG172.9; TP181

文献标识码: A

文章编号: 1002-185X(2022)04-1304-08

核电站的安全高效运行离不开核电材料服役的可靠性。镍基合金由于具有优异的耐腐蚀性以及高温力学性能被广泛用作核电站关键部件及焊缝材料, 如压水堆核电站蒸汽发生器传热管、反应堆压力容器顶部贯穿件及焊缝、蒸汽发生器水室分隔板及焊缝、主管道异种金属焊缝等<sup>[1-4]</sup>。其中, 镍基 600 合金通常应用于早期建设的核电站中, 在高温高压水服役环境中具有应力腐蚀 (SCC) 敏感性<sup>[5]</sup>, 如 2000 年美国 ANO 核电站稳压器仪表探头和一回路线系统测温、测压探头焊缝发生 SCC, 美国 ST. Lucie 核电站因稳压器及一回路线系统小管径管嘴 SCC 问题导致一回路线泄漏量超标。镍基 690 合金在镍基 600 合金基础上, 将 Cr 含量提高至 30%, 抗应力腐蚀性能更优, 被广泛用于替代镍基 600 合金部件及焊缝材料。但是, 实验室研究结果表明<sup>[6,7]</sup>, 镍基 690 合金在模拟核电站服役工况环境中仍存在发生应力腐蚀开裂的可能。因此, 建立镍基 690 合金在模拟核电站高温高压水环境中的应力腐蚀裂纹扩展速率预测模型对于核电站长期服役安全性评价具有重要的意义。

目前, 应力腐蚀裂纹扩展预测模型可分为 2 类, 一类是基于应力腐蚀开裂机理提出的理论预测模型<sup>[8-13]</sup>, 具有良好的应力腐蚀现象解释性; 另一类是依据大量实验室和工程数据建立的经验预测

模型, 具有很强的应用基础<sup>[14,15]</sup>。权威的镍基 690 合金应力腐蚀裂纹扩展速率预测模型是美国电力研究院 (Electric Power Research Institute, EPRI) 发布的 MRP-386 经验预测模型<sup>[16]</sup>, 采用美国通用公司、美国阿贡实验室、英国阿美科福斯特惠勒公司、美国贝蒂斯和诺尔斯原子能实验室、西班牙 CIEMAT 公司、日本东北大学等权威机构数据拟合回归建立。由于模型参数仅包含裂纹扩展激活能、裂纹扩展时对应的绝对温度、裂纹尖端应力强度因子、溶解氢因子等, 而 SCC 行为影响因素多达二十余种, 因此该参数化模型存在预测精度不高的问题。如何建立高精度的、可用于工程评估的镍基 690 合金应力腐蚀裂纹扩展预测模型是当前面临的难题。机器学习由于不对模型基础分布或模型结构进行任何假设, 通过引入更高的复杂度和计算量, 采用算法挖掘多维数据之间的关联关系, 得到结果近似基础分布, 近年来在材料服役行为预测方面逐渐得到应用<sup>[17-20]</sup>。尤其针对多因素耦合作用下的材料服役行为预测建模问题较常规的参数化建模更具优势, 可以有效解决参数化模型无法准确表达高维数据关联关系的难题。但需要指出的是, 由于机器学习为数据驱动, 模型精度严重依赖于样本数据的数量和质量。模拟核电站高温高压水环境应力腐蚀裂纹扩展实验难度大、周期长、成本高, 因此导致目前镍基 690 合金应力腐

收稿日期: 2021-04-12

基金项目: 国家重点研发计划 (2017YFB0702200); 江苏省基础研究计划 (自然科学基金) 面上项目 (BK20181177)

作者简介: 梅金娜, 女, 1981 年生, 博士, 教授级高级工程师, 苏州热工研究院有限公司, 江苏 苏州 215004, E-mail: meijinna@cgnpc.com.cn

蚀裂纹扩展速率高质量的数据少。而使用低质量的数据进行训练将对模型引入较大的偏差，在工程应用中可能得出误导性的结论，导致较高的安全风险。因此，针对镍基 690 合金应力腐蚀裂纹扩展速率预测这一问题，机器学习建模面临挑战。

为克服上述参数化模型和机器学习模型的缺点和局限性，近年来研究学者通过将机器学习算法与领域知识结合，建立了多种改进模型，显著提高了机器学习训练效率、模型置信度及准确性。如 Kasabov 等<sup>[21]</sup>构建了基于基因结构化知识的神经网络隐藏层，将知识型神经网络（knowledge-based neural networks, KBNN）应用于癌症概况分析，创建了更准确的全局和个性化癌症分类和预测系统；Yeomans 等<sup>[22]</sup>利用模糊集理论将矿化知识作为增强特征纳入到随机森林建模过程中，基于知识引导的随机森林钨矿勘探模型较基于原始数据集所建立的模型置信度更高；Simoff 等<sup>[23]</sup>将数据科学中的矢量量化技术应用到支持向量机（SVM）建模过程，建立一种分层半参数机器学习方法（VQSVM），能够合并领域知识并降低模型对不平衡数据集的敏感性。

