

学校代码: 10363

学 号: 2220320164



Anhui Polytechnic University

题目 基于声发射技术的工业机器人 减速机故障辨识

论文作者 尤军

校内导师 程子安

校外导师 袁学超

专业学位类别 电子信息

研究方向（领域） 声发射无损检测

论文提交日期: 2025 年 5 月 15 日

分类号：TP242.2
密 级：公开

单位代码：10363
学 号：2220320164

基于声发射技术的工业机器人减速机故障辨识

Fault Identification of Industrial Robot Gearbox Based on Acoustic Emission Technology

学生姓名：	尤军
校内导师：	程子安
校外导师：	袁学超
专业学位类别：	电子信息
研究方向（领域）：	声发射无损检测

论文答辩日期： 2025 年 5 月 7 日

安徽工程大学学位论文原创性声明

本人郑重声明：我恪守学术道德，崇尚严谨学风。所呈交的学位论文，是本人在导师的指导下，独立进行研究工作所取得的成果。除文中已明确注明和引用的内容外，本论文不包含任何其他个人或集体已经发表或撰写过的作品及成果的内容。论文为本人亲自撰写，我对所写的内容负责，并完全意识到本声明的法律后果由本人承担。

学位论文作者签名：尤军
日期：2025 年 5 月 7 日

安徽工程大学学位论文版权使用授权书

学位论文作者完全了解学校有关保留、使用学位论文的规定，同意学校保留并向国家有关部门或机构送交论文的复印件和电子版，允许论文被查阅或借阅。本人授权安徽工程大学可以将本学位论文的全部或部分内容编入有关数据库进行检索，可以采用影印、缩印或扫描等复制手段保存和汇编本学位论文。

保密 ☐，在 年解密后适用本版权书。

本学位论文属于

不保密 ☒。

学位论文作者签名：

尤军

日期：2025 年 5 月 7 日

指导教师签名：

程子岳

日期：2025 年 5 月 7 日

基于声发射技术的工业机器人减速机故障辨识

摘 要

在“十四五”规划大力推进智能制造的背景下，工业机器人在制造业中的角色愈发重要，它不仅显著提高了生产效率，还推动了产业向更高层次转型。作为工业机器人传动系统的核心部件，减速机在复杂恶劣的工作环境中容易出现损伤，这不仅会影响机器人的运动精度，还可能导致设备停机，对企业的生产效率造成不利影响。传统的故障检测手段往往难以在损伤初期就准确发现问题，而声发射检测（Acoustic Emission Testing, AET）技术凭借其非侵入性和高灵敏度的优势，为此类问题提供了有效的解决途径。本文针对减速机突发故障与行星齿轮损伤，搭建实验平台采集 AE 信号，提出多种创新方法，融合频域分析与机器学习，克服噪声干扰与复杂工况挑战，显著提升故障辨识精度与适用性。

首先，针对减速机突发故障，本文提出了一种结合时域指标与连续小波变换的辨识方法。通过对减速机在工作过程中产生的 AE 信号进行实时监测和分析，利用时域指标反映信号的变化特性，捕捉减速机运行中的异常情况；同时采用连续小波变换进行时频联合分析，提取关键特征频率，从而提升故障辨识精度。实验结果表明，该方法能够有效辨识减速机突发故障，且传感器的安装位置对辨识效果具有显著影响。

其次，针对减速机行星齿轮的损伤辨识问题，本文提出了一种频

域分析方法。通过小波包分解将信号分解为不同频段的节点信号，并结合峭度和频谱熵筛选出包含损伤信息最显著的节点信号，以此重构 AE 信号。随后，利用希尔伯特（Hilbert）包络解调方法提取调制成分，并通过包络谱揭示与齿轮损伤相关的边带特征，最终通过相对边带强度（Relative Sideband Strength, RSS）对边带进行量化分析，从能量分布的角度进一步验证损伤状态的显著性。实验结果表明，该方法在高转速工况下能够有效识别减速机行星齿轮损伤，具有较高的鲁棒性与辨识精度。

最后，为了克服低转速工况下频域分析方法的局限性，本文提出了一种结合声发射特征与 PSO-BP 神经网络的故障辨识方法。通过对不同转速工况下的 AE 信号进行分段，提取每段 AE 信号的特征参数，并利用主成分分析（Principal Component Analysis, PCA）降维优化特征矩阵，结合 PSO-BP 神经网络模型进行减速机行星齿轮损伤识别。实验结果显示，该方法在低转速工况下依然能够实现高效、精确的行星齿轮损伤辨识，显著提升了减速机故障辨识体系的适用性。

本文的研究为工业机器人减速机故障辨识提供了一种新的分析方法和思路，可在一定程度上提升智能制造领域的设备监测能力和运行可靠性。

关键词：工业机器人减速机，声发射技术，频域分析，机器学习，小波变换

FAULT IDENTIFICATION OF INDUSTRIAL ROBOT GEARBOX BASED ON ACOUSTIC EMISSION TECHNOLOGY

ABSTRACT

Within the framework of the "14th Five-Year Plan" promoting intelligent manufacturing, industrial robots significantly enhance production efficiency and equipment reliability. As critical transmission components, gearboxes are prone to damage in complex environments, impacting robot precision and potentially causing equipment downtime, adversely affecting production efficiency. Traditional fault detection methods struggle to accurately detect early-stage damage, whereas Acoustic Emission Testing(AET) technology, with its non-invasive and high-sensitivity advantages, offers an effective solution for early fault diagnosis. This study targets sudden faults and planetary gear damage in gearboxes, employing an experimental platform to collect AE signals and proposing innovative methods integrating frequency domain analysis and machine learning to overcome random noise and complex conditions, significantly enhancing fault diagnosis precision and adaptability.

First, for sudden gearbox faults, an identification method combining time-domain indicators and continuous wavelet transform is proposed.

Through real-time monitoring of AE signals generated during gearbox operation, time-domain indicators capture signal variations and operational anomalies, while continuous wavelet transform extracts key frequency features through time-frequency analysis, improving diagnostic accuracy. Experiments demonstrate that this method effectively diagnoses sudden faults, with sensor placement significantly influencing performance.

Second, for planetary gear damage, a frequency domain analysis method is developed. Wavelet packet decomposition segments signals into frequency-band node signals, with kurtosis and spectral entropy selecting the most damage-relevant signals for AE signal reconstruction. Hilbert envelope demodulation extracts modulation components, and envelope spectra reveal sideband characteristics related to gear damage. Sidebands are quantified using Relative Sideband Strength (RSS), validating damage significance based on energy distribution. Experiments confirm that this method accurately diagnoses planetary gear damage under high-speed conditions, exhibiting high robustness and precision.

Finally, to address the limitations of frequency domain analysis at low speeds, a fault diagnosis method integrating AE features with a Particle Swarm Optimization-Backpropagation (PSO-BP) neural network is proposed. AE signals across multiple speeds are segmented, with feature parameters extracted. Principal Component Analysis (PCA)

optimizes the feature matrix through dimensionality reduction, and the PSO-BP neural network accurately identifies planetary gear damage. Experiments show that this method achieves efficient and precise diagnosis at low speeds, significantly enhancing the applicability of the fault diagnosis system.

This research provides innovative approaches for gearbox fault diagnosis, significantly enhancing equipment monitoring and operational reliability in intelligent manufacturing.

KEY WORDS: industrial robot gearbox, acoustic emission technology, frequency domain analysis, machine learning, wavelet transform

目录

第 1 章 绪论	1
1.1 研究背景及意义	1
1.2 国内外研究现状	3
1.2.1 基于频域分析的故障辨识方法研究现状	3
1.2.2 基于机器学习的故障辨识方法研究现状	4
1.3 论文主要研究内容及技术路线	5
第 2 章 基于声发射技术的工业机器人减速机突发故障辨识研究	7
2.1 声发射时域指标与时频域分析方法	7
2.1.1 时域指标的定义	7
2.1.2 连续小波变换理论	8
2.2 减速机突发故障模拟实验	9
2.3 实验结果分析	10
2.4 本章小结	14
第 3 章 基于频域分析的工业机器人减速机行星齿轮损伤辨识研究	15
3.1 行星齿轮损伤 AE 信号的频域特征提取方法	15
3.1.1 小波包分解	15
3.1.2 峭度的定义	16
3.1.3 自相关分析	17
3.1.4 频谱熵	17
3.1.5 Hilbert 包络解调	18
3.2 行星齿轮损伤特征频率	19
3.3 基于频域分析的损伤辨识流程	20
3.4 行星齿轮损伤实验设计	21
3.5 实验结果分析	22
3.6 本章小结	28
第 4 章 基于 BP 神经网络的工业机器人减速机行星齿轮损伤辨识研究	30
4.1 行星齿轮智能损伤辨识方法	30

4.1.1 主成分分析	30
4.1.2 PSO-BP 神经网络	32
4.1.3 声发射特征参数	35
4.2 行星齿轮智能损伤辨识流程	35
4.3 实验结果分析	36
4.4 本章小结	39
第 5 章 总结与展望	41
5.1 总结	41
5.2 展望	41
参考文献	43
附录 1	48
附录 2	49
攻读学位期间发表的学术论文及成果目录	50
致谢	51

第 1 章 绪论

1.1 研究背景及意义

随着工业自动化的迅猛发展,使得现代制造业已经离不开工业机器人这一核心装备。国家“十四五”规划全力推进智能制造战略,促使工业机器人应用范围迅速扩大。传统上,汽车制造、金属加工和电子组装领域是其主要阵地,如今航空航天、精密仪器、医疗器械乃至食品加工行业也开始广泛采用^[1,3]。这种扩展趋势使生产线自动化水平显著提高,同时有力驱动制造业向高端智能领域迈进。

工业机器人通常被用于执行高强度、高精度和高重复性的任务,如焊接、喷涂、机械加工以及装配等对生产效率和产品质量具有极高要求的工序。相较于人工操作,工业机器人能够大幅减少因疲劳或疏忽导致的失误。此外,在高温、强腐蚀性以及存在毒害风险的环境中,其应用有效降低了作业人员的安全隐患。

减速机作为工业机器人关节处的核心传动部件,直接影响工业机器人的运动精度、负载能力及稳定性。减速机的主要功能就是将电机的高速旋转转化为低速高扭矩输出,以确保工业机器人能够执行精确的位移、转向及力控任务^[4,5]。以五轴机器人为例,其关节处多选用高精度行星减速机,以确保各轴间的运动协调,从而实现高精度的定位和重复性作业。工业机器人及行星减速机内部齿轮的结构如图 1-1 所示。




图 1-1 工业机器人及行星减速机内部齿轮结构

然而,工业机器人长期处于复杂且恶劣的工作环境,减速机内部零件难免遭受冲击、振动和摩擦影响,导致逐渐发生磨损,并产生微小损伤。这些早期的微

小损伤若未被及时发现并加以修复，可能会在长期的交变应力下逐渐扩展，导致工业机器人的运动精度下降，甚至会使自动化生产线面临停机风险，从而导致企业的巨大经济损失^[6, 7]。因此，实时监测减速机健康状况，发现微小损伤并采取维护措施，成为工业自动化领域迫切需要解决的问题。

在工业设备监测领域，传统的故障检测方法主要包括振动检测、温度监测和电流检测，但这些方法在实际应用中存在明显短板。以应用最广的振动检测为例，工程师通过加速度传感器采集设备的振动信号来判断设备内部零件的健康状态。但早期损伤产生的振动特征较为微弱，不易被检测到^[8, 9]。温度监测作为一种辅助手段，其局限性在于热传导的滞后性，只有当损伤严重影响润滑状态或导致摩擦加剧时，温度才会出现异常。电流检测虽然能非侵入式获取电机驱动电流波形，但由于微小损伤对电流信号的影响较弱，往往淹没在负载波动和供电质量变化的噪声中，使得早期损伤特征难以有效提取和识别。因此，这些传统的故障检测方法对于微小损伤识别的局限性较大，难以实现有效的早期故障预警^[10, 11]。

由于传统故障检测方法难以识别早期损伤，当前业界迫切需要一种高精度、实时性强且适用于复杂工况的故障检测技术，以提升减速机的健康监测水平。AET 技术是一种无损检测方法，通过监测材料在应力作用下因裂纹扩展、摩擦或变形等动态过程释放的高频弹性波，来评估其健康状态，近年在机械设备状态监测中备受重视。相较于传统检测手段，AET 技术不仅能在设备运转时实时采集数据，还能精准捕捉微小裂纹扩展或材料磨损产生的弹性波信号，使工程师能够在故障萌芽阶段及时预警^[12, 13]。在工业机器人减速机的故障检测中，工程师只需在壳体表面安装 AE 传感器，就能实时捕捉材料内部的高频应力波。这种“听诊”方式避免了复杂的拆解流程，使工程师能够在设备运转中实时监测齿轮啮合异常或轴承磨损，并结合高效的信号分析方法提升诊断结果的可靠性^[14, 15]。

