

文章编号: 1001-4888(2024)05-0625-12

基于声发射多维度时序特征的 铝锂合金应力腐蚀损伤分类方法研究*

尹章程, 雷义舫, 宋海鹏

(中国民航大学 中欧航空工程师学院, 天津 300300)

摘要: 航空合金的应力腐蚀开裂是飞机结构重要失效形式之一, 本文针对铝锂合金应力腐蚀多类损伤耦合问题, 结合 Tsfresh 库和机器学习算法提出了一种基于声发射多维度时序特征的应力腐蚀损伤分类方法; 综合声发射损伤分类与电化学噪声数据, 讨论了铝锂合金应力腐蚀损伤演化规律。结果显示, 相较于传统特征参数, 多维度时序特征参数与类型标签的相关性更高, 12 种机器学习算法在测试集上的平均准确率由 90.26% 提升至 98.87%, 表明以多维度时序特征进行损伤分类具有显著优势; 铝锂合金应力腐蚀损伤演化过程可被分为电化学活化、裂纹萌生、裂纹扩展阶段; 电化学活化阶段试件表面的缺陷经去钝化—再钝化循环逐步扩展为蚀坑, 裂纹萌生阶段出现氢致开裂, 裂纹扩展阶段存在滑移溶解, 裂纹扩展导致试件最终失效。

关键词: 声发射; 铝锂合金; 应力腐蚀; 损伤分类

中图分类号: TB302.5 **文献标识码:** A **DOI:** 10.7520/1001-4888-23-262

0 引言

铝锂合金是近年来发展迅速的新兴航空材料, 具有密度低、比强度高、疲劳性能好等优异的力学性能, 目前已被广泛应用于飞机隔框、壁板、蒙皮等重要结构^[1]。铝锂合金在飞机服役过程中承受载荷与环境腐蚀的共同作用, 容易出现应力腐蚀开裂现象, 引发结构过早失效^[2]。开展铝锂合金应力腐蚀实验研究, 深入认识其损伤演化规律, 对保障飞行安全具有重要意义。

近年来, 金属材料应力腐蚀开裂 (SCC) 过程研究受到广泛关注。有限元法^[3]、相场法^[4]、分子动力学模拟^[2]等数值仿真方法已被成功应用于不锈钢、铝合金等典型金属材料的应力腐蚀开裂研究, 以模拟腐蚀坑演化及裂纹扩展。由于金属材料应力腐蚀开裂的影响因素众多, 其演化过程具有动态性和非均匀性, 数值仿真工作的进一步发展仍需更丰富的实验信息。在实验研究方面, 国内外学者利用声发射 (AE)^[5-6]、数字图像相关 (DIC)^[7]、电化学^[6-7]等多种在线观测实验方法研究了材料在应力腐蚀工况下的损伤演化过程。例如 CALABRESE 等^[8]使用 AE 技术研究了不锈钢在 $MgCl_2$ 溶液中的 SCC 行为, 认为 AE 信号的能量可用于 SCC 的不同阶段划分, 包括电化学活化阶段、裂纹萌生阶段、裂纹扩展阶段和最终的灾难性失效。KUANG 等^[7]利用数字图像相关方法观测镍基合金 690 在压水反应堆水循环中的应力腐蚀现象, 实验结果表明, 晶界附近的局部正应变是晶界表面氧化膜破裂的主要驱动力。KO-VAC 等^[9]利用电化学噪声法研究了 304 不锈钢缺口试件的恒载荷应力腐蚀开裂过程, 发现电流噪声的

* 收稿日期: 2023-12-15; 修回日期: 2024-05-23

基金项目: 国家自然科学基金项目 (11972364)

通信作者: 宋海鹏 (1986-), 男, 博士, 教授。主要研究领域: 实验力学测试技术, 工程/实验数据智能分析。Email: hpsong@cauc.edu.cn

直流分量随着溶解强度的增加而上升,并且直流分量与活性裂纹溶解产生的阳极区域面积呈正相关。

由于在应力腐蚀过程中,金属材料的腐蚀损伤与机械损伤(塑性变形、裂纹扩展等)相互耦合^[10],如何进行不同损伤类型的准确识别是铝锂合金应力腐蚀研究的难点问题,也是深入研究其应力腐蚀损伤演化规律的瓶颈问题。声发射技术能够有效监测金属材料在应力腐蚀过程中由腐蚀和载荷引起的声学信号,这些声学信号包含大量波形数据和特征信息,已被成功应用于不同类型的损伤识别^[11-12]。目前基于声发射的金属应力腐蚀损伤分类方法大致可以分为两类,一类是基于特征参数的统计分析,例如 PARK 等^[5]监测 304L 不锈钢管应力腐蚀的声发射信号,分别灌入蚀刻剂和蒸馏水进行对比实验,基于幅值和能量的统计分布,设置幅值低于 12mV 和能量低于 $3777\mu\text{V}\cdot\text{s}$ 为腐蚀信号与非腐蚀信号的区分指标;XU 等^[13]通过对 304 不锈钢应力腐蚀过程中声发射信号的幅值特征进行统计分析,认为裂纹扩展的信号幅值显著高于材料溶解和晶间腐蚀。另一类则是借助降维、聚类等机器学习算法,对声发射信号进行更加准确地分类,例如 LI 等^[14]采用 K-means 算法将 304 不锈钢应力腐蚀过程中的 AE 信号聚类为 3 簇,并基于各簇信号的特征参数分布规律,将这 3 簇信号分别与材料腐蚀、裂纹萌生与扩展及气泡破裂相对应;ZHANG 等^[10]收集 304 不锈钢在高温水中应力腐蚀的声发射信号,将上升时间等 7 个特征参数的分布和应力腐蚀各阶段建立关联,并使用随机森林算法区分了声发射信号中的突发型和连续型信号。

