

分类号：TP242.2

密 级：公开

单位代码：10363

学 号：2220320189

基于声发射信号时频域特征的工业机器人故障辨识研究

Research on fault identification of industrial robots based on
time-frequency domain characteristics of acoustic emission
signals

学生姓名：董仕尚

校内导师：李明（教授）

校外导师：袁学超

专业学位类别：工程硕士

研究方向（领域）：声发射无损检测

论文答辩日期：2025 年 5 月 10 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：董仕岗

日期：2025年5月12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：黄仕岗

日期：2025 年 5 月 12 日

指导教师签名：[Signature]

日期：2025 年 5 月 12 日

基于声发射信号时频域特征的工业机器人故障辨识研究

摘要

工业机器人在现代工业生产中发挥着十分重要的作用，随着工业生产自动化、智能化及规模化的迅猛发展，工业机器人的应用也急剧增加。然而，高强度作业容易导致工业机器人产生疲劳损伤和故障，甚至引发严重安全事故。因此，借助无损检测手段，对工业机器人的健康状况进行动态检测，是保障工业机器人安全生产的关键支撑。声发射检测（Acoustic emission testing, AET）作为一种被动无损检测方法，能够在不受到结构几何形状约束的情况下，对复杂机械结构进行动态检测，为工业机器人的损伤检测提供了可行性。为此，本文以工业机器人为研究对象，通过分析声发射（Acoustic emission, AE）信号在工业机器人中传播时的时频特征，提出工业机器人损伤故障的辨识方法，为工业机器人安全健康检测提供一种有效的解决方案。本文的主要研究工作和创新点如下：

（1）针对 AE 信号 Lamb 波在工业机器人金属材料的传播特性，提出一种基于金豺优化（Golden jackal optimization, GJO）变分模态分解（Variational mode decomposition, VMD）参数和连续小波变换（Continuous wavelet transform, CWT）的 AE 信号降噪与特征提取方法。以徐乃星源（Hsu-Nielsen source, HNS）作为 AE 源，以 AE 信号的最小排列熵最小为优化适度函数，GJO 自适应地确定 VMD 的最佳模式数（K）和惩罚因子（ α ），采用最大相关系数法对 AE 波形进行重构，有效避免了传统 VMD 分析过程中出现的过分解、欠分解、频带丢失及冗余等问题。在此基础上，研究基于 Lamb 波频散特性的工业机器人金属材料 AE 信号传播特性，利用 CWT 在小波时频域中识别出 AE 信号 Lamb 波的 A0 和 S0 模态。并提出一种 AE 源定位算法。该算法利用 S0 模态的群速度，并结合了到达时间差（Time difference of arrival, TDOA）和两个传感器之间的几何关系。结果显示，GJO-VMD 克服了传统 VMD 的缺陷，与 CWT 结合后，而且能够有效提升工业机器人金属结构的 AE 源定位精度。

(2) 针对 AE 信号在工业机器人机械本体内外表面的损伤识别, 提出了一种基于小波去噪 (Wavelet denoising, WD) 和经验模态分解 (Empirical mode decomposition, EMD) 的工业机器人机械本体 AE 信号特征提取方法, 以探究 AE 信号在机械本体上的传播规律, 为工业机器人的检测提供早期准备。为了避免使用自选小波尺度进行小波分解的局限性, 以及单个指标不能很好地评价本征模函数 (Intrinsic mode function, IMF) 与原始信号的相关性问题, 根据传感器的响应频率范围对原始信号进行 4 层小波分解。选取传感器响应频率稳定范围内的小波细节进行初步重构, 然后利用 EMD 方法将去噪后的信号分解为 7 个 IMF, 利用相关系数和方差贡献率的综合信息重构 AE 信号波形。将 EMD 分析与单指标相结合的重构方法与本文提出的方法进行了比较, 验证了所提方法的可靠性。此外, 提取了 AE 信号在本体内表面和外表面上传播频率特征。最后, 基于 TDOA 原理, 计算 AE 信号在本体内表面和外表面的传播速度。并根据定位算法实现 AE 源定位。结果表明, 所提出的信号重构方法能够有效提取 AE 信号的特征, 基于特征频率和 TDOA 的定位算法的平均定位精度达到 0.86%。

(3) 针对工业机器人机械轴的故障诊断, 提出一种基于 AE 信号 GJO-VMD 能量谱 (Variational mode decomposition energy spectrum, VMDES) 与粒子群算法 (Particle swarm optimization, PSO) 优化支持向量机 (Support vector machine, SVM) 的工业机器人智能故障诊断模型。该模型借助改进的 VMD 算法把原始 AE 信号分解成多个本征模函数, 计算每层本征模态函数对应的能量特征, 当工业机器人出现故障时, 能量会发生变化, 并将能量特征用于设计、训练和测试所提出的模型。实验结果显示, 运用 GJO-VMDES-PSO-SVM 模型开展故障诊断工作, 故障识别率超过了 98.33%。

本研究涵盖了信号处理、传播特性分析以及智能诊断等方面。通过对工业机器人金属结构、机械本体和机械轴三大关键部位的深入研究, 为工业机器人的全生命周期健康管理提供了较好的创新和工程应用。对提升智能制造系统的安全性 with 可靠性具有重要意义。

关键词: 声发射, 工业机器人, 故障辨识, 时频特征, Lamb 波, 变分模态分解

RESEARCH ON FAULT IDENTIFICATION OF INDUSTRIAL ROBOTS BASED ON TIME-FREQUENCY DOMAIN CHARACTERISTICS OF ACOUSTIC EMISSION SIGNALS

ABSTRACT

Industrial robots play a pivotal role in modern industrial production. With the rapid advancement of automation, intelligence, and scaling in industrial manufacturing, the applications of industrial robots have surged exponentially. However, high-intensity operations often lead to fatigue damage and malfunctions in these robots, potentially triggering severe safety incidents. Therefore, dynamic health monitoring of industrial robots through non-destructive testing methods is a critical pillar for ensuring safe production. As a passive non-destructive testing technique, acoustic emission testing (AET) enables dynamic, non-invasive testing of complex mechanical structures without geometric constraints, offering feasibility for damage detection in industrial robots. This paper focuses on industrial robots as the research subject and proposes a method for identifying damage and malfunctions by analyzing the time-frequency characteristics of acoustic emission (AE) signals propagating through robot structures. This approach provides an effective solution for safe and healthy operation monitoring of industrial robots. The main research contributions and innovations are as follows:

(1) A method for AE signal denoising and feature extraction is proposed, integrating golden jackal optimization (GJO)-optimized variational mode decomposition (VMD) parameters and continuous wavelet transform (CWT). This approach targets the propagation characteristics of Lamb waves in metallic materials of industrial robots.

Using the Hsu-Nielsen source (HNS) as the AE excitation source, the minimum permutation entropy of AE signals serves as the optimization fitness function. GJO adaptively determines the optimal mode number (K) and penalty factor (α) for VMD. The maximum correlation coefficient method reconstructs AE waveforms, effectively mitigating issues such as over-decomposition, under-decomposition, frequency band loss, and redundancy inherent in traditional VMD analysis. Building upon this framework, propagation characteristics of AE signals in industrial robot metallic materials are analyzed based on Lamb wave dispersion properties. CWT identifies the A_0 and S_0 modes of Lamb waves in the wavelet time-frequency domain. An AE source localization algorithm is developed, leveraging the group velocity of the S_0 mode and integrating time difference of arrival (TDOA) with geometric relationships between two sensors. The results show that GJO-VMD overcomes the defects of traditional VMD, and can effectively improve the AE source location accuracy of industrial robot metal structures when combined with CWT.

(2) A feature extraction method for AE signals in industrial robot mechanical structures is proposed, integrating wavelet denoising (WD) and empirical mode decomposition (EMD). This approach investigates propagation patterns of AE signals on mechanical surfaces to facilitate early-stage non-destructive testing for industrial robots. To address limitations of manual wavelet scale selection and single-metric evaluation of intrinsic mode function (IMF) correlation with original signals, a four-layer wavelet decomposition is performed based on sensor response frequency ranges. First, wavelet details within stable sensor frequency bands are preliminarily reconstructed. EMD then decomposes the denoised signals into seven IMF. A composite metric combining correlation coefficients and variance contribution rates reconstructs AE waveforms, overcoming limitations of traditional single-metric methods. Comparative analysis between EMD-single-metric reconstruction and the proposed approach validates the method's reliability. Frequency characteristics of AE

signals propagating on interior and exterior surfaces of mechanical structures are extracted. Using TDOA principles, propagation velocities on interior and exterior surfaces are calculated. An AE source localization algorithm achieves accurate positioning by integrating surface velocity data. Results demonstrate that the proposed signal reconstruction method effectively extracts AE signal features, with the TDOA-based localization algorithm achieving an average accuracy of 0.86%.

(3) An intelligent fault diagnosis model for industrial robot mechanical shafts is proposed, integrating golden jackal optimization-variational mode decomposition energy spectrum (GJO-VMDES) of AE signals and particle swarm optimization (PSO) optimized support vector machine (SVM). The model decomposes raw AE signals into multiple IMF using an improved VMD algorithm. Energy features corresponding to each IMF layer are calculated, as energy distributions shift when faults occur in industrial robots. These energy features are utilized for designing, training, and testing the diagnostic model. Experimental results demonstrate that the GJO-VMDES-PSO-SVM model achieves a fault recognition rate exceeding 98.33%.

This research encompasses signal processing, propagation characteristic analysis, and intelligent diagnosis. Through in-depth investigations of three critical components in industrial robots - metallic structures, mechanical bodies, and mechanical shafts, it provides innovative solutions and engineering applications for full-life-cycle health management of industrial robots. This contributes significantly to enhancing the safety and reliability of smart manufacturing

Dong Shishang (Electronic information)

Supervised by Li Ming

KEY WORDS: Acoustic emission, industrial robots, fault identification, time-frequency characteristics, Lamb waves, variational mode decomposition

目录

第 1 章 绪论	1
1.1 论文研究背景及意义	1
1.2 工业机器人结构故障诊断研究现状	2
1.3 AE 检测的发展现状	3
1.4 AE 信号时频域特征分析的研究现状	4
1.5 论文主要内容和技術路线	6
第 2 章 基于 GJO-VMD-CWT 的 AE 特征提取及源定位方法	8
2.1 AE 特征提取方法及原理	8
2.1.1 变分模态分解基本原理	8
2.1.2 金豺优化算法基本原理	9
2.1.3 金豺优化变分模态分解算法	10
2.1.4 金豺优化变分模态分解的流程	10
2.1.5 相关系数基本理论	11
2.1.6 连续小波变换基本原理	12
2.1.7 Lamb 波基本理论	12
2.2 实验与分析	13
2.2.1 实验设置与 AE 信号采集	13
2.2.2 GJO 算法的参数设置	14
2.2.3 AE 信号特征提取与分析	15
2.2.4 对比研究	16
2.2.5 AE 信号 Lamb 波模态识别	17
2.3 AE 源定位研究	18
2.3.1 定位算法	18
2.3.2 实验验证	19
2.4 本章小结	20
第 3 章 AE 信号在工业机器人机械本体上的传播特性	22
3.1 基于 WD-EMD 的 AE 信号特征提取方法	22
3.1.1 小波降噪基本原理	22

3.1.2 经验模态分解基本原理	22
3.1.3 方差贡献率基本理论	23
3.2 实验与分析	23
3.2.1 实验设置与信号采集	23
3.2.2 AE 信号小波降噪结果分析	24
3.2.3 小波降噪后 AE 信号 EMD 结果分析	26
3.2.4 对比研究	28
3.3 AE 信号分类与源定位方法	29
3.3.1 AE 信号在机器人本体的内外表面上的传播速率	29
3.3.2 本体内外表面 AE 信号损伤类型的识别	30
3.3.3 AE 源定位研究	31
3.4 本章小结	32
第 4 章 基于 AE-VMD 能量谱的工业机器人故障辨识	33
4.1 工业机器人故障辨识方法	33
4.1.1 GJO-VMD 能量谱	33
4.1.2 粒子群算法基本原理	33
4.1.3 支持向量机基本原理	34
4.1.4 粒子群算法优化支持向量机	34
4.1.5 GJO-VMDES-PSO-SVM 诊断模型	34
4.2 实验与分析	35
4.2.1 实验设置与信号采集	35
4.2.2 故障辨识结果分析	37
4.2.3 对比研究	38
4.3 本章小结	40
第 5 章 总结与展望	41
5.1 研究总结	41
5.2 未来展望	42
参考文献	44
附录	50
攻读学位期间发表的学术论文及成果目录	51
致谢	53

插图目录

图 1-1	焊接生产线上的工业机器人.....	1
图 1-2	汽车生产线上的工业机器人.....	1
图 1-3	AE 检测原理.....	2
图 1-4	PAC 公司声发射仪.....	4
图 1-5	VS 公司声发射仪.....	4
图 1-6	软岛公司声发射仪.....	4
图 1-7	论文主要技术路线.....	7
图 2-1	GJO-VMD 算法优化过程框图.....	11
图 2-2	钢板中不同模态声波的相速度和群速度与频厚积的关系曲线.....	13
图 2-3	实验装置、传感器布置图.....	13
图 2-4	原始 AE 信号时域和频域图.....	13
图 2-5	GJO 算法优化 VMD 参数的收敛曲线.....	15
图 2-6	IMF 分量信号时域波形三维图和频谱图.....	15
图 2-7	各 IMF 与原始信号相关系数柱形图.....	16
图 2-8	重构后 AE 信号波形图和频谱图.....	16
图 2-9	分解后各分量与原始信号的相关系数.....	17
图 2-10	IMF 分量重构后的频率分析.....	17
图 2-11	重构后 AE 信号小波时频图.....	18
图 2-12	声源定位几何示意图.....	18
图 3-1	工业机器人 AE 信号采集点与传感器分布.....	24
图 3-2	AE 信号在本体的内外表面上传播的原始波形和频谱.....	24
图 3-3	RS-2A 传感器的灵敏度曲线.....	25
图 3-4	小波细节信号的频率范围.....	25
图 3-5	本体内外表面上 AE 信号的重构波形和频谱.....	26
图 3-6	S'_{e-1} 和 S'_{i-1} 信号的 EMD 分析结果.....	26
图 3-7	相关系数和方差贡献率的柱状图和线状图.....	27
图 3-8	EMD 分析重构后的 AE 信号波形和频谱.....	28
图 3-9	原始信号 EMD 分析后的相关系数和方差贡献率的点线图和柱状图.....	28
图 3-10	外表面重构的 AE 信号的频谱图.....	29

图 3-11	内表面重构的 AE 信号的频谱图	29
图 3-12	AE 信号在机器人身体的内外表面上的传播速度折线图	29
图 4-1	PSO-SVM 优化过程框图	34
图 4-2	GJO-VMDES-PSO-SVM 模型	35
图 4-3	实验装置与测试现场	36
图 4-4	工业机器人机械轴正常信号 AE 波形	36
图 4-5	工业机器人机械轴故障信号 AE 波形	36
图 4-6	工业机器人损伤信号 VMD 能量谱	37
图 4-7	训练集 PSO-SVM 模型仿真结果和混淆矩阵	38
图 4-8	测试集 PSO-SVM 模型仿真结果和混淆矩阵	38
图 4-9	训练集 SVM 模型仿真结果和混淆矩阵	39
图 4-10	测试集 SVM 模型仿真结果和混淆矩阵	39

