

航空结构声发射数据质量评估与 疲劳损伤监测方法

鲁凡, 李响, 雷亚国, 李乃鹏, 杨彬

(西安交通大学现代设计及转子轴承系统教育部重点实验室, 710049, 西安)

摘要: 针对声发射技术在监测航空结构微裂纹萌生拓展时面临的结构微损伤特征难以提取、噪声干扰下损伤定位精度不高等问题,提出了面向航空结构健康监测的声发射数据质量评估与疲劳损伤监测方法。基于深度卷积自编码器,建立了声发射信号的数据质量智能评估模型,通过提取原始声发射数据的高层特征,实现了裂纹损伤与噪声信号的自适应识别,完成了声发射信号的自动降噪。采用航空铝合金结构件疲劳试验中采集的声发射监测数据对所提方法进行实验验证,结果表明:所提方法计算得到早期健康阶段数据和中后期损伤阶段数据的平均重构误差分别为 0.007 和 0.020,准确地实现了噪声信号与损伤信号的有效甄别。损伤起始时间比试验中发现宏观裂纹的时间早 22 min,能够在裂纹萌生拓展的早期阶段有效预警。与原始定位图相比,在剔除了噪声信号后进行损伤拓展定位,能够清晰地呈现出裂纹的长期发展趋势。实验结果证明了所提方法具有在工程场景下应用的潜力。

关键词: 声发射信号;结构健康监测;卷积自编码器;数据质量评估;疲劳损伤

中图分类号: V216.3 **文献标志码:** A

DOI: 10.7652/xjtuxb202509001 **文章编号:** 0253-987X(2025)09-0001-10

Method of Acoustic Emission Data Quality Assessment and Fatigue Damage Monitoring for Aeronautical Structures

LU Fan, LI Xiang, LEI Yaguo, LI Naipeng, YANG Bin

(Key Laboratory of Education Ministry for Modern Design and Rotor-Bearing System,

Xi'an Jiaotong University, Xi'an 710049, China)

Abstract: To address the challenges in monitoring micro-crack initiation and propagation in aeronautical structures using acoustic emission (AE) technology, including difficulties in extracting micro-damage features and low damage localization accuracy under noise interference, this study proposes a method that enhances aeronautical structural health monitoring through AE data quality assessment and fatigue damage monitoring for aeronautical structures. The method establishes an intelligent quality assessment model for AE signals based on a deep convolutional autoencoder, which extracts high-level features from raw AE data to achieve adaptive discrimination between crack-induced signals and noise, enabling automatic denoising of AE signals. Experimental validation is conducted using AE monitoring data collected from fatigue tests of aerospace

收稿日期: 2025-02-16。 作者简介: 鲁凡(2002—),男,硕士生;李响(通信作者),男,教授,博士生导师。 基金项目: 国家自然科学基金资助项目(52005086);航空科学基金资助项目(2024Z071070001);新基石科学基金会所设立的科学探索奖资助项目。

网络出版时间: 2025-05-12

网络出版地址: <https://link.cnki.net/urlid/61.1069.t.20250510.1718.002>

aluminum alloy components. The results demonstrate that the proposed method yields average reconstruction errors of 0.007 and 0.020 for data from the early healthy stage and mid-to-late damage stage, respectively, achieving accurate differentiation between noise and damage signals. The detected damage initiation time is 22 min earlier than the macroscopic crack observation time in the experiment, proving effective for early warning during crack initiation and propagation. Compared to original localization maps, the damage progression localization after noise removal clearly reveals the long-term crack development trend. The experimental results demonstrate the potential applicability of the proposed method in engineering scenarios.