本研究提出一种知识型随机森林模型（knowledge-based random forest, KBRF），将随机森林（random forest, RF）模型作为可变参数与 MRP-386 经验预测模型结合，利用机器学习非结构化特征，对具备丰富领域知识的结构化经验公式进行改进，建立适用于中国压水堆核电站镍基 690 合金部件反应堆冷却剂条件应力腐蚀裂纹扩展的工程预测模型。

### 1 KBRF 模型

随机森林算法是以决策树为基础的集成学习算法，通过随机重复采样技术和节点随机分裂技术递归构建多棵决策树，构建的模型可降低决策树之间的相关性，有效处理高维度数据，对异常值和噪声数据的容忍度较高，具有较好的泛化能力与准确性<sup>[24]</sup>。KBRF 建模流程如图 1 所示。

对某一特定领域问题，假设数据为  $D = \{(x_1, a_e^1), \dots, (x_i, a_e^i)\}$ ，其中  $x_i = (x_i^1, x_i^2, \dots, x_i^Z)$  为包含  $Z$  个属性的特征变量， $a_e$  为目标值，参数化模型  $f_{KN}$  预测结果  $a_{KN}$  为：

$$a_{KN}^i = f_{KN}(x_i) \tag{1}$$

目标值与参数化模型预测结果比值  $C_i$  为：

$$C_i = \frac{a_e^i}{a_{KN}^i} = \frac{a_e^i}{f_{KN}(x_i)} \tag{2}$$

构建  $x_i$  与  $C_i$  数据集  $H_i$  为：

$$H_i = \{(x_1, C_1), \dots, (x_i, C_i)\} \tag{3}$$

随机森林机器学习采用随机重复采样技术对数据集  $H_i$  有放回地抽取得到  $N$  个含有  $m$  个样本的子集  $\theta_k$ ，针对每个子集建立一棵 CART（classification and regression tree）决策树  $h(x_i, \theta_k)$ 。集成所有的决策树，构成随机森林，对  $N$  棵决策树的预测结果求算术平均值，得到随机森林模型预测输出<sup>[24]</sup>：

$$a_{RF}^i = \frac{1}{N} \sum_{k=1}^N h(x_i, \theta_k) \tag{4}$$

进一步对具备特定领域知识的参数化模型与随机森林机器学习模型进行组合，得到 KBRF 预测模型：

$$a_{KBRF} = a_{KN}^i \cdot a_{RF}^i = f_{KN}(x_i) \cdot \frac{1}{N} \sum_{k=1}^N h(x_i, \theta_k) \tag{5}$$

## 2 基于 KBRF 模型预测镍基 690 合金 SCC 裂纹扩展速率

### 2.1 KBRF 模型构建

镍基 690 合金高温高压水环境 SCC 裂纹扩展行为已有大量研究<sup>[25-27]</sup>。EPRI 材料可靠性项目基于实验数据建立了镍基 690 合金应力腐蚀裂纹扩展速率预测参数化模型 MRP-386<sup>[16]</sup>：

$$CGR_{MRP-386} = \alpha K^\beta \exp\left[\frac{-Q}{R} \left(\frac{1}{T} - \frac{1}{T_{ref}}\right)\right] \frac{f_{H_2}}{f_{H_2,ref}} \tag{6}$$

式中， $CGR$ （m/s）为温度  $T$  下裂纹生长速率， $Q$  为裂纹扩展激活能，约为 120 kJ/mol， $R$  为气体常量，为  $8.314 \times 10^{-3}$  kJ/(mol·K)， $T$  为裂纹扩展时对应的