插表目录

表 2-1	各变量之间的相关性强度	11
表 2-2	GJO 算法参数	14
表 2-3	实际的 θ 和 γ 角度大小	19
表 2-4	S0 模态与纵波波速定位对比分析的参数	20
表 3-1	工业机器人主要参数	23
表 3-2	不同位置的 AE 信号的特征频率和最大能量	30
表 3-3	在四个测试位置上的两个传感器的频率	31
表 3-4	计算角度和实际角度 (α 和 β) 以及参数大小	32
表 4-1	参数与适应度的平均值、样本集、标签	37
表 4-2	各故障诊断模型训练集和测试集故障诊断率	40

第1章 绪论

1.1 论文研究背景及意义

工业机器人在智能制造、汽车生产、医疗等领域有着广泛应用，对国内外经济的高速发展起到了至关重要的作用。由于工业机器人长期处于复杂恶劣的工作环境以及连续高强度和多种复杂工况下运转，致使其重要构件出现损伤，最终引发重大的经济损失和人员伤亡。所以，对工业机器人进行故障辨识十分重要。在工业机器人的使用量不断增加的同时，由机器人机械故障引发的事故和经济损失的发生几率也随之上升。例如：2015年美国、德国汽车制造工厂工业机器人致死工人事件、2018年美国亚马逊仓库机器人误将喷雾罐刺穿致使多人送医等。因此，工业机器人故障诊断与健康预测技术目前已经成为研究热点^[1]。



图 1-1 焊接生产线上的工业机器人



图 1-2 汽车生产线上的工业机器人

无损检测（Non-destructive testing, NDT）是一个跨学科的研究主题，涉及用于材料非侵入性的分析和测量技术，广泛应用于机械结构的损伤识别^[2]。目前，常用的无损检测方法包括超声检测^[3]、热像技术^[4]、磁粉检测^[5]等。但是，超声检测在复杂受限结构检测时存在一定的局限性，无法通过有限的扫查面实现检测区域的全覆盖或者缺陷检出率无法满足要求。热像技术在结构复杂的机械检测中可能面临集成化和多源信息融合发展的挑战，需要逐步向小型集成化方向发展，以满

足实际无损检测应用中原位测量及低能耗的需求。磁粉检测只能用来检测材料表面和近表面缺陷，不能检测埋藏较深的缺陷，且通常采用目视法检查缺陷，磁痕的判断和解释需要有技术经验，难以检测几何结构复杂的工件。声发射检测（Acoustic emission testing, AET）是一种适合在无法直接测量的恶劣环境下进行实时连续检测的方法，相比于传统的离线、表面检测方法，AET 具有在线实时检测，灵敏度高，覆盖范围广等优点^[6]。AE 检测原理如图 1-3 所示。



图 1-3 AE 检测原理

根据材料力学和弹性力学理论，一旦工业机器人发生不可预测的损伤，将会以机械波的形式释放应变能。这种机械波也被称为声发射（Acoustic emission, AE）信号，它的波速与材料的弹性常数之间有对应关系。因此，AET 为工业机器人的健康监测提供了一种可行的途径。鉴于此，本论文选取工业机器人作为研究目标，通过收集其模拟故障状态下的 AE 信号，着重针对信号的分析 and 处理展开深度探究，进而提出一种基于 AE 信号时频域特性的工业机器人故障辨识方法。本论文的分析结论与研究成果，会助力 AET 在工业机器人损伤识别领域的进一步发展，对于达成工业机器人的健康监测目标。

1.2 工业机器人结构故障诊断研究现状

故障诊断技术最早由 MEHRA 等人^[7]提出，而针对工业机器人的故障诊断技术则首次出现在 LEE M 等人^[8]的研究中。安海博等^[9]对工业机器人的 RV 减速器的 AE 信号传播机理进行定量的分析，实现对减速器磨损等故障的准确监测与评估。赖泽浪^[10]针对工业机器人关节 RV 减速器展开啮合传动以及振动信号源的剖析工作。接着，依据小波理论与相位时域平均法来提取残余振动信号，进而实施关节故障诊断操作，同时运用残余振动信号的均方根和功率谱熵这两项健康指标，对故障严重程度予以量化呈现。最终，经由仿真分析与现场试验的验证，证实了将小波理论与相位时域平均法相互融合的算法，能够有效地提升故障诊断的精准度。刘伟等^[11]为了便于监测工业机器人轴电流，设计了一种基于霍尔传感器的系统实现方案。选用闭环霍尔电流传感器，利用可编程逻辑控制器，实现工业机器人轴

电流非接触式测量与采集。LONG J 等^[12]以关节型工业机器人在不同故障模式下的姿态数据为基础, 构建起了一种依托混合算法模型的健康评估方法。该方法借助稀疏自编码器的编码与解码流程, 对姿态数据进行重构, 随后把最后一层隐藏层自动学习到的深层特征当作分类器的输入内容, 运用这种方式, 在对多关节工业机器人多种故障进行识别时, 能够达到较高的准确率。ELANGOVAN K 等^[13]提出了一种基于支持向量机的机器人故障诊断系统。该系统通过对机载惯性测量单元传感器数据进行分析, 以此来区分故障情况与非故障情况。并且, 其采用了两种不同类型的支持向量机, 而每种支持向量机又各自运用了两种不同的内核, 进而对这四种分类器的故障分类性能展开比较。

1.3 AE 检测的发展现状

20 世纪 50 年代, 德国科学家凯泽 (J.KAISER) 是 AE 研究领域的先驱之一。他在研究金属材料的声发射现象时发现了“凯泽效应”, 即材料在重复加载过程中, 只有当应力超过之前所施加的最大应力时, 才会产生明显的 AE 信号^[14]。这一发现为利用 AE 技术来监测材料的受力历史和损伤程度提供了重要的理论基础, 随后, 美国在 1963 年和 1964 年相继成功的将 AE 技术应用于火箭筒水压试验检测和北极星导弹检测^[15]。

20 世纪 60-70 年代, 美国的 DUNEGAN 和 HARRIS 等学者在 AE 检测技术的应用开发方面起到了关键作用。他们致力于将 AET 应用于实际的工业检测中, 如压力容器和管道的检测^[16]。他们的研究推动了 AE 传感器技术的改进, 提高了传感器的性能和可靠性。在这个阶段, 出现了专门用于 AET 的传感器, 如压电陶瓷传感器。与早期的传感器相比, 其频率响应范围更宽, 能够更好地捕捉不同频率的 AE 信号^[17]。20 世纪 80-90 年代, 研究人员在 AE 信号处理算法方面做出了许多贡献。一些学者将小波分析等先进的信号处理方法引入 AET 领域。这些学者利用计算机技术对 AE 信号进行复杂的时-频域分析, 以提取更准确的信号特征^[18]。

20 世纪 70 年代初我国也开始了对 AET 的研究, 其中一些科研院所和大学如中国科学院地球物理研究所、山东大学等, 相继应用 AET 研究了岩石力学, 建立了与地震预报紧密联系^[19]和复合材料的损伤断裂特性, 以实现裂纹开裂点的实时测量和预报^[20]。与此同时, 部分公司研制出了一些便携式的 AE 检测仪器, 此类仪器可用于工业现场对大型设备展开检测工作。美国 PAC 公司早在 20 世纪 80 年代中期设计了第二代 AE 源定位检测仪器, 该仪器有着体积较小、便于携带的特点,

并且配备了一系列高级检测和数据分析软件,具备对被测构件 AE 源进行实时分析以及定位的能力,这也为 AET 应用于实际现场检测提供了关键设备^[21]。

自 20 世纪 90 年代至今,外国的美国 PAC 公司、德国 Vallen Systeme 公司等,我国的广州声华公司、北京软岛公司等,他们前仆后继地完成了多通道 AE 采集与分析系统的设计开发。这些系统相比较与以前的版本,具有体积小,运算速度快等优点,不仅能够完成 AE 参数测量和 AE 源的实时定位任务,还可以实现 AE 波形的显示、存储以及时频分析。促使 AE 技术发展成为一种成熟的无损检测方法,进而在各个工业领域中得到了广泛应用^[22]。



图 1-4 PAC 公司声发射仪



图 1-5 VS 公司声发射仪



图 1-6 软岛公司声发射仪

1.4 AE 信号时频域特征分析的研究现状

时频分析方法通过提取时域与频域的联合分布信息,能够精准地归纳信号频率随时间的变化趋势。目前,常用的时频分析方法主要有小波分解 (Wavelet decomposition, WD)、经验模态分解 (Empirical mode decomposition, EMD)、变分模态分解 (Variational mode decomposition, VMD) 等在工业机器人损伤特征提取领域得到了广泛运用。

WD 通过伸缩和平移的方式对信号的高频时段和低频频次进行细分,实现了信号在时频域特性上的自适应提取。龚斌等^[23]利用 DB5 小波对碳钢 AE 信号进行 6 层小波变换,区分了碳钢裂纹扩展和塑性变形过程中的故障特征。马永辉等^[24]针对深孔钻孔 AE 信号中的噪声问题,证明了时域和频域分析在特征分析中的局限性,然后利用 DB6 小波对汽车 CNG 气瓶裂纹 AE 信号进行 7 层小波分解,得出不同类型 AE 信号在同一频率范围内占据不同能量比例系数的结论。针对深孔钻孔 AE 信号中的噪声问题。李占国等^[25]采用 Sym6 小波基函数对深孔钻孔 AE 信号进行 4 层小波分解进行降噪,有效去除 AE 信号中的噪声,同时保持了信号的完整性,避免了信号失真,显著提高了去噪效果。ZHOU T 等^[26]提出了一种自适应 WD 方法,利用置换熵评价信号噪声水平,提出了一种新的特征提取方法。WD 对故障特征具有较好的信号去噪性能。罗蕊寒等^[27]对盲源分离后木材三点弯曲破坏的 AE 信号采用 5 层小波分解,并与已知信号的频域特征进行对比,有效提取信号特征。

EMD 是对传统基于傅立叶变换的线性和稳态频谱分析方法的重大改进，是一种非常适用于非线性、非平稳信号的自适应时频分析方法^[28]。EMD 在无需预先设定基函数的情况下，可根据自身的时间尺度特征将复杂的非线性、非平稳信号分解为有限个本征模态函数（Intrinsic mode function, IMF），这些 IMF 包含了原始信号在不同时间尺度下的局部特征，再结合希尔伯特变换针对各个 IMF 分量进行相应处理，进而获取带有物理意义的时频图^[29]。EMD 分析法在机械故障诊断应用十分广泛。TANG Y 等^[30]提出了一种新的相关 EMD 方法，该方法利用互相关来确定 IMF 之间的依赖关系，从而从复杂信号中提取相关 IMF。该方法在分析多个 AE 传感器采集的模拟测试信号和实际测量的局部放电信号方面具有良好的可行性，并成功地实现了相关 IMF 的筛选和去噪。陶栩等^[31]利用 EMD 提取含有故障特征信息的轴承的不同阶数的 IMF，通过选取较大的峰值来选取各阶的 IMF 分量，并对重构信号的包络谱进行分析。最后，通过频域变换得到准确的故障特征信息，具有较好的工程应用价值。为了解决管道泄漏 AE 信号中的噪声干扰问题。吴旭景等^[32]采用 EMD 对信号进行分解，并对高频成分进行小波分解去噪，保留有用的信号特征，最后对去噪后的信号进行重构，更准确地定位泄漏源，提高信号处理效果。LI R 等^[33]提出了一种基于 EMD 和 AE 特征量化的旋转机械健康监测与故障检测方法，验证了该方法在分离转矩齿轮箱故障检测中的有效性。方赛银等^[34]将 WD 和 EMD 技术应用于木材 AE 信号的特征分析，利用相关原理确定了 IMF 主成分，有效识别了木材 AE 信号的特征频率范围。此外，将瞬时频率测定与 AE 事件统计相结合，提高特征分析效果，具有更清晰的物理意义。

VMD 是由 DRAGOMIRETSKIY 等^[35]提出的一种自适应且完全非递归的模式变分与信号处理方法。在处理非平稳序列时，VMD 展现出了更出色的分解能力与自适应能力。VMD 方法已经在诸多领域得到了大范围的应用，比如机械系统损伤识别领域、轴承故障检测、机电设备寿命预测领域等。LIU Z 等^[36]开发了一种基于 VMD 和快速谱峭度的滚动轴承故障特征提取方法，解决了从容易受环境噪声影响的信号中提取故障特征的难题。任学平等^[37]利用 VMD 对轴承早期故障信号进行预处理，并根据峰度准则选取峰度值较大的分量进行重构，成功提取了轴承早期故障信号。研究表明，VMD 算法中的模式数 K 和惩罚因子 α 对分解结果有显著影响^[38]。若 K 过大，可能引发过度分解；而 K 值过小则会造成分解不充分。同样，过大的 α 可能致使频带信息丢失，而过小的 α 可能导致信息冗余。因此，确定 $\{K, \alpha\}$ 的最优参数组合是实现有效分解的关键^[39]。为了提高 VMD 分析的准确性，研究

人员开发了自适应算法来优化关键参数之间的相互作用。唐贵基等^[40]利用最小包络熵作为优化函数来确定 VMD 的最优参数组合。他们采用粒子群优化 (Particle swarm optimization, PSO) 算法设置惩罚参数和组件数量, 然后使用优化后的参数对故障信号进行处理。LIU J 等^[41]采用遗传变异粒子群算法进行参数优化, 利用 VMD 对故障信号进行处理, 相比较传统的 VMD 而言精确的提取了故障特征。李颖等^[42]提出了一种利用天鹰优化 (Aquila optimizer, AO) 的优化方法, 该方法以各分量的最小样本熵作为适应度函数来优化 VMD, 提取往向压缩机的故障特征。

1.5 论文主要内容和技術路线

本文基于声发射信号时频域特征的工业机器人故障辨识研究:

第 1 章就关于论文的研究背景和意义展开讨论, 继而引出 AET 和时频域分析在工业机器人损伤辨识中的应用。

第 2 章为提升 AE 信号处理效果, 基于 GJO 算法优化 VMD 参数和 CWT 的 AE 信号降噪与特征提取方法。以 HNS 为 AE 源, 将最小排列熵作为优化适度函数, 让 GJO 算法自适应确定 VMD 最佳模式数与惩罚因子, 借助最大相关系数法重构波形, 规避传统 VMD 分析弊端。利用 CWT 识别 Lamb 波 A0 和 S0 模态, 结合 S0 模态群速度、TDOA 及传感器几何关系构建 AE 源定位算法。经仿真实验证实, GJO-VMD 与 CWT 可克服传统 VMD 和短时傅立叶变换 (Short-time Fourier transform, STFT) 缺点, 有效提高定位精度。