Keywords: acoustic emission signal; structural health monitoring; convolutional autoencoder; data quality assessment; fatigue damage

由于航空飞行器长期服役于恶劣工况下,其关键构件在内外动态载荷、腐蚀疲劳等因素的持续性影响下产生疲劳损伤。这些损伤会在未被察觉的情况下逐渐积累,形成疲劳裂纹,减少飞行器的使用寿命,降低其安全性能,甚至导致结构的故障和破坏,造成灾难性的后果。通过结构健康监测(SHM)技术对航空结构的疲劳裂纹扩展进行在线监测和诊断,对保障航空飞行器的高性能、高可靠性运行具有重要意义^[1-4]。在多种无损检测方法中,基于声发射的 SHM 技术具有灵敏度高、实时连续、几乎不受结构几何形状限制等优势,广泛应用于多种复杂形状航空飞行器结构件的损伤监测^[5]。

飞行器结构疲劳试验作为模拟真实服役工况的地面试验,是验证结构疲劳强度、发现材料薄弱部位、评估机体安全寿命的重要手段^[6]。试验中应用声发射技术的主要目的是对结构损伤的发生进行早期预警定位、对损伤扩展情况进行有效监控。然而,由于试验工况复杂、声发射源种类繁多、噪声干扰严重,声发射 SHM 技术尚未完全发挥其优势。具体表现在两方面:一方面,试验中存在大量噪声干扰,使得微弱的疲劳裂纹萌生、扩展产生的声发射信号容易被淹没^[7];另一方面,以参数分析法^[8-10]和波形分析法^[11]为代表的传统的声发射信号处理方法如依赖专家知识,在建立人工特征与损伤模式间的内在联系时的稳定性与准确性仍有待加强,智能化程度亦未达到理想水平。

对于声发射 SHM 技术,将不同类型声发射源产生的信号进行特征提取与模式识别,提取出损伤源的相关信息,对于裂纹监测意义重大。近年来,以卷积神经网络(CNN)为代表的深度学习方法依赖强大的自动特征提取和海量数据处理能力,成为机械装备结构健康监测领域研究热点^[12-16]。Sikdar

等^[17]和 Barile 等^[18]都利用 CNN 自动从声发射信号的时频图中提取损伤特征,识别材料中的不同损伤模式。König 等^[19]基于声发射信号特征和长短期记忆网络提出了一种数据驱动的滑动轴承磨损监测模型,实现了实时、量化的磨损监测。Du 等^[20]采用声发射技术和具有注意力机制的深度学习模型,以自动化损伤诊断过程并提高预测精度。Li 等^[21]提出了基于物理引导的 CNN 模型,将网络输出应用高斯混合模型进行聚类,实现了高强度螺栓连接不同损伤阶段的区分。以上工作均是利用监督学习的方法对实验室中不同损伤模式下获取的声发射信号进行分类工作,然而在工程实际中,大部分数据是缺失明确健康状态的,因此无监督学习的声发射信号分析方法更具有工程应用价值,但目前相关研究较少。李睿等^[22]使用自编码器和 K 均值聚类算法对复合材料板的声发射断铅和摩擦信号进行聚类分析,与工程应用仍存在一定距离。

针对上述问题,提出了基于卷积自编码器的声发射数据质量评估方法,用于识别航空结构件疲劳破坏过程中的声发射损伤信号,再根据损伤信号的相关信息,对航空结构进行裂纹监测。首先,进行航空铝合金结构件的疲劳试验,采集声发射监测数据集。其次,采用卷积自编码器表征学习声发射信号的深层特征并进行信号重构,以模型输出的重构误差作为数据质量评估标准,实现了无需先验信息的声发射信号损伤模式识别。最后,使用损伤信号的到达时间等信息进行早期损伤预警和损伤拓展定位,实现航空结构件疲劳过程中裂纹的有效监测。

1 数据质量评估与损伤监测方法

本文所提方法的整体框架如图 1 所示,主要包

括疲劳试验与声发射数据采集、声发射数据质量评估与损伤识别、早期损伤预警与损伤拓展预警 3 个部分。其中, μ 为重构误差的均值, σ 为重构误差的标准差, c 为连续触发数, c_L 为连续触发数的阈值。

1.1 卷积自编码器

卷积自动编码器是一种无监督学习的神经网络,由编码器和解码器两个对称部分组成。编码器部分通过卷积、池化、激活等操作,将原始数据映射为深层特征,解码器则通过转置卷积和反池化等,尽可能地将深层特征准确地重构为原始输入数据。通过最小化原始输入数据与重构数据之间的重构误差,利用误差反向传播算法训练网络,使编码器和解码器学习到数据的隐含表示,网络输出尽可能地逼近网络输入^[23]。