尽管声发射技术在故障检测中优势明显，但其工程应用仍面临信号传播路径复杂、环境噪声干扰、特征提取困难等现实挑战。为了解决这些问题，本文将 AET 技术与频域分析方法和机器学习方法相结合，提出了一种高效的工业机器人减速机故障辨识方案。本文提出的故障辨识方案可为工业机器人减速机的状态监测提供新的技术支持，同时在预测性维护研究中具有一定的应用价值。

1.2 国内外研究现状

1.2.1 基于频域分析的故障辨识方法研究现状

频域分析方法作为故障诊断技术的基石,通过时-频转换揭示设备状态信息。例如,当减速机出现断齿或者疲劳裂纹时,通过傅里叶变换分析齿轮啮合产生的特定频率特征,进而识别齿轮故障^[16]。然而,傅里叶变换虽然能有效提取稳态工况下的主频成分,但在处理变速工况时,由于全局基函数的局限性,会产生频谱能量扩散现象^[17]。对此,学者们提出了多种改进方法,如经验模态分解(Empirical Mode Decomposition, EMD)和小波包分解(Wavelet Packet Decomposition, WPD)等,以克服傅里叶变换的不足。

EMD 是一种自适应信号分解技术,它能够将非平稳信号分解为若干个本征模态函数(Intrinsic Mode Function, IMF),每个 IMF 代表信号中的局部特征^[18]但在实际工程中,其端点效应会导致信号首尾出现幅值畸变。相较而言, WPD 能够通过小波基函数实现可控的频带划分,因此可以通过更加灵活细致的频带划分提取信号的细节信息,从而精确捕捉与故障相关的特征^[19]。

在国内,学者们广泛开展了关于频域分析方法的研究。例如,沙云东等^[20]结合 WPD 和峭度成功重构了滚动轴承的故障信号,并通过 Hilbert 包络解调提取出轴承的故障特征频率。刘泽锐等^[21]采用 VMD 结合峭度优化信号分解,随后进行快速谱峭度分析,最后精准识别了轴承故障。刘文朋等^[22]提出了一种自适应的共振解调方法,通过 WPD 分解原始信号,并结合包络信号的自相关谱和峭度指标进行信号重构,最终实现了精确的故障模式识别。

国外学者在频域分析方法的研究上也取得了显著进展。例如, Yang J.Z 等^[23]提出了一种基于局部均值分解(Local Mean Decomposition, LMD)和 WPD 相结合的故障特征提取方法,成功克服了模态混叠问题,并显著提高了故障辨识的精度。Li H 等^[24]采用包络峭度和频谱熵结合 VMD 的模态选择方法,通过互相关系数选取最佳 IMF 进行轴承的故障模式识别。Zhou X.L 等^[25]提出了一种 VMD 结合最大重叠离散小波包变换(Maximum Overlap Discrete Wavelet Packet Transform, MODWPT)的方法,通过增强信号降噪技术,有效滤除了机械振动中的噪声成分,提升了信号特征提取的准确性和稳定性。

1.2.2 基于机器学习的故障辨识方法研究现状

随着智能化技术的发展,机器学习方法逐渐成为故障诊断领域的重要研究方向。早期的机器学习方法主要包括支持向量机(Support Vector Machine, SVM)和BP神经网络(Back Propagation Neural Network, BPNN)。SVM能够通过核函数将非线性问题映射到高维空间来实现故障模式的分类,但其表现依赖参数优化,且处理多类别问题存在一定困难^[26]。BPNN凭借出色的非线性拟合能力,广泛应用于故障模式识别,但传统的梯度下降法在训练时收敛速度慢且易陷入局部最优^[27]。针对这些问题,近年来研究者们引入包括遗传算法(Genetic Algorithm, GA)和粒子群算法(Particle Swarm Optimization, PSO)等优化手段,大幅改善了SVM和BPNN的分类性能。此外,深度学习方法逐渐成为故障诊断领域的研究热点,通过构建卷积神经网络(Convolutional Neural Networks, CNN)等深度神经网络模型,自动从复杂信号中提取高阶特征,显著提高了故障诊断精度^[28]。然而,深度学习模型通常需要大量计算资源和高性能硬件支持,训练和推理成本较高。对于简单故障辨识任务,PSO-BP神经网络的方法,凭借高效的特征提取和低计算复杂度,能够精准实现声发射信号的故障辨识。

在国内,学者们在机器学习领域的研究主要集中在特征提取和分类方法的优化上。例如,张军翠等^[29]通过提取时域特征、频域特征及EEMD模糊熵等复杂度特征,构建了一个18维的特征矩阵输入到SVM中,并运用天牛须搜索算法(Beetle Antennae Search, BAS)优化SVM的参数,显著提高了故障诊断的准确率。郭文军等^[30]采用EMD分解提取非平稳故障信号,使用自回归模型提取深层故障特征,并通过广义回归神经网络进行训练,最终成功定位了旋转机械的故障。甄冬等^[31]针对滚动轴承复合故障数据难以获取的问题,提出基于包络谱语义构建的零样本诊断方法,结合包络谱预处理和语义空间映射,通过单一故障数据训练,实现未见复合故障的准确识别,最高准确率达87.83%。

国外学者也在机器学习方法的应用方面取得了显著进展。例如,Ye Q等^[32]提出了一种基于自动编码器的深度神经网络(Deep Neural Network, DNN)模型,用于自适应学习故障信号特征,并结合局部保持投影(Locality Preserving Projection, LPP)融合多传感器信号特征,构建了基于多个DNN的新型故障辨识模型。Viveros P等^[33]将人工神经网络(Artificial Neural Network, ANN)与SVM

和主成分分析（Principal Components Analysis, PCA）相结合，提出了一种混合机器学习模型，显著提高了故障模式的识别精度。Lu Q.D 等^[34]通过提取设备在不同运行条件下的时域和频域特征，利用改进的距离评估方法从多维特征向量中选择敏感特征，采用递归最小二乘反向传播神经网络（Recursive Least Square Backpropagation Neural Network Algorithm, RLS-BPNN）进行故障诊断，进一步提高了模型的准确性和稳定性。

1.3 论文主要研究内容及技术路线

本文以工业机器人减速机为研究对象，针对减速机突发故障和行星齿轮损伤辨识问题，提出了多种有效的故障辨识方法。具体内容安排如下：

第一章介绍了工业机器人是现代制造业中的重要地位，阐述了工业机器人减速机故障辨识的研究意义。随后综述了国内外学者在减速机故障辨识方面的研究进展，重点探讨了频域分析方法和机器学习方法在故障诊断中的应用。

第二章针对减速机突发故障辨识，提出了一种结合时域指标与连续小波变换的故障辨识方法。时域指标可以反映信号的变化特性，能够捕捉减速机运行中的异常情况。连续小波变换则通过时频联合分析，捕捉减速机突发故障的瞬态特征。实验结果显示该方法能够精准识别减速机的突发故障。

第三章针对减速机行星齿轮损伤辨识，提出了一种频域分析方法。首先，采用小波包分解将原始 AE 信号分解成多个节点信号，并通过峭度指标筛选出周期性成分较强的节点信号。然后，对筛选出的节点信号进行自相关分析，并计算频谱熵，选择频谱熵值最大的节点信号进行 AE 信号重构。最后，通过包络谱揭示重构 AE 信号中与齿轮损伤相关的边带特征，并使用相对边带强度（RSS）对边带特征进行量化分析并设定阈值，从而确保行星齿轮损伤的准确识别。实验结果表明，该方法能够准确识别减速机行星齿轮损伤。

第四章针对低转速工况下频域分析方法的局限性，提出了一种结合声发射特征与 PSO-BP 神经网络的故障辨识方法。首先，通过对多种工况下的 AE 信号进行分段处理，提取每段信号的声发射特征参数。然后，采用 PCA 降维方法优化特征矩阵，减少特征冗余，提高神经网络的训练效率。最后，运用 PSO 算法优化 BP 神经网络，建立了一种能够适应多种转速工况的减速机行星齿轮损伤辨识

模型。实验结果表明，该方法有效解决了低转速工况下减速机行星齿轮损伤辨识的难题，提升了减速机故障诊断体系的适用性和准确性。

第五章总结了全文的研究工作，回顾了各章节的主要工作和贡献，并对所提出的方法在工业机器人减速机故障辨识中的应用价值以及未来研究方向进行了讨论。

本文的技术路线如图 1-2 所示。




图 1-2 论文的技术路线

第 2 章 基于声发射技术的工业机器人减速机突发故障辨识研究

在工业机器人减速机的所有故障类型中，齿轮的突发性断裂故障因其破坏性强、影响范围广以及发生时间难以精确预测等特点，对设备的正常运行构成了严重威胁。因此，建立高效、精准的突发故障辨识方法，对于保障工业机器人稳定运行具有重要的工程价值。

为了探索基于声发射技术的减速机突发故障辨识方法，并研究传感器布置对故障检测效果的影响，本章搭建了一个由伺服电机和减速机组成的测试平台。并在减速机壳体及其支架上分别安装 AE 传感器，以同步采集 AE 信号。考虑到在不破坏设备的前提下模拟突发故障，实验依据美国材料试验协会（American Society of Testing Materials, ASTM）声发射无损检测标准，采用铅芯折断法在减速机壳体表面模拟突发故障源，以获取与真实材料断裂相似的 AE 信号，为后续分析提供可靠的数据支持。

为了提取 AE 信号的故障特征，本章分别从统计学分析和时频域分析两个角度展开研究。在统计学分析部分，提取 AE 信号的时域特征指标，以反映减速机发生突发故障时的信号变化特性。在时频域分析部分，引入连续小波变换（Continuous Wavelet Transform, CWT），利用其良好的时间-频率局部化特性，对 AE 信号进行分解，提取关键频段的能量分布特征。最终，通过比较不同测点的 AE 信号特性，提出了一种适用于减速机突发故障的辨识方法。

2.1 声发射时域指标与时频域分析方法

2.1.1 时域指标的定义

在减速机突发故障辨识中，时域指标作为信号处理的“第一视角”，其价值在于通过物理可解释的数学表征揭示机械状态的变迁。其中，绝对均值可以识别设备运行状态的整体变化；峰值能及时捕捉突发的强烈冲击；脉冲指标则能够进一步量化冲击信号的强度和突发性。通过对这三种指标的综合分析，可以有效剖析信号的不同特征，从而为减速机的突发故障辨识提供依据。表 2-1 展示了这三

种时域指标的物理意义和计算方法。其中 x_i 为原始信号, $i=1, 2, 3, \dots, N$, N 为信号的数据长度。

表 2-1 时域指标的定义

时域指标	计算公式	物理意义
绝对均值	$AM = \frac{1}{N} \sum_{i=1}^N x_i $	反映信号的整体振幅水平
峰值	$PE = \max(x_i)$	信号最高振幅的绝对值
脉冲指标	$IMI = \frac{PE}{AM}$	衡量信号中的冲击幅值相对于均值的变化程度

2.1.2 连续小波变换理论

与传统的傅里叶变换、短时傅里叶变换(Short-Time Fourier Transform, STFT)相比,小波变换在时频联合分析方面具有显著优势。小波变换采用可变尺度的窗函数(小波函数),能够根据信号的局部特征自适应调整时间分辨率和频率分辨率,具有多分辨率分析的特性。在低频部分,小波变换具有较高的频率分辨率和较低的时间分辨率,适合捕捉信号的长时变化趋势;在高频部分,小波变换具有较高的时间分辨率和较低的频率分辨率,更适合检测突变特征^[35]。这种特性使得小波变换特别适用于机械故障信号分析,如冲击信号检测、瞬态信号提取以及非平稳信号分析等。

在小波分析中,信号 $x(t)$ 通常被认为属于平方可积函数空间 $L^2(R)$, 即满足:

$$\int_{-\infty}^{+\infty} |x(t)|^2 dt < \infty \quad (2-1)$$

小波变换的核心在于小波母函数 $\psi(t)$, 其需满足平方可积条件 $\psi(t) \in L^2(R)$, 且满足容许性条件:

$$C_\psi = \int_0^{+\infty} \frac{|\Psi(w)|^2}{w} dw < \infty \quad (2-2)$$

其中, $\Psi(w)$ 为小波母函数 $\psi(t)$ 的傅里叶变换:

$$\Psi(w) = \int_{-\infty}^{+\infty} \psi(t) e^{-j\omega t} dt \quad (2-3)$$

容许性条件确保小波基函数的平均值为零，即小波母函数必须是零均值函数，满足：

$$\int_{-\infty}^{+\infty} \psi(t) dt = 0 \quad (2-4)$$

这样可以保证小波变换不会在直流成分上积累能量。通过对小波母函数进行伸缩和平移，可以得到一族小波基函数：

$$\psi_{a,b}(t) = \frac{\Psi(\frac{t-b}{a})}{\sqrt{a}} \quad (2-5)$$

其中 $a, b \in \mathbb{R}$, $a \neq 0$ 。 a 为尺度因子，控制小波基函数的伸缩，即频率分辨率。 b 为时间平移因子，控制小波基函数在时间上的平移。因此，对任意信号 $x(t)$ 的连续小波变换定义如下：

$$W_x(a,b) = \frac{\int_{-\infty}^{+\infty} x(t) \psi(\frac{t-b}{a}) dt}{\sqrt{a}} \quad (2-6)$$