第 3 章针对工业机器人机械本体 AE 信号, 提出基于 WD 和 EMD 的特征提取方法。先依据传感器响应频率范围对原始信号进行 4 层小波分解, 选取稳定范围小波细节初步重构。随后运用 EMD 将去噪后信号分解成 7 个 IMF 分量, 通过相关系数和方差贡献率综合信息实现波形重构。提取 AE 信号在本体内外表面传播频率特征, 基于 TDOA 原理计算传播速度, 最终依靠定位算法完成 AE 源定位。

第 4 章构建基于 AE 信号 GJO-VMDES 与 PSO-SVM 的工业机器人智能故障诊断模型。运用改进 VMD 算法将原始 AE 信号分解为多个 IMF 分量, 计算各层 IMF 能量特征。由于工业机器人发生故障时能量会发生变化, 将这些能量特征用于模型设计、训练与测试, 从而达成工业机器人智能故障诊断的目的。

最后, 对全文进行总结并对未来的研究进行展望。本文的主要技术路线图如图 1-7 所示。




图 1-7 论文主要技术路线

第2章 基于 GJO-VMD-CWT 的 AE 特征提取及源定位方法

本章针对工业机器人金属材料上的声发射 (Acoustic emission, AE) 信号 Lamb 波, 展开传播特性、模态识别与 AE 源定位的研究。提出了基于 GJO 算法优化 VMD 参数结合最大相关系数的 AE 信号 Lamb 波模态提取和基于 CWT 的 Lamb 波模态识别方法。经过与 EMD、CEEMDAN 等方法对比, 验证所提方法的优越性。并根据 AE 信号 Lamb 波 S0 模态的群速度、TDOA 及 AE 源与传感器的几何关系, 提出一种特殊的源定位算法。

2.1 AE 特征提取方法及原理

2.1.1 变分模态分解基本原理

变分模态分解 (Variational mode decomposition, VMD) 是一个自适应、准正交的信号分解方法, 能够将多分量调幅调频信号一次性分解成多个单分量调幅调频信号^[43]。

假设原信号 $x(t)$ 是多分量信号, 被分解为 k 个本征模函数 (Intrinsic mode function, IMF), 且各 IMF 的中心频率为 ω_k , 则构造的约束变分模型为:

$$\begin{aligned} \min_{\{u_k\}, \{\omega_k\}} & \left\{ \sum_k \left\| \partial_t \left[\left(\sigma(t) + \frac{j}{\pi} \right) * u_k(t) \right] \exp(-j\omega_k t) \right\|_2^2 \right\}; \\ \text{subject to} & \sum_k u_k(t) = x(t) \end{aligned} \quad (2-1)$$

式中, $\delta(t)$ 是脉冲函数, “*” 表示卷积。 ∂_t 表示对 t 求偏导。 $u_k(t)$ 是 AE 信号经过 VMD 分解后得到的 k 个 IMF。

式(2-1)可以通过引入一个二次惩罚函数项 α 和拉格朗日乘子项 λ 通过式(2-2)来将一个有约束最优化问题转换为一个无约束最优化问题:

$$\begin{aligned} L(\{u_k(t)\}, \{\omega_k(t)\}, \lambda) = & \alpha \sum_k \left\| \partial_t \left[\left(\sigma(t) + \frac{j}{\pi} \right) * u_k(t) \right] \exp(-j\omega_k t) \right\|_2^2 \\ & + \left\| x(t) - \sum_k u_k(t) \right\|_2^2 + \left\langle \lambda(t), x(t) - \sum_k u_k(t) \right\rangle. \end{aligned} \quad (2-2)$$

利用交替方向乘子算法持续更新各个 IMF 及中心频率, 从而求得式(2-2)增广拉格朗日函数的鞍点, 即为所求问题的最优解, 从而通过式(2-3)实现对原始信号的分解:

$$\hat{u}_k^{n+1}(\omega) = \frac{\hat{x}(\omega) - \sum_{i \neq k} \hat{u}_i(\omega) + \frac{\hat{\lambda}(\omega)}{2}}{1 + 2\alpha(\omega - \omega_k)^2} \quad (2-3)$$

式中, $\hat{u}_k^{n+1}(\omega)$, $\hat{\lambda}(\omega)$ 和 $\hat{x}(\omega)$ 分别表示信号 $\hat{u}_k^{n+1}(t)$, $\hat{\lambda}(t)$ 和 $\hat{x}(t)$ 的傅里叶变换。

在 IMF 分量及其中心频率 ω_k 完成更新之后, 能够借助式(2-4)对拉格朗日乘子 $\hat{\lambda}$ 进行更新, 计算公式如下:

$$\hat{\lambda}^{n+1}(\omega) = \hat{\lambda}^n(\omega) + \tau \left(\hat{x}(\omega) - \sum_k \hat{u}_k^{n+1}(\omega) \right) \quad (2-4)$$

最后, 当满足式(2-5)所示的迭代收敛准则时, 信号的 VMD 分析过程完成, 即:

$$\sum_k \left\| \hat{u}_k^{n+1} - \hat{u}_k^n \right\|_2^2 / \left\| \hat{u}_k^n \right\|_2^2 < \varepsilon \quad (2-5)$$

式中, ε 的值通常设定为 10^{-6} 。

2.1.2 金豺优化算法基本原理

金豺优化 (Golden jackal optimization, GJO) 算法是 CHOPRA 等人^[44]在 2022 年提出的一种新型的元启发式群智能算法, 该算法是一种模仿金豺相互合作狩猎行为的新型智能优化算法。

与其他群智能算法相同, 搜索个体随机的放置在搜索空间内^[45], GJO 初始化数学描述如下:

$$Y_0 = Y_2 + R \times (Y_1 - Y_2) \quad (2-6)$$

式中: Y_0 表示初始金豺种群的位置; R 是 $[0,1]$ 范围内的均匀随机向量; Y_1 和 Y_2 分别是求解问题的上下边界。

运用优化适度函数对优化过程中每个猎物的适度值进行估计, 如此一来, 便能够得到优化的适度值矩阵:

$$F_{OA} = [f(a)] = [f(Y_{n,1}; Y_{n,2}; \dots; Y_{n,k})] \quad (2-7)$$

F_{OA} 表示猎物的适应度值矩阵; $f(a)$ 代表适应度函数或者目标函数。其中, 与适应度最优值相对应的解即为雄豺位置坐标, 而与次优值相对应的解则为雌豺位置坐标。

搜索猎物阶段: 如果雄豺发现到猎物并开始追逐, 而猎物意识到并逃脱后, 雄豺会带领雌豺继续等待或寻找其他猎物^[46]。对于金豺群体中的雄豺和雌豺而言, 它们感知到的猎物的相对位置可以用以下式子表示:

$$\begin{cases} Y_1(t) = Y_g(t) - E \cdot |Y_g(t) - rl \cdot \text{Prey}(t)| \\ Y_2(t) = Y_m(t) - E \cdot |Y_m(t) - rl \cdot \text{Prey}(t)| \end{cases} \quad (2-8)$$

式中: t 为当前迭代次数, Y_g , Y_m 分别表示第 t 次迭代的雄豺和雌豺的位置;

rl 表示一个基于莱维分布的随机数, E 为猎物的逃脱能量, $Prey$ 表示猎物矩阵; $Y_1(t)$, $Y_2(t)$ 为经过 t 次迭代后雄豺和雌豺更新后的位置。如公式(2-9)所示:

$$E = E_1 - E_0 = (2 * R - 1) - \left[1.5 * \left(1 - \frac{t}{T} \right) \right] \quad (2-9)$$

E_1 表示猎物能量的下降过程; E_0 表示猎物能量的初始状态。 R 为 $[0,1]$ 范围内的随机数, T 为最大迭代次数。

最后, 金豺种群中的每个个体的更新位置为:

$$Y(t+1) = \frac{Y_1(t) + Y_2(t)}{2} \quad (2-10)$$

包围并抓捕阶段: 当猎物被包围时, E_0 的能量会随之减少, 此时, 金豺就会攻击并吞食猎物, 其数学模型如下:

$$\begin{cases} Y_1(t) = Y_g(t) - E \cdot |rl \cdot Y_g(t) - Prey(t)| \\ Y_2(t) = Y_m(t) - E \cdot |rl \cdot Y_m(t) - Prey(t)| \end{cases} \quad (2-11)$$

2.1.3 金豺优化变分模态分解算法

在 GJO 算法优化 VMD 参数的过程中, 将最小化排列熵作为目标。对于 VMD 分析后的每个模态分量 IMF, 计算其排列熵 PE_k , 总的适应度函数可以定义为式 (2-12), 通过 GJO 算法找到一组和的值, 使得 F_{OA} 最小。

$$F_{OA} = \sum_{k=1}^K PE_k \quad (2-12)$$

GJO 算法模拟金豺群体的行为, 群体中的金豺个体代表不同的 K 和 α 组合, 通过适当的映射将金豺个体的位置向量映射到 K 和 α 的取值范围。雄豺负责探索新的参数空间区域, 寻找可能使适应度函数值更小的位置。雌豺根据雄豺的位置和群体信息来更新自己的位置, 以期找到更优的 K 和 α 组合。在每次迭代过程中, 对每个金豺个体所代表的 K 和 α 组合进行 VMD 分析, 计算分解后模态分量的排列熵之和。随着迭代的进行, 金豺个体不断更新自己的位置 (即更新 K 和 α 的值), 适应度函数值不断优化。当算法达到最大迭代次数或者满足一定的收敛条件时, 就认为找到了最优或近似最优的和组合, 使得 VMD 分解后的模态分量排列熵最小, 从而实现了 VMD 参数的优化。

2.1.4 金豺优化变分模态分解的流程

GJO-VMD 算法利用 GJO 算法搜索出分解层数 K 及惩罚因子 α , 确定最优的 $\{K, \alpha\}$ 。其核心是以最小排列熵作为适应度函数, 以此求得最优结果。具体优化过程

如图 2-1 的框图所示。排列熵值可以有效反映时间序列的复杂程度和规则程度。这说明 VMD 在使用搜索到的 $\{K, \alpha\}$ 时的分解效果较为优秀。当 GJO 算法满足此算法的终止条件时，会输出最终的最优解 $\{K, \alpha\}$ 组合设为 VMD 初始的参数，并对数据进行分解。




图 2-1 GJO-VMD 算法优化过程框图

2.1.5 相关系数基本理论

为了依据 IMF 重构 AE 波形，对每个 IMF 与原始信号进行相关系数计算，相关系数是反应两个变量 x 和 y 之间线性关系程度，相关系数的值范围在-1 到 1 之间，越接近 1 表示两者之间的线性相关性越强^[47]。相关系数的计算方法如下式(2-13)：

$$R = \frac{\sum_{t=0}^T x(t)y_i(t)}{\sqrt{\sum_{t=0}^T x^2(t) \sum_{t=0}^T y_i^2(t)}} \quad (2-13)$$

式中： t 为信号的采样时间， $x(t)$ 为原始信号， $y_i(t)$ 为各层 IMF 分量信号。

计算出相关系数后，可以根据表 2-1 所示的值来确定变量之间的相关强度。

表 2-1 各变量之间的相关性强度

$ R $	相关性
0.7-1.0	极强相关
0.5-0.7	强相关
0.3-0.5	中等相关
0.2-0.3	弱相关
0.0-0.2	极弱相关或无相关

2.1.6 连续小波变换基本原理

与一维时域或频域信号相比，图像是一个二维数据矩阵，包含了更丰富的特征信息，可以用来表示更复杂的数据分布，目前广泛使用 Wigner-Ville 分布、Hilbert 变换（Hilbert transform, HT）、STFT 和 CWT 来获取时频图像^[48]。然而，本文收集的是铅芯折断的 AE 信号属于非平稳信号。在实际应用中，Wigner-Ville 分布可能导致内在交叉干扰项的问题，HT 会产生严重的边界效应，对原始数据造成干扰^[49]。与这些时频分析方法相比，CWT 具有多尺度、多分辨率的优势，能够精确提取信号局部的时空分布特征。对信号 $x(t)$ 进行连续小波变换可以描述为式(2-14)：

$$CWT_x(b, a) = a^{\frac{1}{2}} \int x(t) \Psi\left(\frac{t-b}{a}\right) dt \quad (2-14)$$

其中： a 是缩放常数， b 是平移常数， $\Psi_{a,b}(t)$ 为母小波的共扼运算。

2.1.7 Lamb 波基本理论

板波的狭义解释通常为 Lamb 波，在金属的损伤识别与定位中有广泛的应用^{[50][51][52]}，按照质点的位移分布不同将 Lamb 波分为对称型（S 型）和反对称（A 型）。当板厚一定时，频率越高则相速度越低，在波形传播过程中各个频率成分被逐渐分开，这种现象被称为频散（Dispersion）^[53]。描述频散特性的方程是 RAYLEIGH-Lamb 方程(2-15)和(2-16)：

对称模式：

$$(p^2 - 1)^2 \tan \frac{\pi f d}{C_p} p + 4 p q \tan \frac{\pi f d}{C_p} q = 0 \quad (2-15)$$

反对称模式：

$$(p^2 - 1)^2 \tan \frac{\pi f d}{C_p} q + 4 p q \tan \frac{\pi f d}{C_p} p = 0 \quad (2-16)$$

其中： $p^2 = (C/C_s)^2 - 1$ ， $q^2 = (C/C_p)^2 - 1$ ， C 是 Lamb 波的相速度， C_s 是横波速度， C_p 是纵波速度， f 是频率， d 是板厚。

根据 DS5-16C 声发射仪中的声速标定软件，计算得到在厚度为 10mm 的钢板中纵波声速约为 5690m/s，横波声速约为 3200m/s，有关相速度和群速度曲线详见图 2-2a 和图 2-2b。从图 2-2 可以观察到，当频厚积（ $f \cdot d$ ）小于 2 时，仅有两种模态。因此，通过控制频厚积的大小，可以使 Lamb 波传播模式趋向于低阶，即 S0 和 A0 模态^[54]。在 AE 模态理论中，前者被称为扩展波，而后者被称为弯曲波。在

低频段，扩展波的频散现象不明显。




图 2-2 钢板中不同模态声波的相速度和群速度与频厚积的关系曲线

2.2 实验与分析

2.2.1 实验设置与 AE 信号采集

实验现场见图 2-3 所示，采用了北京软岛公司的 DS5-16C 声发射采集系统，配备了 RS-2A 型压电陶瓷传感器，其中心频率为 150kHz，频率响应范围为 0kHz ~ 400kHz。采样频率设置为 3MHz，前置放大器的增益调至 40dB。实验材料的尺寸为 480mm × 300mm × 10mm 的金属板。AE 源采用徐乃星源（Hsu-Nielsen source, HNS），即使用直径为 0.5mm 的 HB 铅笔，铅芯伸长 3.5mm，断铅时确保铅芯与钢板表面的夹角为 30°。在钢板的 A 位置断铅，该位置与传感器 1 的距离为 85mm。传感器 1 与传感器 2 之间的距离为 300mm。采集到的原始 AE 信号的时域图与频域图详见图 2-4（图 2-4 横坐标为时间和频率，纵坐标为幅值）。




图 2-3 实验装置、传感器布置图




图 2-4 原始 AE 信号时域和频域图

原始 AE 信号的频谱显示出多个显著的中心频率。在 0kHz ~ 50kHz 范围内，主要中心频率为 18kHz。50kHz ~ 100kHz 范围内的中心频率为 66kHz，而 100kHz ~