1.2 声发射信号的数据质量评估与损伤识别

根据声发射信号的时域波形特征和物理来源,可以将信号分为突发型信号和连续型信号两类^[24],如图 2 所示。首先,突发型信号的时域波形中通常存在明显的脉冲成分,而连续型信号波形杂乱无章,成分复杂。其次,两者的产生源头有明显差异。突发型信号源于材料中裂纹的萌生、拓展或者结构的断裂破坏,通过断铅实验也可以获得突发型的声发射信号。连续型信号通常在材料的塑性变形过程中产生,与裂纹发展的关联性较小,在裂纹发展监测中的参考价值相对有限。由于试验中主要关注疲劳裂纹的发展情况,因此认为连续型信号是噪声信号,数据质量低;突发型信号是损伤信号,数据质量高,并依据其进行裂纹监测。




图 1 本文所提方法的整体框架

Fig. 1 Overall framework of the proposed method




图2 不同类型声发射信号的时域波形

Fig. 2 Different acoustic emission waveforms in time domain

由于强大的无监督特征学习和数据重构能力,本文采用卷积自编码器网络进行数据质量评估。声发射信号的数据质量评估的方法如图3所示。




图3 声发射信号的数据质量评估方法

Fig. 3 Data quality evaluation for acoustic emission signals

在模型训练阶段,将试件健康阶段的噪声信号输入模型中,通过最小化噪声信号与重构信号之间的均方误差,使卷积自编码器学习到噪声信号的特征表示。在模型测试阶段,将疲劳试验的所有声发射信号都输入到模型中,如果输入数据与健康状态噪声信号波形类似,由于之前充分学习过噪声信号的特征,自编码器对其进行重构时产生的重构误差较小;反之,如果输入数据与裂纹萌生拓展状态损伤信号波形类似,模型输出的重构误差会明显偏大。训练完毕后,由于模型输出的噪声信号的重构误差较小且基本符合正态分布规律,因此可以将模型的重构误差作为数据质量评估的标准,利用 3σ 原则对全体数据的重构误差进行筛选,识别损伤信号。均方误差损失函数的计算式如下

$$L_{\text{mse}} = \frac{1}{N} \sum_{n=1}^N (y(n) - x(n))^2 \quad (1)$$

式中: L_{mse} 为均方误差损失函数; $y(n)$ 为卷积自编码器重构得到的信号; $x(n)$ 为原始信号; N 为数据点个数。

1.3 数据预处理方法

为了使数据质量评估模型在训练过程中能充分学习到噪声信号的特征,有必要通过合适的数据预处理方法,获得一个几乎完全由噪声信号构成的训练集。然而,即使是在疲劳试验中早期健康阶段,由于环境噪声、偶然外界扰动等因素,偶尔也有非噪声波形的信号出现。如果选取早期阶段的数据直接训练模型,势必会在一定程度上降低模型的数据质量评估性能。本文通过数据归一化、随机选取和数据清洗3个步骤,去除训练集中的非噪声信号。

数据归一化方法采用 Z-Score 标准化,将原始数据转换为符合标准正态分布的数据,能够有效提高数据可比性,削弱数据解释性。由于卷积自编码器中采用均方误差作为损失函数,其对信号的幅值较为敏感,数据归一化还能有效降低信号幅值差异对数据质量评估结果的影响,提高损伤信号识别准确率。

构建训练集时,在宏观裂纹出现前的健康阶段数据中随机抽样,得到初始训练集。峭度是描述信号 $x(n)$ ($n = 1, 2, \dots, N$) 分布平坦程度的特征参数,计算式如下

$$K_t = \frac{\sum_{n=1}^N (x(n) - \bar{x})^4}{(N-1)\sigma_1^4} \quad (2)$$

式中: K_t 为信号峭度; $\bar{x}$ 为信号均值; σ_1 为信号标准差。

由于损伤信号中存在明显的脉冲成分,其峭度会明显高于噪声信号,因此本文利用信号的峭度参数和箱型图异常值检测方法,对初始训练集进行数据清洗,剔除其中的非噪声信号。

1.4 损伤监测方法

识别出各通道原始声发射数据中的损伤信号后,需要将它们匹配成声发射事件,才能进行后续的预警与定位工作。本文根据各通道信号到达时间相似性进行事件匹配,首先将各通道损伤信号到达时间的数量级换算至 μs ;接着对换算后的到达时间以 10^a 整除,其中 a 为相似性判断参数;最后,对比各通道信号的到达时间,若多个通道中存在到达时间相同的信号,则一一匹配输出为有效声发射定位事件组。依据断铅实验的结论,将 a 设为 3,将 μs 级及