尽管上述研究已涉及了多种机器学习分类算法,但这些算法所参考的特征集仍主要为声发射信号常用的时域和频域特征参数(例如上升时间、平均频率等),特征数量通常低于 10 个,其维度和多样性上存在局限性。具体而言,每个声发射事件的原始波形均为包含 2048 个采样点对应幅值的时间序列数据,现有研究中常用的特征参数是通过相对单一的信号处理方法将波形数据降维采样到不足 10 维的结果,这种传统特征参数的选取方式虽然能够简化数据处理流程,但同时也注定会丢失大量信息。当声发射信号的来源较为复杂时,传统特征参数难以捕获区分不同损伤类型的关键信息^[15]。鉴于上述原因,目前基于声发射对各类复杂损伤的分类效果仍有较大提升空间(不仅限于金属材料应力腐蚀研究,对于其他材料和工况亦是如此),因此亟需发展基于多维度时序特征的损伤分类方法。

本文针对铝锂合金应力腐蚀多类损伤耦合问题发展基于声发射多维度时序特征的损伤分类方法。通过实验设计构建突发型和连续型信号、腐蚀损伤与机械损伤 2 种分类数据集;提出一种基于 Tsfresh 库的多维度时序特征提取方法,将提取到的 794 个特征应用于损伤分类;采用 12 种常用的有监督机器学习算法验证分类效果,并使用训练后的算法模型对铝锂合金应力腐蚀过程的声发射信号进行损伤分类;结合声发射数据、电化学噪声、表面形貌特征,讨论铝锂合金应力腐蚀开裂过程的损伤演化过程与损伤机制。

1 铝锂合金应力腐蚀实验

本文开展铝锂合金应力腐蚀实验,实验装置示意图及试件尺寸如图 1 所示。实验选用 2050-T8 铝锂合金板材,根据 HB 7235-1995 标准设计成哑铃型试件,试件平行段长度为 25mm,宽度为 6mm,厚度为 2mm,对试件夹持端进行适当加长以便于安装声发射探头。本文采用 NKK-4050 应力腐蚀试验机对铝锂合金试件在腐蚀溶液中进行慢应变速率拉伸实验,横梁位移速率设置为 10^{-5}mm/s ,腐蚀溶液为 pH=1 的 3.5wt.% NaCl 溶液。实验采用 Mistras 公司的 PCI-2 型声发射系统,配备 R-15 探头和 AMP 2/4/6 前置放大器,前置放大器增益设为 40dB,采样率为 2MSPS,即每个声发射事件有 2048 个采样点,采样间隔为 $5\times 10^{-7}\text{s}$;对铝锂合金应力腐蚀实验的声发射环境噪声进行预监测,获知大部分环境噪声引起的声发射信号的幅值为 19dB~22dB,因此将声发射的阈值设为 30dB。使用 Princeton PARSTAT 2273 电化学工作站监测试件在加载过程中的电化学信号,以对损伤阶段划分进行辅助分析;采用三电极连接模式,工作电极直接连接铝锂合金试件;参比电极为 Ag/AgCl 电极,放置于靠近试件的位置但不与试件相接触;辅助电极为碳棒,置于腐蚀溶液中、距离试件较远的位置;设置采样间隔为 2s,交流刺激信号振幅为 10mV。试样除实验区外,暴露在溶液中的部分被缠上绝缘胶带,尽量减少非实验区发生腐蚀等情况对实验结果产生的影响。除应力腐蚀实验外(应力和腐蚀共同作用),同时设计

了腐蚀实验(不施加载荷)和拉伸实验(不施加腐蚀)2种实验,用于分别收集来源于腐蚀损伤信号和机械损伤信号的纯净数据集。




图 1 (a) 铝锂合金应力腐蚀实验装置示意图;(b) 试件尺寸

Fig. 1 (a) schematic diagram of the stress corrosion test device for aluminum lithium alloy; (b) specimen dimensions

2 基于声发射多维度时序特征的应力腐蚀损伤分类方法

本文发展的基于声发射多维度时序特征的应力腐蚀损伤识别方法主要包括数据集构建、多维度时序特征提取、分类模型训练 3 个环节,其流程示意图如图 2 所示。




图 2 基于声发射多维度时序特征的铝锂合金应力腐蚀损伤分类流程示意图

Fig. 2 Flowchart of stress corrosion damage classification of aluminum-lithium alloys based on multi-dimensional time series features of AE signals

2.1 数据集构建

为建立声发射信号与应力腐蚀不同损伤之间的对应关系,本文基于单轴拉伸实验、腐蚀液浸泡实验构建了 2 种不同类型的数据集。第一种数据集是腐蚀损伤与机械损伤数据集;该数据集将腐蚀实验产生的声发射信号标记为腐蚀损伤信号,将单轴拉伸实验产生的数据标记为机械损伤信号^[5]。第二种数据集为突发型与连续型信号数据集;现有研究表明^[10,16],机械损伤信号可进一步分为突发型与连续型 2 种,突发型信号通常对应于裂纹萌生或扩展,而连续型信号通常对应于塑性形变,2 种信号的典型波形