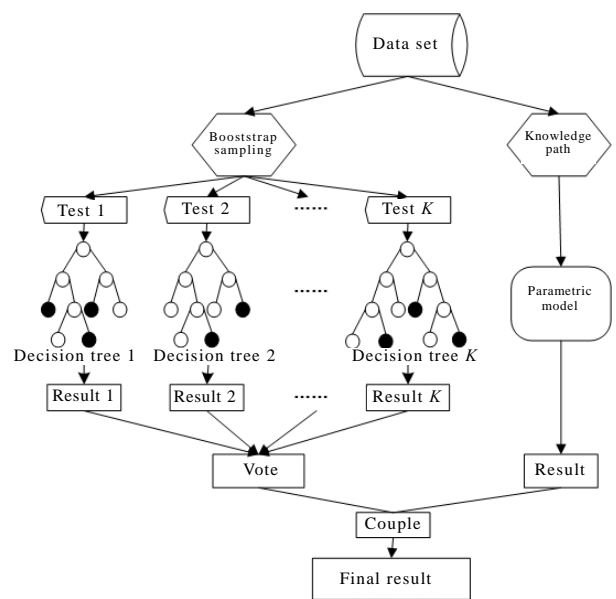


图 1 KBRF 建模流程图

Fig.1 Flow chart of KBRF model

绝对温度,  $T_{ref}$  (K) = 598.15 K (325 °C) 为归一化数据时所对应的参考温度,  $\alpha$  为裂纹扩展速率系数, 325 °C 时,  $\alpha=1.19 \times 10^{-13}$  m/s,  $K$  (MPa·√m) 为裂纹尖端应力强度因子,  $\beta$  为指数, 值为 2,  $\frac{f_{H_2}}{f_{H_2ref}}$  为溶解氢因子, 通过镍基 690 合金不同温度和氢浓度条件下溶解氢因子数据表查寻或者线性内插计算得到。

MRP-386 模型由行业内权威机构建立, 在业内较为广泛应用, 本研究选择其作为参数化模型, 融合随机森林机器学习模型, 建立镍基 690 合金 SCC 裂纹扩展速率预测模型 KBRF, 流程如图 2 所示, 具体步骤如下:

第 1 步: 导入镍基 690 合金 SCC 裂纹扩展速率原始数据 340 组, 并分为训练集 300 组, 用于训练模型, 测试集 40 组, 用于评估模型训练效果。

第 2 步: 采用 MRP-386 模型计算训练集中镍基 690 合金裂纹扩展速率, 以实验值  $CGR_{exp}$  与 MRP-386 模型预测值  $CGR_{MRP-386}$  比值  $D_i$ , 建立数据集  $M_i$ , 其中  $b_i$  为 SCC 裂纹扩展影响因素。

$$D_i = CGR_{exp}^i / CGR_{MRP-386}^i \quad (7)$$

$$M_i = \{(b_i, D_i), \dots, (b_i, D_i)\} \quad (8)$$

第 3 步: 采用随机森林对数据集  $M_i$  进行建模, 建立  $b_i$  与  $D_i$  之间映射关系, 并进行超参数优化, 直至误差符合精度要求。

第 4 步: 将 MRP-386 模型与超参数优化后的随机森林模型进行组合, 建立 KBRF 模型 (式 (9))。输入测试集, 获得基于 KBRF 模型的镍基 690 合金 SCC 裂纹扩展速率预测结果。

$$CGR_{KBRF} = CGR_{RF} \cdot CGR_{MRP-386} \\ = CGR_{RF} \cdot \alpha K^\beta \exp\left[\frac{-Q}{R} \left(\frac{1}{T} - \frac{1}{T_{ref}}\right)\right] \frac{f_{H_2}}{f_{H_2ref}} \quad (9)$$

### 2.2 样本及数据预处理

利用 300 组镍基 690 合金在模拟压水堆反应堆冷却剂条件下的 SCC 裂纹扩展速率实验数据进行建模, 数据特征涵盖材料性能、加工条件、水化学环境等 (见表 1)。

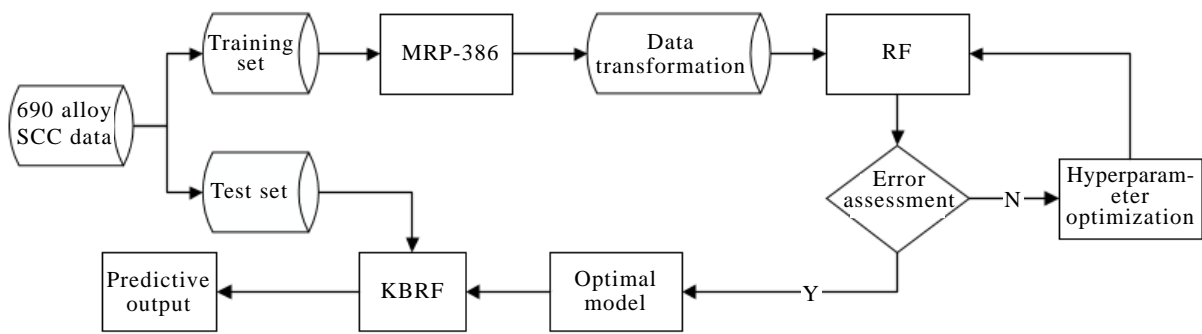


图 2 基于 KBRF 模型的镍基 690 合金应力腐蚀裂纹扩展速率预测流程图

Fig.2 Flow chart for predicting stress corrosion crack growth rate of Ni-based 690 alloy based on KBRF model