以上到达时间完全相同的两个声发射信号匹配成一个事件。

根据声发射信号寻找飞行器结构由健康阶段衰退为损伤阶段的具体时间,即初始损伤时刻,对于结构的及时检查维修及剩余寿命预测都具有重要意义。本文使用 1 min 内的声发射损伤次数和连续触发算法实现早期损伤预警。首先,统计 1 min 内的损伤信号个数。然后,若连续 c_L 时间内损伤次数均大于 0,则认为裂纹已经开始发展,并将这段时间内的第一个声发射损伤信号的到达时间作为损伤起始时间,进行早期损伤报警。如果后续连续 c'_L 内出现损伤次数为 0 的情况,则重置损伤起始时间并重新计算。本文中连续触发时间 c_L 设为 3 min,断触时间 c'_L 设为 2 min,能够较为及时且准确地进行早期损伤预警。

到达时间差(TDOA)定位法是一种常用声发射源定位方法,可以用于显示裂纹拓展过程在时间、空间上的分布^[25]。该方法依靠各传感器接收信号到达时间差、波速、探头间距等参数及其相关定位算法来确定裂纹位置。本文主要用到了一维线定位方法,该方法使用 2 个声发射传感器构成一个定位组,分别放置在检测区域的两侧。裂纹扩展时,裂纹损伤发出的声发射信号先后到达这 2 个传感器,构成一个定位事件组。裂纹位置可以由定位事件组中信号的到达时间差计算得到,计算式如下

$$l = \frac{L - (t_{a2} - t_{a1})v}{2}$$

(3)

式中: l 是裂纹拓展位置与 1 号传感器的距离; L 是 2 个传感器之间的距离; t_{a1} 、 t_{a2} 分别是声发射信号到达 1 号和 2 号传感器的时间; v 是应力波在试件材料中的传播速度。

2 疲劳试验验证

2.1 试验过程与数据采集

设计并开展了航空铝合金板材的全寿命疲劳破坏试验。试验中使用的航空铝合金试验件如图 4 所示,其基本尺寸参数如表 1 所示。试验件材料采用高强度、高耐腐蚀性能的 7050 航空铝合金,广泛应用于航空飞行器中承受较大载荷的机身结构和机翼部件。试验开始前,在板材的中心位置处使用激光切割方式加工直径为 5 mm 的圆形孔洞,用于引导裂纹的初始萌生位置。试验中,使用疲劳拉伸机对试件在其长度方向上施加大小为 1.7~17 kN、频率为 5 Hz 的正弦波周期性载荷直至结构断裂破坏。在周期性载荷的持续作用下,试件材料的疲劳程度

不断加重,逐渐引起内部微观结构的变化,形成微小缺陷。这些缺陷会在载荷的持续作用下不断发展,形成宏观裂纹,之后裂纹快速拓展,直到整个结构件的断裂破坏。试验中,通过设置噪声元件来引入可控的背景噪声,在一定程度上模拟飞机飞行过程中所面临的复杂噪声环境。




图 4 航空铝合金试验件

Fig. 4 Aviation aluminum alloy specimens

表 1 铝合金板试验件基本尺寸参数

Table 1 Parameters of aluminum alloy specimens

试件尺寸/ (mm×mm)	测试区域尺寸/ (mm×mm)	传感器 设置坐标	波形信号 数量
320×40	100×40	# 1:(-70,0) # 2:(70,0)	4 806×2