200kHz 范围内的中心频率则为 147kHz，200kHz ~ 300kHz 范围内的中心频率是 281kHz。超过 300kHz 的频率未出现中心峰。图 2-4 显示 AE 信号包含多种频率成分，难以区分主要、次要成分和无关成分，也无法辨别出 Lamb 波模态。因此，需要对原始 AE 信号进行分解，并提取主次要成分。

2.2.2 GJO 算法的参数设置

在进行信号分解前，需要设定适当的模态数量 K 和惩罚参数 α 。目前，常采用中心频率观察法^[55]来确定 K 值，该方法通过观察不同 K 值下的中心频率来确定最佳 K 值。然而，该方法存在偶然性，并且只能确定模态数量 K ，无法确定惩罚参数 α 。因此，对于 VMD 参数的优化至关重要。下表 2-2 为 GJO 算法的参数设置。

表 2-2 GJO 算法参数

参数	设定值
α 和 K 的下限	{100 3}
α 和 K 的上限	{2500 12}
Dim	2
T	20
N	30

表中 Dim 为优化变量数目，T 为最大迭代数目，N 为种群规模。本研究主要利用 GJO 优化 VMD 的两个关键参数，即分解模态数 K 和惩罚因子 α ，所以优化变量 Dim 数目设置为 2，以对应这两个待优化参数；迭代次数设置需兼顾算法收敛效果与计算效率。若迭代次数太少，算法可能无法充分搜索到最优解；若太多，计算时间会大幅增加。经多次试验，设置最大迭代数目 T 为 20，在此研究中可使 GJO 在合理时间内找到较优的 VMD 参数解；种群规模影响算法的搜索范围和收敛速度。规模较小，搜索空间有限，可能遗漏最优解；规模过大，计算复杂度会剧增，种群规模 N 设为 30，能在保证一定搜索广度的同时控制计算量，确保算法有效运行；分解模态数 K 值决定了 VMD 分析后得到的 IMF 分量的数目， K 取值过大会导致过分解，产生虚假模态，使分解结果过于复杂且难以解释； K 取值过小则会欠分解，不能充分提取信号中隐含的特征信息。在本研究中， K 的下限设为 3，上限设为 12，在此范围内寻找合适的 K 值，以实现声发射信号的有效分解。惩罚因子 α 取值影响模态分量的带宽，与带宽成反比， α 设置较小，会出现模态重叠现象，不同模态之间的界限模糊，影响信号特征提取； α 设置较大，虽能避免

模态混叠，但会造成局部信息丢失，导致信号细节特征被忽略。本研究中 α 的下限设为 100，上限设为 2500，通过 GJO 在该区间内寻找合适的 α 值，平衡频带信息保留与模态分离效果。

将上表中的参数代入上述算法中进行优化，经过 20 次迭代之后。得到收敛曲线如图 2-5 所示（图 2-5 横坐标为迭代次数，纵坐标为排列熵最优值）。




图 2-5 GJO 算法优化 VMD 参数的收敛曲线

2.2.3 AE 信号特征提取与分析

由图 2-5 中的迭代趋势可以观察到，在第 8 次迭代时出现的目标函数的最优值为 0.36。此时，GJO 搜索的分解模态数量 K 和惩罚参数 α 分别为 2322 和 6。然后将 A 位置采集的由 1300 个点组成的原始 AE 信号（如图 2-4 所示）进行分解， τ 设置为 4×10^{-6} 。因此，选取 VMD 分析的模态个数为 6。分解后得到的各个模态的波形图和频谱图如图 2-6a（图 2-6a 横坐标为时间，纵坐标为幅值）和图 2-6b 所示（图 2-6b 横坐标为频率，纵坐标为幅值）。




图 2-6 IMF 分量信号时域波形三维图和频谱图

使用式(2-13)计算 IMF 细节信号与原始信号的相关系数，得到柱形图如图 2-7（图 2-7 横坐标为 IMF 分量，纵坐标为相关系数值）。当相关系数大于 0.5 时，IMF 与原始信号呈强相关；反之，呈弱相关或无相关。因此，将阈值设为 0.5。从柱状图中可见，IMF3 和 IMF6 的相关系数分别为 0.57 和 0.68，与原始信号呈强相关。而 IMF1、IMF2、IMF4 和 IMF5 与原始信号的相关系数均小于 0.5，呈弱相关或无相关，可以认为是虚假的 IMF。因此，仅保留 IMF3 和 IMF6 分量进行重构，而其余分量则忽略不计。如图 2-8（图 2-8 横坐标为时间和频率，纵坐标为幅值和能量）。是将 IMF3 和 IMF6 进行重构处理，并进行快速傅里叶变换（Fast Fourier transformation, FFT）后得到功率谱。




图 2-7 各 IMF 与原始信号相关系数柱形图




图 2-8 重构后 AE 信号波形图和频谱图

从功率谱中可以观察到信号中含有两种明显的频率成分。在蓝框中，主频率中心为 18kHz，信号能量为 0.16；而在粉红框中，主频率中心为 147kHz，信号能量为 0.08，前者是后者的两倍。由此可判定，中心频率为 18kHz 的信号为主要成分，而中心频率为 147kHz 的信号为次要成分。综上所述，虽然可以从原始信号中分离出主次成分的中心频率，但无法从幅值谱和功率谱中找出 AE 信号的 Lamb 波模态。因此，需要对信号进行进一步的处理。

2.2.4 对比研究

由上述可知 GJO-VMD 结合相关系数的方法从原始信号中分离出了主次成分的中心频率。本小节将使用 EMD^[56]和完全自适应噪声集合经验模态分解（Complementary ensemble empirical mode decomposition with adaptive noise, CEEMDAN）^[57]分析法结合相关系数提取原始信号的主次要成分与本文提出的方法进行对比分析，以验证本文方法的可靠性。图 2-9 分别是 EMD 和 CEEMDAN 分析法分解原始信号后得到的 IMF 个数，及 IMF 与原始信号的相关系数。根据上述的阈值设为 0.5。

从柱状图 2-9（图 2-9 横坐标为 IMF 分量，纵坐标为相关系数值）。中可见，对于 EMD 的分析结果，IMF1 和 IMF5 的相关系数分别为 0.50 和 0.55，与原始信号呈强相关，其他的分量不计入后续的重构。对于 CEEMDAN 的分析结果，IMF3、IMF4 和 IMF7 的相关系数分别为 0.58、0.60 和 0.62，与原始信号呈强相关，其他的分量不计入后续的重构。重构后的频谱如图 2-10 所示（图 2-10 横坐标为频率，纵坐标为能量）。图 2-10 显示两者重构后的频谱中均包含多种频率成分，难以区分主要、次要成分和无关成分，也无法辨别出 Lamb 波模态。由此可见，EMD 和 CEEMDAN 对 AE 信号的特征提取不准确，导致主次要成分无法与无关成份分离，对后续使用 CWT 识别 Lamb 波的模式产生了巨大的影响。




图 2-9 分解后各分量与原始信号的相关系数




图 2-10 IMF 分量重构后的频率分析

综上所述，通过对比发现本文提出 GJO-VMD 分析法有效避免了信号分解过程中可能产生的模态混叠及过分解和欠分解状况。而且，对 AE 信号的主次要成份提取优于 EMD 和 CEEMDAN，后两者对 AE 信号的特征提取不可靠。

2.2.5 AE 信号 Lamb 波模态识别

根据前人经验^[54]，使用 STFT 后得到的时频联合分布图可以区分 S0 和 A0 模态，但存在一定局限性。因为 STFT 具有固定的时频分辨率，这意味着它可能无法准确描述不同频率和时间上的信号特征，且 STFT 中固定的基函数不一定与信号特征匹配良好，因此模式识别效果可能不佳。相比之下，CWT 可以调整不同频率和时间上的分辨率，更适应信号的特性。CWT 的多尺度分析能力可以同时捕获信号的局部和全局特征，并且能够将信号与不同尺度的小波基函数进行匹配，这种匹配性更适合信号的模式识别任务。鉴于这些优势，本研究提出了一种连续小波变换的 Lamb 波模态识别方法，采用 Daubechies 4 (db4) 小波作为小波基函数，得到的小波时频图如图 2-11 所示（图 2-11 横坐标为时间，纵坐标为频率）。根据图 2-11 可以观察到在 0.26 μ s 处对应的是图 2-8 粉红框中频率为 147kHz 的成分，其能

量虽小但传播速度快，因此可判断为 S_0 模式，其波形对应图 2-8 中的红圈所示，对应的频厚积为 $1.47\text{MHz}\cdot\text{mm}$ 。而在 $0.3\mu\text{s}$ 时，对应的是图 2-8 蓝框中频率为 18kHz 的成分，其能量虽大但传播速度慢，因此可判断为 A_0 模式，对应的频厚积为 $0.18\text{MHz}\cdot\text{mm}$ 。综上所述，根据 Lamb 波在钢板中的群速度频散曲线， S_0 模式的群速度理论值为 5390m/s 。




图 2-11 重构后 AE 信号小波时频图

2.3 AE 源定位研究

2.3.1 定位算法

依据上述可知，使用 S_0 模态的群速度作为 AE 信号的传播速度记为 v ，传感器 1 和传感器 2 之间的间距记为 l ，徐乃星源与传感器 1 的间距记为 l_1 ，与传感器 2 的间距记为 l_2 ，AE 信号到达传感器 1 的时间记为 t_1 ，到达传感器 2 的时间记为 t_2 ，到达两个传感器的时间差为 Δt ，产生 AE 信号的时刻记为 t_0 。在 l ， l_1 ， l_2 围成的三角形中， l 与 l_1 的夹角记为 θ ， l 与 l_2 的夹角记为 γ ，几何平面示意图如图 2-12 所示。




图 2-12 声源定位几何示意图

其中所有变量满足下列关系式：

$$\left. \begin{aligned} l_1 \cos \theta + l_2 \cos \gamma &= l \\ l_1 \sin \theta &= l_2 \sin \gamma \\ l_i &= v(t_i - t_0), i = 1, 2 \\ \Delta t &= |t_1 - t_2| \end{aligned} \right\} \quad (2-17)$$

由它们之间的变量关系可得：

$$L(\theta, \gamma) = \left(\frac{\sin(\theta + \gamma)}{\sin \theta - \sin \gamma} \right) (v \cdot \Delta t) \quad (2-18)$$

其中， L 为定位算法计算所得的两个传感器之间的距离，而实际距离为 l 。因此 θ 和 γ 可依据均方误差（Mean square error, MSE）原理通过优化方法确定，同时满足式(2-19)的条件约束：

$$\min_{\theta, \gamma} \left\{ E = (l - L)^2 \right\} \quad (2-19)$$

当 E 最小时，则所得到 θ 和 γ 是可作为计算 AE 源的角度。

2.3.2 实验验证

在图 2-12 中，按照徐乃星源的定义，分别在钢板表面的 B、C、D、E、F 点进行铅芯折断。然后计算 AE 信号到达两个传感器的时间差，并将其代入上述算法中，从而得到 θ 和 γ 的计算角度。实际角度则由量角器测量得到。下表 2-3 显示实际的 θ 和 γ 值。在本文的实验条件下，A0 模态或 S 波相对较慢的传播速度会导致信号在时间和频率特性上与 S0 模态或 P 波重叠或混合。在钢板结构中，不同的波模在传播过程中相互影响，特别是由于速度和传播特性的差异。这使得确定时间差 Δt 具有挑战性。因此，仅分别采用 S0 模态的群速度和纵波速度进行定位计算并进行比较。

表 2-3 实际的 θ 和 γ 角度大小

AE 源	实际角度/度	
	θ	γ
B	110	26.3
C	80.5	46.8
D	46	97.5
E	63	51
F	30	85.5

信号经过特征提取后，S0 模态到达传感器的时间与未经处理的信号纵波到达传感器的时间不同，因此它们的 Δt 也各不相同。S0 模态到达传感器的时间差可根

据小波时频图显示的时间计算，而纵波到达传感器的时间差可由 DS5-16C 配置的软件直接测得。计算得到的参数如表 2-4 所示。

根据表 2-4 的数据可见，基于 S0 模态群速度的发射源定位计算得到的角度与实际测量的角度存在一定的误差，但误差在 0 度到 4 度的很小范围内波动，误差在允许范围之内。根据计算的角度和测得的时间差带入式(2-18)中可得 L 的大小，再带入式(2-19)中计算出的均方误差如表 2-4 所示，其定位的相对误差平均在 0.48% 左右，表明计算结果与实际结果相当接近。然而，对于使用纵波波速代入该定位算法中，计算得到的 L 与实际结果相差很大，误差也十分大，虽然在 D 点和 F 点处计算的 L 与实际距离相差不大，误差也很小，但其计算出的 θ 和 γ 与实际的角度的有非常大的差距。因此，在该算法中使用纵波速度是不可靠的。

表 2-4 S0 模态与纵波波速定位对比分析的参数

AE 源	S0 模态 C_g (5390m/s)					纵波 (5690m/s)				
	θ	γ	$\Delta t/\mu s$	L/mm	$\delta/\%$	θ	γ	$\Delta t/\mu s$	L/mm	$\delta/\%$
B	112.1	27.2	40.1	300.2	0.04	106.5	22.8	37.9	292.1	62.4
C	79	45.6	18.0	298.9	1.21	70	40.8	17.1	317.8	316.8
D	44	96.8	26.2	299.2	0.64	56	110	24.1	299.8	0.04
E	61.7	49.8	6.98	300.2	0.04	58.6	45	6.57	248.1	2693.6
F	32.5	83.6	30.7	299.3	0.49	32.6	91	29.0	298.1	3.61
Average value				299.6	0.48	Average value				291.2 615.3

2.4 本章小结

本章节针对 AE 信号 Lamb 波在工业机器人金属材料中的传播特性，提出基于 GJO-VMD 和 CWT 的 AE 信号降噪与特征提取方法，有效提升 AE 源定位精度，具体成果如下：

(1) 运用最小排列熵作优化适度函数，采用 GJO 算法优化 VMD，确定其最佳模态个数 K 和惩罚因子 α 参数，结合相关系数重构法，能准确提取 AE 号主次要成分，避免传统 VMD 过分解和欠分解问题。

(2) 借助 CWT 得到的小波时频图可有效识别钢板中 Lamb 波模态，对比可知 EMD 和 CEEMDAN 分析法对 AE 信号主次要成分提取不够准确。提出特殊平面定位方法，利用低频段扩展波 S0 群速度、TDOA 及 AE 源与传感器几何关系，实现 AE 源准确定位。

(3) 提出的联合方法可有效识别声波模态，AE 源定位算法定位精度高，计

算角度与实际测量角度误差在 0 到 4 度小范围内波动，相对误差平均约 0.48%。使用纵波波速计算的定位算法相对误差大，虽距离定位结果与实际相似，但角度误差大，不适用于 AE 源定位。