其中， $W_x(a,b)$ 表示信号在不同尺度 a 和时间位置 b 上的小波系数。这些小波系数能够有效反映信号在特定时间尺度下的局部特征，尤其是信号的瞬时变化特性。小波变换的核心思想是通过原始信号与具有不同伸缩和位移参数的小波基函数进行内积，得到小波系数。小波系数的本质是原始信号与小波基函数的相似程度，小波系数的模值反映了信号在不同尺度上的能量分布。在实际应用中，减速机的 AE 信号会受到各种噪声的干扰，利用小波变换的局部化性质可以有效抵抗噪声干扰并突出信号中的瞬时冲击特征，从而实现减速机突发故障辨识。


2.2 减速机突发故障模拟实验

实验试件是由芜湖固高自动化技术有限公司提供的工业机器人减速机和伺服电机组成的测试装置。实验中的数据采集平台采用北京软岛 DS5-16C 声发射仪和两个 RS-2A 型声发射传感器。前置放大器的放大倍数设置为 40 dB，信号的采样频率设置为 3 MHz，AE 传感器的谐振频率为 150 kHz，伺服电机的转速设置为 300 rpm。

为了评估传感器的安装位置对突发故障信号提取的影响，本实验在减速机壳体和支架上分别安装两个 AE 传感器。减速机壳体上的 AE 传感器记为 CH1，支

架上的 AE 传感器记为 CH2。在实验开始前,首先采集减速机正常工作状态下的 AE 信号,用于后续与突发故障信号进行对比分析。由于直接在减速机内部制造真实的突发断裂故障存在较大的实验风险,且难以实现可控的重复试验。因此,实验依据 ASTM 关于声发射无损检测的相关标准,采用铅芯折断法模拟突发故障源,该方法可在不破坏设备的前提下产生与真实材料断裂相似的 AE 信号,并具备良好的重复性和可控性。

具体做法是使用直径为 0.5 mm 的 HB 铅笔,铅芯伸出长度约为 3 mm,铅芯与减速机壳体表面夹角约为 30° 进行折铅,以模拟减速机的机械部件在长期载荷作用下逐步演化为突发断裂的损伤效应。分别在 CH1 和 CH2 传感器处记录折铅产生的 AE 信号。通过 CH1 和 CH2 信号的对比分析,可研究 AE 信号在不同测点的传播规律,并评估测点布置对故障检测的影响,为工业机器人减速机的在线监测提供实验依据。实验平台及传感器的安装位置如图 2-1 所示。



(a) 实验平台

(b) 传感器的安装位置

图 2-1 减速机突发故障模拟实验平台及传感器的安装位置

2.3 实验结果分析

实验采集了减速机在正常状态和突发故障状态下的 AE 信号,首先对其时域波形进行分析。图 2-2 和图 2-3 分别展示了减速机两种状态下 CH1 和 CH2 采集到的 AE 信号原始波形。由图 2-2 可知,减速机正常状态下 AE 信号的整体波动较为平稳,这表明此时减速机内部各部件之间的协作处于正常状态,没有明显的异常因素干扰。而对比图 2-3 可以清晰的发现,当减速机发生突发故障时,AE 信号的波形中出现了显著的突发信号,其幅值远远超过正常状态下的幅值波动范围,这就直观地反映出减速机受到了强烈的冲击作用。




图 2-2 减速机正常状态下的时域波形




图 2-3 减速机发生突发故障状态下的时域波形

为了更加精确地探究减速机在这两种状态下的时域特征差异,本章计算了减速机两种状态下 AE 信号的时域指标,计算结果如表 2-2 所示。

表 2-2 减速机两种状态下的时域指标

减速机状态	传感器	绝对均值	峰值	脉冲指标
正常状态	CH1	0.41	1.58	3.82
	CH2	0.15	0.58	3.76
突发故障状态	CH1	0.42	5.96	14.15
	CH2	0.16	3.08	19.33

根据表 2-2 可知,当减速机发生突发故障后,CH1 和 CH2 采集到的 AE 信号绝对均值分别由 0.41 变为 0.42 和 0.15 变为 0.16,说明 AE 信号的整体能量水

平并未发生显著变化。这表明突发故障发生时，AE 信号主要表现为短时突发的高幅值冲击，而整体能量水平的变化较小。CH1 和 CH2 采集到的 AE 信号峰值出现了显著增加，CH1 的峰值由 1.58 增加到 5.96，CH2 由 0.58 增加到 3.08，这表明突发故障引起了 AE 信号中瞬态高能冲击的出现。CH1 和 CH2 采集到的 AE 信号脉冲指标剧烈上升，尤其是 CH2 的脉冲指标从 3.76 急剧上升至 19.33，相较于 CH1（从 3.82 增至 14.15）的增长更为显著。这是因为突发故障状态下的 AE 信号从 CH1 传播到 CH2 的过程中绝对均值下降了 63%，而峰值仅下降了 48%。这说明 AE 信号在传播过程中，尽管整体能量有所衰减，但高幅值冲击信号的衰减程度相对较低，使得脉冲特征更加突出。

经过上述分析可以得出，突发故障对 AE 信号的影响主要表现为短时间内的低幅值冲击。此外，安装在减速机支架上的传感器 CH2，对于突发故障信号的响应更为敏感，特别是在脉冲特征的放大方面更加明显。因此，在实际工程应用中，可以考虑利用支架上的 AE 传感器，通过脉冲指标的变化来实现更灵敏的突发故障辨识。

然而，仅依赖时域特征可能会受到信号噪声和外部干扰的影响，因此需要进一步进行时频域联合分析，以更全面地揭示减速机突发故障的特征。本章进一步采用连续小波变换对减速机两种状态下的 AE 信号进行时频域联合分析，通过时频图提取特征频率，进一步增强对突发故障的辨识能力。连续小波变换的时频图频率分辨率为 $3 \times 10^6 / 256 \approx 12 \text{ kHz}$ 。在时频图中，灰度值越高表示小波系数的模值越大，代表信号能量越强。减速机两种状态下 CH1 和 CH2 采集到的 AE 信号时频图如图 2-4 和图 2-5 所示。




图 2-4 减速机正常状态下的时频图




图 2-5 减速机发生突发故障状态下的时频图

由图 2-4 可知，在减速机正常状态下，整体信号分布较为均匀，没有明显的突发信号，符合正常运转状态下 AE 信号的特征。在 CH1 中 17 kHz 附近的信号能量相对较强，说明减速机正常运行时 AE 信号主要集中在该频段。而在 CH2 中 47 kHz 附近的信号能量则相对突出，表明 AE 信号在传播过程中发生了一定的频率变化。然而，由图 2-5 可以观察到，当减速机发生突发故障时，时频图中出现了持续时间短、频率覆盖范围广的突发信号，表明减速机发生突发故障时释放了瞬态冲击能量。在 CH1 中信号能量集中在 170 kHz 附近，CH2 则在 100 kHz 附近的信号能量较强。通过对比减速机两种状态下频率分布的差异性，可以看出频域特征可以有效识别减速机的突发故障。

为了进一步分析减速机在正常状态与突发故障状态下 AE 信号的频域特征，本研究选取了四种关键特征频率（17 kHz、47 kHz、100 kHz、170 kHz），并在表 2-3 中列出了这四种特征频率分别在 CH1 和 CH2 中的小波系数模值（记作 Coefs）。

表 2-3 减速机两种状态下的四种特征频率

减速机状态	特征频率	CH1 中的 Coefs	CH2 中的 Coefs
正常状态	17 kHz	1.97	0.41
	47 kHz	1.00	0.89
突发故障状态	100 kHz	2.64	3.93
	170 kHz	9.75	1.47

由表 2-3 可知,在减速机正常状态下,AE 信号的主要特征频率集中在 17 kHz 和 47 kHz。17 kHz 频率的 Coefs 在 CH1 处为 1.97,但在 CH2 处下降至 0.41,下降幅度达 79%,表明该频率的能量在传播过程中受到了较强的衰减。这种现象可能与减速机支架的结构阻尼效应有关,使得低频信号在支架上传播时衰减较快。而 47 kHz 频率的 Coefs 从 CH1 的 1.00 下降至 CH2 的 0.89,下降幅度仅为 11%,表明该频率在传播过程中受到了较弱的衰减作用。相比于 17 kHz,47 kHz 频率的 AE 信号在支架上的能量保持较高,可能与该频率对应的机械振动模式更加适应支架的结构特性有关。

当减速机发生突发故障后,AE 信号中 170 kHz 和 100 kHz 频率的能量发生了明显变化。170 kHz 频率的 Coefs 在 CH1 处达到 9.75,但在 CH2 处大幅下降至 1.47,下降幅度达 85%。这一现象说明,高频信号在传播过程中能量衰减更快。而 100 kHz 频率的 Coefs 却呈现上升趋势,从 CH1 的 2.64 增加到 CH2 的 3.93,上升幅度达 49%。这种能量放大效应可能与支架结构对特定频率的共振效应有关,即减速机突发故障所激发的 100 kHz 频率成分,与支架的固有模态产生耦合,使得该频率成分在 CH2 处的能量得到了增强。由此可知,减速机在两种状态下特征频率的变化能够作为突发故障辨识的显著判据,实现对突发故障的有效辨识。

2.4 本章小结

本章针对工业机器人减速机的突发故障辨识展开研究,通过时域指标计算、时频域联合分析及特征频率传播特性的深入分析,成功识别了减速机的突发故障,并验证了传感器安装位置对故障辨识效果的影响。实验结果表明,将 AE 传感器安装在减速机支架上,相较于安装在减速机壳体上,能够更显著地放大突发故障信号的脉冲特性和特定频率成分,从而提高突发故障的辨识准确性。本章的研究不仅成功识别了减速机突发故障 AE 信号的特征,还揭示了不同频率成分在结构传播过程中的变化规律,虽然特征频率的变化并非唯一,但是通过结合时域指标和时频域特征可以有效增强减速机突发故障辨识的准确性。

第3章 基于频域分析的工业机器人减速机行星齿轮损伤辨识研究

工业机器人减速机在长期运行过程中,行星齿轮需承受交变载荷与高速旋转冲击,容易发生疲劳磨损和微小裂纹等渐进性损伤。若未能及时检测和干预,这些早期损伤可能在长期交变应力作用下逐步扩展,最终演变为突发的断裂故障。因此,行星齿轮早期的损伤辨识对于维护工业机器人减速机稳定运行具有重要意义。然而,行星齿轮早期的损伤信号特征微弱,容易被噪声淹没,导致传统的时域指标计算和时频域联合分析方法难以有效提取损伤特征。为此,本章提出了一种基于频域分析的损伤特征提取方法,以提高减速机行星齿轮损伤的辨识能力,提高故障预警的有效性。

本章采用小波包分解对 AE 信号进行多尺度分解,以获取损伤信号在不同频段上的细节特征,并利用峭度分析衡量信号的尖峰特性,以揭示损伤产生的瞬态冲击特征。同时,为了增强损伤信号的周期性信息提取能力,引入自相关分析方法,以突出齿轮啮合过程中受损部位的重复冲击特性。此外,考虑到 AE 信号在损伤发生后频谱特征的变化,本章进一步计算频谱熵,以表征信号频率分布的复杂度,并结合 Hilbert 变换进行包络解调,以提取损伤冲击信号的特征频率。最终,为了实现对损伤状态的量化评估,本章提出了一种基于相对边带强度(Relative Sideband Strength, RSS)的方法,以提供更为直观的损伤量化指标。

本章的研究目的在于解决传统方法难以有效提取早期损伤特征的问题,通过多层次的信号处理方法,提高行星齿轮的损伤辨识精度,从而为减速机的健康监测提供更可靠的技术支持。

3.1 行星齿轮损伤 AE 信号的频域特征提取方法

3.1.1 小波包分解

小波包分解(Wavelet Packet Decomposition, WPD)是小波变换的拓展形式,相较于传统的小波变换,其不仅对信号的低频部分进行分解,同时也对高频部分进行进一步地细化拆分,使得信号的频带划分更加精细,从而提高了对复杂信号

特征的提取能力^[36, 37]。在 AE 信号分析中，小波包分解可以更精准地分离出不同频段的特征信息，以便于捕捉行星齿轮损伤产生的特定冲击频率成分，进而提升故障辨识的准确性。