特征如图3所示,突发信号具有短暂、尖锐的波形,连续型信号为相对稳定的波动,2种信号的波形图可通过人工目视区分;从单轴拉伸实验产生的数据中随机抽取500个声发射信号样本后,通过人工标注构建突发型与连续型信号数据集。




图3 2种典型声发射信号的波形图:(a)突发型信号;(b)连续型信号

Fig. 3 Wave diagrams of two typical acoustic emission signals: (a) burst signal; (b) continuous signal

2.2 多维度时序特征提取算法

声发射信号本质上是复杂的时间序列数据,现有研究存在特征参数维度及多样性不足的问题(特征数量通常低于10个),亟需发展针对声发射信号的多特征提取方法。目前针对时间序列的多特征提取方法主要有深度学习编码和多信号处理算子组合应用2种。

深度学习编码方法通过构建2个网络模型分别作为编码器与解码器来提取特征,编码器负责将高维数据映射到低维特征空间,而解码器则试图从这些低维特征中重构原始数据,训练目标为最小化输入数据与重建数据之间的差异,从而迫使模型对原数据提炼有效特征;可对时间序列编码的深度学习模型,例如长短期记忆网络(LSTM)等,已开始声发射研究中初步应用^[17-18]。这些深度学习模型对数据的质量和数量有较高要求,对于声发射数据分析而言,高质量标签及数据量是影响这些模型应用效果的重要因素。李睿等^[17]通过构建基于卷积神经网络的编码解码器对铅芯在玻纤复材板上摩擦与断裂的信号进行了分类。周俊等^[18]构建了基于LSTM的深度学习模型,直接以波形识别声发射类型。本文尝试使用基于LSTM的深度学习编码方法提取声发射特征,但经过测试,将这些模型应用于本文的数据集后,算法无法收敛,提取的特征准确性低于70%,表明已有的深度学习模型对不同实验的泛化性有待提高。

相较于深度学习方法,多信号处理算子组合应用方法无需依赖大量标签数据。Tsfresh库^[19]是组合了一系列时间特征提取算子的开源工具库,它能综合考虑趋势、纹理、分布、相关性等多个维度,利用傅里叶变换、小波变换等多种信号处理方法,实现大量时序特征的自动识别,在默认配置下总共能提取794个时序特征,从而降低遗漏重要特征的风险。其中部分特征提取方法的名称与设计原理见表1。PETELIN等^[20]借助Tsfresh库中的多种信号处理算子对包含 10^5 条来自工业、金融、社会学等多个领域时序数据的M4竞赛数据集^[21]提取多维度时序特征,并使用不同的机器学习模型进行了复杂的预测任务,验证了Tsfresh库的出色泛化性。此外,基于Tsfresh的多维度时序特征提取方法已用于医学、天文学等领域的时序信号处理^[22-25],并取得良好效果。

相较于传统特征参数,Tsfresh库能从更多维度描述声发射波形特征,提取多维度时序特征有助于发掘不同损伤类型声发射信号的区分指标,提高特征提取准确性和泛化性;结合可以去除冗余和低相关度特征的筛选机制,能够提高分类算法模型的训练效率。因此,本文基于Tsfresh库发展声发射多维度时序特征提取方法。

2.3 有监督分类算法

当通过隔离实验、人工标注等方式获知部分声发射对应的损伤类型后,可采用这些数据训练机器学习算法模型,使模型能对实验中其他声发射数据的损伤类型进行分类^[26]。为进一步从多个角度来评估使用多维度时序特征相较于使用传统的特征参数进行损伤分类的优势,本文构建并使用现有研究中常用的12种有监督分类机器学习算法来对不同数据集进行分类训练,包括Boosting树算法^[27]、随机森林

算法^[10]、极端随机树算法^[28]、K 近邻算法^[15]、神经网络算法^[17]等,算法列表及其特点见表 2。

表 1 Tsfresh 库包含的部分特征提取方法的名称与设计原理^[25]

Tab. 1 The name and design principle of some features in Tsfresh^[25]

名称	设计原理
平均值	作为时间序列的基准线,反映序列的平均水平
标准偏差	表示时间序列的离散程度,衡量数据的波动性
变异系数	以标准偏差与均值的比率反映数据离散程度
局部波动	平滑曲线与原始曲线的差异
动态步长局部波动	具有动态步长的局部波动,捕捉细微变化
平滑因子	整体数目与转折点数目的比率
对称值	曲线的对称性,反映数据分布的均衡性
波动率	量化时间序列的整体波动能力
偏度	统计数据分布程度和偏斜方向的估计
近似熵	衡量时间序列的周期性、不可预测性和波动性
自回归系数	量化数据的周期性
峰度	概率密度分布曲线在平均值处峰值的特征数
绝对变化之和	时间序列一阶差分的绝对值之和
线性趋势	对时间序列的索引从 0 到序列长度减 1 的值进行线性最小二乘回归
快速傅里叶变换	绝对傅里叶变换谱及其统计信息

表 2 本文所用的 12 种有监督分类机器学习算法

Tab. 2 12 supervised classification machine learning algorithms used in this article

