

分类号: TP242.2

密 级: 公开

学校代码: 10363

学 号: 2220340108



安徽工程大学

Anhui Polytechnic University

硕士学位论文

题 目 基于声发射的工业机器人
减速器故障识别研究

论 文 作 者 张浩

指 导 教 师 郭黎 教授

学 科 (专 业) 控制科学与工程

研 究 方 向 工业机器人健康监测

论文提交日期: 2025 年 5 月 16 日

分类号: TP242.2

单位代码: 10363

密 级: 公开

学 号: 2220340108

题 目 基于声发射的工业机器人减速器故障识别研究

题 目 Research on Fault Identification of Industrial Robot
Reducer Based on Acoustic Emission

论文作者: _____ 张浩

校内导师: _____ 郭黎

专 业: _____ 控制科学与工程

研究方向: _____ 工业机器人健康监测

论文答辩日期: _____ 2025 年 5 月 11 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：张浩

日期：2025 年 5 月 14 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：张浩 指导教师签名：邵

日期：2025 年 5 月 14 日 日期：2025 年 5 月 14 日

基于声发射的工业机器人减速器故障识别研究

摘 要

工业机器人在智能制造中发挥着不可替代的作用,随着我国现代工业的快速发展,工业机器人的数量也随之快速增多。然而,在高强度生产作业中工业机器人的传动结构可靠性和稳定性降低,甚至会发生严重事故导致重大经济损失和人身伤亡。因此,研究其传动结构故障的识别方法对保证机器人安全稳定运行具有十分重要的现实意义。

本文以工业机器人核心传动部件减速器为研究对象,针对其在复杂工况下故障识别精度不足的行业痛点,开展基于声发射技术的智能故障识别方法研究。作为工业机器人三大核心部件之一,减速器易出现齿轮磨损、轴承点蚀、断齿等机械故障,传统故障识别方法存在局限性。声发射技术作为动态无损检测方法,通过采集材料内部能量释放产生的高频弹性波(频率范围 50kHz-1MHz),可有效捕捉裂纹扩展、摩擦接触等早期故障信号,具有灵敏度高、实时性强等独特优势。本文主要研究工作和创新内容如下:

(1) 针对小波分析法和自适应噪声完全集合经验模态分解在声发射信号降噪与重构应用中存在对噪声信号敏感,去噪效果不足等问题,提出一种基于小波分解(Wavelet Transform, WT)和自适应噪声完全集合经验模态分解(Complete Ensemble Empirical Mode Decomposition With Adaptive Noise, CEEMDAN)相结合的声发射信号(Acoustic Emission, AE)降噪方法,实验采用减速器铅芯折断声发射信

号验证, 相较单一分解方法, 信号信噪比提升 11dB, 降噪结果得到了明显的提升。

(2) 针对工业机器人在长时间持续运行过程中减速器容易出现行星轮磨损出现故障的问题。提出一种采用河马算法(Hippopotamus Optimization Algorithm, HO)优化变分模态分解(Variational Mode Decomposition, VMD)的信号降噪方法, 然后结合多重分形去趋势波动分析(Multifractal Detrended Fluctuation Analysis, MFDFA)对减速器行星轮 AE 信号进行故障识别。研究结果表明, 通过信号的多重分形参数分布可实现对减速器行星轮裂纹故障的识别。

(3) 针对汽车工厂因长期使用而产生故障的工业机器人减速器进行故障识别研究, 提出一种基于卷积神经网络(Convolutional Neural Network, CNN)和双向长短时记忆网络(Bidirectional Long Short-Term Memory, BiLSTM)并行的故障识别网络, 通过对比不同结构的识别网络准确率验证所提方法的有效性, 故障识别准确率达到了 96.66%, 可以有效的对工业机器人减速器故障进行识别。

本研究涵盖了信号处理以及智能识别等方面。通过对工业机器人传动部件关键部位减速器的深入研究, 为工业机器人减速器的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与可靠性具有重要意义。

关键词: 声发射技术, 减速器故障识别, 变分模态分解, 神经网络, 连续小波变换

RESEARCH ON FAULT IDENTIFICATION OF INDUSTRIAL ROBOT GEARBOXES BASED ON ACOUSTIC EMISSION

ABSTRACT

Industrial robots play an irreplaceable role in intelligent manufacturing, and with the rapid development of modern industry in China, the number of industrial robots has also increased rapidly. However, in high-intensity production operations, the reliability and stability of the transmission structure of industrial robots decrease, and serious accidents may even occur, resulting in significant economic losses and personal injuries. Therefore, studying the identification method of transmission structure faults is of great practical significance for ensuring the safe and stable operation of robots.