小波包分解的核心思想是利用多尺度滤波器组进行信号分解，在每一层分解中，信号都会经过低通滤波器和高通滤波器进行带通拆分，从而形成完整的小波包树状结构。小波包分解的递归计算公式如下：

$$\begin{cases} W_{j,2k}(t) = 2^{-\frac{j}{2}} \sum_{m \in Z} h_m W_{j-1,k+m}(t) \\ W_{j,2k+1}(t) = 2^{-\frac{j}{2}} \sum_{m \in Z} g_m W_{j-1,k+m}(t) \end{cases} \quad (3-1)$$

式中， h_m 表示低通滤波器， g_m 表示高通滤波器。 j 表示分解层数（ j 为偶数表示经过低通滤波器， j 为奇数表示经过高通滤波器）， k 表示小波包的位置偏移量。 $W_{j,k}$ 为小波包系数，它表示信号在不同频段上的分解成分。在实际应用中，选择合适的小波基函数对于信号分析至关重要。本研究通过对 Daubechies 系列小波的多次实验分析发现，db4 小波基在 AE 信号分析中能够较好地保留信号的主要特征，并且在频域上具有较强的局部化能力，因此本章选取 db4 作为小波包分解的小波基函数。此外，为了平衡信号特征提取的精细程度与计算复杂度，本研究对 AE 信号进行了三层小波包分解。分解后得到 8 个节点信号，其中每个节点信号的带宽为 62.5 kHz，三层小波包分解的示意图如图 3-1 所示。




图 3-1 三层小波包分解示意图

3.1.2 峭度的定义

峭度（Kurtosis）是一种描述信号统计特征参数，主要用于衡量信号概率

密度分布的尖峰程度和尾部形状。对于平稳的高斯信号，峭度值通常接近 3，而对于含有冲击成分或突变特征的非平稳信号，峭度值通常会显著偏离 3，尤其是信号中存在瞬态冲击或脉冲信号的情况下，峭度值往往会较高。行星齿轮的损伤通常会产生周期性冲击信号，使 AE 信号在时间域上呈现脉冲特征。因此，利用峭度可以有效检测 AE 信号中冲击成分的增强。峭度的计算公式为：

$$\begin{cases} \mu = \frac{1}{n} \sum_{i=1}^n x_i \\ KU = \frac{\frac{1}{n} \sum_{i=1}^n (x_i - \mu)^4}{\left(\frac{1}{n-1} \sum_{i=1}^n (x_i - \mu)^2\right)^2} \end{cases} \quad (3-2)$$

其中 x_i 为信号的第 i 个数据点， $i=1, 2, 3 \dots n$ ， μ 为信号的均值。在本章的研究中，峭度被用作初步筛选指标，用于筛选出包含尖峰冲击特征的节点信号。

3.1.3 自相关分析

自相关分析是一种用于研究信号在当前时刻与另一个时刻之间相关性的方法，广泛应用于周期性信号检测、噪声抑制以及特征信号增强。对于旋转机械而言，齿轮损伤通常会在齿轮啮合过程中周期性地产生冲击信号，这些冲击信号会随着旋转周期不断重复，因此其 AE 信号具有一定的周期性特征。通过计算 AE 信号的自相关函数，可以提取其中的周期性成分，同时削弱随机噪声的影响，从而提升信号的信噪比，使得行星齿轮损伤的特征更加明显。信号 $x(t)$ 的自相关函数数学表达式为：

$$\begin{aligned} R_x(\tau) &= E[x(t), x(t-\tau)] \\ &= \lim_{T \rightarrow \infty} \frac{1}{T} \int_0^T x(t)x(t-\tau)dt \end{aligned} \quad (3-3)$$

其中， $R_x(\tau)$ 为信号 $x(t)$ 在时延 τ 处的自相关值； T 为信号 $x(t)$ 的时间长度， τ 为时间延迟。当减速机行星齿轮发生损伤时，AE 信号会呈现明显的周期性冲击特征，因此在自相关函数中，信号的周期性成分会表现为明显的峰值。而随机噪声通常是非周期性的，自相关运算同时可以起到噪声抑制的作用^[38, 39]。

3.1.4 频谱熵

在信号分析中，频谱熵是一种用于衡量信号频谱分布复杂程度的指标，它反

映了信号在频域中的不确定性。若信号的能量集中在少数特定频率附近，则该信号的频谱结构较为简单，频谱熵较小；反之，若信号的能量在多个频率范围内均匀分布，则频谱的复杂度较高，频谱熵也相应增大。因此，频谱熵可以用于评估信号的调制特性、能量分布特征以及故障模式下的频谱变化^[40, 41]。频谱熵的计算基于信号频谱的概率分布，其具体计算过程为：

首先对信号的自相关函数进行快速傅里叶变换，得到功率谱密度 $A(f)^2$ ，再将功率谱密度归一化，得到每个频率分量的概率分布：

$$P(f) = \frac{A(f)^2}{\sum_f A(f)^2} \quad (3-4)$$

然后通过概率分布计算信号的频谱熵：

$$SE = -\sum_f P(f) \cdot \log(P(f)) \quad (3-5)$$

其中 $P(f)$ 为频率分量 f 的归一化频率； SE 为频谱熵，表示频谱信息量的大小。

在行星齿轮损伤辨识中，齿轮正常啮合时，其 AE 信号的能量主要集中在啮合频率及其谐波附近，信号频谱较为稳定，表现为较低的频谱熵值。然而，当齿轮发生损伤（如点蚀、断裂）时，啮合过程中产生的不规则冲击信号会引入额外的频率成分，导致 AE 信号的频谱变得更加复杂，使得频谱熵增大。因此，通过计算 AE 信号的频谱熵，可以有效量化齿轮损伤导致的频谱变化，为故障识别提供依据。

3.1.5 Hilbert 包络解调

在旋转机械的故障诊断中，Hilbert 包络解调是一种用于提取调制信号包络特征的数学工具，特别适用于非平稳信号的冲击特征提取。对于减速机行星齿轮而言，其 AE 信号通常包含明显的调制特性。这是因为齿轮的啮合过程会随着旋转出现周期性变化，使得 AE 信号呈现规律性的频率调制特征。

在减速机正常状态下，行星齿轮的啮合信号主要受到齿轮转动周期的影响，其调制频率较为稳定。然而，当减速机行星齿轮发生损伤时，损伤部位在啮合过程中会产生额外的冲击，这些冲击会进一步调制齿轮正常啮合的信号，使 AE 信号中的调制成分不再局限于单一频率，而是形成了多频率调制特征。为了捕捉这些调制特征的变化，本章采用 Hilbert 包络解调方法提取信号中的周期性冲击成

分。Hilbert 包络解调通过分离信号的振幅包络，能够有效揭示信号中潜在的调制特性和周期性规律^[42, 43]。给定一个时域 AE 信号 $x(t)$ ，其 Hilbert 变换的数学表达为：

$$\tilde{x}(t) = \frac{1}{\pi t} * x(t) = \frac{1}{\pi} \int_{-\infty}^{+\infty} \frac{x(\tau)}{t - \tau} d\tau \quad (3-6)$$

$x(t)$ 的解析信号为：

$$z(t) = x(t) + j\tilde{x}(t) \quad (3-7)$$

通过对解析信号取模就得到了 $x(t)$ 的 Hilbert 包络信号：

$$a(t) = |z(t)| \quad (3-8)$$

对 $a(t)$ 进行快速傅里叶变换可以得到包络谱，进而提取 $x(t)$ 中有关行星齿轮损伤的信息。

3.2 行星齿轮损伤特征频率

在减速机的正常运行过程中，行星齿轮与齿圈及太阳齿轮的持续啮合会在 AE 信号的频谱中形成特定的频率分布。这种频率分布主要由齿轮的啮合关系和旋转运动决定，在频谱上通常表现为啮合频率及其谐波分量。其具体表现为 AE 信号频谱中出现处于 $f_m \pm k_1 f_c$ (k_1 为整数) 位置的峰值频率，且相邻峰值频率之间的间隔为行星架输出转频的倍数 $k_1 f_c$ 。

当减速机内部的行星齿轮出现损伤时，行星齿轮与其他齿轮在啮合过程中会受到额外的冲击，这些冲击信号会以调制效应的形式影响 AE 信号的频谱特征^[44, 45]。因此，在 AE 信号频谱中除了会出现齿轮正常啮合所产生的峰值频率，还会出现与峰值频率等间隔的边带，且边带一般出现在 $f_m \pm k_1 f_c \pm m f_p$ 位置 (m 为整数)，边带与峰值频率之间的间隔为减速机行星齿轮损伤特征频率的倍数 $m f_p$ 。

为了量化 AE 信号频谱中边带成分的强度，并分析其在齿轮损伤辨识中的作用，本章引入相对边带强度 (Relative Sideband Strength, RSS) 作为行星齿轮损伤辨识指标。RSS 通过计算边带频率的能量与峰值频率的能量占比，来衡量齿轮损伤对 AE 信号调制效应的影响程度。具体来说，在减速机正常状态下，各个齿轮之间的啮合较为平稳，AE 信号频谱中的能量主要集中在峰值频率 $f_m \pm k_1 f_c$ 附近，而边带频率的能量较弱，因此 RSS 值较低。在减速机行星齿轮损伤状态下，

由于损伤引起的二次调制效应，频谱中的能量不仅集中在峰值频率附近，还在边带频率 $f_m \pm k_1 f_c \pm m f_p$ 附近显著增加，使得 RSS 值显著上升。因此，通过计算 AE 信号频谱中的 RSS 值，可以有效判断减速机行星齿轮是否出现损伤。RSS 的具体计算公式为：

$$RSS = \frac{\sum_i A_{side,i}}{\sum_j A_{peak,j}} \quad (3-9)$$

其中， $A_{side,i}$ 为边带频率 $f_{side,i}$ 对应的幅值， $A_{peak,j}$ 为峰值频率 $f_{peak,j}$ 对应的幅值。 f_m 、 f_c 以及 f_p 的物理意义如表 3-1 所示。

表 3-1 f_m 、 f_c 以及 f_p 的物理意义

公式	物理意义
$f_m = \frac{z_1 \cdot z_2}{z_1 + z_2} f_0$	行星齿轮与齿圈的啮合频率
$f_c = \frac{z_2}{z_1 + z_2} f_0$	行星架的输出转频
$f_p = \frac{f_m}{z_3}$	行星齿轮局部损伤特征频率

注 a: z_1 为齿圈齿数， z_2 为太阳齿轮齿数， z_3 为行星齿轮齿数， f_0 是太阳齿轮作为主动轮的绝对旋转频率。

3.3 基于频域分析的损伤辨识流程

当减速机行星齿轮发生损伤时，其啮合过程会产生周期性的冲击信号，这种冲击信号会调制齿轮正常啮合的信号，从而在 AE 信号中表现为特定频率成分的显著变化。因此，从 AE 信号中精准提取与齿轮损伤相关的周期性冲击成分，是实现行星齿轮损伤辨识的关键。基于此，本章提出了一种系统性的工业机器人减速机行星齿轮损伤特征提取方法，其具体步骤如下：

(1) 采集的 AE 信号中包含多种混杂成分，包括齿轮正常啮合的频率、行星齿轮损伤导致的周期性冲击频率以及背景噪声频率。为实现不同成分的有效分离，本章采用小波包分解方法，将 AE 信号分解为不同频带的节点信号。小波包分解

能够提供精细的频带划分，为后续准确提取特征频率提供基础。

(2) 齿轮的正常啮合和损伤引起的冲击信号均具有较强的周期性特征，因此本章采用峭度作为初步筛选指标，筛选出周期性成分较强的节点信号。由于峭度对周期性尖峰信号较为敏感，可以快速定位可能包含损伤信息的节点信号。然而，峭度本身无法明确区分冲击信号的来源，尤其在低频范围，高峭度值的节点信号可能主要反映齿轮正常啮合的特性，而缺乏足够的损伤信息。

(3) 针对峭度筛选中可能残留随机噪声的问题，本章对筛选出的节点信号进一步进行自相关分析。自相关分析能够有效削弱节点信号中的随机噪声，突出周期性成分。由于行星齿轮损伤引起的边带频率会使频谱的信息量增加，因此本章引入频谱熵作为辅助筛选指标。频谱熵值越高，表明信号中包含与齿轮损伤有关的信息量越多。通过计算节点信号的频谱熵值，选择频谱熵最大的节点信号进行 AE 信号重构，从而有效保留与损伤相关的频率成分。

(4) 对重构后的 AE 信号进行 Hilbert 包络解调，提取信号中的调制成分。Hilbert 包络解调能够有效揭示信号中的调制特性，从而突出与齿轮损伤相关的边带特征。在此基础上，通过计算包络谱中边带频率与峰值频率的 RSS 值，对频域特征进行量化分析，从而进一步提升行星齿轮损伤的辨识精度。