模型名称	模型概述
XGBoost ^[29]	基于梯度提升决策树的模型,支持线性模型和树模型
WeightedEnsemble ^[30]	集成选择加权模型,通过为基模型分配权重优化预测
LightGBM ^[31]	基于梯度提升的决策树模型,以直方图切分特征
CatBoost ^[32]	用于分类、回归任务的梯度提升决策树模型,有良好可解释性
RandomForestGini ^[10]	使用基尼不纯度作为分裂标准的随机森林模型
RandomForestEntr ^[28]	与 RandomForestGini 类似,但使用信息增益比作为分裂标准
ExtraTreesGini ^[26]	使用基尼不纯度作为分裂标准的极端随机树模型
ExtraTreesEntr ^[28]	与 ExtraTreesGini 类似,但使用信息增益比作为分裂标准
KNeighborsUnif ^[26]	基于统一权重的 K 近邻模型,各邻近节点拥有相同权重
KNeighborsDist ^[15]	基于距离权重的 K 近邻模型,各邻近节点的权重由距离决定
NeuralNetFastAI ^[33]	基于 FastAI 的深度神经网络模型,支持自动化特征工程
DeepNeuralNet ^[17]	基于 Pytorch 的深度神经网络模型,支持复杂非线性关系和大数据集

对于每个数据集,分别整理其传统特征参数与多维度时序特征,抽取总量的 20%作为测试集,其余数据作为训练集,对模型进行训练。为了降低超参数设置对训练结果的影响,本文使用 Autogluon 框架^[28]对表 2 中的机器学习算法模型进行训练。Autogluon 框架是一个开源的自动机器学习框架,能对超参数进行自适应调优,在多个公开数据集上的测试效果与业内专家手动调参的模型相当。由于多个

模型堆叠使用通常会显著减少最终预测结果的方差,效果优于仅使用单个模型^[34],因此在各个模型训练完成后,采用多层堆叠的方式将模型进行组合预测,最终对每个模型预测的结果按照测试集上的准确率进行加权平均。

3 实验结果分析

3.1 特征提取效果分析

为了深入评估特征与标签之间的相关性,选择了皮尔逊相关系数矩阵作为主要的分析方法。当特征与类型标签的相关系数的绝对值在 0.4 以上时,可认为该特征在不同标签上有良好的区分度,能作为区分标签的重要信息。相关系数的计算公式为

$$\rho_{X,Y} = \frac{E[(X - EX)(Y - EY)]}{\sigma_X \sigma_Y} \quad (1)$$

式中: E 为期望运算符; X, Y 为 2 个变量; σ_X, σ_Y 分别为 X, Y 的标准差; $\rho_{X,Y}$ 为 X 与 Y 的相关系数。

传统特征参数中,本文选取常用的上升时间、计数、持续时间、振幅、平均频率、绝对能量、峰值频率 7 个参数^[10]进行分析。突发型与连续型信号、腐蚀与机械损伤信号,这两类数据集的特征参数和标签的相关系数如图 4 所示。使用传统特征参数中的与标签相关系数最高的 3 个参数作为坐标轴,声发射信

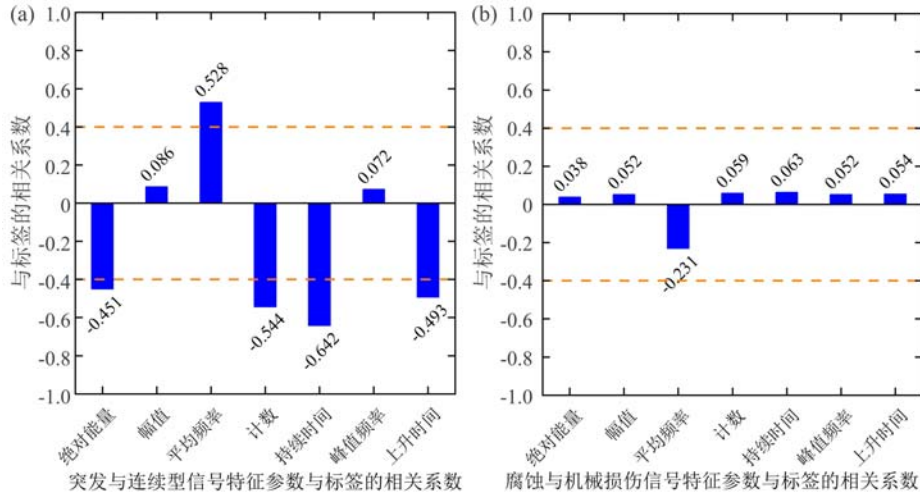


图 4 特征参数与标签的相关系数柱状图:(a)突发型与连续型信号;(b)腐蚀与机械损伤信号

Fig. 4 Histogram of correlation coefficients between feature parameters and labels:

(a) burst and continuous signals; (b) corrosion and mechanical damage signals

号在该坐标系中的分布如图 5 所示,由图可见突发型和连续型信号能被传统特征参数较好地区分,但腐蚀和机械损伤信号在特征空间分布上重叠水平较高,没有形成明显的聚类趋势,表明传统特征参数对腐蚀和机械损伤信号缺乏足够的区分度。

通过 Tsfresh 库提取的 794 个时序特征与标签的相关系数如图 6 所示,结合图 4 进行分析可知,对于突发型与连续型信号数据集,传统特征参数与标签的相关系数绝对值在 0.4 以上的仅有 5 个,而多维度时序特征中有 66 个;对于腐蚀损伤与机械损伤信号数据集传统特征参数与标签的相关系数绝对值最大值仅为 0.23,其余特征参数均小于 0.07;而多维度时序特征提取算法提取的 794 个时序特征中仍有 45 个在 0.4 以上。