第3章 AE 信号在工业机器人机械本体上的传播特性

在本章中，着重对声发射（Acoustic emission, AE）信号在工业机器人机械本体上的传播特性以及 AE 源定位展开研究。主要提出了基于 WD-EMD 结合相关系数和方差贡献率的信号降噪与特征提取方法。该方法能够精准地提取出 AE 信号在工业机器人机械本体内外表面传播时的频率特性。同时，经过多次实验，获取内外表面的特征频率范围。在此基础上，将第 2 章所提出的声源定位算法应用至工业机器人机械本体之上，进而结合所得到的特征频率范围，共同对本体内外表面的 AE 源位置进行判定。

3.1 基于 WD-EMD 的 AE 信号特征提取方法

3.1.1 小波降噪基本原理

小波去噪（Wavelet denoising, WD）一般是通过离散小波变换对信号进行分解^[58]。分解后的信号保留不同维数的信息，通过设置阈值进行小波重构，实现信号去噪。离散小波变换（Discrete wavelet transform, DWT）的原理是：

$$DWT_x(a, b) = \int x(t) \cdot \Psi_{a,b}(t) dt \quad (3-1)$$

式(3-1)中： a 是缩放常数， b 是平移常数， $\Psi_{a,b}(t)$ 为母小波的共扼运算， $x(t)$ 为给定原始信号。

对于降噪后的子小波，通过式(3-2)进行重构：

$$x(t) = \sum_{a,b} DWT_x(a, b) \psi_{a,b}(t) \quad (3-2)$$

3.1.2 经验模态分解基本原理

经验模态分解（Empirical mode decomposition, EMD）将信号分解成多个局部特征，即本征模函数（Intrinsic mode function, IMF）。每个 IMF 代表信号中的一个局部振动模式^[59]。它是将一个非平稳信号分解成若干个 IMF 单分量信号和一个残余函数的形式。即

$$x(t) = \sum_{i=1}^n I_i(t) + r(t) \quad (3-3)$$

式中， $I_i(t)$ 为若干个 IMF 分量， $r(t)$ 为残余函数。

每个 IMF 分量必须满足以下条件：

1) 在给定的信号数据段内，极值点和过零点的个数必须完全对应或至多相差一个。

2) 在任意时刻或任意点，由局部最大值形成的上包络线与由局部极小值形成的下包络线的平均值为零。

3.1.3 方差贡献率基本理论

方差贡献率（Variance accounted for, VAF）是评估模型因子的重要指标之一，VAF 的值越高则模型对实际数据的解释效果越好，模型预测结果越接近实际结果^[60]。为此，本文通过计算每个 IMF 的 VAF，并结合相关系数选择用于重构的 IMF 波形。VAF 的计算公式为：

$$VAF = \frac{V_I}{V_T} \times 100\%, I = 1, 2, 3, \dots \quad (3-4)$$

其中，第 I 个 IMF 的方差为 V_I ，总方差为 V_T 。

3.2 实验与分析

3.2.1 实验设置与信号采集

研究材料是国产工业六轴机器人，具体型号和参数如表 3-1 所示：

表 3-1 工业机器人主要参数

名称	参数
额定功率	1KW
额定电压	220V
产品型号	ER3B-C10
最大负载	3KG
设备重量	27KG

该工业机器人本体由金属整体浇铸而成，而且本体外表面有均匀漆面涂层。本实验同样采用软岛 DS5-16C 声发射仪采集信号，采样速率设定为 3MHz，传感器为 RS-2A 压电陶瓷传感器，前置放大器增益调至 40dB。

同样采用 HNS 作为模拟故障信号，并使用透明胶布将 AE 传感器固定在机器人本体上，上面为一号传感器记为 1[#]传感器，下面二号传感器记为 2[#]传感器，传感器之间的距离为 180mm，如图 3-1 所示为工业机器人的机体模型，传感器的布置位置以及各个测试点（1、2、3、4、5 号）的位置，其中 1 号点与两个传感器在同一水平线上，其余点在传感器的左边，分别于传感器呈一定的角度。




图 3-1 工业机器人 AE 信号采集点与传感器分布

3.2.2 AE 信号小波降噪结果分析

在两个传感器位于同一水平线的前提下，距离 1#传感器 60mm 的本体内外表面进行铅芯折断产生 AE 源（即图 3-1 中 1 号点），采集到了 4 组原始 AE 信号，4 组信号中外表面的信号记为 S_{e-1} 和 S_{e-2} ，内表面的信号记为 S_{i-1} 和 S_{i-2} 。从原始信号中截取长度为 2ms 的 AE 事件用于特征分析，相应的波形和频谱如图 3-2 所示（图 3-2 横坐标为时间和频率，纵坐标为幅值）。在时域波形图 a1), b1) 和 a2), b2) 中可以看到 AE 信号从突然发生到逐渐衰减的整个过程。其中 S_{e-1} (S_{i-1}) 的信号幅值明显大于 S_{e-2} (S_{i-2}) 的信号幅值，其原因是 1#传感器距离 AE 源更近。




图 3-2 AE 信号在本体的内外表面上传播的原始波形和频谱

在频谱图中内外表面上的 AE 信号能量集中在 0kHz ~ 200kHz 范围内。由于 AE 信号的持续时间非常短，其频谱在原始信号中不易识别。本实验使用的 RS-2A 传感器的灵敏度曲线如图 3-3 所示。

虽然产品规定了 50kHz ~ 400kHz 的有效频率范围，但灵敏度在 100kHz ~ 200kHz 范围内最稳定。这种稳定性导致传感器在该频率范围内对 AE 信号进行最佳放大。传感器的放大系数在 0kHz ~ 100kHz 频率范围内稳定性较差，所以在此范

围内的信号将被排除在分析之外。




图 3-3 RS-2A 传感器的灵敏度曲线。

根据原始信号的时域波形，可以大致识别出振幅较大、衰减明显的 AE 事件。然而，频谱图并没有显示 AE 事件对应的信号频率。为了解决这一问题，本文首先利用小波分析对原始信号进行逐层分离，然后从细节信号中重构 AE 信号。由于传统的滤波方法会引起信号的幅度和相移，小波降噪可以有效地保留了信号的细节，避免了传统滤波方法中信号细节的丢失。由于铅芯折断是突发 AE 信号，这些信号主要体现在小波分解后的细节信号部分，可以根据小波分解得到的细节信号重构波形。

将 S_{e-1} (S_{e-2}) 和 S_{i-1} (S_{i-2}) 信号分别进行四层小波分解。图 3-4 为分解后的小波细节信号的频率范围图，对应 750kHz ~ 1.5MHz、375kHz ~ 750kHz、187.5kHz ~ 375kHz、93.75kHz ~ 187.5kHz 的高频范围。




图 3-4 小波细节信号的频率范围

由于本体内外表面的 AE 信号频率集中在 100kHz~200kHz 范围内，因此 3 层和 4 层细节信号的频率范围满足要求。另外，1 层和 2 层细节信号的幅值相对于高频是低的，可以认为是需要丢弃的高频噪声。因此，只处理 3 层和 4 层的细节信号。

根据前文，内外表面的 AE 信号频率集中在 100kHz ~ 200kHz，所以， S_{e-1} 和

S_{e-2} 信号就可以由第 3、4 层分解信号重构而成，重构后的波形如图 3-5a1), b1) 所示。其中第 3 层信号频率在 180kHz ~ 370kHz 之间，说明该信号是 AE 信号与噪声信号的混合信号，AE 信号占比较大。1[#] 传感器采集的 AE 信号频率主要集中在 140kHz ~ 180kHz 之间，2[#] 传感器频率主要集中在 130kHz ~ 180kHz 之间。同样， S_{i-1} 和 S_{i-2} 是由 3 层和 4 层细节信号重构的。重构波形如图 3-5a2), b2) 所示（图 3-5 横坐标为时间和频率，纵坐标为幅值）。对重构信号进行频率分析可以看出，1[#] 传感器的 AE 信号主要集中在 120kHz ~ 160kHz 之间，而 2[#] 传感器的 AE 信号主要集中在 120kHz ~ 180kHz 之间。




图 3-5 本体内外表面上 AE 信号的重构波形和频谱

3.2.3 小波降噪后 AE 信号 EMD 结果分析

在图 3-2 中已经得到了机器人本体外表面原始折铅 AE 信号的特征，并对原始 AE 信号进行了小波降噪，降噪后 AE 信号波形如图 3-5 所示，记外表面降噪后的信号为 S'_{e-1} 和 S'_{e-2} ，内表面降噪后的信号为 S'_{i-1} 和 S'_{i-2} 。现对其进行 EMD 分析，分解后可得到 7 层 IMF 细节信号，其中 S'_{e-1} 和 S'_{i-1} 信号的 EMD 分析结果如图 3-6a、图 3-6b 所示。




图 3-6 S'_{e-1} 和 S'_{i-1} 信号的 EMD 分析结果

分别计算 S'_{e-1} 和 S'_{e-2} (S'_{i-1} 和 S'_{i-2}) 信号 EMD 分析后的各个 IMF 分量与去噪后 AE 信号的相关系数及对应的方差贡献率, 计算结果如图 3-7 所示 (图 3-7 横坐标为 IMF 分量信号, 纵坐标为方差贡献率和相关系数)。从图 3-7 的信息可以看出, S'_{e-1} 的前两个高频分量 IMF1 和 IMF2 的相关系数分别为 0.58 和 0.77。由表 2-1 可知, IMF1 和 IMF2 的相关系数分别为 0.58 和 0.77。相关性对应较强和极强, 其 VAF 分别为 44.9% 和 58.2%, 两个分量信号对实际数据有较好的解释效果, 预测结果与实际结果接近。IMF3 分量信号与去噪 AE 信号的相关系数为 0.42。确定了 IMF3 分量信号与去噪的 AE 信号具有中等相关性, 但 VAF 仅为 28.1%, 不到前两者的一半。预测结果低于实际结果。虽然相关性适中, 但在重构范围内不考虑该分量。IMF4、IMF5、IMF6 和 IMF7 的相关系数均小于 0.2, VAF 均小于 10%。它们与去噪后的 AE 信号相关性极弱或不相关, 不纳入后续分析。




图 3-7 相关系数和方差贡献率的柱状图和线状图

同时, S'_{e-2} 的前两个高频分量 IMF1 和 IMF2 的相关系数分别为 0.71 和 0.67。由表 2-1 可知, IMF1 和 IMF2 与 AE 信号相关性强, 其 VAF 分别为 48.8% 和 42.0%。确定 IMF3 分量信号与 AE 信号具有中等相关性, VAF 为 35.7%。三个分量信号对实际数据有较好的解释效果, 预测结果与实际结果较为接近。IMF5、IMF6、IMF7 的相关系数均小于 0.2, VAF 均小于 10%。这些分量与去噪后的 AE 信号相关性很弱或没有相关性, 因此不包括在后续分析中。根据上述分析对信号进行重构, 然后进行频率分析, 如图 3-8 所示 (图 3-8 横坐标为时间和频率, 纵坐标为幅值)。

S'_{i-2} 的前两个高频 IMF 分量与去噪 AE 信号的相关系数分别为 0.65 和 0.67。由表 2-1 可知, IMF1 和 IMF2 与 AE 信号有很强的相关性。两组分的 VAF 分别为 44.2% 和 42.0%。结果表明, 这两个分量对实际数据有较好的解释效果, 预测结果与实际结果接近。IMF3 分量信号与去噪 AE 信号的相关系数为 0.39, 但 VAF 为 27.0% 因此不计入后续分析。IMF4、IMF5、IMF6 和 IMF7 的相关系数均小于 0.2,

VAF 均小于 10%，与去噪后的 AE 信号相关性极弱或不相关，因此在后续分析中不考虑。根据上述分析，对信号进行重构经过频率分析后得到图 3-8b。




图 3-8 EMD 分析重构后的 AE 信号波形和频谱

从图 3-8a 和图 3-8b 中可以看出，信号经过 EMD 分析和重构后，呈现出一个完整的 AE 过程。重构波形与原始 AE 信号的幅值非常接近。此外，在 S'_{e-1} 信号的频谱中，可以看到主频率分布在 144 kHz 左右。同样， S'_{e-2} 信号的主频率分布在 177 kHz 左右。在 S'_{i-1} 信号的频谱中，可以看到主频率分布在 122 kHz 左右， S'_{i-2} 信号的主频率分布在 169 kHz 左右。

3.2.4 对比研究

本小节采用 EMD 分析方法分别计算了 IMF 的相关系数和 VAF。选择具有大相关系数和 VAF 的信号重构，再进行频率分析。最后，将该方法与本文提出的方法进行了比较。由于同时分析内外表面的所有 AE 数据需要较长的时间，因此每个表面只分析一组 AE 数据。下图 3-9（图 3-9 横坐标为时间和频率，纵坐标为幅值）为上述信号中两组内外表面原始 AE 信号经过 EMD 分析后分别计算各层 IMF 的相关系数与 VAF 的点线图（相关系数）和柱状图（VAF）。




图 3-9 原始信号 EMD 分析后的相关系数和方差贡献率的点线图和柱状图

对于外表面分析结果，重构相关系数较强和中等的 IMF，并进行频率分析，如图 3-10a 所示。同时，选取方差贡献率较大的 IMF 进行重构并进行频率分析，如图 3-10b 所示（图 3-10 和 3-11 横坐标为频率，纵坐标为幅值）。

同样，用相同的方法重构内表面并进行频率分析，结果如图 3-11a 和图 3-11b 所示。本文所用传感器的带宽范围为 50kHz ~ 400kHz，根据文献^[61]，图 3-10 和图 3-11 中部分信号的频率峰值均低于传感器的下限频率 50kHz。虽然可以看到能量较高的主频率，但整个频谱中仍然混杂着各种次频率，不能真正反映信号的主要特性。因此，单独使用 EMD 和单一指标提取频率特征是不可靠的。




图 3-10 外表面重构的 AE 信号的频谱图




图 3-11 内表面重构的 AE 信号的频谱图

3.3 AE 信号分类与源定位方法

3.3.1 AE 信号在机器人本体的内外表面上的传播速率

为了得到 AE 信号在本体内外表面的传播速度，本文采用时差定位法计算，首先将两个传感器传感器摆放间隔一段距离 (ΔL)，然后在波形采集软件上得到两信号到达传感器所需要的时间，计算得到时间差 (Δt)，最后计算 AE 信号在本体内外表面的传播速率 $v = \Delta L / \Delta t$ 。




图 3-12 AE 信号在机器人身体的内外表面上的传播速度折线图

现设定 $\Delta L=180mm$ ，传感器在外表面放置位置如图 3-1 所示。计算得到 AE 信号在本体内外表面的传播平均速度如图 3-12 所示。（图 3-12 横坐标为时间，纵坐标为速度）其中，蓝线表示 AE 信号在外表面上的传播速度趋势，红线表示内表面。经计算，AE 信号在外表面上的平均传播速度为 4734m/s，在内表面上的平均传播速度为 4463m/s。

3.3.2 本体内外表面 AE 信号损伤类型的识别

在前文中通过对工业机器人本体 1 号点位置进行铅芯折断，经过 WD 和 EMD 分析后得到其外表面的折铅频率：1#传感器频率为 144kHz，2#传感器频率为 177kHz 和内表面的折铅频率：1#传感器频率为 122kHz，2#传感器频率为 169kHz；外表面的 AE 信号传播速度平均为 4734m/s，内表面的 AE 信号传播速度平均为 4463m/s，经过分析数据发现，不同位置的 AE 信号它们的频率特性及幅值各不相同，因此，可以用这些差异来判断 AE 信号的产生类型。