此过程中材料会发出声发射信号,并由声发射监测仪器采集得到。选用 2 个中心频率为 150 kHz 的 R15 型谐振式压电传感器放置在板材横向采集声发射信号,对裂纹进行线定位监测。经过多次断铅试验测试,在 AEwin 软件中设置采集参数:信号幅值门阈值为 40 dB;前放增益为 40 dB;系统采样频率为 1 MHz;峰值定义时间(PDT)为 300 μ s;声发射事件定义时间(HDT)为 600 μ s;撞击闭锁时间(HLT)为 500 μ s,最大持续时间为 10 ms,每个声发射波形信号均有 1 024 个采样点。试验中记录了试件总寿命为 212 min,总应力循环次数为 74 133 次。试验过程中,试件上宏观裂纹出现时间为 192 min,此时应力循环次数为 68 255 次,此后试件继续受到疲劳载荷作用,其内部裂纹快速发展,并在 20 min 内断裂破坏。

2.2 数据分析

在 AEwin 软件对试验中 140 min 到试验结束时间段内试件连续加载过程中采集到的声发射监测数据进行重放(140 min 之前试件均处于健康阶段,分析价值较小),初步显示声发射监测方法定位效果,如图 5 所示。





图 5 原始数据在 AEwin 软件的定位结果
Fig. 5 Localization results of raw data in AEwin


在试验的早期时间段内,试件处于健康状态,裂纹还未出现,定位点呈现零散分布,采集的声发射信号大多是噪声信号。承受长时间的疲劳载荷作用后,在试验的中后期(约 2 500 s 开始),可以看到在试件的中间位置处定位点逐渐增多,出现了裂纹萌生发展的迹象。之后裂纹不断发展,损伤信号的数量快速

增加,试件中心的定位点扩展到周围位置,直到试件断裂。然而,试验过程始终包含有大量噪声信号引起的错误定位点,对裂纹监测显示造成干扰,导致损伤监测定位图无法清晰显示裂纹的发展情况。


结合试验记录中宏观裂纹出现时间和图 5 中的定位结果,可以初步将试验划分成健康阶段、轻微损伤、重度损伤阶段,3 个阶段中典型声发射信号的时域和频域图如图 6 所示。从时域和频域图中可以看出,随着试件损伤程度的增加,声发射信号时域图中的电压逐渐提高,脉冲波形成分愈发突出,频域主要成分集中在 150 kHz。随着损伤加重,150 kHz 以下频率成分削弱,150 kHz 以上频率成分增强。




(a)600 s 时(健康状态)信号时域图




(b)600 s 时(轻微损伤)信号频域图




(c)2 800 s 时(健康状态)信号时域图



(d)2 800 s 时(轻微损伤)信号频域图



(e)4 200 s 时(健康状态)信号时域图



(f)4 200 s 时(轻微损伤)信号频域图

图 6 实验中各阶段中典型声发射信号时域和频域图

Fig. 6 Time-domain and frequency-domain images of typical acoustic emission signals in each stage of the experiment

2.3 模型结构与训练设置

数据质量评估模型的卷积自编码器结构由编码器、解码器及损失函数组成,编码器部分由 6 层卷积层和池化层构成,解码器部分为与之对称的反卷积和反池化层,网络结构如表 2 所示。各卷积层的卷积核大小均设为 3,步长均设为 1,且进行零补操作,卷积核数分别为 16、32、64。池化层中选用最大池化方式进行数据降维,选择 LeakyReLU 激活函数。解码器利用反卷积、反池化等操作,尽可能地还原原

始输入。网络训练过程中选择均方误差函数作为损失函数,用于衡量原始数据和重构数据的偏差。模型训练阶段,输入数据为经过预处理后几乎仅包含噪声成分的训练集,采用 Adam 优化器进行参数更新,共迭代训练 300 轮。训练过程中采用学习率衰减策略,设置初始学习率为 0.001,衰减间隔为 50,衰减幅度为 0.8。模型测试阶段,输入为经过 Z-Score 标准化处理的全部声发射信号数据,批量大小设为 1,以输出每个信号对应的重构误差。