抽取多维度时序特征中与标签的相关系数最大的 3 个参数,分别为 Lempel-Ziv 复杂度、连续小波变换峰值数量以及双点嵌入近似熵,将其作为坐标轴绘制信号三维分布图如图 7 所示,由图可见不同类型的声发射信号在特征空间中展现出明显的聚类趋势,所选的多维度时序特征参数具有良好的类内相似性和类间差异性,能够有效区分不同损伤来源的信号。

3.2 分类算法效果分析

在各个数据集上使用多种机器学习算法构建的模型进行训练,再将模型应用于测试集进行预测,并

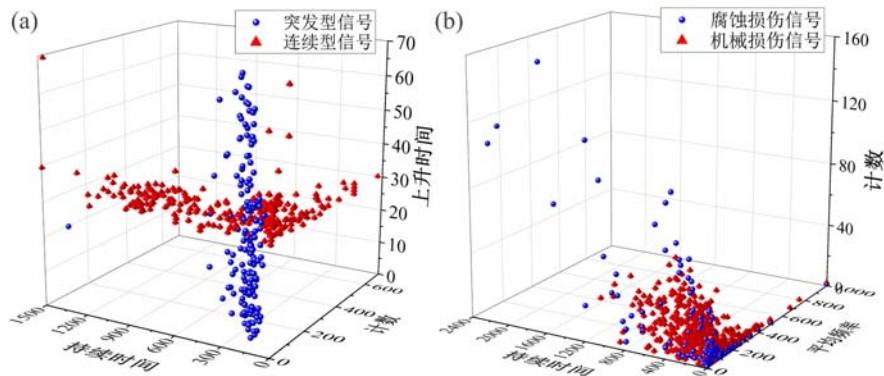


图 5 以传统特征参数为坐标轴的数据分布图:(a)突发型与连续型信号;(b)腐蚀与机械损伤信号

Fig. 5 Data distribution diagram with traditional characteristic parameters as the coordinate axis:

(a) burst and continuous signals; (b) corrosion and mechanical damage signals




图 6 多维度时序特征与标签的相关系数柱状图:(a)突发型与连续型信号;(b)腐蚀与机械损伤信号

Fig. 6 Histogram of correlation coefficients between time series features and labels:

(a) burst and continuous signals; (b) corrosion and mechanical damage signals




图 7 以多维度时序特征为坐标轴的数据分布图:(a)突发型与连续型信号;(b)腐蚀与机械损伤信号

Fig. 7 Data distribution diagram with time series features as the coordinate axis:

(a) burst and continuous signals; (b) corrosion and mechanical damage signals

将预测结果与标签进行对比,以此计算的模型准确率见表 3。由表可知,在突发型与连续型信号数据集上,使用传统特征参数进行预测的平均准确率为 94.44%,低于使用多维度时序特征的 99.48%;在腐蚀损伤与机械损伤信号数据集上,使用传统特征参数进行预测的平均准确率为 86.08%,显著低于使用多维度时序特征的 98.25%。由此可见,多维度时序特征相对于传统特征参数在分类效果上具有显著优势。此外,上述使用 Tsfresh 库对声发射波形进行特征提取的方法,可以推广至更多材料和工况,该特

征提取方法为声发射信号损伤分类研究提供了新思路。

表3 各算法在2种测试集上的分类准确率

Tab.3 Classification accuracy of each algorithm on 2 test sets

	突发性与连续型信号		腐蚀与机械损伤信号	
	传统特征参数	多维度时序特征	传统特征参数	多维度时序特征
XGBoost	90.74%	100.00%	89.02%	99.49%
WeightedEnsemble	96.29%	98.76%	89.02%	99.49%
LightGBM	96.29%	100.00%	85.58%	100.00%
CatBoost	96.29%	100.00%	85.31%	100.00%
RandomForestGini	92.59%	100.00%	85.11%	100.00%
RandomForestEntr	92.59%	100.00%	85.04%	100.00%
NeuralNetFastAI	92.59%	98.76%	84.98%	99.49%
ExtraTreesGini	94.44%	100.00%	84.78%	99.49%
ExtraTreesEntr	94.44%	98.76%	84.71%	99.49%
KNeighborsUnif	94.44%	98.76%	84.57%	90.77%
KNeighborsDist	96.29%	98.76%	84.10%	90.77%
DeepNeuralNet	96.29%	100.00%	90.77%	100.00%
平均准确率	94.44%	99.48%	86.08%	98.25%

3.3 铝锂合金应力腐蚀损伤演化分析

铝锂合金应力腐蚀实验声发射信号的累积计数曲线、加载曲线与电化学噪声曲线如图8所示。结合声发射累积计数与电化学噪声曲线的拐点与变化趋势,可将SCC过程大致分为3个阶段:0~2700s为电化学活化阶段(阶段I),2700s~5300s为裂纹萌生阶段(阶段II),5300s至断裂为裂纹扩展阶段(阶段III)^[8]。具体而言,阶段I的电化学噪声保持在较高水平,声发射活动较少;阶段II电化学噪声信号快速变化,声发射累积计数曲线斜率增大;阶段III的电化学噪声保持在较低水平,声发射活动显著增多。