表 1 镍基 690 合金 SCC 裂纹扩展数据特征值

Table 1 Characteristic values of SCC crack growth data of Ni-based 690 alloy

Characteristic parameter	Value
As received condition	AR, MA, HTMA
Cold work degree/%	0~32
Processing method	CF, CR, HAZ, HT, TS
Product form	CRDM, bar, plate
Orientation	C-L, C-R, L-T, S-L, S-T, T-L, T-S
Hardness, HV/MPa	1550~3210
Load type	CK, CL, PPU, bolt
$K/MPa \cdot \sqrt{m}$	13.5~53
Temperature/°C	290~360
Dissolved $H_2/mL \cdot kg^{-1}$	1~81

Note: AR-as received; MA-mill anneal; HTMA-high temperature mill anneal; CF-cold forged; CR-cold rolled; HAZ-heat affected zone; HT-heat treatment; TS-tempformed steel; CRDM-control rod drive mechanism, C-circumferential/tangential direction; L-length/longitudinal/axial direction; R-radial direction; S-thickness/short transverse; T-width/long transverse; CK-constant stress intensity factor; CL-constant load; PPU-periodic partial unloading

随机森林算法只接受定量特征值作为输入，而应力腐蚀裂纹扩展速率数据中试样条件、热处理方式、试样类型、裂纹扩展方向和载荷类型属于非连续的类别型变量，因此采用数字编码方式将定性特征值映射为定量特征值，并采用式 (10) “MinMaxScaler” 方法对数据进行归一化处理，以消除不同量级特征数据对目标函数的影响。

$$X_i = \frac{x_i - \min(x_i)}{\max(x_i) - \min(x_i)} \quad (10)$$

式中， $\max(x_i)$ 为特征数据  $x_i$  的最大值， $\min(x_i)$ 为特征数据  $x_i$  的最小值， $X_i$ 为变换之后的数据。

### 2.3 超参数优化

随机森林算法以决策树为基础， $N\_estimators$ (子树的数量)、 $Max\_depth$ (子树的最大叶子生长深度)是对算法性能影响较大的超参数，本研究采用网格搜索算法 (grid search, GA) 对随机森林超参数进行优化，设置  $N\_estimators$ 、 $Max\_depth$  参数范围分别为 (0, 200)、(0, 100)，依次改变  $N\_estimators$ 、 $Max\_depth$ ，通过比较不同参数取值的模型可释方差，确定随机森林算法最佳参数组合。

## 3 结果与讨论

### 3.1 特征量分析结果

图 3 为采用随机森林算法分析各应力腐蚀影响因素对镍基 690 合金应力腐蚀裂纹扩展的重要性程度结果。可以看出，特征重要性评分由高到低降序排列依次为应力强度因子、温度、溶解氢含量、冷加工程度、硬度、裂纹扩展方向、热处理方式、试样类型、载荷类型和试样条件。因此确定最优特征子集为应力强度因子、温度、溶解氢含量、冷加工程度、硬度、裂纹扩展方向、热处理方式、试样类型、试样条件和载荷类型，这些特征参数均对应应力腐蚀裂纹扩展速率有不同程度的影响，这与前人实验研究结果相一致<sup>[28-33]</sup>，如：应力强度因子增大导致裂纹尖端应变速率增加，裂纹扩展速率随之增大；由于裂纹扩展过程中所涉及的离子扩散速率、界面反应速率、材料力学性能和电化学电位等都是温度的函数，因此温度对裂纹扩展速率 CGR 的影响极其复杂；溶解氢能够降低 690 合金腐蚀电位，产生致密氧化膜，裂纹扩展速率较慢；冷加工导致材料晶界损伤、晶粒碎化、屈服强度升高等，使得 SCC 的敏感性增加。

### 3.2 RF 建模结果

图 4a 和 4b 分别为 RF 模型可释方差与子树的数量、以及子树的最大叶子生长深度的关系曲线，可

以看出，RF 模型可释方差随着子树的数量的增加而升高，当子树的数量达到 30 后收敛，并当子树的数量增加至 141 时取得最高分。将子树的数量固定为 141，调整每棵子树的最大叶子生长深度，发现模型可释方差随子树的最大叶子生长深度的增加呈先升高后下降的趋势，并当最大叶子生长深度达到 11 时

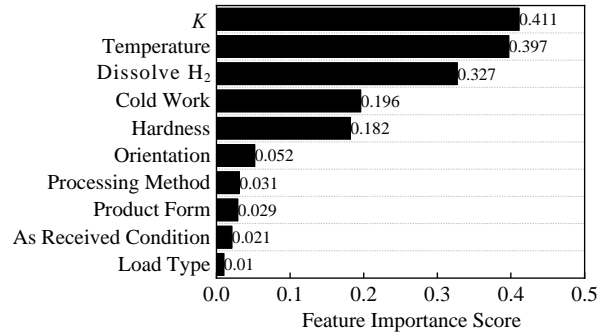


图 3 镍基 690 合金应力腐蚀裂纹扩展的特征重要性排序  
Fig.3 Feature importance ranking of stress corrosion crack growth of Ni-based 690 alloy