3.4 行星齿轮损伤实验设计

为了验证本章所提方法对工业机器人减速机行星齿轮损伤辨识的有效性，在减速机内部的一个行星齿轮上人为加工了一个长度约为 5 mm，宽度约为 3 mm，深度约为 1 mm 的损伤。由于信号的频率主要集中在 0~500 kHz 的范围内，为了便于数据存储与分析，对原始 AE 信号进行了 1 MHz 的重采样。伺服电机的转速设置为 1200 rpm，分别采集减速机正常状态和减速机行星齿轮损伤状态下的 AE 信号。工业机器人减速机各部件齿轮的齿数如表 3-2 所示。损伤的行星齿轮和 AE 传感器的安装位置如图 3-2 所示。通过理论计算得到的工业机器人减速机损伤特征频率如表 3-3 所示。

表 3-2 工业机器人减速机各部件齿轮的齿数

齿圈	太阳齿轮	行星齿轮
108	54	27




图 3-2 损伤的行星齿轮、AE 传感器的安装位置及实验测试现场

表 3-3 工业机器人减速机损伤特征频率理论值

f_0	f_m	f_c	f_p
20 Hz	720 Hz	6.67 Hz	26.67 Hz

3.5 实验结果分析

首先根据第 2 章所提方法对减速机两种状态下的 AE 信号进行时域指标计算，计算结果如表 3-4 所示。

表 3-4 减速机两种状态下的时域指标

减速机状态	绝对均值	峰值	脉冲指标
正常状态	0.55	5.86	3.24
行星齿轮损伤状态	0.73	6.78	4.97

由表 3-4 可知，行星齿轮损伤状态下的绝对均值、峰值以及脉冲指标均略高于正常状态。这表明，在行星齿轮损伤状态下，AE 信号的整体能量水平有所增加，脉冲特性也稍有增强。然而，这种变化幅度较小，并没有表现出显著的损伤特征，因此无法作为可靠的判别依据。接着，对减速机两种状态下的 AE 信号进行连续小波变换，如图 3-3 所示。

从图 3-3 可以观察到，减速机两种状态下的频率主要集中在 0kHz 到 40kHz 的范围内，且能量较高的频率均集中在 15kHz 附近，因此没有出现明显的频谱能量分布差异。这表明早期行星齿轮损伤的信号特征微弱，难以在时频图中体现出显著特征。因此，无论是时域指标计算还是时频域联合分析，都无法有效识别减速机行星齿轮损伤。




图 3-3 减速机两种状态下的时频图

鉴于此，本章进一步采用包络分析方法，以增强微弱损伤信号的特征提取能力。本章对减速机两种状态下的 AE 信号进行包络分析。根据表 3-3 可知，行星架的输出转频为 6.67 Hz，则单个行星齿轮绕太阳齿轮旋转一圈需要 0.15 秒，为了使损伤冲击在多个啮合周期内得到体现，本章截取行星齿轮绕太阳齿轮中心旋转两圈的数据进行分析。减速机两种状态下的 AE 信号时域波形图如图 3-4 所示。




图 3-4 原始 AE 信号的时域波形图

由图 3-4 可以观察到，减速机两种状态下的 AE 信号均呈现一定的周期性特征，但在损伤状态下，信号的波动幅度存在一定的异常增大现象。为了进一步揭示 AE 信号的频谱特性，通过对 AE 信号进行 Hilbert 包络解调，得到减速机两种状态下的 AE 信号包络谱，如图 3-5 所示。




图 3-5 原始 AE 信号的包络谱

由图 3-5 可知，减速机两种状态下的峰值频率都出现在 $f_m \pm k_1 f_c$ 的位置，且相邻峰值频率之间的间隔为 $50f_c$ ，因此包络谱能够识别出减速机内部齿轮正常啮合的特征频率。然而，在行星齿轮损伤状态下，包络谱中出现了与峰值频率等间隔的边带，但是边带间隔为 33 Hz。而由表 3-3 可知， $f_p=26.67$ Hz，因此边带与峰值频率之间的间隔并不满足 mf_p (m 为整数)，这是因为损伤造成的周期性冲击信号被噪声掩盖，直接对采集的 AE 信号进行 Hilbert 包络解调会将噪声信号也进行包络提取，从而影响损伤周期性冲击信号的提取，所以单独依赖包络谱分析无法识别出减速机行星齿轮是否出现损伤。

前述的时域指标计算、时频域联合分析以及包络分析均表明，在行星齿轮损伤的早期阶段，AE 信号的特征变化较为微弱，难以通过这些方法准确识别损伤特征。为此，本章进一步提出基于频域分析的方法，以增强损伤特征的提取能力，并与上述分析结果进行对比，以验证其有效性。本章分别对减速机两种状态下的 AE 信号进行 3 层小波包分解，得到节点信号 re_p1~re_p8。在进行小波包分解时，由于分解过程涉及信号的卷积操作，信号的起始端和末端可能因为缺少足够的相邻数据点支持而产生失真，这会导致节点信号的边缘部分出现幅值异常，进而影响故障特征的提取。为了减少这种影响，本章剔除了每个节点信号两端幅值异常的数据点，从而确保 AE 信号特性的真实反映。为了评估减速机在正常状态和行星齿轮损伤状态下 AE 信号的冲击特征，本文计算了减速机两种状态下每个节点信号的峭度值，如图 3-6 所示。




图 3-6 减速机两种状态下 re_p1~re_p8 的峭度值

由图 3-6 可知，在减速机正常状态下，节点信号 re_p5 的峭度值最高。这是因为减速机正常运行时，其内部齿轮在正常啮合过程中产生的周期性冲击信号，与 re_p5 对应的频率范围高度匹配，因此 re_p5 能够清晰反映齿轮正常啮合的特征。然而，当减速机的行星齿轮发生损伤后，re_p5 的峭度值显著下降，而 re_p2~re_p4 以及 re_p6~re_p8 的峭度值则有所增加。这种变化的原因在于齿轮损伤改变了啮合过程的动态特性，导致原本由齿轮正常啮合产生的周期性冲击信号在 re_p5 中减少，同时损伤部位在啮合过程中引入了新的冲击成分。这些新的冲击成分具有尖峰特征，使得包含损伤相关频率的节点信号的峭度值显著提高。

在减速机正常状态下，re_p5 的峭度值最高，说明该信号主要反映了齿轮正常啮合过程中周期性冲击的特征，因此将 re_p5 作为重构 AE 信号的优选节点。然而，在行星齿轮损伤状态下，尽管 re_p5 的峭度值依然较高，但它主要反映了正常啮合的周期性信号，而损伤相关的冲击信号则更多分布在其他节点信号中，特别是 re_p2~re_p4 以及 re_p6~re_p8。由于齿轮正常啮合的周期性信号在低频段占主导地位，齿轮损伤产生的较微弱的冲击信号容易被掩盖，导致低频段的节点信号难以有效区分齿轮损伤特征。另一方面，齿轮损伤产生的短时冲击和非平稳特征在高频范围内表现的更为显著。因此，为了更好地捕捉损伤特征，本章的研究聚焦于高频段的节点信号，特别是 re_p6~re_p8。

为了从 re_p6~re_p8 中进一步识别出包含损伤信息最多的节点信号，首先对这些节点信号进行自相关分析，以削弱随机噪声并突出其周期性特征。在此基础

上, 计算节点信号的频谱熵, 作为衡量其频谱信息量的指标。频谱熵值越高, 表明信号频谱中的能量分布越分散, 信号中包含有关损伤的信息量越多。为了确保分析结果的可靠性和稳定性, 本章将减速机行星齿轮损伤状态下 10 段独立的 AE 信号作为样本, 分别计算了 re_p6~re_p8 的频谱熵, 如图 3-7 所示。




图 3-7 10 段减速机行星齿轮损伤状态下 AE 信号 re_p6~re_p8 的频谱熵

由图 3-7 可知, 在不同实验样本中, 节点信号 re_p7 的频谱熵值始终保持在最高水平, 这表明 re_p7 的能量分布最复杂, 包含的信息量最多。因此, 为了能够最大程度地保留损伤特征信息, 本章选取 re_p7 作为行星齿轮损伤状态下的重构 AE 信号, 重构 AE 信号如图 3-8 所示。




图 3-8 减速机两种状态下的重构 AE 信号

由图 3-8 可知, 在减速机正常状态下, 其内部齿轮啮合产生的 AE 信号呈现

出较为平稳的波动状态，幅值变化相对较小。这表明在正常状态下，齿轮间的啮合过程相对稳定，没有明显的异常冲击或干扰。而在减速机行星齿轮损伤状态下，损伤的行星齿轮与其他部件啮合产生的 AE 信号不再像正常状态下那样平稳，而是出现了间歇性的强烈冲击信号。这种冲击信号的出现是由于行星齿轮损伤后，与其他齿轮的啮合不再均匀，导致在啮合过程中产生了额外的冲击力，反映了行星齿轮损伤对啮合过程产生了实质性的影响。为了将故障信息进一步提取出来，本章对减速机两种状态下的重构 AE 信号分别进行 Hilbert 包络解调，得到减速机两种状态下的包络谱，如图 3-9 所示。




图 3-9 减速机两种状态下的包络谱

由图 3-9 可以观察到，在减速机正常状态下，AE 信号的峰值频率主要分布在 $f_m \pm k_1 f_c$ 位置处，且相邻峰值频率之间的间隔均为 $50f_c$ 。这种频谱特征与理论分析完全一致，验证了本章所提分析方法的合理性和有效性。然而，当减速机的行星齿轮发生损伤后，频谱特性发生了显著变化。虽然峰值频率仍然保持在 $f_m \pm k_1 f_c$ 位置处，但是峰值频率附近新增了明显的边带频率，并且峰值频率与其相邻的边带频率之间的间隔为 $6f_p$ 。这种边带频率的出现是由于齿轮损伤导致啮合过程的动态特性发生了变化，损伤部位引入了新的非平稳冲击成分，从而在频谱中形成与损伤直接相关的边带特征。边带频率的分布为减速机行星齿轮损伤状态的识别提供了重要依据。

为了进一步量化 AE 信号中边带成分的特征表现，本章采用 RSS 作为损伤辨识的关键判据，并对减速机正常状态与行星齿轮损伤状态下的 AE 信号进行了

对比分析。本章计算了减速机两种状态下 10 段独立 AE 信号样本的 RSS 值，如图 3-10 所示。




图 3-10 减速机两种状态下 10 段独立 AE 信号样本的 RSS 值

由图 3-10 可知，减速机行星齿轮损伤状态下的 RSS 值显著高于正常状态，其中正常状态下的 RSS 值分布在 0.1~0.3 之间，而行星齿轮损伤状态下的 RSS 值分布在 0.4~0.9 之间。基于两种状态 RSS 值的分布特征，本研究取正常状态 RSS 值上限 0.3 和损伤状态 RSS 值下限 0.4 的中点，即 0.35 作为阈值，以此作为判断减速机行星齿轮是否发生损伤的判据。该阈值的选择基于 RSS 值在不同状态下的区分度，能够有效避免正常状态 RSS 值波动带来的误判，同时确保对损伤状态的敏感性。

综上所述，通过结合 AE 信号包络谱中的边带特征与 RSS 值量化分析，本章所提出的方法能够有效捕捉行星齿轮的损伤特征，实现对减速机行星齿轮损伤状态的精准识别。

3.6 本章小结

本章提出了一种针对工业机器人减速机行星齿轮损伤的 AE 信号特征提取方法，系统性地解决了从复杂 AE 信号中提取关键损伤特征的难题。该方法首先通过小波包分解实现信号的多频带分离，在此基础上结合峭度指标初步筛选出周期性较强的节点信号，并进一步通过自相关分析削弱随机噪声，突出损伤信号的周

期性特征。随后，引入频谱熵评估各节点信号的频谱信息量，进一步筛选出与损伤最相关的特征信号。为了更准确地揭示损伤对 AE 信号调制特性的影响，采用 Hilbert 包络解调提取信号的调制成分，并通过引入相对边带强度（RSS）量化指标对损伤状态进行可靠评估，实现了从信号分解到损伤状态定量化诊断的多层次有机结合。研究表明，该方法能够有效提取行星齿轮损伤特征，增强损伤信号的可识别性，并实现对行星齿轮损伤状态的精准辨识。本研究为基于 AE 信号的减速机健康监测提供了技术支撑，未来可将其进一步应用于工业机器人减速机的智能故障诊断，提高设备运行的可靠性和稳定性。

第4章 基于BP神经网络的工业机器人减速机行星齿轮损伤辨识研究

在第3章中,针对减速机行星齿轮损伤的辨识问题,提出了一种基于小波包分解、峭度分析、自相关分析、频谱熵筛选和 Hilbert 包络解调的多层次特征提取方法以揭示行星齿轮损伤的边带特征,并通过相对边带强度(RSS)设置阈值,辨识减速机是否出现损伤。然而,该方法在不同工况下可能会受到运行条件变化的影响,导致边带特征不显著,使得行星齿轮损伤难以辨识。