图8 应力腐蚀实验声发射信号累积计数、电化学噪声电流信号及加载曲线随时间变化图

Fig.8 Cumulative counts of acoustic emission signals, electrochemical noise current signals and loading curves changing with time in stress corrosion experiments

阶段I中,电化学噪声电流的持续波动,可归因于试件表面的缺陷经过去钝化—再钝化循环逐步扩展为蚀坑^[35];阶段II中,电流值在这一阶段发生显著波动并快速下降,对应于蚀坑内出现氢致开裂,裂纹的产生使合金产生新鲜裸露表面,从而造成电化学信号快速变化^[36];进入阶段III时,声发射信号累积计数快速增长,同时该阶段的电化学电流值趋于稳定,对应于稳定裂纹的扩展^[37]。

进一步通过本文发展的基于多维度时序特征的损伤分类方法对铝锂合金应力腐蚀声发射信号进行分类,首先进行腐蚀损伤与机械损伤信号的分类,然后对分类结果为机械损伤的信号进行突发型与连续型信号的分类,其中突发型信号对应于裂纹萌生或扩展,连续型信号对应于塑性变形,3 种损伤类型的声发射信号如图 9 所示。




图 9 应力腐蚀实验的声发射信号分类结果:(a) 计数分布;(b) 累积计数曲线

Fig. 9 Classification results of AE signals in stress corrosion experiments:

(a) distribution of counts; (b) curve of cumulative counts

由图 9 可知,对应于电化学活化过程阶段 I 的机械损伤信号较少,声发射信号主要源于腐蚀,且信号的计数普遍较少,可归因于氢气泡在蚀坑底部摩擦或撞击^[38]。对应于裂纹萌生或扩展的突发型信号在约 2600s 后明显增多,与阶段 II 为裂纹萌生阶段相吻合;期间连续型信号开始少量出现,可归因于裂纹尖端产生的塑性形变。阶段 III 期间,对应于塑性形变的连续信号的累积计数呈阶梯性增长,与滑移溶解模型吻合^[39],即当累积计数曲线斜率较小时,裂纹表面被钝化,扩展速率降低;当累积计数曲线斜率较大时,裂纹尖端的塑性形变会破坏脆性氧化膜,使得金属在重新建立氧化膜之前发生溶解,导致裂纹扩展,该过程在 13000s~14000s 之间尤为集中,期间的声发射信号出现计数峰值,与裂纹的快速扩展、大量的裂纹合并相吻合;此后机械损伤的声发射累积计数曲线趋于平缓,对应于裂纹大量合并后可进一步扩展的裂纹尖端密度降低^[40]。

综上所述,铝锂合金应力腐蚀的损伤演化过程可被分为电化学活化、裂纹萌生、裂纹扩展阶段,各阶段损伤演化机理示意图如图 10 所示,电化学活化阶段试件表面的缺陷经过去钝化一再钝化循环逐步扩




图 10 铝锂合金应力腐蚀损伤演化机理示意图:(a) 电化学活化阶段;(b) 裂纹萌生阶段;(c) 裂纹扩展阶段

Fig. 10 Schematic diagram of each evolution stage of SCC for aluminum-lithium alloy:

(a) the electrochemical activation stage; (b) the crack initiation stage; (c) the crack propagation stage

展为蚀坑;裂纹萌生阶段出现氢致开裂;裂纹扩展阶段存在滑移溶解,裂纹持续扩展将导致试件最终失效。

4 结 论

本文针对铝锂合金应力腐蚀多类损伤耦合问题,发展了一种基于声发射多维度时序特征的损伤分类方法,主要结论如下:

(1) 与传统特征参数相比,对声发射信号提取的多维度时序特征与信号类型具有更高的相关性。对于突发型与连续型信号数据集,与标签之间的相关系数在 0.4 以上的特征参数由 5 个提升至 66 个;对于腐蚀与机械损伤数据集,则从 0 个提升至 45 个。

(2) 使用多维度时序特征进行分类模型训练时,相较于传统特征参数,12 种机器学习算法在测试集上的平均准确率由 90.26% 提升至 98.87%;突发型与连续型信号数据集上的准确率从 94.44% 提升至 99.48%,腐蚀损伤与机械损伤数据集上的准确率从 86.08% 提升至 98.25%。

(3) 铝锂合金应力腐蚀损伤演化过程可被分为电化学活化、裂纹萌生、裂纹扩展阶段;电化学活化阶段试件表面的缺陷经过去钝化—再钝化循环逐步扩展为蚀坑;裂纹萌生阶段出现氢致开裂;裂纹扩展阶段存在滑移溶解,裂纹扩展导致最终失效。

参 考 文 献:

- [1] LEQUEU P, SMITH K P, DANIÉLOU A. Aluminum-copper-lithium alloy 2050 developed for medium to thick plate[J]. *Journal of Materials Engineering and Performance*, 2010, 19(6):841–847.
- [2] LIU X, KIM S Y, LEE S H, et al. Atomistic investigation on initiation of stress corrosion cracking of polycrystalline Ni₆₀Cr₃₀Fe₁₀ alloys under high-temperature water by reactive molecular dynamics simulation[J]. *Computational Materials Science*, 2021, 187:110087.
- [3] LIU C, KELLY R G. A review of the application of finite element method (FEM) to localized corrosion modeling [J]. *Corrosion*, 2019, 75(11):1285–1299.
- [4] CUI C, MA R, MARTÍNEZ-PAÑEDA E. A phase field formulation for dissolution-driven stress corrosion cracking[J]. *Journal of the Mechanics and Physics of Solids*, 2021, 147:104254.
- [5] PARK J, KIM J S, LEE D Y, et al. Real-time monitoring of stress corrosion cracking in 304L stainless steel pipe using acoustic emission[J]. *Journal of Nuclear Materials*, 2022, 571:154009.
- [6] KOVA J, LEGAT A, ZAJEC B, et al. Detection and characterization of stainless steel SCC by the analysis of crack related acoustic emission[J]. *Ultrasonics*, 2015, 62:312–322.
- [7] KUANG W, NING Z, YUE H, et al. The correlation between the dislocation slip/grain boundary interaction mode and the resistance to SCC initiation of Alloy 690 in simulated PWR primary water[J]. *Corrosion Science*, 2023, 217:111096.
- [8] CALABRESE L, BONACCORSI L, GALEANO M, et al. Identification of damage evolution during SCC on 17-4 PH stainless steel by combining electrochemical noise and acoustic emission techniques[J]. *Corrosion Science*, 2015, 98:573–584.
- [9] KOVAC J, ALAUX C, MARROW T J, et al. Correlations of electrochemical noise, acoustic emission and complementary monitoring techniques during intergranular stress-corrosion cracking of austenitic stainless steel [J]. *Corrosion Science*, 2010, 52(6):2015–2025.
- [10] ZHANG Z, WU X, TAN J. In-situ monitoring of stress corrosion cracking of 304 stainless steel in high-temperature water by analyzing acoustic emission waveform[J]. *Corrosion Science*, 2019, 146:90–98.
- [11] 武梦雅, 刘云芳, 李鹏, 等. 碳纤维复合材料自行车前叉冲击-疲劳测试的声发射研究[J]. *实验力学*, 2023, 38(3):387–402 (WU Mengya, LIU Yunfang, LI Peng, et al. Acoustic emission study on impact-fatigue test of carbon fiber composite bicycle front fork[J]. *Journal of Experimental Mechanics*, 2023, 38(3):387–402 (in Chinese))
- [12] 李建宇, 贾中汇, 张扬扬. 铝合金在不同应力状态下微损伤演化的声发射研究[J]. *实验力学*, 2020, 35(4):650–658 (LI Jianyu, JIA Zhonghui, ZHANG Yangyang. Study on the micro-damage evolution of aluminum alloy under different stress states based on acoustic emission[J]. *Journal of Experimental Mechanics*, 2020, 35(4):650–658 (in Chinese))

- [13] XU J, WU X, HAN E H. Acoustic emission response of sensitized 304 stainless steel during intergranular corrosion and stress corrosion cracking[J]. *Corrosion Science*, 2013, 73:262–273.
- [14] LI J, DU G, JIANG C, et al. The classification of acoustic emission signals of 304 stainless steel during stress corrosion process based on K-means clustering[J]. *Anti-Corrosion Methods and Materials*, 2012, 59(2):76–80.
- [15] ALMEIDA R S M, MAGALHÃES M D, KARIM M N, et al. Identifying damage mechanisms of composites by acoustic emission and supervised machine learning[J]. *Materials & Design*, 2023, 227:111745.
- [16] MÁTHIS K, PRCHAL D, NOVOTN R, et al. Acoustic emission monitoring of slow strain rate tensile tests of 304L stainless steel in supercritical water environment[J]. *Corrosion Science*, 2011, 53(1):59–63.
- [17] 李睿, 张纯, 万乐, 等. 基于无监督深度学习的声发射信号聚类分析[J]. *无损检测*, 2021, 43(2):5–10 (LI Rui, ZHANG Chun, WAN Le, et al. Clustering analysis of acoustic emission signals based on unsupervised deep learning[J]. *Nondestructive Testing*, 2021, 43(2):5–10 (in Chinese))
- [18] 周俊, 尹悦, 夏斌. 基于 LSTM 神经网络的声发射信号识别研究[J]. *计算机科学*, 2021, 48(增刊 2):319–326 (ZHOU Jun, YIN Yue, XIA Bin. Acoustic emission signal recognition based on long short time memory neural network[J]. *Computer Science*, 2021, 48(Suppl. 2):319–326 (in Chinese))
- [19] CHRIST M, BRAUN N, NEUFFER J, et al. Time series feature extraction on basis of scalable hypothesis tests (tsfresh-a python package)[J]. *Neurocomputing*, 2018, 307:72–77.
- [20] PETELIN G, CENIKJ G, EFTIMOV T. Towards understanding the importance of time-series features in automated algorithm performance prediction[J]. *Expert Systems with Applications*, 2023, 213:119023.
- [21] MAKRIDAKIS S, SPILLOTIS E, ASSIMAKOPOULOS V. The M4 competition: results, findings, conclusion and way forward[J]. *International Journal of Forecasting*, 2018, 34(4):802–808.
- [22] DEMPSEY D E, CRONIN S J, MEI S, et al. Automatic precursor recognition and real-time forecasting of sudden explosive volcanic eruptions at Whakaari, New Zealand[J]. *Nature Communications*, 2020, 11(1):3562.
- [23] KENNEDY A, NASH G, RATTENBURY N J, et al. Modelling the projected separation of microlensing events using systematic time-series feature engineering[J]. *Astronomy and Computing*, 2021, 35:100460.
- [24] 胡少康, 张道辉, 赵新刚, 等. 基于特征工程与级联森林的中风患者手部运动肌电识别方法[J]. *机器人*, 2021, 43(5):526–538 (HU Shaokang, ZHANG Daohui, ZHAO Xingang, et al. An sEMG-based hand motion recognition method for stroke patients with feature engineering and cascade forest[J]. *Robot*, 2021, 43(5):526–538 (in Chinese))
- [25] YANG Z, ABBASI I A, MUSTAFA E E, et al. An anomaly detection algorithm selection service for IOT stream data based on tsfresh tool and genetic algorithm[J]. *Security and Communication Networks*, 2021, 2021:6677027.
- [26] MUIR C, SWAMINATHAN B, ALMANSOUR A S, et al. Damage mechanism identification in composites via machine learning and acoustic emission[J]. *NPJ Computational Materials*, 2021, 95:1–15.
- [27] UNTERBERG M, VOIGTS H, WEISER I F, et al. Wear monitoring in fine blanking processes using feature based analysis of acoustic emission signals[J]. *Procedia CIRP*, 2021, 104:164–169.
- [28] QI W, XU C, XU X. AutoGluon: a revolutionary framework for landslide hazard analysis[J]. *Natural Hazards Research*, 2021, 1(3):103–108.
- [29] CHEN T, GUESTRIN C. XGBoost: a scalable tree boosting system[C]. *New York: Association for Computing Machinery*, 2016:785–794.
- [30] CARUANA R, NICULESCU-MIZIL A, CREW G, et al. Ensemble selection from libraries of models[C]. *New York: Association for Computing Machinery*, 2004:18.
- [31] WANG D, LI L, ZHAO D. Corporate finance risk prediction based on LightGBM[J]. *Information Sciences*, 2022, 602:259–268.
- [32] HUANG G, WU L, MA X, et al. Evaluation of CatBoost method for prediction of reference evapotranspiration in humid regions[J]. *Journal of Hydrology*, 2019, 574:1029–1041.
- [33] HOWARD J, GUGGER S. Fastai: a layered API for deep learning[J]. *Information*, 2020, 11(2):108.
- [34] DIETTERICH T G. Ensemble methods in machine learning[C]. *Berlin: Springer Berlin Heidelberg*, 2000:1–15.
- [35] DELAUNOIS F, TSHIMOMBO A, STANCIU V, et al. Monitoring of chloride stress corrosion cracking of