图 4 可释方差与子树的数量、子树的最大叶子生长深度的关系

Fig.4 Relationships between explained\_variance and N\_estimators (a), Max\_depth (b)

取得最高分。因此，确定 RF 算法最佳参数组合为 [N\_estimators: 141, Max\_depth: 11]。

采用网格搜索优化后的随机森林算法 RF 对镍基 690 合金 SCC 裂纹扩展速率进行建模，训练集上的模型预测结果见图 5a，为进行对比，图 5b~5d 中同时给出了采用线性回归算法 (Linner)、网格搜索优化的支持向量机算法 (SVR) 和网格搜索优化的梯度提升树算法 (GBDT) 的预测结果。预测值和实验值的  $R^2$  和线性拟合斜率越接近 1，则模型关联性越强。可以看出，基于非线性的 RF 算法、GBDT 算法和 SVR 算法的  $R^2$  均优于基于线性的 Linner 算法，表明镍基 690 合金应力腐蚀裂纹扩展速率与各特征值之间呈现复杂的非线性关系。其中，SVR 算法出现大量异常偏差点，线性拟合斜率偏差大，可能是由于其核函数在向高维空间映射时稳定性变差。基于树模型的 RF 算法和 GBDT 算法建模结果  $R^2$  分别为 0.89 和 0.90，MAPE 分别为 2.05 和 8.17，拟合效果显著优于 SVR 算法和 Linner 算法，说明 GBDT 算法和 RF 算法在处理高维度数据集方面具有显著优势，主要原因是 SVR 算法虽然可以建立小样本情况下的非线性映射，但是由于其本身属于浅层模型，对复杂结构的 SCC 裂纹扩展速率数据集预

测效果仍有待提高，而 RF 算法与 GBDT 算法属于数据驱动的集成类建模算法，比一般浅层模型层数更多，更适用于 SCC 裂纹扩展速率数据的预测。进一步比较发现，GBDT 算法在预测过程中出现负值，过拟合程度高，这是因为 GBDT 算法训练过程为串行训练，通过预测偏差的加权融合获得目标值，对异常值敏感，而 RF 算法针对多棵决策树预测结果投票表决，削弱了异常值的影响。

### 3.3 KBRF 建模结果

图 6 为 KBRF 模型、MRP-386 模型预测镍基 690 合金在模拟核电站反应堆冷却剂环境中 SCC 裂纹扩展速率分别与应力强度因子、冷加工程度、温度和溶解氢的关系曲线，由于 MRP-386 模型变量不包含冷加工程度，因此图 6b 中无 MRP-386 模型预测结果。可以看出，KBRF 模型预测结果与实验值较为接近，而 MRP-386 模型预测结果则显著低于实验值。这是由于 MRP-386 模型基于 SCC 裂纹扩展理论分析对模型变量及结构进行假设，利用经验数据集，采用统计分析方法对模型参数进行求解。但由于 SCC 本质上为多因素耦合作用行为，各影响因素之间非线性关系复杂，模型假设偏差大，因此难以参数化准确表达。




图 5 不同算法在镍基 690 合金应力腐蚀裂纹扩展速率训练集预测结果

Fig.5 Prediction results of different algorithms on Ni-based 600 alloy stress corrosion cracking growth rate training set: (a) RF, (b) Linner, (c) SVR, and (d) GBDT

进一步分析发现, 随应力强度因子增大、冷加工程度增加和温度升高, 应力腐蚀裂纹扩展速率 KBRF 模型预测值增大, 随溶解氢含量的增加, KBRF 模型预测结果出现极值, 这一规律与目前实验研究结果一致<sup>[34-36]</sup>。应力强度因子增大导致裂纹尖端应变速率增加, 裂纹扩展速率随之升高; 冷加工程度越高, 材料的屈服强度也越高, 而屈服强度增大会限制塑性区尺寸, 增大裂纹尖端的应变梯度, 促进 SCC 扩展; 镍基 690 合金在不同温度下的 SCC 裂纹扩展速率随温度的演变满足阿伦尼乌斯公式, 与绝对温度的倒数成反比关系; 溶解氢可以改变镍基合金材料的腐蚀电化学电位, 当溶解氢含量使电位接近发生 Ni/NiO 转变的对应电位时, 镍基合金处于不稳定状态, 裂纹扩展速率增大<sup>[37]</sup>。这里需要指出的是, 虽然 MRP-386 模型与 KBRF 模型类似, 都能够预测出随应力强度因子、温度等参数 SCC 裂纹扩展速率的变化趋势, 但却未能准确预测溶解氢含量对 SCC 裂纹扩展速率的影响。这是因为虽然 MRP-386 模型包含了溶解氢对镍基 690 合金裂纹扩展的影响, 但溶解氢的影响涉及温度和腐蚀电位等的耦合作用, 模型结构复杂, 尚缺乏足够的对参数进行准确地求解。上述研究结果说明 KBRF 模型较