为了实现在多种转速工况下识别减速机行星齿轮损伤,本章进一步探索了BP神经网络在减速机行星齿轮损伤辨识中的应用。通过构建分类模型,建立AE信号特征与损伤状态之间的映射关系,以提高损伤辨识的自动化水平。本章首先针对不同减速机工况下的AE信号,按照转速将数据划分为多个样本,并计算声发射特征参数,构建特征矩阵。随后,为降低特征维度、减少冗余信息并突出关键信息,采用主成分分析(Principal Components Analysis, PCA)进行特征优化,提高模型的训练效率。在此基础上,运用粒子群优化(Particle Swarm Optimization, PSO)算法优化的BP神经网络构建损伤辨识模型,以提升分类性能并增强损伤辨识的精度和稳定性。

本章的研究目标是利用智能数据分析方法,提高行星齿轮损伤辨识的准确性和鲁棒性,并深入探索AE信号特征与损伤模式之间的映射关系,为后续的智能故障诊断提供理论依据和技术支撑。

4.1 行星齿轮智能损伤辨识方法

4.1.1 主成分分析

主成分分析(Principal Components Analysis, PCA)是一种数据降维和特征提取的统计分析方法,主要用于降低数据维度、去除冗余信息,同时尽可能保留原始数据中的主要信息^[46]。在高维数据集中,不同特征之间可能存在较强的相关性,导致特征冗余,并影响后续神经网络模型的计算效率和泛化能力。PCA通过构造一组新的无相关特征(主成分),用少数几个主成分代替原始高维数据,

实现降维的同时保留尽可能多的有效信息。其核心思想就是通过线性变换，将原始数据投影到新的坐标系中，使得投影后的数据在某些方向上的方差最大，即找到一组正交基，使得数据在这些基上的投影尽可能保留原始数据的变异信息。

PCA 主要包括以下步骤：

假设特征矩阵为 $X_{m \times n}$ ，其中 m 为样本数， n 为特征数。由于不同特征的量纲不同，直接计算协方差矩阵可能会导致某些特征对结果影响过大，因此首先需要对数据进行标准化处理，使每个特征服从均值为 0、方差为 1 的标准正态分布：

$$Z = \frac{X_{ij} - \frac{1}{m} \sum_{i=1}^m X_{ij}}{\sqrt{\frac{1}{m-1} \sum_{i=1}^m (X_{ij} - \frac{1}{m} \sum_{i=1}^m X_{ij})^2}} \quad (4-1)$$

其中 X_{ij} 表示第 i 个样本的第 j 个特征， Z 表示标准化后的特征矩阵。

为了度量不同特征之间的相关性，需要计算标准化特征矩阵 Z 的协方差矩阵 C ：

$$C = \frac{1}{m-1} Z^T Z \quad (4-2)$$

其中 C 为 $n \times n$ 维的协方差矩阵。对协方差矩阵 C 做特征值分解，求取特征值和特征向量：

$$C = V \Lambda V^T \quad (4-3)$$

其中 Λ 是一个对角矩阵，其对角线元素就是特征值 $\lambda_1, \lambda_2, \lambda_3 \dots \lambda_n$ ； V 是一个正交矩阵，其列是协方差矩阵的特征向量 $e_1, e_2, e_3 \dots e_n$ 。特征值的大小表示该主成分能解释的数据方差信息量。较大的特征值对应的信息量较大，较小的特征值对应的信息量较少。

为了尽可能地多保留原始数据信息，同时减少维度，需要计算主成分的累计方差贡献率，以确定选取多少个主成分，主成分的累计方差贡献率计算公式为：

$$\sigma_p = \frac{\sum_{k=1}^p \lambda_k}{\sum_{k=1}^n \lambda_k} \quad (p \leq n) \quad (4-4)$$

一般情况下，按照累计方差贡献率 $\sigma_p \geq 85\%$ 的原则选取前 p 个主成分以确保保留足够的信息量^[47, 48]。选取对应的前 p 个特征向量构成矩阵 $D=[e_1, e_2, e_3 \dots e_p]$ ， $Y=ZD$ 即为降维到 p 维的特征矩阵。主成分本质上就是矩阵 Z 中特征的线性组合，

也是矩阵 Y 中的新特征。在本研究中，PCA 主要用于对 AE 信号的特征参数进行优化，去除冗余信息，提高损伤模式识别的稳健性。

4.1.2 PSO-BP 神经网络

BP 神经网络（Back Propagation Neural Network, BPNN）是一种基于误差反向传播训练的多层前馈网络，它的基本思想是梯度下降法^[49]。其结构通常由输入层，隐含层和输出层组成，如图 4-1 所示。




图 4-1 神经网络结构示意图

其中，输入层用于接收 AE 信号的特征；隐含层用于特征学习，一般使用非线性激活函数对输入数据进行非线性变换；输出层用于损伤分类，输出损伤类别的预测概率。BP 神经网络隐含层的节点个数可以根据经验公式^[50]来确定：

$$h = \mu + \sqrt{\alpha + \beta} \quad (4-5)$$

其中， α 为输入层节点个数， β 为输出层节点个数， μ 一般取 [1,10] 之间的常数。

BP 神经网络的训练过程主要就是将给定的训练样本通过初始权重值与初始偏置值进行前向传播，然后计算预测值与实际值之间的偏差（损失函数）进行反向传播，再通过优化算法以迭代更新的方式搜索最优权重值和偏置值，最终得到一个具有预测和分类能力的网络模型^[51]。BP 神经网络的具体训练过程包括以下步骤：

(1) 输入特征并经过神经网络各层的权重变换和非线性激活进行前向传播，生成输出预测值：

$$H = f(WX + b) \quad (4-6)$$

其中， W 为权重矩阵， b 为偏置向量， $f(\cdot)$ 为激活函数。

(2) 通过损失函数计算预测值与真实值之间的误差：

$$Loss = \frac{1}{m} \sum_{i=1}^m (Y_i - \hat{Y}_i)^2 \quad (4-7)$$

(3) 根据损失函数计算梯度，利用梯度下降更新权重进行反向传播：

$$W^{(t+1)} = W^{(t)} - \eta \frac{\partial Loss}{\partial W} \quad (4-8)$$

其中 η 为学习率。

尽管 BP 神经网络具有强大的学习能力，但传统的梯度下降法容易受到初始权重的影响，会导致不收敛和易陷入局部最优等问题，因此本研究采用粒子群优化（Particle Swarm Optimization, PSO）算法代替传统梯度下降法，对 BP 神经网络的权重和偏置进行全局优化，以提高模型的稳定性和全局搜索能力。

PSO 算法是一种基于群体智能的全局优化方法，其核心思想源于鸟群觅食行为的模拟。该算法通过粒子间的信息共享，在搜索空间中不断调整运动方向，以逐步逼近最优解^[52, 53]。PSO 算法的迭代过程如图 4-2 所示。




图 4-2 PSO 算法的迭代过程

在 PSO 算法中，粒子的运动受当前位置和速度的影响，并通过动态调整加速因子与惯性权重来优化搜索路径。具体而言，该算法通过最小化损失函数，优化 BP 神经网络的初始参数，使其更易于收敛至最优解。其中，每个粒子的位置对应于 BP 神经网络的一组权重和偏置，速度则决定了参数更新的方向和幅度。PSO 算法的迭代公式如下：

$$v_i(t+1) = w \cdot v_i(t) + c_1 \cdot r_1 \cdot (p_i - x_i(t)) + c_2 \cdot r_2 \cdot (g - x_i(t)) \quad (4-9)$$

$$x_i(t+1) = x_i(t) + v_i(t+1) \quad (4-10)$$

其中，式(4-9)用于更新粒子的速度，式(4-10)则计算粒子的新位置。变量 $v_i(t)$ 和变量 $x_i(t)$ 分别是粒子 i 在 t 时刻的速度和位置， p_i 代表粒子 i 经历的历史最佳位置，而 g 是整个种群的全局最优位置，惯量权重 w 取值范围通常在 $[0,1]$ 之间以平衡全局探索和局部开发能力。此外， c_1 和 c_2 是加速因子，通常设定为 2，而 r_1 和 r_2 为 $[0,1]$ 之间的随机数，用于引入一定的随机性，增强搜索多样性。

为了进一步提高模型的泛化能力，本文在适应度函数的构造上引入了训练误差和验证误差的加权组合。该方法有助于平衡模型在训练集和验证集上的表现，从而降低过拟合的风险。适应度函数的计算公式如下：

$$Fitness = \alpha \cdot MSE_{tr} + (1 - \alpha) \cdot MSE_{val} \quad (4-11)$$

其中， α 为权重系数，控制 MSE_{tr} （训练误差）和 MSE_{val} （验证误差）之间的平衡。训练误差用于衡量模型在训练数据上的拟合效果，而验证误差则反映了模型的泛化能力。为了在训练精度和泛化能力之间取得平衡，本文将 α 设置为 0.5。

为确保 PSO-BP 神经网络的性能并验证其优势，本章设计与传统梯度下降法优化 BP 神经网络（GD-BP 神经网络）的对比实验，两者采用相同的网络结构与数据输入。BP 神经网络采用三层结构，输入层节点个数为 PCA 降维后保留的特征个数，隐层神经元数量根据经验公式并通过试凑法^[54]确定为 10，输出层设置为 2 个节点分别表示正常与损伤状态，激活函数选用 Sigmoid 以增强非线性映射能力。PSO-BP 神经网络中，PSO 算法参数设置为：粒子数量为 30，以保证搜索空间覆盖；最大迭代次数为 300，以确保函数收敛；加速因子为 2，以平衡个体与全局经验；惯性权重为 0.5，兼顾全局探索与局部收敛；调优过程以最小化 $Fitness$ 为目标，不断调整优化权重值与偏置值，以提高低转速工况下行星齿轮

的损伤辨识准确率。GD-BP 神经网络采用梯度下降法优化权重和偏置，学习率设为 0.01 以确保稳定更新，迭代次数设为 300 以维持与 PSO-BP 神经网络一致的计算量。

4.1.3 声发射特征参数

在本章的研究中，为了更加全面地表征 AE 信号的损伤特征，本研究对分段后 AE 信号样本计算了 15 个声发射特征参数。这些参数涵盖了 9 个时域特征参数、3 个统计指标以及 3 个频域特征参数，共同构成了 AE 信号在时域和频域上的完整描述体系，为损伤模式的识别提供了充足的数据支持。其中，时域特征参数主要用于刻画 AE 信号的幅值变化及瞬时冲击特性；统计指标则反映了 AE 信号的整体分布特性；频域特征参数主要描述 AE 信号在不同频率范围内的能量分布特性。声发射特征参数的数学表达式详见附录。

4.2 行星齿轮智能损伤辨识流程

为了克服低转速工况下减速机行星齿轮损伤辨识困难的问题，本章提出了一种基于声发射特征和 PSO-BP 神经网络的损伤辨识方法。该方法利用 PCA 进行特征降维，以提取 AE 信号中的主要信息，并将降维后的特征输入到 PSO 优化的 BP 神经网络进行损伤模式学习，从而构建一个高效、稳定的减速机行星齿轮损伤辨识模型。该方法的具体步骤如下：

(1) 根据减速机行星架的输出转频，对减速机在正常状态和行星齿轮损伤状态下的 AE 信号进行分段处理。行星架的输出转频为 f_c ，每段信号长度对应一个完整的齿轮啮合周期 $T=1/f_c$ 。这样，每个周期内的 AE 信号可视为一个独立样本，共计得到 m 个样本。这种样本划分方式能够确保 AE 信号的周期性特征得到充分保留，同时提高损伤模式识别的稳定性。

(2) 计算每个样本的 15 个声发射特征参数，并构成一个 $m \times 15$ 的特征矩阵 $X_{m \times 15}$ 。为了消除不同特征量纲的影响，对矩阵进行标准化处理，得到特征矩阵 $Z_{m \times 15}$ 。

(3) 利用 PCA 降维，根据累计方差贡献率大于 85% 的准则，保留前 p 个主成分，并构成矩阵 $D_{15 \times p}$ 对特征矩阵 $Z_{m \times 15}$ 进行降维，降维后得到特征矩阵 $U_{m \times p}$ 。

(4) 将降维后的特征矩阵 $U_{m \times p}$ 作为 BP 神经网络的输入，并采用 PSO 算法优

化 BP 神经网络的权重和偏置，以避免不收敛以及局部最优问题的影响。训练完成后，将独立的测试样本输入到训练好的 PSO-BP 神经网络中，并输出损伤识别结果。

4.3 实验结果分析

在第 3 章中，基于频域分析的方法在高转速工况下表现出了较好的减速机行星齿轮损伤辨识能力。然而在低转速工况下，由于 AE 信号中的损伤特征较为微弱，信号的包络谱容易受到背景噪声和其他频率成分的干扰，导致损伤特征频率难以突出，从而显著降低了故障辨识的准确性。本章根据第 3 章提出的频域分析方法，分析了减速机转速设置为 600rpm 工况下采集的 AE 信号，并得到了相应的包络谱如图 4-3 所示。