- austenitic stainless steel; identification of the phases of the corrosion process and use of a modified accelerated test [J]. *Corrosion Science*, 2016, 110:273–283.
- [36] WALL F D, STONER G E. The evaluation of the critical electrochemical potentials influencing environmentally assisted cracking of Al-Li-Cu alloys in selected environments[J]. *Corrosion Science*, 1997, 39(5):835–853.
- [37] BREIMESSER M, RITTER S, SEIFERT H P, et al. Application of electrochemical noise to monitor stress corrosion cracking of stainless steel in tetrathionate solution under constant load[J]. *Corrosion Science*, 2012, 63: 129–139.
- [38] WU K, JUNG W S, BYEON J W. In-situ monitoring of pitting corrosion on vertically positioned 304 stainless steel by analyzing acoustic-emission energy parameter[J]. *Corrosion Science*, 2016, 105:8–16.
- [39] NEWMAN R C, HEALEY C. Stability, validity, and sensitivity to input parameters of the slip-dissolution model for stress-corrosion cracking[J]. *Corrosion Science*, 2007, 49(10):4040–4050.
- [40] BOLIVAR J, FRÉGONÈSE M, RÉTHORÉ J, et al. Evaluation of multiple stress corrosion crack interactions by in-situ digital image correlation[J]. *Corrosion Science*, 2017, 128:120–129.

Research on classification method of stress corrosion damage of aluminum-lithium alloy based on multi-dimensional time series features of acoustic emission

YIN Zhangcheng, LEI Yilu, SONG Haipeng

(Civil Aviation University of China, China-European Institute of Aeronautical Engineers, Tianjin 300300, China)

Abstract: Stress corrosion cracking (SCC) in aerospace alloys is a critical failure mode in aircraft structures. A classification method based on multidimensional time-series features of acoustic emission (AE) was employed to address the problem of multi-type damage coupling in lithium-aluminum alloys, utilizing the Tsfresh library and machine learning algorithms. By combining AE damage classification with electrochemical noise data, the study discussed the damage evolution stages of aluminum-lithium alloys under SCC. The research indicated that, compared to traditional feature parameters, multi-dimensional time series feature parameters had a higher correlation with damage type labels, and the average accuracy of 12 machine learning algorithms on the test set increased from 90.26% to 98.87%, indicating that using multi-dimensional time series features for damage classification had significant advantages. The SCC damage evolution process of aluminum-lithium alloys can be divided into three stages: electrochemical activation, crack initiation, and crack propagation. In the electrochemical activation stage, defects on the specimen surface gradually expanded into pits through de-passivation and re-passivation cycles. Hydrogen-induced cracking appeared during the crack initiation stage, slip dissolution existed during the crack expansion stage, and cracks gradually expanded until ultimate failure happened.

Keywords: acoustic emission; aluminum-lithium alloy; stress corrosion; damage classification