表 2 网络结构参数

Table 2 Parameters of network structure

编号	网络层	卷积核尺寸	步长	零补操作	输出尺寸
1	卷积层 1	3×16	1	是	$1\,024 \times 16$
2	池化层 1	2×1	2	否	512×16
3	卷积层 2	3×32	1	是	512×32
4	池化层 2	2×1	2	否	256×32
5	卷积层 3	3×64	1	是	256×64
6	池化层 3	2×1	2	否	128×64
7	反池化层 1	2×1	2	否	256×64
8	反卷积层 1	3×32	1	是	256×32
9	反池化层 2	2×1	2	否	512×32
10	反卷积层 2	3×16	1	是	512×16
11	反池化层 3	2×1	2	否	$1\,024 \times 16$
12	反卷积层 3	3×1	1	是	$1\,024 \times 1$

2.4 数据质量评估与损伤识别结果

数据质量评估模型输出的声发射信号的重构误差随时间的分布如图 7 所示。噪声信号在试件疲劳过程中的各时间段内广泛存在,而损伤信号从 1 800 s 左右开始出现,并持续地增加,在试验后期试件即将断裂时数量达到最多。使用卷积自编码器进行数据质量评估,并根据早期健康阶段数据的重构误差和 3σ 原则计算得到噪声和损伤信号的分类阈值约为

0.011,最终在 4 806 个声发射信号中共识别得到 1 379 个损伤信号。早期健康阶段数据的平均重构误差为 0.007,中后期损伤阶段数据的平均重构误差为 0.020,两者有较大差距,说明该模型能实现损伤信号与噪声信号的有效分类。




图 7 数据质量评估与损伤识别

Fig. 7 Data quality assessment and damage identification

利用参数分析法可以在一定程度上验证此模型的损伤识别效果。对分类得到的噪声信号和损伤信号使用幅值、振铃计数、能量、上升时间、持续时间、偏斜度、峭度、重心频率及峰值频率 9 个特征参数进行分析,结果如图 8 所示。




图 8 噪声和损伤信号的特征参数分析

Fig. 8 Parameter analysis of noise and damage signals

除上升时间和持续时间外,噪声信号的特征参数均表现平稳,而损伤信号的特征参数如幅值、能量表现出随时间上升的趋势。在这些特征参数中,损伤信号的峭度、重心频率两个参数与噪声信号在分布上存在明显的差异。

2.5 损伤监测结果

将两个通道中识别的声发射损伤信号根据到达时间相似性匹配成定位事件。其中通道1共识别1442个损伤信号,通道2识别1379个损伤信号,最终匹配得到1307个声发射损伤事件。两个通道识别的损伤信号匹配率均高于90%,侧面说明使用本文方法进行损伤识别的准确率较高。统计1 min内的事件数,根据连续触发方法进行早期损伤预警。计算得到损伤起始时间为1764 s,对应试件寿命时间约为170 min。而试验中通过相机记录试件上宏观裂纹的发展情况,192 min时才发现宏观裂纹的存在。说明此方法可以在早期时段检测到裂纹萌生的迹象。

最后利用TDOA法进行损伤拓展定位,结果如图9所示。可以看到,从大约1800 s开始,裂纹从板材中心位置处开始发展,随着疲劳的加重,逐渐向板材的两侧拓展,最终在板材即将断裂时,板材横向的所有位置上均出现损伤定位点。整个过程与疲劳试验中铝合金板的健康状态变化情况相符。因此,认为数据质量评估方法去除了原始数据集中的绝大部分噪声信号,实现了铝合金板疲劳过程中裂纹拓展的有效监测,能够清晰地显示出裂纹的时空发展趋势。




图9 损伤拓展定位结果

Fig. 9 Result of damage expansion localization

3 结论

针对航空结构疲劳试验采集的声发射数据中存

在大量噪声信号干扰,进而导致裂纹监测损伤定位不准确的问题,本文基于卷积自编码器建立了声发射信号的数据质量评估方法,实现了声发射信号的智能损伤识别、早期损伤预警与损伤拓展定位。主要研究结论如下。

(1)使用卷积自编码器模型对声发射信号进行数据质量评估与智能损伤识别,在4806个声发射数据中共识别了1379个损伤信号。早期健康阶段数据和后期损伤阶段数据的平均重构误差分别为0.007和0.020,差距较大,说明该模型能实现损伤信号与噪声信号的有效分类。