从图 4-3 可以看出，AE 信号的包络谱在正常状态和损伤状态下均呈现出 $f_m \pm k_1 f_c$ 位置的峰值频率，且相邻峰值频率之间的间隔均为 $50f_c$ 。这表明，即使行星齿轮发生损伤，其在包络谱中的主要频率成分仍与正常状态相似，未能显著体现损伤特征。尽管损伤状态下的包络谱中出现了一些边带，但边带与峰值频率之间的间隔不等距，并且不能与理论计算值相匹配。这主要是在低转速工况下，损伤引发的冲击信号较弱，使得损伤特征频率难以突出，导致无法清晰地判断出减速机的行星齿轮是否发生损伤。




图 4-3 转速设置为 600rpm 工况下减速机两种状态下的包络谱

为了弥补低转速工况下频域分析方法的不足，本章提出了一种结合 AE 信号

特征和 PSO-BP 神经网络的智能损伤辨识方法,通过多维特征提取、降维优化和智能分类模型,提高多种转速工况下的行星齿轮损伤辨识精度。本章选择减速机在 300rpm、600rpm、900rpm 和 1200rpm 四种工况下的 AE 信号作为实验数据。依据第 3 章表 3-1 所提到的公式计算减速机在不同转速工况下行星架的输出转频,根据此转频将减速机两种状态下不同工况的 AE 信号进行分段处理。每段 AE 信号的数据长度如表 4-1 所示。

表 4-1 减速机四种工况下行星架的输出转频及每段 AE 信号的数据长度

减速机工况	行星架的输出转频	AE 信号的数据长度
300rpm	1.67Hz	6×10^5
600rpm	3.33Hz	3×10^5
900rpm	5Hz	2×10^5
1200rpm	6.67Hz	1.5×10^5

接着,计算每段 AE 信号的 15 个声发射特征参数。为了构建训练集,本章从减速机正常状态和行星齿轮损伤状态下每种转速工况中各取 100 个样本,组成一个 800×15 的特征矩阵 $X_{800 \times 15}$ 。同时,为了验证模型的泛化能力,从减速机两种状态下每种转速工况又各取 25 个样本,组成一个 200×15 的特征矩阵作为独立的测试集。为了便于分析,本章列出了测试集样本的编号及对应的运行状态,如表 4-2 所示。

表 4-2 测试集样本的编号及对应的运行状态

样本序号	转速工况	减速机状态
1~25	300rpm	正常状态
26~50	300rpm	行星齿轮损伤状态
51~75	600rpm	正常状态
76~100	600rpm	行星齿轮损伤状态
101~125	900rpm	正常状态
126~150	900rpm	行星齿轮损伤状态
151~175	1200rpm	正常状态
176~200	1200rpm	行星齿轮损伤状态

由于特征矩阵中的一些特征之间具有较强的相关性,这可能会增加后续算法的学习负担。因此在进行数据处理时,本章采用 PCA 对标准化后的特征矩阵 $Z_{800 \times 15}$ 进行降维,减少冗余信息的同时提取出最能代表数据特征的主成分,从而优化模型的训练效率。使用 PCA 降维得到的前 p 个主成分的累计方差贡献率如表 4-3 所示。

表 4-3 前 p 个主成分的累计方差贡献率

前 p 个主成分	前 p 个主成分的累计方差贡献率
e_1	78.6%
e_2	95%
e_3	97.4%
...	...
e_{15}	100%

由表 4-3 可知,前 2 个主成分 (e_1 和 e_2) 的累计方差贡献率已经超过 85%,说明这两个主成分已经能够保留矩阵 $Z_{800 \times 15}$ 的大部分信息,因此选取 e_1 和 e_2 构成矩阵 $D=[e_1, e_2]$ 。随后,利用矩阵 D 对特征矩阵 $Z_{800 \times 15}$ 进行降维,得到降维后的特征矩阵 $U_{800 \times 2}$ 。最后,将 $U_{800 \times 2}$ 输入到 PSO-BP 神经网络以及 GD-BP 神经网络中进行训练。模型训练完成后,本章运用独立的测试集对两个模型的泛化性能进行了验证与对比,PSO-BP 神经网络验证结果如图 4-4 所示,GD-BP 神经网络验证结果如图 4-5 所示。




图 4-4 PSO-BP 神经网络训练出的模型在独立测试集中的验证结果




图 4-5 GD-BP 神经网络训练出的模型在独立测试集中的验证结果

从图 4-4 可以看出，PSO-BP 神经网络在低转速工况（300rpm 和 600rpm）下的分类准确率达到 100%，在 900rpm 工况下为 98%，在 1200rpm 工况下再次达到 100%。这些结果表明，PSO-BP 神经网络能有效提取行星齿轮损伤的 AE 信号特征，显著提升低转速工况的辨识精度，弥补了第 3 章频域分析方法在 600rpm 工况下特征不显著的不足，并在高转速工况下保持优异性能。图 4-5 显示，GD-BP 神经网络在 300rpm、600rpm 以及 900rpm 工况下与 PSO-BP 神经网络的识别效果是相同的，但在 1200rpm 工况下的识别准确率仅为 80%。这表明 GD-BP 在高转速工况下易受初始权重影响，收敛至局部最优，导致性能下降。相比之下，PSO-BP 通过全局优化确保了全转速工况（300rpm-1200rpm）的高鲁棒性和稳定性，其优异的辨识精度和多工况适应性更适合复杂工业场景下的实时故障诊断。

综上，基于 AE 信号特征和 PSO-BP 神经网络训练出的损伤识别模型能够有效提升低转速工况下的行星齿轮损伤辨识精度，弥补了频域分析方法难以在低转速工况下准确提取损伤特征的缺陷，为复杂工况下的智能故障诊断提供了可靠的技术支持。

4.4 本章小结

本章针对低转速工况下减速机行星齿轮损伤难以辨识的问题，提出了一种结合声发射特征与 PSO-BP 神经网络智能损伤辨识方法。该方法通过将减速机正

常状态和行星齿轮损伤状态下四种转速工况的 AE 信号，依据行星架的输出转频进行分段，并计算每段 AE 信号的特征参数。为了避免传统梯度下降法在训练过程中存在的步长选择困难及其不收敛的问题，本章引入了 PSO 算法来优化 BP 神经网络的综合适应度函数。此外，为了降低 PSO 算法的学习负担，本章使用 PCA 对特征矩阵进行降维。实验结果表明，本章所提方法通过结合声发射特征和 PSO-BP 神经网络，在低转速工况下实现了高效、精确的损伤识别。因此，本章所提方法有效补充了第 3 章中提出的高转速工况下的频域分析方法，进一步增强了减速机故障辨识体系的适用性和准确性。

第 5 章 总结与展望

5.1 总结

在现代制造业中，工业机器人的重要性日益凸显，而减速机作为其核心部件，长期处于复杂且恶劣的工作环境，容易受到损伤，进而影响工业机器人的稳定运行。然而，传统的故障检测方法在减速机早期故障识别方面仍存在一定的局限性。为此，本文基于声发射技术，针对减速机突发故障及行星齿轮损伤辨识进行了深入研究，并提出了多种高效的故障辨识方法。本文的主要贡献如下：

针对减速机的突发故障辨识问题，本文采集并分析了减速机在实际运行过程中产生的 AE 信号，并提出了一种结合时域指标和连续小波变换的故障辨识方法。时域指标可用于描述信号的变化特性，从而有效揭示减速机运行过程中的异常状态。而连续小波变换则用于对信号进行时频联合分析，捕捉减速机突发故障的瞬态特征。实验结果表明，脉冲指标在突发故障辨识中表现尤为突出，且传感器的安装位置对检测效果有显著影响。结合时域指标和时频域分析，可实现更精确的减速机突发故障辨识。

针对减速机行星齿轮损伤辨识问题，本文提出了一种频域分析方法。通过小波包分解、峭度筛选、自相关分析、频谱熵计算以及 Hilbert 包络解调等技术，提取了行星齿轮损伤的特征频率，并运用 RSS（相对边带强度）对损伤特征进行了量化，最终成功实现了减速机行星齿轮损伤的精准识别。

此外，针对低转速工况下频域分析方法的局限性，本文进一步提出了一种基于声发射特征与 PSO-BP 神经网络的故障辨识方法。首先，利用 PCA 降维保留主要信息。然后，利用 PSO 算法训练 BP 神经网络，实现多种转速工况下的减速机行星齿轮损伤识别。该方法不仅弥补了频域分析方法的不足，同时提升了减速机故障辨识体系的适用性和准确性，为减速机健康监测提供了更加全面的解决方案。

5.2 展望

尽管本研究在减速机故障辨识方面取得了积极成果，但在实际工业应用中，

减速机往往同时受到多种故障模式的影响，导致诊断过程更加复杂。因此，未来研究需要进一步拓展现有方法，重点关注多故障模式共存情况下的辨识策略，以提升诊断方法的适用性与鲁棒性。此外，随着机器学习与智能优化算法的快速发展，未来可以结合更先进的智能诊断技术，提高故障辨识的效率和准确性。在此基础上，还可以进一步探索低功耗、实时性强的诊断系统，尤其是在嵌入式系统和工业现场的应用中，为工业机器人减速机的全生命周期管理提供更加可靠和精准的支持。

参考文献

- [1] 黄大为, 褚嘉政. 工业机器人赋能制造企业服务化转型[J]. 中国商论, 2024, 33(24): 156-160.
- [2] Gao X.L, Luo C.L, Shou J. Effect of industrial robot use on China's labor market: Evidence from manufacturing industry segmentation[J]. Intelligent and Converged Networks, 2023, 4(2): 106-115.
- [3] 王青, 王宇璐. 工业机器人应用对制造业高质量发展的影响研究[J]. 工业技术经济, 2023, 42(02): 115-124.
- [4] 胡阿林, 白亚玲, 刘新文. 少齿差行星齿轮减速器设计及在珩磨头中的应用[J]. 金属加工(冷加工), 2024, (10): 33-36.
- [5] 周恒宇, 崔权维, 周建星. 二级齿轮减速器高速级轴承动态特性分析[J]. 轴承, 2024, (04): 28-35.
- [6] Teng W, Ding X, Tang S.Y, etc. Vibration analysis for fault detection of wind turbine drivetrains—a comprehensive investigation[J]. Sensors, 2021, 21(5): 1-33.
- [7] Zhou X, Zhou H.C, He Y.M, etc. Harmonic reducer in-situ fault diagnosis for industrial robots based on deep learning[J]. Science China Technological Sciences, 2022, 65: 2116-2126.
- [8] Ghadarah N, Ayre D. A review on acoustic emission testing for structural health monitoring of polymer-based composites[J]. Sensors, 2023, 23(15): 6945.
- [9] Das S, Jain N, Saha A. Noncontact self-vibration compensated position sensitive detector based low-frequency vibration measurement[J]. IEEE Transactions on Instrumentation and Measurement, 2024, 73: 1-8.
- [10] Crescentini M, Syeda S.F, Gibiino G.P. Hall-effect current sensors: Principles of operation and implementation techniques[J]. IEEE Sensors Journal, 2021, 22(11): 10137-10151.
- [11] Muir C, Swaminathan B, Almansour A S, etc. Damage mechanism identification in composites via machine learning and acoustic emission[J]. npj Computational Materials, 2021, 7(1): 95.

- [12]鞠晓臣, 梁永奇, 赵欣欣, 等. 采用声发射技术检测钢桥疲劳裂纹[J]. 哈尔滨工程大学学报, 2023, 44(04): 649-656.
- [13]张继轩, 豆涵杰, 刘涛, 等. 基于 MEMS 声发射传感器的齿轮故障检测系统[J]. 压电与声光, 2024, 46(05): 638-643.
- [14]Tang L.J, Wu X, Wang D.X, etc. A comparative experimental study of vibration and acoustic emission on fault diagnosis of low-speed bearing[J]. IEEE Transactions on Instrumentation and Measurement, 2023, 72:1-11.
- [15]Leaman F, Baltes R, Clausen E. Comparative case studies on ring gear fault diagnosis of planetary gearboxes using vibrations and acoustic emissions[J]. Forschung Im Ingenieurwesen/Engineering Research, 2021, 85(2), 619–628.
- [16]盛嘉玖, 陈果, 贺志远, 等. 一种齿轮故障协同诊断与预警方法[J]. 噪声与振动控制, 2024, 44(06): 111-115+164.
- [17]Xie X.Z, Guan S.H, Li J.L, etc. Photonic Fractional Fourier Transformation Based on Discrete-Frequency Processing[J]. Journal of Lightwave Technology, 2022, 40(20): 6875-6881.
- [18]向明胜, 冯坤, 贾韶辉, 等. 强噪声条件下基于 EMD-AE 优选特征的离心泵多故障诊断方法[J]. 振动与冲击, 2024, 43(23): 66-74.
- [19]魏靖依. 基于小波包分解岩石破裂声发射信号响应机制与脆性评价研究[J]. 特种油气藏, 2024, 31(03): 52-60.
- [20]沙云东, 陈兴武, 栾孝驰, 等. 基于小波包分解-峭度值指标-希尔伯特包络解调融合方法处理声发射信号的滚动轴承故障诊断[J]. 科学技术与工程, 2023, 23(21): 9315-9323.
- [21]刘泽锐, 邢济收, 王红军, 等. 基于 VMD 与快速谱峭度的滚动轴承故障诊断[J]. 电子测量与仪器学报, 2021, 35(02): 73-79.
- [22]刘文朋, 杨绍普, 李强, 等. 一种自适应共振解调方法及其在铁路轴承故障诊断中的应用[J]. 振动与冲击, 2021, 40(18): 86-93.
- [23]Yang J.Z, Zhou C.J A fault feature extraction method based on IMD and wavelet packet denoising[J]. Coatings, 2022, 12(2): 156.
- [24]Li H, Liu T, Wu X, etc. An optimized VMD method and its applications in bearing fault diagnosis[J]. Measurement, 2020, 166: 108185.