表 3-2 不同位置的 AE 信号的特征频率和最大能量

AE源	源类型	频率（kHz）		能量（ μJ ）	
		1#传感器	2#传感器	1#传感器	2#传感器
1号点	外表面	144	177	0.30	0.15
	内表面	122	169	0.14	0.12
2号点	外表面	128	166	0.21	0.13
	内表面	114	140	0.14	0.11
3号点	外表面	143	163	0.37	0.23
	内表面	113	133	0.16	0.13
平均值	外表面	138	168	0.29	0.14
	内表面	116	147	0.14	0.11
标准差	外表面	8	6	0.07	0.04
	内表面	3	9	0.02	0.05

在如图 3-1 所示两个位置 2 号点和 3 号点均位于传感器左端的机器人本体上，分别在其外表面和内表面进行铅芯折断，得到 AE 信号在经过 WD 和 EMD 分析处理后得到它们各自的特征频率和最大能量如表 3-2 所示。

由表 3-2 可知外表面的 AE 信号频率都相对较稳定，标准差较小，说明数据波动较小，1#传感器频率的平均值在 130kHz~145kHz 之间，2#传感器频率的平均值都在 150kHz~170kHz 之间；内表面的 AE 信号频率也相对较稳定，标准差较小，1#传感器频率的平均值在 110kHz~120kHz 之间，2#传感器频率的平均值在

130kHz~140kHz 之间。而且由于涂层的影响外表面的 AE 信号能量高于内表面的信号能量。在机器人本体左下方内表面或外表面四个位置分别进行铅芯折断，经过 WD 和 EMD 分析处理后得到如表 3-3 所示频率特性。

对于这四组数据，可以通过上述频率范围来判断这四个位置是在外表面还是内表面。根据之前的讨论，外表面和内表面的信号频率具有不同的特征范围，由于外表面 1#传感器与内表面 2#传感器的频率范围基本一致，仅单独靠 1#传感器或 2#传感器无法判断出折铅类型，因此判断折铅类型必须由内外表面两个通道的频率范围共同决定。

表 3-3 在四个测试位置上的两个传感器的频率

AE源	测试点	频率 (kHz)		源类型
		1#传感器	2#传感器	
4号点	<i>a</i>	135	167	外表面
	<i>b</i>	116	135	内表面
5号点	<i>c</i>	129	160	外表面
	<i>d</i>	104	132	内表面

表 3-3 中位置在位置 *a* 和 *c* 处采集的 AE 信号的 1#传感器特征频率：135kHz 和 129kHz，2#传感器特征频率：167kHz 和 160kHz，它们均在外表面的频率范围内，因此，可以判断位置 *a* 和 *c* 的铅芯折断位置位于外表面。位置 *b* 和 *d* 处采集的 AE 信号的 1#传感器特征频率：116kHz 和 104kHz，2#传感器特征频率：135kHz 和 132kHz，它们均在内表面的频率范围内，因此，可以判断位置 *b* 和 *d* 的铅芯折断位置位于内表面。

综上所述，机器人本体内外表面的频率特性在不同的平均范围内，由此可以判断外部涂层的特性对 AE 信号的传播速度和特征频率产生了显著影响。

3.3.3 AE 源定位研究

根据第 2 章 2.3 小节提出的源定位算法，对机器人机械本体表面的 AE 源进行定位，定位结果和精度如表 3-4 所示。由表 3-4 中的数据可见在每个测试点上，通过时差 AE 源定位计算得到的角度与实际测量的角度存在一些差异，但误差在 1 度到 5 度的范围内波动。根据计算的角度和测得的时间差带入式(2-18)中可得 L 的大小，再带入式(2-19)中计算出的均方误差如表 2-4 所示，定位的精度 $\delta\%$ 平均约为 0.86%，表明计算结果与实际结果相当接近。

表 3-4 计算角度和实际角度 (α 和 β) 以及参数大小

AE源	源类型	计算角度/度		实际角度/度		L/mm	$\delta\%$
		α	β	α	β		
2号点	外表面	161.8	12.3	161.5	12.8	181.2	0.80
	内表面	161.7	12.5	161.4	12.6	181.4	1.10
3号点	外表面	118.9	25.5	123.0	26.3	180.4	0.08
	内表面	118.7	25.9	123.4	26.0	178.8	0.80
4号点	外表面	35.1	65.0	35.5	65.2	182.3	2.90
	内表面	35.0	65.3	35.7	64.8	179.4	0.20
5号点	外表面	20.3	132.6	20.1	134.0	180.6	0.20
	内表面	20.2	132.7	21.4	134.6	181.7	1.60
Average						180.7	0.86

3.4 本章小结

本章节针对 AE 信号在工业机器人机械本体内外表面的传播特性，提出基于 WD-EMD 的 AE 信号特征提取方法，以探究 AE 信号在机械本体上的传播规律，为工业机器人检测做早期准备，研究成果如下：

(1) 明确 AE 信号特征频率范围，本体外表面 1#传感器频率平均值在 130kHz~145kHz 之间，2#传感器平均值为 150kHz~168kHz；内表面 1#传感器测得平均值在 115kHz~120kHz 间，2#传感器在 133kHz~140kHz 间。

(2) 确定 AE 信号传播速度，外表面平均传播速度为 4734m/s，内表面为 4463m/s。可依内外表面主要频率范围识别发射源类型，利用信息结合不同波速计算位置，实现 AE 源准确定位，基于几何关系并结合主频率范围的源定位算法平均精度约 0.86%。

(3) 涂层材料和结构特征对 AE 信号传播速度、频率有直接影响，外表面涂层会引起声波速度和频率变化，还导致信号幅度和能量衰减，且在高频范围衰减显著。

第4章 基于 AE-VMD 能量谱的工业机器人故障辨识

在本章中,首先采集工业机器人机械轴的正常和故障声发射(Acoustic emission, AE)信号,随后运用第2章所提出的 GJO-VMD 方法对 AE 信号进行分解,由此得到若干层 IMF 细节分量,并进一步计算这些分量的能量谱特征。与此同时,提出了基于 PSO-SVM 的工业机器人智能故障诊断模型。接着,把计算所得的能量谱特征用于所提出模型的设计、训练以及测试环节,最终实现对工业机器人故障的有效辨识。

4.1 工业机器人故障辨识方法

4.1.1 GJO-VMD 能量谱

GJO-VMD 能量谱是采用能量的方式来呈现 VMD 分析的结果。选取分解后各个分量信号 IMF 的平方随时间的积分作为能量的标识,第 i 个频带的能量 E_i 的表达式为:

$$E_i = \int_{-\infty}^{\infty} IMF_i(t)^2 dt \quad (4-1)$$

在进行 VMD 分析时,信号能量会保持守恒状态,也就是分解后各个 IMF 的能量总和与原始信号的能量是相等的。所以,能够将分解后各个频带的能量在总能量中所占的百分比选作特征向量,这也就是能量谱,其具体如式(4-2)所示:

$$ES = \left[\frac{E_1}{E}, \frac{E_2}{E}, \dots, \frac{E_i}{E} \right], i=1,2,3 \dots \quad (4-2)$$

4.1.2 粒子群算法基本原理

粒子群算法(Particle swarm optimization, PSO)是一种智能寻优算法,每个粒子由位置、速度、适应值来表示其特征^[62]。在 D 维区间中, $X = (X_1, X_2, \dots, X_D)^T$ 为粒子在搜索空间中的位置, $V_i = (V_{i1}, V_{i2}, \dots, V_{iD})^T$ 为粒子的位置变化速率, $P_i = (P_{i1}, P_{i2}, \dots, P_{iD})^T$ 为个体极值, $P_g = (P_{g1}, P_{g2}, \dots, P_{gD})^T$ 为群体极值。随着迭代次数的增加,大部分粒子逼近全局最优解,形成一个新的粒子种群,不断逼近目标值^[63]。粒子速度与位置更新的表达式为:

$$\begin{cases} V_{id}^{k+1} = \omega V_{id}^k + c_1 r_1 (P_{id}^k - X_{id}^k) + c_2 r_2 (P_{gd}^k - X_{id}^k) \\ X_{id}^{k+1} = X_{id}^k + V_{id}^{k+1} \end{cases} \quad (4-3)$$

其中： c_1 、 c_2 为学习因子， k 为当前迭代次数， ω 为惯性权重， r 为[0, 1]内的任意随机数。

4.1.3 支持向量机基本原理

支持向量机（Support vector machine, SVM）是一种广泛使用的二值分类器，它寻求识别具有不同类之间最大边界的最优超平面^[64]。该超平面是通过求解学习样本得到的，目的是使超平面与不同类别的样本点之间的距离最大化^[65]。这个优化过程可以被框定为最小化超平面法向量的范数，从而寻求最小化目标函数的最优解。目标函数在数学上定义为式(4-4)：

$$\min_{\omega, b} \frac{1}{2} \|\omega\|^2 \quad (4-4)$$

$$\text{subject to } y_i (\omega^T x_i + b) \geq 1, \forall i = 1, 2, \dots, n$$

其中： x_i 为第 i 个样本点， y_i 为对应的类标号， ω 为超平面的法向量， b 为超平面的截距。

4.1.4 粒子群算法优化支持向量机

PSO-SVM 流程图如图 4-1 所示，PSO 算法优化 SVM 时，为了获得最高的分类准确率，常以径向基核函数参数 C 和惩罚参数 g 为待优化参数，利用 PSO 算法对其进行优化^[66]。最后，将特征向量输入到分类器中，对工业机器人故障信号进行自动识别和分类。




图 4-1 PSO-SVM 优化过程框图

4.1.5 GJO-VMDES-PSO-SVM 诊断模型

文中提出了 GJO-VMDES-PSO-SVM 智能故障诊断方法，用于工业机器人故障辨识，该方法流程如图 4-2 所示。步骤如下：

- (1) 由声发射仪采集系统收集工业机器人运行动作一致时不同轴的正常和故障 AE 信号；
- (2) 将原始数据进行截取，对截取的数据进行 GJO-VMD 分析得到若干层 IMF 函数；
- (3) 对分解后得到的 IMF 分量信号进行能量谱的特征提取；
- (4) 将 GJO-VMD 能量谱分为训练样本和验证样本，用一系列训练样本构造 PSO-SVM，然后用于训练样本的无监督特征学习，用于工业机器人故障辨识；
- (5) 使用验证样本验证所提出方法的性能，并报告诊断结果。




图 4-2 GJO-VMDES-PSO-SVM 模型

4.2 实验与分析

4.2.1 实验设置与信号采集

文中使用固高自动化技术有限公司提供的六轴工业机器人运行时产生的 AE 故障数据集来评估验证 GJO-VMD 与 PSO-SVM 对工业机器人故障诊断的有效性，实验装置与测试现场如图 4-3 所示。本实验采用北京软岛 DS5-16C 声发射仪和 AE_DS5 信号采集系统进行声发射信号采集，采样频率 3MHz，前置放大器设置为 40dB，使用 RS-2A 型压电陶瓷传感器，中心频率为 150kHz，频率响应范围为 0kHz~400kHz。




图 4-3 实验装置与测试现场

采用北京软岛 DS5-16CAE 仪和自带的 AE_DS5 信号采集系统进行信号采集，采样频率 3MHz，前置放大器设置为 40dB。采集工业机器人 6 种工况下的 AE 信号，分别为：4 轴正常信号、5 轴正常信号、6 轴正常信号、4 轴故障信号、5 轴故障信号、6 轴故障信号。在进行数据采集工作时，让工业机器人执行相同的运动轨迹，采集机器人不同轴的正常和故障数据。




图 4-4 工业机器人机械轴正常信号 AE 波形




图 4-5 工业机器人机械轴故障信号 AE 波形

如图 4-4 和图 4-5 所示为三个轴采集的正常和故障信号的其中一个样本的 AE

波形（图 4-4 和 4-5 横坐标为样本数量，纵坐标为幅值）。

4.2.2 故障辨识结果分析

用 GJO 算法优化 VMD 时，主要参数的详见表 2-2，将原始数据对 3 种类型的故障数据进行处理，计算 VMD 参数（分解层数与惩罚因子）的平均值和每组数据的适应度平均值。将原始的 6 种类型数据各自截取成样本长度为 5000，样本数量为 100 的子信号进行信号处理，计算 VMD 参数（分解层数与惩罚因子）的平均值和每组数据的适应度平均值，结果如下表 4-1 所示。

表 4-1 参数与适应度的平均值、样本集、标签

信号类型	样本个数	平均惩罚因子 α	平均分解层数 K	平均适应度	标签
4 轴正常信号	100	1336	10	0.423	1
5 轴正常信号	100	1647	10	0.432	2
6 轴正常信号	100	1254	10	0.421	3
4 轴故障信号	100	1094	10	0.422	4
5 轴故障信号	100	1502	10	0.424	5
6 轴故障信号	100	937	10	0.423	6

工业机器人所产生的故障信号经 GJO-VMD 分解处理后，得到 10 个 IMF 模态分量。接着，使用式(4-1)计算各个频带的能量，再计算原始信号的总能量，继而使用式(4-2)计算能量谱，通过归一化后将其作为特征向量。如图 4-6 所示（图 4-6 横坐标为 IMF 分量信号，纵坐标为能量）为三个轴采集的正常和故障信号的其中一个样本的能量谱。随后，把这些特征向量转换为特征矩阵，在特征矩阵的第 11 列插入故障类型标签，并将其添加到总的特征矩阵中。最后将总的特征矩阵转换为表格，构建成数据集，特征提取的标签类型如表 4-1 所示。




图 4-6 工业机器人损伤信号 VMD 能量谱

在最终构建完成的数据集里，涵盖了 4 轴正常信号、5 轴正常信号、6 轴正常

信号、4 轴故障信号、5 轴故障信号和 6 轴故障信号。其中，每一组信号类型所包含的样本数量均为 100，由此可得，数据集的总样本数量为 600。

随后，按照 8:2 的比例对这些样本数据进行随机划分，使其成为训练集与测试集两部分，其中训练集包含了 80% 的样本数据，而测试集则包含 20% 的样本数据。接着，将划分好的训练集与测试集数据输入至 PSO-SVM 模型中，开展相应的训练与测试工作。在这一过程中，借助 PSO 算法来筛选出最佳的径向基核函数参数 g 以及惩罚参数 C 。训练集 PSO-SVM 模型仿真结果和混淆矩阵如图 4-6 所示，测试集 PSO-SVM 模型仿真结果和混淆矩阵如图 4-7 所示，PSO-SVM 模型训练集和测试集故障诊断率为 99.17% 和 98.33%。