(2)利用损伤信号根据1 min内的损伤次数和连续触发方法进行早期损伤报警,得到损伤起始时间为170 min,而试验记录中在192 min时才发现裂纹的存在,说明此方法可以在裂纹萌生的早期时段发现裂纹萌生的迹象。与原始数据在AEwin软件中的定位图相比,在剔除了噪声信号后进行损伤拓展定位,可以清晰地显示出裂纹的时空发展趋势。

参考文献:

- [1] 房芳, 郑辉, 汪玉, 等. 机械结构健康监测综述 [J]. 机械工程学报, 2021, 57(16): 269-292.
FANG Fang, ZHENG Hui, WANG Yu, et al. Mechanical structural health monitoring: a review [J]. Journal of Mechanical Engineering, 2021, 57(16): 269-292.
- [2] GHOLIZADEH S, LEMAN Z, BAHARUDIN B T H T. A review of the application of acoustic emission technique in engineering [J]. Structural Engineering and Mechanics, 2015, 54(6): 1075-1095.
- [3] VERSTRYNGE E, LACIDOGNA G, ACCORNERO F, et al. A review on acoustic emission monitoring for damage detection in masonry structures [J]. Construction and Building Materials, 2021, 268: 121089.
- [4] MCCRORY J P, VINOGRADOV A, PEARSON M R, et al. Acoustic emission monitoring of metals [M]//GROSSE C U, OHTSU M, AGGELIS D G, et al. Acoustic Emission Testing: Basics for Research-Applications in Engineering. Cham, Belin: Springer International Publishing, 2022: 529-565.
- [5] 杨宇, 王彬文, 祁小凤. 面向全尺寸民机结构疲劳试验的声发射监测技术 [J]. 航空学报, 2022, 43(6): 241-253.
YANG Yu, WANG Binwen, QI Xiaofeng. Acoustic emission monitoring technology for fatigue test of full-