- [25] Zhou X.L, Wang X.K, Wang H.T, etc. Method for denoising the vibration signal of rotating machinery through VMD and MODWPT[J]. *Sensors*, 2023, 23(15): 6904.
- [26] 郑祥, 张鸿鹄, 魏岩岩. 基于改进 SVM 的变电站设备红外图像故障诊断方法研究[J]. *电测与仪表*, 2024, 61(12): 49-55.
- [27] 颜磊, 王国兵, 翁旭峰, 等. 基于改进 WOA-BP 神经网络的电气火灾预警算法[J]. *电子设计工程*, 2025, 33(01): 21-26.
- [28] 闵永智, 令世文, 王果. 基于混合特征选择和 IOMA-CNN 的变压器故障诊断[J]. *电力系统保护与控制*, 2024, 52(23): 1-9.
- [29] 张军翠, 王立成. 基于天牛须搜索优化支持向量机液压泵故障诊断[J]. *噪声与振动控制*, 2022, 42(03): 105-109.
- [30] 郭文军, 张自来, 陈丽君. EMD-AR 和 GRNN 算法下的航空液压泵多模态故障诊断分析[J]. *液压与气动*, 2022, 46(06): 151-158.
- [31] 甄冬, 孙赫明, 冯国金, 等. 基于包络谱语义构建的零样本滚动轴承复合故障诊断方法[J]. *振动与冲击*, 2024, 43(14): 189-200+283.
- [32] Ye Q, Liu S, Liu C. A deep learning model for fault diagnosis with a deep neural network and feature fusion on multi-channel sensory signals[J]. *Sensors*, 2020, 20(15): 4300.
- [33] Viveros P, Moya C, Mena R, etc. An integrated approach: A hybrid machine learning model for the classification of unscheduled stoppages in a mining crushing line employing principal component analysis and artificial neural networks[J]. *Sensors*, 2024, 24(17): 5804.
- [34] Lu Q.D, Yang R, Zhong M.Y, etc. An improved fault diagnosis method of rotating machinery using sensitive features and RLS-BP neural network[J]. *IEEE Transactions on Instrumentation and Measurement*, 2019, 69(4): 1585-1593.
- [35] 杨海英, 许鹏. 基于连续小波变换的滑移装载机驾驶室噪声分析[J]. *机械制造*, 2020, 58(11): 50-52.
- [36] 余慧敏, 朱姣姿. 基于新模态-小波包分解的超宽带雷达生命体征信号去噪算法[J]. *电子测量与仪器学报*, 2024, 38(03): 143-151.
- [37] 葛君超, 王利鹏. 基于小波包分解的船用柴油机燃油电磁阀故障诊断方法[J]. *舰船科学技术*, 2023, 45(18): 105-108.

- [38]唐璐, 卢官明, 戚继荣, 等. 基于 CEEMDAN 与自相关函数的心音去噪[J]. 软件工程, 2025, 28(01): 14-18.
- [39]曹燕, 王一歌, 李欣雯, 等. 一种基于窄带自相关的实信号频率估计算法[J]. 科学技术与工程, 2020, 20(07): 2756-2761.
- [40]刘云鹏, 周旭东, 王博闻, 等. 用于变压器端部垫块脱落故障识别的时间序列频谱熵稳定度算法[J]. 华北电力大学学报(自然科学版), 2022, 49(04): 23-32.
- [41]肖学, 田仁飞, 赵乾辰. 时频谱熵属性在春光油田储层预测中的应用研究[J]. 复杂油气藏, 2020, 13(01): 18-21+41.
- [42]程乾生. 希尔伯特变换与信号的包络、瞬时相位和瞬时频率[J]. 石油地球物理勘探, 1979(03): 1-14.
- [43]彭国良, 郑近德, 潘海洋, 等. 集成全息希尔伯特谱分析及其在滚动轴承故障诊断中的应用[J]. 振动与冲击, 2024, 43(13): 98-105+125.
- [44]Yu J.B, Wang S.Y, Wang L, etc. Gearbox fault diagnosis based on a fusion model of virtual physical model and data-driven method[J]. Mechanical Systems and Signal Processing, 2023, 188: 109980.
- [45]冯志鹏, 赵锺锺, 褚福磊. 行星齿轮箱齿轮局部故障振动频谱特征[J]. 中国电机工程报, 2013, 33(05): 119-127+19.
- [46]Nayak D, Jonnalagadda A, Balakrishnan U, etc. A co-kurtosis PCA based dimensionality reduction with nonlinear reconstruction using neural networks[J]. Combustion and Flame, 2024, 259: 113192.
- [47]季珊珊, 杜华东, 管伟琴, 等. 噪声干扰下基于 PCA-SF 的轴承故障诊断方法[J]. 噪声与振动控制, 2024, 44(03): 132-137.
- [48]赵琳琳, 温国锋, 杨永清. 突发事件网络舆情反转的 PCA-LDA-LSSVM 预测模型[J]. 中国安全生产科学技术, 2023, 19(08): 186-190.
- [49]游清悦, 曹博, 彭丁萍, 等. 基于粒子群优化 BP 神经网络的核事故源项反演[J]. 核电子学与探测技术, 2025, 45(03): 371-381.
- [50]徐婧雯, 杨平, 阴晓俊. 基于 EMD 分解和 Levy-SSA-BP 神经网络的齿轮故障诊断[J]. 机械传动, 2024, 48(05): 152-157.
- [51]Tian Y, Fu D, Li G. Research on the generalization problem of BP neural network[J]. IEEE Access, 2024, 12: 125416-125426.

- [52]Qian Z.Y, Cao Y.H, Sun X.S, etc. Clustering optimization for triple-frequency combined observations of BDS-3 based on improved PSO-FCM algorithm[J]. Remote Sensing, 2022, 14(15): 3713.
- [53]Wu Z.D, Luo Y.S, Hu S.L. Optimization of jamming formation of USV offboard active decoy clusters based on an improved PSO algorithm[J]. Defence Technology, 2024, 32: 529-540.
- [54]Yang X, Zhou J, Wen D. An optimized BP neural network model for teaching management evaluation[J]. Journal of Intelligent & Fuzzy Systems, 2021, 40: 3215-3221.

附录 1

表 1 声发射信号时域特征参数

时域特征参数	计算公式
能量	$E = \sum_{i=1}^N x_i^2$
标准差	$STD = \sqrt{\frac{\sum_{i=1}^N (x_i - \frac{1}{N} \sum_{i=1}^N x_i)^2}{N-1}}$
峰值	$PE = \max(x_i)$
有效值	$RMS = \sqrt{\frac{1}{N} \sum_{i=1}^N (x_i)^2}$
峭度	$KU = \frac{1}{N} \frac{\sum_{i=1}^N (x_i - \frac{1}{N} \sum_{i=1}^N x_i)^4}{STD^4}$
绝对均值	$AM = \frac{1}{N} \sum_{i=1}^N x_i $
方根幅值	$ROA = \left(\frac{\sum_{i=1}^N \sqrt{ x_i }}{N} \right)^2$
偏度	$SK = \frac{1}{N} \frac{\sum_{i=1}^N (x_i - \frac{1}{N} \sum_{i=1}^N x_i)^3}{STD^3}$
平均功率	$AVP = \frac{E}{N}$

表 2 声发射信号统计指标

统计指标	计算公式
波形指标	$WAI = \frac{RMS}{AM}$
脉冲指标	$CRI = \frac{PE}{RMS}$
裕度指标	$MAI = \frac{PE}{ROA}$

附录 2

表 3 声发射信号频域特征参数

频域特征参数	计算公式
重心频率	$FC = \frac{\sum_{i=1}^N f_i \cdot X(f_i) ^2}{\sum_{i=1}^N X(f_i) ^2}$
均方频率	$MSF = \frac{\sum_{i=1}^N f_i^2 \cdot X(f_i) ^2}{\sum_{i=1}^N X(f_i) ^2}$
频率标准差	$RVF = \sqrt{MSF - FC^2}$

注 a: x_i 为信号序列, $i=1\dots N$ 。 d 为提取声发射事件的阈值。 $X(f_i)$ 是信号在频率 f_i (f_i 为第 i 个频率分量) 处的幅值。

攻读学位期间发表的学术论文及成果目录

一、发表的学术论文

- [1] **You J**, Qiao S, Cheng Z, etc. Research on the Method of Sudden Failure Identification for Industrial Robot Gearboxes Based on Acoustic Emission Technology[C]. International Conference on Robotics, Control and Automation Engineering. Suzhou, China, 2023, pp.411-415. DOI: 10.1109/RCAE59706.2023.10398875. (EI (CA), 已检索, Accession number: 20240815576716)
- [2] Dong S, **You J**, Li M, etc. Investigation of Lamb wave modes recognition and acoustic emission source localization for steel plate based on golden jackal optimization VMD parameters and CWT[J]. Measurement, 2024, 242: 116103. DOI:<https://doi.org/10.1016/j.measurement.2024.116103>. (SCI 2 区 TOP, JCR:Q1, IF=5.2, 已检索, **WOS:001352895400001**)
- [3] Dong S, **You J**, Li M, etc. Research on features and localization of AE signals from the mechanical body of industrial robots based on WD-EMD[J]. Measurement Science and Technology, 2024, 35(9): 096117. DOI:10.1088/1361-6501/ad545f. (SCI 3 区, JCR:Q1, IF=2.7, 已检索, **WOS:001250045300001**)

二、实用新型专利

- [1] 程子安, **尤军**, 李明, 郭黎. 安徽工程大学产业创新技术研究有限公司, 安徽工程大学. 一种声发射传感器的固定装置: 202322800450.6[P]. 2024-06-21. (实用新型专利授权)

致谢

在读研的这段宝贵时光里，诸多师长、亲友与同学在学业、生活和精神上给予了我莫大支持与帮助，让我得以稳步前行。这份情谊我铭记于心，满怀感恩，在此，我想向他们献上最诚挚的谢意。

我首先要衷心感谢程子安老师和李明老师。程老师即便平日工作繁忙，时间极为紧凑，却依旧在有限的指导时间里，竭尽全力为我答疑解惑，为我的研究指明方向。而李明老师在学术的海洋中为我点亮了一盏明灯，在 A413 实验室的学习期间，给予了我许多宝贵的学术指导。在整个硕士阶段，两位导师对我研究过程中遭遇的重重困难，以及论文撰写时的反复打磨，都给予了无微不至的关怀与悉心指导。他们严谨的治学态度、渊博的学术知识以及精益求精的科研精神，始终激励着我在学术道路上奋勇前行。

此外，我由衷感谢芜湖固高自动化技术有限公司的袁学超老师，正是他的支持与帮助，为我的实验提供了优越的条件，使我的研究得以顺利完成。同时，感谢绍兴市协同智造促进中心的祝新军院长、高琦樑老师、徐旦老师、金丹老师和陈科行老师，在我绍兴联培期间，他们不仅给予了我学术上的指导，也在生活中提供了诸多帮助，让我得以安心求学。

我最深的感激，献给我的父母。你们是我生命中最坚实的依靠。多年来，你们不仅在物质上给予我毫无保留的支持，更在精神上给予我无尽的关爱与鼓励。每当我因学业压力而倍感焦虑、陷入迷茫时，是你们耐心的倾听和温暖的话语，如春风化雨，让我重新找回勇气，振作精神。

感谢我的同门，在科研这条充满挑战的道路上，我们并肩作战，相互交流、分享经验，一起攻克了一个又一个难关。每一次激烈的讨论、每一个灵感的碰撞，都成为我们前进的动力。感谢我的室友们，在生活中给予我贴心的陪伴，让我在忙碌的学习之余，也能感受到家一般的温暖。那些一起度过的欢乐时光，成为了我求学生涯中最珍贵的回忆。也要感谢我的朋友们，尽管大家身处不同的城市，各自忙碌，但你们始终牵挂着我的学业和生活。在我需要倾诉时，你们总是第一时间倾听，给予我安慰和建议。