图 4-7 训练集 PSO-SVM 模型仿真结果和混淆矩阵




图 4-8 测试集 PSO-SVM 模型仿真结果和混淆矩阵

4.2.3 对比研究

在本小节中，将上述数据集按照同样比例划分的训练集与测试集导入未经过 PSO 优化的 SVM 模型内，对其展开训练与测试操作。同时设定该模型的径向基核

函数参数 g 为 0.01，惩罚参数 C 为 10。

训练集 SVM 模型仿真结果及混淆矩阵呈现于图 4-8，而测试集 SVM 模型仿真结果和混淆矩阵则展示在图 4-9 中。对于未优化的 SVM 模型，其训练集的故障诊断率为 65.63%，测试集的故障诊断率为 67.50%。显而易见，经过 PSO 优化后的 SVM 模型，在故障诊断率方面大幅超越了这种传统的、未优化的 SVM 模型。由此可见，PSO 算法提升了 SVM 模型的分类准确率，让故障诊断模型更加精准，极大地提高了工业机器人故障诊断的准确性和可靠性。




图 4-9 训练集 SVM 模型仿真结果和混淆矩阵




图 4-10 测试集 SVM 模型仿真结果和混淆矩阵

此外，为了体现 PSO-SVM 模型相比较于其他传统模型的优势，使用 BP 神经网络（Back Propagation, BP）、卷积神经网络（Convolutional Neural Network, CNN）、长短期记忆神经网络（Long Short-Term Memory, LSTM）、极限学习机（Extreme Learning Machine, ELM）模型对 GJO-VMD 能量谱数据集进行处理，得到其诊断结果如表 4-2 所示。对比发现，传统 SVM 的诊断效果最差，LSTM 的测试集故障诊断率为 91.77%，但训练集故障诊断率较低；ELM 的训练集故障诊断

率为 93.33%，但测试集故障诊断率较低；BP 和 CNN 的训练集和测试集故障诊断率均较低，而 PSO-SVM 故障诊断模型的准确率优于传统的 SVM 以及 BP、CNN、LSTM 和 ELM 模型等经典模型。

表 4-2 各故障诊断模型训练集和测试集故障诊断率

诊断模型	训练集%	测试集%
PSO-SVM	99.17%	98.33%
SVM	65.63%	67.50%
BP	89.17%	83.33%
CNN	88.43%	80.77%
LSTM	85.00%	91.77%
ELM	93.33%	88.33%

综上所述：将 GJO 算法和 VMD 相融合，在提取工业机器人 AE 信号的特征方面更具成效。相较于传统的频域分析或者时域分析方法，该融合方式能够更为全面地捕捉到信号所具有的非线性与非平稳特性。而将 PSO 算法与 SVM 相结合，则对 SVM 模型的参数选取以及核函数的运用进行了优化，不仅提升了故障诊断结果的准确性，还增强了模型的鲁棒性，使其在面对复杂多变的情况时仍能保持良好的诊断性能。

4.3 本章小结

在本章节里，创新地提出了一种 GJO-VMDES-PSO-SVM 故障诊断方案。通过分析，精准获取了 AE 信号在工业机器人处于不同故障类型时所呈现的能量特征，这为 AET 后续在工业机器人状态监测领域的应用筑牢了基础。具体研究成果如下：

(1) 运用 GJO 算法对 VMD 的参数实施优化，确定了最优的分解层数 K 以及惩罚因子 α ，显著提升了信号的分解质量与效果。对经 VMD 分解后得到的各个模态分量开展能量谱分析，能够清晰地呈现出不同频率段内的能量分布态势。通常情况下，故障信号会在某些特定的频率区间内出现能量的异常波动，而借助 VMD 能量谱，能够有效地突出这些与故障相关的能量特征，让故障特征更加鲜明。

(2) 采用 PSO 算法对 SVM 进行优化处理，合理选取了最佳的径向基核函数参数 g 和惩罚参数 C 。相较于传统的 SVM，PSO-SVM 在工业机器人故障诊断方面展现出了更高的精度，能够更准确地判断工业机器人的故障情况。

(3) 相比较与传统的智能故障诊断方法而言，PSO-SVM 模型在工业机器人故障诊断中具有显著的效果。

第 5 章 总结与展望

5.1 研究总结

工业机器人作为现代工业生产的重要组成部分，为实现生产过程机械化和自动化的打下坚实的基础。由于长期在恶劣环境中和高强度的负载下工作，容易产生疲劳损伤而导致故障的发生，从而导致大量经济流失甚至人员伤亡。因此，研究有效的工业机器人结构损伤识别技术对预防灾难性事故的发生、保证工业机器人系统安全、稳定运行具有重要意义。

然而，实际采集到的 AE 信号往往具有非线性与非平稳的特质，而且信号中通常夹杂着大量源于背景噪声的干扰信息，这就使得有效的 AE 信号变得极为微弱，也给信号特征信息的提取造成了严峻的挑战。由此可见，深入开展针对非线性、非平稳信号处理方法的研究，是达成基于 AET 的工业机器人损伤识别目标的必要前置条件。鉴于此，本论文将工业机器人确定为研究对象，重点针对 AE 信号的分析与处理进行深入探索，进而提出一种依据 AE 信号时频域特征的工业机器人故障辨识方案，并运用实验验证、对比研究等方式，对所构建的基于 AE 信号处理的工业机器人损伤识别方法的有效性加以验证。本文的研究成果预期能够推动研究人员对 AE 信号分析与处理方法展开更为深入的研讨，为 AET 在工业机器人损伤识别方面的应用贡献新的理念和思路。

本论文的主要工作和贡献如下：

（1）提出一种基于 GJO-VMD 和 CWT 的 AE 信号降噪与特征提取方法。该优化 VMD 方法有效避免了传统 VMD 分解过程中产生过分解和欠分解及频带丢失和冗余的情况，使用 CWT 有效避免使用 STFT 导致模式识别效果可能不佳的情况。并提出了利用 S0 模式的群速度，结合 TDOA 和两个传感器之间的几何关系的 AE 源定位算法，可以有效提高工业机器人金属材料的 AE 源定位精度。

（2）提出了一种基于 WD-EMD 的工业机器人机械本体 AE 信号特征提取方法，以探究 AE 信号在机械本体上的传播规律，为工业机器人 AE 无损检测提供早期准备。根据传感器的响应频率范围对原始信号进行 4 层小波分解，避免了使用自选小波尺度进行小波分解的局限性。利用相关系数和方差贡献率的综合信息重构 AE 信号波形避免了单个指标不能很好地评价 IMF 与原始信号的相关性问题。提取 AE 信号在本体内表面和外表面上传播频率特征，再基于 TDOA 原理，计算

AE 信号在本体内表面和外表面的传播速度。并根据 AE 源定位算法实现 AE 源定位。

(3) 提出一种基于 AE 信号 GJO-VMDES 与 PSO-SVM 的工业机器人智能故障诊断模型。该模型通过 GJO 算法优化 VMD 参数方法将原始 AE 信号分解为多个本征模态函数, 计算每层本征模态函数对应的能量特征, 当工业机器人出现故障时, 能量会发生变化, 并将能量特征用于设计、训练和测试所提出的模型。实验结果表明, 故障识别率达到了 98.33% 以上。

本论文的主要创新点如下:

(1) 将最小排列熵作为优化函数, 采用 GJO 算法对 VMD 的参数进行优化, 提出了一种基于 AE 源、传感器几何关系的平面定位算法;

(2) 根据传感器的响应频率范围对原始信号进行小波分解, 避免了使用自选小波尺度进行小波分解的局限性; 利用相关系数和方差贡献率的综合信息重构 AE 信号波形避免了单个指标不能很好地评价独立模态函数与原始信号的相关性问题。

(3) 引入粒子群算法对支持向量机的参数进行优化。PSO 算法具有高效的全局搜索能力, 能够在众多参数组合中快速找到最优解, 从而提升 SVM 模型的分类准确率和泛化能力, 让故障诊断模型更加智能和精准。

5.2 未来展望

随着工业自动化进程的飞速发展, 工业机器人在生产制造领域的应用愈发广泛, 其运行的可靠性和稳定性成为保障生产效率与质量的关键因素。AET 作为一种极具潜力的无损检测手段, 在工业机器人损伤检测领域呈现出十分广阔的发展前景。由于受到作者研究时间、学术水平以及科研条件等因素的制约, 随着论文研究的持续推进, 作者深刻认识到, 在后续的研究过程中, 以下几个方面仍有待进一步深入探索。

(1) AE 信号的处理和分析面临着诸多挑战, 如噪声干扰、信号特征提取困难等。未来, 将致力于开发更为先进的信号处理算法, 如基于深度学习的神经网络算法, 能够自动学习和识别 AE 信号中的微弱损伤特征, 有效区分不同类型和程度的损伤信号, 从而显著提高损伤检测的准确性和可靠性。

(2) 单一的 AE 参数往往难以全面、准确地反映工业机器人的损伤状况。未来, 将 AE 信号与其他检测参数, 如振动信号、温度信号、应变信号等进行有机融合, 成为技术发展的重要方向。通过多传感器数据采集和融合分析技术, 能够获

取工业机器人更丰富的运行状态信息，实现对损伤的全方位、多角度监测。

(3) 传感器是 AET 应用的关键部件，其性能的优劣直接影响检测结果的质量。未来，将不断涌现出新型的 AE 传感器，具有更高的灵敏度、更宽的频率响应范围和更强的抗干扰能力。

(4) 工程化问题的深入研究

1) 实时性、传感器部署与计算资源优化：针对当前研究未涉及的工业环境中的实时性、传感器部署复杂度、计算资源需求等工程化问题，计划在后续研究中展开深入探讨。在实时性方面，将深入分析现有算法的计算流程，通过优化算法结构、采用并行计算技术等手段，提高故障辨识的速度，以满足工业现场对实时监测的需求。对于传感器部署复杂度问题，将结合工业机器人的结构特点和实际运行环境，研究传感器的最优布局策略，在保证检测精度的前提下，降低传感器部署成本和复杂度。同时，评估不同算法在实际工业场景中的计算资源需求，探索通过硬件加速、算法简化等方式，减少对计算资源的依赖，使研究成果更易于在工业现场推广应用。

2) 在线监测系统设计与硬件部署规划：增加在线监测系统设计框架的研究，综合考虑数据采集、传输、处理以及故障诊断等各个环节，构建一套完整、高效的工业机器人在线监测系统。该系统将具备实时数据采集、远程监控、智能诊断等功能，能够及时发现工业机器人的故障隐患并进行预警。在硬件部署方案方面，将研究适合工业环境的硬件选型和配置，确保系统的稳定性和可靠性。同时，考虑硬件的可扩展性和兼容性，以便在未来能够方便地进行系统升级和功能扩展。

3) 算法计算复杂度与实时性优化策略研究：深入探讨算法计算复杂度与实时性之间的关系，通过理论分析和实验验证，找出影响算法实时性的关键因素。针对这些因素，提出相应的优化策略，如采用更高效的数值计算方法、优化算法的迭代过程等。同时，利用仿真和实际工业场景测试，对优化后的算法进行性能评估，确保在提高实时性的同时，不降低故障辨识的准确率。

参考文献

- [1] 季成丞, 王锴, 袁德成. 工业机器人故障诊断与健康预测方法研究[J]. 自动化技术与应用, 2023, 42(02): 1-9+13.
- [2] LIU Z, SHENG Y, WANG X, et al. Magneto acoustic emission technique: A review of methodology, applications, and future prospects in non-destructive testing[J]. NDT & E International, 2024, 146: 103171.
- [3] MINSU J, MINSEOK C, WONJAE C, et al. Near-surface defect detection in ultrasonic testing using domain-knowledge-informed self-supervised learning[J]. Ultrasonics, 2025, 147: 107528.
- [4] MUKHERJEE S, GOWEN A. A review of recent trends in polymer characterization using non-destructive vibrational spectroscopic modalities and chemical imaging[J]. Analytica chimica acta, 2015, 895: 12-34.
- [5] WU Q, KANG D, QIN X, et al. Magnetic particle inspection: Status, advances, and challenges-Demands for automatic non-destructive testing[J]. NDT & E International, 2024, 143: 103030.
- [6] ZHANG X, WANG Y, LI M, et al. Dynamic damage evaluation of indexing table spindle in automobile production line based on AE time-domain damage factor[J]. Measurement, 2025, 249: 117002.
- [7] MEHRA K, PESCHON J. An innovations approach to fault detection and diagnosis in dynamic systems[J]. Automatica, 1971, 7(5): 637-640.
- [8] LEE M, BARNES D, HARDY N. Knowledge based error recovery in industrial robots[C]. 8th International Joint Conference on Artificial Intelligence (IJCAI-83). Morgan kaufmann publishers inc, 1983: 824-826.
- [9] 安海博, 梁炜, 张吟龙. 机器人 RV 减速器声发射信号传播机理分析及实验研究[J]. 机器人, 2020, 42(05): 557-567.
- [10] 赖泽浪. 基于电流与模态分析的工业机器人关节故障诊断[D]. 昆明: 昆明理工大学, 2022.
- [11] 刘伟, 赵玄玉, 查明虎, 等. 基于霍尔传感器的工业机器人轴电流监测研究[J]. 湖北民族大学学报(自然科学版), 2022, 40(03): 289-293.
- [12] LONG J, MOU J, ZHANG L, et al. Attitude data-based deep hybrid learning

- architecture for intelligent fault diagnosis of multi-joint industrial robots[J]. Journal of Manufacturing Systems, 2021, 61: 736-745.
- [13]ELANGO VAN K, KRISHNASAMY T, MOHAN R, et al. Fault diagnosis of a reconfigurable crawling-rolling robot based on support vector machines[J]. Applied sciences, 2017, 7(10): 1025.
- [14]DUNEGAN L , TATRO A. Passive pressure transducer utilizing acoustic emission[J]. Review of Scientific Instruments, 1967, 38(8): 1145-1147.
- [15]裴承璠, 欧阳值鹏. 国外无损检测仪器概况(续完)[J]. 无损检测, 1978, (01): 1-13.
- [16]RESCALVO J, SUAREZ E, VALVERDE P, et al. Health monitoring of timber beams retrofitted with carbon fiber composites via the acoustic emission technique[J]. Composite structures, 2018, 206: 392-402.
- [17]李旭, 霍林生, 李宏男, 等. 混凝土结构中 PZT 传感器的多功能性分析及应用[J]. 振动、测试与诊断, 2015, 35(04): 709-714+799.
- [18]李录平, 邹新元, 唐月清. 小波变换在声发射信号特征参数检测中的应用[J]. 振动与冲击, 2001, 20(02): 69-70+83+97.
- [19]陈颀. 声发射技术在岩石力学研究中的应用[J]. 地球物理学报, 1977, 20(04): 312-322.
- [20]WANG L , MING C , ZHONG H , et al. Prediction of critical rupture of plasma-sprayed yttria stabilized zirconia thermal barrier coatings under burner rig test via finite element simulation and in-situ acoustic emission technique[J]. Surface and coatings technology, 2019, 367: 58-74.
- [21]SALEEM M, SHAHUL H, ARUMUGAM V. Damage and failure assessment of banana-ramie-epoxy composites using acoustic emission monitoring[J]. Construction and building materials, 2024, 449: 138489.
- [22]李杨. 基于声发射技术的工业机器人结构损伤识别方法研究[D]. 南京: 东南大学, 2022.
- [23]龚斌, 金文, 李兆南, 等. 基于小波变换的金属材料声发射特性研究[J]. 石油化工高等学校学报, 2008, (01): 87-91.
- [24]马永辉, 刘康, 杨大志, 等. 基于小波的材料裂纹声发射信号特征[J]. 无损检测, 2012, 34(06): 8-11+16.