MRP-386 模型更加能够准确反映主要影响因素对 SCC 裂纹扩展速率的影响。

图 7 为 KBRF 模型在镍基 690 合金应力腐蚀裂纹扩展测试集上的预测结果, 为进行对比, 图中同时给出了 RF 模型和 MRP-386 模型的预测结果。并计算了 KBRF 模型、RF 模型和 MRP-386 模型误差值, 见图 8。可以看出, MRP-386 模型预测值离散分布在  $y=x$  下方, 预测值多小于实验值, 误差值较大, 工程应用安全裕度不足。KBRF 模型集中分布在  $y=x$  附近, 线性拟合斜率更接近于 1,  $R^2$  值较 MRP-386 模型由 0.197 提高至 0.811、MSE 由 1.775 降低至 0.109, 较 MRP-386 模型分别提高 311.7% 和降低 93.9%, 说明预测效果更优, 可以更好地表征 SCC 特征参数与裂纹扩展速率之间的关联。这是由于与 MRP-386 模型相比, KBRF 模型引入随机森林模型对 MRP-386 模型偏差进行学习, 即通过多棵不同的决策树改变模型的复杂度, 集成所有决策树的结果来得到目标模型的近似分布, 从而建立反映多类型、高维度数据关联关系的非参数预测模型, 极大提升预测准确度。此外, 对比发现 KBRF 模型  $R^2$  较 RF 模型提高 10.6%, MSE 降低 10.7%, 说明将机器学习算法与领域知识结合, 先验知识的引入增强了模型的鲁棒性, 准确性和结构稳定性更高。

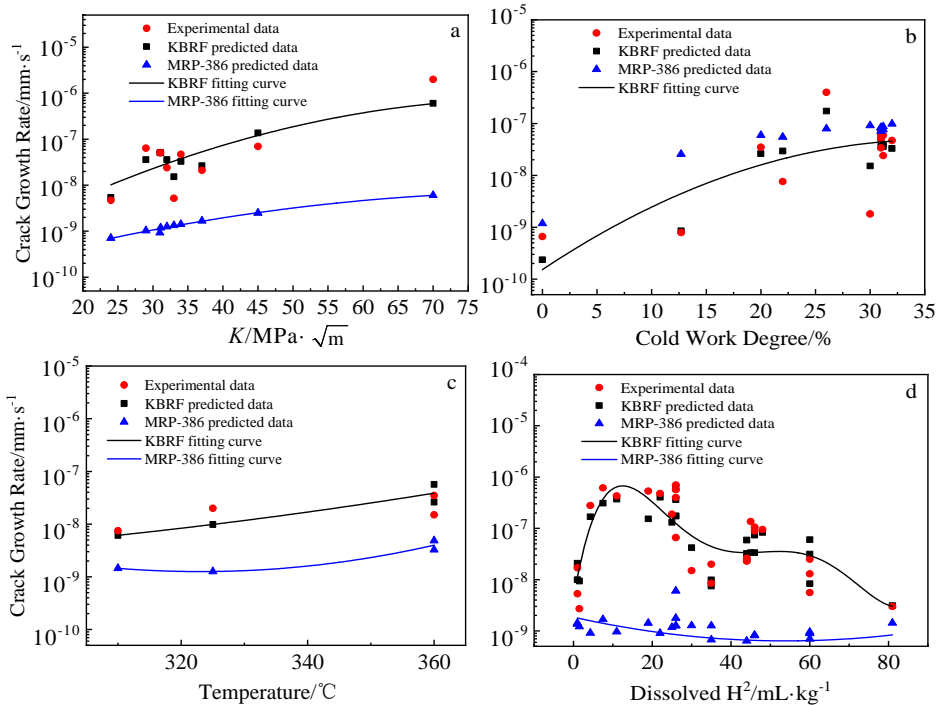


图 6 KBRF 模型、MRP-386 模型预测得到的镍基 690 合金 SCC 裂纹扩展速率与应力强度因子, 冷加工程度, 温度和溶解氢的关系

Fig.6 Relationships between SCC crack growth rate predicted by KBRF model and MRP-386 model and stress intensity factor (a), cold working degree (b), temperature (c), and dissolved  $H_2$  (d)