- scale civil aircraft structure [J]. *Acta Aeronautica et Astronautica Sinica*, 2022, 43(6): 241-253.
- [6] 王彬文, 陈先民, 苏运来, 等. 中国航空工业疲劳与结构完整性研究进展与展望 [J]. *航空学报*, 2021, 42(5): 1-39.
- WANG Binwen, CHEN Xianmin, SU Yunlai, et al. Research progress and prospect of fatigue and structural integrity for aeronautical industry in China [J]. *Acta Aeronautica et Astronautica Sinica*, 2021, 42(5): 1-39.
- [7] 白生宝, 肖迎春, 杨宇, 等. 飞机结构强度试验中的声发射应用进展 [J]. *环境技术*, 2021, 39(5): 121-124.
- BAI Shengbao, XIAO Yingchun, YANG Yu, et al. Applicate progress of acoustic emission technology in the aircraft structure test [J]. *Environmental Technology*, 2021, 39(5): 121-124.
- [8] DONG Longjun, ZHANG Yihan, BI Shuijin, et al. Uncertainty investigation for the classification of rock micro-fracture types using acoustic emission parameters [J]. *International Journal of Rock Mechanics and Mining Sciences*, 2023, 162: 105292.
- [9] JU Shiyuan, LI Dongsheng, JIA Jinqing. Machine-learning-based methods for crack classification using acoustic emission technique [J]. *Mechanical Systems and Signal Processing*, 2022, 178: 109253.
- [10] ZHANG Zhenghu, DENG Jianhui. A new method for determining the crack classification criterion in acoustic emission parameter analysis [J]. *International Journal of Rock Mechanics and Mining Sciences*, 2020, 130: 104323.
- [11] YANG Zhensheng, YAN Wei, JIN Li, et al. A novel feature representation method based on original waveforms for acoustic emission signals [J]. *Mechanical Systems and Signal Processing*, 2020, 135: 106365.
- [12] 雷亚国, 杨彬, 李乃鹏, 等. 跨设备的机械故障靶向迁移诊断方法 [J]. *机械工程学报*, 2022, 58(12): 1-9.
- LEI Yaguo, YANG Bin, LI Naipeng, et al. Targeted transfer diagnosis method across different machines [J]. *Journal of Mechanical Engineering*, 2022, 58(12): 1-9.
- [13] 雷亚国, 李熹伟, 李响, 等. 面向机械设备通用健康管理的智能运维大模型 [J]. *机械工程学报*, 2025, 61(6): 1-13.
- LEI Yaguo, LI Xiwei, LI Xiang, et al. Research on large model for general prognostics and health management of machinery [J]. *Journal of Mechanical Engineering*, 2025, 61(6): 1-13.
- [14] 李响, 徐宜销, 雷亚国, 等. 面向旋转机械装备的智能故障诊断通用基础模型研究 [J]. *西安交通大学学报*, 2025, 59(7): 1-12.
- LI Xiang, XU Yixiao, LEI Yaguo, et al. Research on general foundation model of intelligent fault diagnosis for rotating machines [J]. *Journal of Xi'an Jiaotong University*, 2025, 59(7): 1-12.
- [15] 李响, 付春霖, 雷亚国, 等. 保证数据隐私的装备协同智能故障诊断联邦迁移学习方法 [J]. *机械工程学报*, 2023, 59(6): 1-9.
- LI Xiang, FU Chunlin, LEI Yaguo, et al. Federated transfer learning method for privacy-preserving collaborative intelligent machinery fault diagnostics [J]. *Journal of Mechanical Engineering*, 2023, 59(6): 1-9.
- [16] 贾峰, 李世豪, 沈建军, 等. 采用深度迁移学习与自适应加权的滚动轴承故障诊断 [J]. *西安交通大学学报*, 2022, 56(8): 1-10.
- JIA Feng, LI Shihao, SHEN Jianjun, et al. Fault diagnosis of rolling bearings using deep transfer learning and adaptive weighting [J]. *Journal of Xi'an Jiaotong University*, 2022, 56(8): 1-10.
- [17] SIKDAR S, LIU Dianzi, KUNDU A. Acoustic emission data based deep learning approach for classification and detection of damage-sources in a composite panel [J]. *Composites: Part B Engineering*, 2022, 228: 109450.
- [18] BARILE C, CASAVOLA C, PAPPALETTERA G, et al. Damage monitoring of carbon fibre reinforced polymer composites using acoustic emission technique and deep learning [J]. *Composite Structures*, 2022, 292: 115629.
- [19] KÖNIG F, MARHEINEKE J, JACOBS G, et al. Data-driven wear monitoring for sliding bearings using acoustic emission signals and long short-term memory neural networks [J]. *Wear*, 2021, 476: 203616.
- [20] DU Jinbo, ZENG Jie, CHEN Chao, et al. Acoustic emission monitoring for damage diagnosis in composite laminates based on deep learning with attention mechanism [J]. *Mechanical Systems and Signal Processing*, 2025, 222: 111770.
- [21] LI Dan, NIE Jiahao, WANG Hao, et al. Loading condition monitoring of high-strength bolt connections based on physics-guided deep learning of acoustic emission data [J]. *Mechanical Systems and Signal Processing*, 2024, 206: 110908.
- [22] 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.
- [23] 张西宁, 向宙, 唐春华. 一种深度卷积自编码网络及其在滚动轴承故障诊断中的应用 [J]. *西安交通大学学报*, 2018, 52(7): 1-8.
- ZHANG Xining, XIANG Zhou, TANG Chunhua. A deep convolutional auto-encoding neural network and its application in bearing fault diagnosis [J]. *Journal of Xi'an Jiaotong University*, 2018, 52(7): 1-8.
- [24] BEHNIA A, CHAI H K, GHASEMIGOL M, et al. Advanced damage detection technique by integration of unsupervised clustering into acoustic emission [J]. *Engineering Fracture Mechanics*, 2019, 210: 212-227.
- [25] 贺谦, 韩凯, 冯建民, 等. 任意构型传声器阵列声源定位方法 [J]. *西安交通大学学报*, 2020, 54(4): 186-192.
- HE Qian, HAN Kai, FENG Jianmin, et al. A sound source localization method for microphone array with arbitrary configuration [J]. *Journal of Xi'an Jiaotong University*, 2020, 54(4): 186-192.

(编辑 杜秀杰)