- [25]李占国, 宗姝, 史尧臣. 小波阈值去噪在深小孔钻削声发射信号处理中的应用[J].制造技术与机床, 2019, (09): 113-117.
- [26]ZHOU T, ZHANG G, LU N, et al. A rotating machinery fault feature extraction approach based on an adaptive wavelet denoising method and synthetic detection index[J]. Measurement science and technology, 2023, 34(7): 075102.
- [27]罗蕊寒, 方赛银, 丁锐, 等. 应用独立成分分析和小波分解对木材声发射信号的析取[J]. 东北林业大学学报, 2022, 50(02): 83-87.
- [28]YANG J, LI P, YANG Y, et al. An improved EMD method for modal identification and a combined static-dynamic method for damage detection[J]. Journal of sound and vibration, 2018, 420: 242-260.
- [29]GUO T, DENG Z. An improved EMD method based on the multi-objective optimization and its application to fault feature extraction of rolling bearing[J]. Applied acoustics, 2017, 127: 46-62.
- [30]TANG Y, TAI C, SU C, et al. A correlated empirical mode decomposition method for partial discharge signal denoising[J]. Measurement science and technology, 2010, 21(8): 085106.
- [31]陶栩. 基于 EMD 的滚动轴承故障诊断方法研究[J]. 自动化与仪表, 2019, 34(04): 56-59.
- [32]吴旭景, 杜斌, 叶陈. 基于 EMD 和小波分解的管道泄漏声发射源定位[J]. 无损检测, 2015, 37(10): 60-63.
- [33]LI R, DAVID H. Rotational Machine Health Monitoring and Fault Detection Using EMD-Based Acoustic Emission Feature Quantification[J]. IEEE Transactions on instrumentation and measurement, 2012, 61(4): 990-1001.
- [34]方赛银, 邱荣祖, 李明. 基于改进 EMD 算法的木材声发射信号特征研究[J]. 振动与冲击, 2018, 37(23): 292-298.
- [35]DRAGOMIRETSKIY K, ZOSSO D. Variational Mode Decomposition[J].IEEE Transactions on signal processing, 2014, 62(3): 531-544.
- [36]LIU Z, XING J, WANG H, et al. Fault diagnosis of rolling bearing based on VMD and fast spectral kurtosis[J]. Journal of electronic measurement and instrument, 2021, 35(02): 73-79.
- [37]任学平, 李攀, 王朝阁. 基于 VMD 和快速谱峭度的滚动轴承早期故障诊断[J].

- 轴承, 2017, (12): 39-43.
- [38]DAI X, YI K, WANG F, et al. Bearing fault diagnosis based on POA-VMD with GADF-Swin Transformer transfer learning network[J]. Measurement, 2024, 238: 115328.
- [39]GAO Z, WANG X, LIN J, et al. Online evaluation of metal burn degrees based on acoustic emission and variational mode decomposition[J]. Measurement, 2017, 103: 302-310.
- [40]唐贵基, 王晓龙. 参数优化变分模态分解方法在滚动轴承早期故障诊断中的应用[J]. 西安交通大学学报, 2015, 49(05): 73-81.
- [41]LIU J, QUAN H, YU X, et al. Fault diagnosis of rolling bearings based on Parameter Optimization VMD and Sample entropy[J]. Acta Automatica sinica, 2022, 48(03): 808-819.
- [42]李颖, 王鹏, 吴仕虎, 等. 基于 AO-VMD 的往复压缩机故障特征提取方法[J]. 机电工程, 2023, 40(05): 673-681.
- [43]赵昕海, 张术臣, 李志深, 等. 基于 VMD 的故障特征信号提取方法[J]. 振动、测试与诊断, 2018, 38(01): 11-19+202.
- [44]CHOPRA N, ANSARI M. Golden jackal optimization: A novel nature-inspired optimizer for engineering applications[J]. Expert systems with application, 2022, 198(7): 116924.
- [45]王军, 王文川, 邱林, 等. 多策略融合改进的金豺优化算法及其在马斯京根模型参数估计中的应用[J]. 中国农村水利水电, 2024, (02): 1-7.
- [46]谢豪, 李立君, 廖凯, 等. 基于金豺优化算法的 PID 参数优化研究[J]. 现代制造工程, 2023, (03): 146-151.
- [47]万陶磊, 常俊杰, 曾雪峰, 等. 基于经验模态分解和相关系数对玻璃纤维增强聚合物复合材料板的损伤识别及扫查成像[J]. 复合材料学报, 2020, 37(08): 1921-1931.
- [48]LIANG P, WANG W, YUAN X, et al. Intelligent fault diagnosis of rolling bearing based on wavelet transform and improved ResNet under noisy labels and environment[J]. Engineering applications of artificial intelligence, 2022, 115: 105269.
- [49]YU Q, ZHANG Y, XU J, et al. Intelligent damage classification for tensile

- p>membrane structure based on continuous wavelet transform and improved ResNet50[J]. Measurement, 2024, 227: 114260.
- [50]刘小峰, 张天瑀, 孙小强, 等. Lamb 波的交叉递归分析在金属板损伤量化中的应用[J]. 振动与冲击, 2022, 41(22): 226-232.
- [51]孟翔震, 李再帏, 朱文发, 等. 基于空耦超声 Lamb 波的金属板状结构内部缺陷检测方法[J]. 应用声学, 2020, 39(02): 316-324.
- [52]范志涵, 张宇, 芮小博. 航天器舱壁结构碎片撞击声发射定位技术研究[J]. 仪器仪表学报, 2020, 41(01): 178-184.
- [53]王祖荫. 声发射技术基础[M]. 山东: 山东科技出版社, 1990: 45-46.
- [54]樊保圣, 闫小青, 扶名福, 等. 基于 Lamb 波频散特性的薄板声发射源定位方法研究[J]. 固体力学学报, 2011, 32(S1): 283-287.
- [55]刘长良, 武英杰, 甄成刚. 基于变分模态分解和模糊 C 均值聚类的滚动轴承故障诊断[J]. 中国电机工程学报, 2015, 35(13): 3358-3365.
- [56]DENG S, AI H, WANG B. Research on the electromagnetic wave absorption properties of GNPs/EMD cement composite[J]. Construction and building materials, 2022, 321: 126398.
- [57]LI Q, WANG G, WU X, et al. Arctic short-term wind speed forecasting based on CNN-LSTM model with CEEMDAN[J]. Energy, 2024, 299: 131448.
- [58]周翠红, 周富强, 刘兆赫, 等. 基于小波降噪的神经网络盾构泥水分离系统参数预测方法[J]. 土木与环境工程学报, 2025, 47(01): 11-17.
- [59]KOPSINIS Y, MCLAUGHLIN S. Development of EMD-Based Denoising Methods Inspired by Wavelet Thresholding[J]. IEEE Transactions on signal processing, 2009, 57(4): 1351-1362.
- [60]何杰, 张世玮, 孙兵川, 等. 基于希尔伯特-黄变换的 2.2 MW 风力发电机噪声特征研究[J]. 计量学报, 2024, 45(12): 1841-1848.
- [61]鞠双, 李新慈, 罗廷芳, 等. 应用小波分析法对马尾松胶合木表面声发射信号特征检测[J]. 东北林业大学学报, 2018, 46(08): 84-90.
- [62]刘冬梅, 霍龙龙, 王浩然, 等. 基于 PSO-SVM 的电流放大器故障诊断研究[J]. 传感器与微系统, 2021, 40(08): 50-52+56.
- [63]王寿元, 李积元, 郎永存, 等. 基于 PSO 优化 SVM 数控机床主轴系统故障诊断的研究[J]. 组合机床与自动化加工技术, 2023, (09): 151-155+159.

- [64]SONG Q, MA M, GUO W, et al. Health state diagnosis of air duct for photovoltaic inverter based on PSO-SVM classifier[J]. Microelectronics reliability, 2023, 150: 115084
- [65]CAI X, WAI R. Intelligent DC arc-fault detection of solar PV power generation system via optimized VMD-based signal processing and PSO-SVM classifier[J]. IEEE Journal of photovoltaics, 2022, 12(4): 1058-1077.
- [66]杨远鹏, 陈志刚, 余志红, 等. 基于 WOA-VMD 与 PSO-SVM 的滚动轴承故障诊断[J]. 制造技术与机床, 2025, (02): 23-29+42.

附录

本文涉及的所有专业名词的全称与缩写

缩写	说明
AE	声发射 (Acoustic emission)
AET	声发射检测 (Acoustic emission testing)
AO	天鹰优化 (Aquila optimizer)
BP	BP 神经网络 (Back Propagation)
CEEMDAN	完全自适应噪声集合经验模态分解 (Complementary Ensemble Empirical Mode Decomposition with Adaptive Noise)
CNN	卷积神经网络 (Convolutional Neural Network)
CWT	连续小波变换 (Continuous wavelet transform)
DWT	离散小波变换 (Discrete wavelet transform)
EMD	经验模态分解 (Empirical mode decomposition)
FFT	快速傅里叶变换 (Fast Fourier transformation)
GJO	金豺优化 (Golden jackal optimization)
HT	希尔伯特变换 (Hilbert transform)
HNS	徐乃星源 (Hsu-Nielsen source)
IMF	本征模函数 (Intrinsic mode function)
LSTM	长短期记忆神经网络 (Long Short-Term Memory)
MSE	均方误差 (Mean square error)
NDT	无损检测 (Non-destructive testing)
PSO	粒子群算法 (Particle swarm optimization)
STFT	短时傅立叶变换 (Short-time Fourier transform)
SVM	支持向量机 (Support vector machine)
TDOA	到达时间差 (Time difference of arrival)
VAF	方差贡献率 (Variance accounted for)
VMD	变分模态分解 (Variational mode decomposition)
WD	小波去噪 (Wavelet denoising)

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] **Dong S**, You J, Li M, et al. 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, JCR: Q1, IF=5.2, 已检索, **WOS:001352895400001**) (本篇论文对应文中第 2 章和第 4 章)
- [2] **Dong S**, You J, Li M, et al. 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**) (本篇论文对应文中第 3 章)
- [3] **Dong S**, Qiao S, Li M, et al. Acoustic Emission Signal Characteristics Extraction Based on Improved EMD Method for Industrial Robot Body[C]. International Conference on Robotics, Control and Automation Engineering. Suzhou, China, 2023, pp.280-284. DOI: 10.1109/RCAE59706.2023.10398749. (EI (CA), 已检索, Accession number: 20240815576762) (本篇论文部分使用于文中第 2 章和第 3 章)
- [4] Qiao S, **Dong S**, Li M, et al. PCA-MD Planetary Gear Damage Identification Method Based on Acoustic Emission Signals[C]. International Conference on Robotics, Control and Automation Engineering. Wuhu, China, 2024. (EI (CA), 已检索, Accession number: 20250617840951)
- [5] Zhang X, Wang Y, Li M, Gong S, **Dong S**, et al. Dynamic damage evaluation of indexing table spindle in automobile production line based on AE time-domain damage factor[J]. Measurement, 2025, 249: 117002. DOI: <https://doi.org/10.1016/j.measurement.2025.117002>. (SCI 2 区 TOP, JCR: Q1, IF=5.2, 已检索, Accession number: 20250717889110)

二、发明和实用新型专利

- [1] 李明, 董仕尚, 程子安, 涂璟. 一种工业机器人的健康监测方法、系统、电子设备以及存储介质: 中国, CN117288837A[P]. (发明公开实质审查)
- [2] 李明, 董仕尚, 涂璟, 程子安, 袁学超. 一种机器人声发射信号的降噪方法及系统: 中国, CN117316172A[P]. (发明公开实质审查) (本项专利使用于文中第 2 章)
- [3] 董仕尚, 王创伟, 丁思成, 乔爱民. 一种光线追踪电路系统及光线追踪器: 中国, CN117478997A[P]. (发明公开实质审查)
- [4] 李明, 董仕尚, 程子安, 郭黎. 一种光源追踪器: 中国, CN221528892U[P]. (实用新型授权)

三、比赛成果

- [1] 芜湖大学生专利创新创业大赛: “董仕尚, 李明, 涂璟, 程子安, 袁学超. 一种机器人 AE 信号的降噪方法及系统” (三等奖)
- [2] 安徽工程大学第十三届专利发明与创新大赛暨 2024 年校研究生专利创新大赛: “董仕尚, 李明, 涂璟, 程子安, 一种工业机器人的健康监测方法、系统、电子设备以及存储介质” (三等奖)
- [3] 安徽工程大学第十三届专利发明与创新大赛暨 2024 年校研究生专利创新大赛: “董仕尚, 李明, 涂璟, 程子安, 袁学超. 一种机器人声发射信号的降噪方法及系统” (优秀奖)

致谢

行文至此，我的硕士求学生涯即将画上句号。在这数年的学习与研究过程中，我得到了众多师长、同学、亲友的关心与支持，心中满是感激，难以言表。

我要衷心感谢我的恩师李明教授。自入学以来，导师便以渊博的学识、严谨的治学态度 and 无私的奉献精神引领我在学术的海洋中探索。从论文选题的确定，到研究思路的梳理，再到论文撰写与修改的每一个细节，导师都给予了我悉心的指导与耐心的帮助。导师不仅在学术上对我严格要求，更注重培养我的独立思考能力和科研创新精神，使我在研究生阶段取得了长足的进步。您的言传身教将永远激励着我在未来的学术道路上奋勇前行，我将铭记您的教诲，努力成为一名对社会有贡献的科研工作者。

衷心感谢程子安老师和郭黎老师。两位老师凭借深厚的专业素养，为我打开了知识的大门，让我能在专业学习的道路上稳步前行，是你们的言传身教，让我懂得了坚持与努力的意义，让我明白了如何在求知的道路上不断进取，更是让我学会了以积极乐观的心态去拥抱生活中的每一次挑战。

感谢芜湖固高自动化技术有限公司的袁学超老师，作为我的校外导师，袁老师对待工作的严谨态度也时刻感染着我，严谨细致的作风让我明白了在追求专业道路上应有的态度，也让我养成了良好的习惯，为我今后的发展奠定了坚实的基础。同时，也要诚挚感谢绍兴职业技术学院的祝新军老师、高琦樑老师、徐旦老师、金丹老师以及陈科行老师。感谢你们在我驻站的那几个月时光里，在生活、学习、科研上给予的帮助。

在论文写作过程中，我也得到了许多同学的帮助。感谢我的同门师兄师姐师弟师妹们，你们在学习和生活中给予了我诸多关心和鼓励，与我分享科研经验和心得，让我在研究生生活中感受到了大家庭的温暖。感谢我的室友们，我们一起讨论问题、互相学习、共同成长。

感谢我的父母，你们一直是我坚强的后盾，给予我无尽的关爱和支持。在我成长的道路上，你们默默付出，为我创造了良好的学习条件，鼓励我追求自己的梦想。感谢我的外婆给予的牵挂与关怀是我前进的动力。

2025 年 4 月

于安徽工程大学高端装备先进感知与智能控制教育部重点实验室 A413