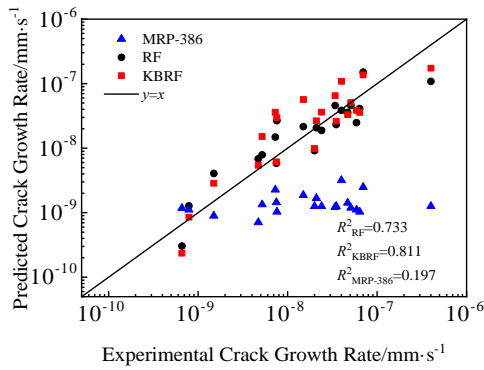


图 7 镍基 690 合金 SCC 裂纹扩展速率测试集预测结果

Fig.7 Prediction results of SCC crack growth rate test set for Ni-based alloy 690




图 8 KBRF 模型与 MRP-386 模型、RF 模型在镍基 690 合金 SCC 裂纹扩展速率测试集上的误差值

Fig.8 Error values of KBRF model and MRP-386 model (a) and RF model (b) in stress corrosion cracking test set of Ni-based alloy 690

## 4 结论

1) 通过随机森林分析得出应力强度、温度、溶解氢含量、冷加工程度、硬度对镍基 690 合金应力腐蚀扩展的重要性排在前列, 包含材料、水化学和力学三方面的影响。利用随机森林可以识别各特征对镍基 690 合金应力腐蚀裂纹扩展影响的重要程度。

2) 采用网格搜索算法优化随机森林算法超参数, 得到最佳参数组合为[N\_estimators: 141, Max\_depth: 11], 模型拟合效果优于 SVR 算法、Linner 算法和 GBDT 算法, RF 算法在处理高维度特征的 SCC 裂纹

扩展速率预测问题方面具有显著优势。

3) MRP-386 模型预测结果则显著低于实验值, 工程应用安全裕度不足。通过融合随机森林机器学习模型与基于领域知识的 MRP-386 参数化模型, 建立了镍基 690 合金 SCC 裂纹扩展速率 KBRF 预测模型, 较 MRP-386 模型更能准确反映应力强度因子、冷加工程度、温度和溶解氢等因素对 SCC 裂纹扩展速率的影响; 预测结果与实验值较为接近,  $R^2$  和 MSE 分别为 0.811 和 0.109, 较 MRP-386 模型分别提高 311.7% 和降低 93.9%, 较 RF 模型分别提高 10.6% 和降低 10.7%, 将应用于压水堆核电站镍基 690 合金部件反应堆冷却剂条件应力腐蚀裂纹扩展工程预测。

## 参考文献 References

- [1] Riess R, Ford F P, Lundgren K. *Advanced Nuclear Technology International Krongjutarvagen 2C*, SE-73050 [R]. Skultuna: ANTI, 2006
- [2] Zhang Jianlong, Cui Yinghao, Xue He. *Rare Metal Materials and Engineering*[J], 2020, 49(5): 1496
- [3] Hwang S S. *Journal of Nuclear Materials*[J], 2013, 443 (1-3): 321
- [4] Han E H, Wang J Q, Wu X Q *et al. Acta Metallurgica Sinica*[J], 2010, 46(11): 1379
- [5] Fang Xiurong, Yang Jinhui, Shao Yanru *et al. Rare Metal Materials and Engineering*[J], 2019, 48(8): 2424
- [6] Meng F J, Wang J Q, Han E H *et al. Corrosion Science*[J], 2009, 51(11): 2761
- [7] Park I G, Lee C S, Hwang S S *et al. Metals and Materials International*[J], 2005, 11(5): 401
- [8] Andresen P L, Ford F P. *Materials Science and Engineering A*[J], 1988, 103(1): 167
- [9] Macdonald D D, Lu P C, Urquidi-Macdonald M *et al. Corrosion*[J], 1996, 52(10): 768
- [10] Macdonald D D. *Corrosion Science*[J], 1996, 38(6): 1003
- [11] Galvele J. *Corrosion Science*[J], 1987, 27(1): 1
- [12] Ford F P. *Corrosion*[J], 1996, 52(5): 375
- [13] Shi J B, Wang J H, Macdonald D D. *Corrosion Science*[J], 2015, 92: 217
- [14] Jung Y C, Chung H S, Lee K S *et al. Metals and Materials International*[J], 2010, 16(2): 267
- [15] Hickling J, McIlree A, Pathania R. *Materials Reliability Program (MRP): Crack Growth Rates for Evaluating Primary Water Stress Corrosion Cracking (PWSCC) of Thick-Wall Alloy 600 Materials*, MRP-55[R]. California:

- Electric Power Research Institute, 2002
- [16] Jenks A, White G, Burkardt M *et al.* *Materials Reliability Program: Recommended Factors of Improvement for Evaluating Primary Water Stress Corrosion Cracking (PWSCC) Growth Rates of Thick Wall Alloy 690 Materials and Alloy 52, 152, and Variants Welds*, MRP 386[R]. California: Electric Power Research Institute, 2017
- [17] Kamrunnahar M, Urquidi-Macdonald M. *Corrosion Science* [J], 2010, 52(3): 669
- [18] Mathew J, Parfitt D, Wilford K *et al.* *Journal of Nuclear Materials*[J], 2018, 502: 311
- [19] Castin N, Pascuet M I, Messina L *et al.* *Computational Materials Science*[J], 2018, 148: 116
- [20] Mei Jinna(梅金娜), Wang Peng(王鹏), Han Yaolei(韩姚磊) *et al.* *Rare Metal Materials and Engineering*(稀有金属材料与工程)[J], 2021, 50(7): 2399
- [21] Song Q, Kasabov N, Ma T M *et al.* *Artificial Intelligence in Medicine*[J], 2006, 36(3): 235
- [22] Yeomans C M, Shail R K, Grebby S *et al.* *Geoscience Frontiers*[J], 2020, 11(6): 2067
- [23] Yu T, Simoff S, Jan T. *Neurocomputing*[J], 2010, 73(13-15): 2614
- [24] Breiman L. *Machine Learning*[J], 2001, 45: 5
- [25] Kuang W J, Was G S. *Corrosion Science*[J], 2020, 163: 108 243
- [26] Chen K, Wang J M, Shen Z *et al.* *Corrosion Science*[J], 2020, 164: 108 313
- [27] Kuang W J, Yue H, Feng X Y *et al.* *Scripta Materialia*[J], 2020, 189: 122
- [28] Terachi T, Yamada T, Miyamoto T *et al.* *Journal of Nuclear Materials*[J], 2012, 426(1-3): 59
- [29] Alexandreanu B, Chopra O K, Shack W J. *Pressure Vessel and Piping Division of the American Society of Mechanical Engineers*[C]. Chicago: ASME, 2009: 153
- [30] Alexandreanu B, Chopra O K, Shack W J. *ASME 2006 Pressure Vessels and Piping Division*[C]. Vancouver: ASME, 2006: 153
- [31] Kim Y J, Andresen P L, Moran E *et al.* *Corrosion*[J], 2005, 61(7): 648
- [32] Seifert H P, Ritter S, Shoji T *et al.* *Journal of Nuclear Materials*[J], 2008, 378(2): 197
- [33] Andresen P L, Morra M M. *Journal of Pressure Vessel Technology*[J], 2007, 129(3): 488
- [34] Zhai Z Q, Toloczko M, Kruska K *et al.* *Corrosion*[J], 2017, 73(10): 1224
- [35] Moss T E, Brown C M, Young G A. *Proceedings of the 18th International Conference on Environmental Degradation of Materials in Nuclear Power Systems-Water Reactors*[C]. Switzerland: The Minerals, Metals & Materials Series, 2019: 261
- [36] Andresen P L, Morra M, Hickling J *et al.* *Proceedings of the 16th International Conference on Environmental Degradation of Materials in Nuclear Power Systems-Water Reactors*[C]. Houston: NACE, 2009: 412
- [37] Andresen P L, Young L M. *Corrosion*[J], 1995, 51(3): 223

## Prediction Model of Crack Growth Rate of Stress Corrosion for Nickel-Base 690 Alloy Based on KBRF Algorithm

Mei Jinna, Wang Peng, Han Yaolei, Cai Zhen, Ti Wenxin, Peng Qunjia, Xue Fei  
(Suzhou Nuclear Power Research Institute, Suzhou 215004, China)

**Abstract:** Stress corrosion cracking (SCC) as a potential failure mechanism endangers structural integrity of the nickel-base 690 alloy components and welds that are widely used in the high temperature and high pressure water environment in pressurized water reactors (PWRs). Due to the complexity of the interweaving influences, the existing parameterized prediction models developed for SCC are limited for engineering assessment by rather lower accuracy. In this study, a KBRF (knowledge-based random forest) model was developed for predicting the SCC growth rate of the nicked-base 690 alloy through combining random forest machine learning algorithm (RF) with domain knowledge-based MRP-386 parameterized model. It is found that the robustness and accuracy of the KBRF model are significantly improved, in comparison with the MRP-386 parameterized model and the RF machine learning model by introducing domain knowledge into the machine learning modeling. The results demonstrate potential engineering application of the presented model on SCC growth rate prediction of nicked-base 690 alloy components and welds in PWRs.

**Key words:** Nickel-base 690 alloy; stress corrosion; crack growth; machine learning; KBRF

Corresponding author: Mei Jinna, Ph. D., Professor, Life Management Technology Center, Suzhou Nuclear Power Research Institute, Suzhou 215004, P. R. China, E-mail: 393992689@qq.com