This article takes the reducer, the core transmission component of industrial robots, as the research object, and focuses on the insufficient fault recognition accuracy in complex working conditions. It conducts research on intelligent fault recognition methods based on acoustic emission technology. As one of the three core components of industrial robots, reducers are prone to mechanical failures such as gear wear, bearing pitting, and tooth breakage, and traditional fault identification methods have limitations. As a dynamic non-destructive testing method, acoustic

emission technology can effectively capture early fault signals such as crack propagation and frictional contact by collecting high-frequency elastic waves (frequency range 50kHz-1MHz) generated by energy release inside the material. It has unique advantages such as high sensitivity and strong real-time performance. The main research work and innovative content of this article are as follows:

(1) Aiming at the problems of sensitivity to noise signals and insufficient denoising effect in the application of wavelet analysis and adaptive noise complete ensemble empirical mode decomposition in the denoising and reconstruction of acoustic emission signals, a denoising method for acoustic emission signals (AE) based on the combination of wavelet transform (WT) and complete ensemble empirical mode decomposition with adaptive noise (CEEMDAN) is proposed. The experiment verifies the AE signal by using a broken lead core of a reducer. Compared with a single decomposition method, the signal-to-noise ratio is improved by 11dB, and the denoising results are significantly improved.

(2) In response to the problem of planetary gear wear and failure in the gearbox during long-term continuous operation. Propose a signal denoising method using Hippopotamus Optimization Algorithm (HO) to optimize Variational Mode Decomposition (VMD), and then combine it with Multifractal detrended Fluctuation Analysis (MFDFA) to identify faults in the AE signal of the reducer. The research results indicate that the

identification of planetary gear crack faults in reducers can be achieved through the multifractal parameter distribution of signals.

(3) A research on fault recognition of industrial robot reducers caused by long-term use in automobile factories is proposed. A parallel fault recognition network based on Convolutional Neural Network (CNN) and Bidirectional Long Short Term Memory (BiLSTM) is proposed. The effectiveness of the proposed method is verified by comparing the accuracy of recognition networks with different structures. The fault recognition accuracy reaches 96.66%, which can effectively identify faults in industrial robot reducers.

This study covers aspects such as signal processing and intelligent recognition. Through in-depth research on the key parts of industrial robot transmission components, such as reducers, good innovation and engineering applications have been provided for the health management of industrial robot reducers. It is of great significance to enhance the safety and reliability of intelligent manufacturing systems.

KEY WORDS: acoustic emission technology, reducer fault identification, variational mode decomposition, Nnural network, continuous wavelet transform

目录

摘 要.....	I
ABSTRACT.....	III
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.....	2
1.2.1 工业机器人故障诊断研究现状.....	2
1.2.2 声发射技术的应用现状.....	4
1.2.3 声发射信号的故障特征提取研究现状.....	5
1.3 主要内容和章节安排.....	9
第 2 章 本文相关理论基础.....	11
2.1 声发射信号处理技术相关理论.....	11
2.1.1 连续小波处理方法基本原理.....	11
2.1.2 完全集成经验模态分解方法基本原理.....	11
2.1.3 变分模态分解基本原理.....	12
2.2 河马优化算法基本理论.....	14
2.3 多重分形去趋势波动分析原理.....	15
2.4 卷积神经网络基本理论.....	16
2.5 双向长短时记忆网络基本理论.....	22
2.6 本章小结.....	26
第 3 章 基于信号分解的减速器故障识别研究.....	27
3.1 减速器声发射信号降噪.....	27
3.1.1 基于完全集成经验模态分解和小波处理的声发射信号降噪方法..	28
3.1.2 基于河马算法优化变分模态分解的声发射信号降噪方法.....	30
3.1.3 工业机器人减速器声发射故障特征提取.....	31
3.2 减速器声发射信号故障识别.....	32
3.2.1 实验数据来源.....	32
3.2.2 实验验证.....	33

3.3 本章小结.....	45
第 4 章 基于神经网络的减速器故障识别研究.....	46
4.1 实验数据来源.....	46
4.2 声发射信号预处理.....	48
4.3 基于连续小波处理和并行神经网络的减速器故障识别.....	49
4.3.1 故障识别仿真实验流程.....	49
4.3.2 模拟数据识别结果分析.....	50
4.3.3 实例数据分析.....	52
4.4 本章小结.....	57
第 5 章 总结和展望.....	58
5.1 本文总结.....	58
5.2 未来展望.....	59
参考文献.....	60
攻读学位期间发表的学术论文及成果目录.....	66
致谢.....	67

第 1 章 绪论

1.1 研究背景及意义

当代科技的革新浪潮推动着工业机器人技术在多领域的深化应用。在汽车制造、智慧医疗和精准农业等产业中，机器人系统的集成应用已形成完备的技术体系，成为支撑国家现代产业升级与创新型经济建设的核心驱动力。在工业 4.0 背景下，智能化装备呈现出多维度的创新趋势：产品谱系持续扩展，作业场景突破传统工业边界，运动控制算法持续迭代，在线识别系统全面实现数据互联。然而，鉴于工业机器人普遍暴露于粉尘、腐蚀性介质等极端作业环境，加之高负荷动态工况下的机械损耗，设备可靠性面临严峻挑战。这类系统性故障不仅可能引发生产线级联失效，更会造成亿元级经济损失与潜在工业安全事故。值得关注的是，我国在机器人本体制造与集成应用领域已实现跨越式发展，伺服电机、控制器等基础部件的国产化率显著提升。但核心技术自主化进程仍存在结构性缺陷，以精密减速器为代表的"卡脖子"问题尤为突出。作为决定机器人运动精度与使用寿命的关键传动装置，高精度减速器的研发突破已成为提升工业机器人技术竞争力的战略制高点。因此，构建多学科交叉的减速器创新研究体系，对于完善我国智能制造产业链具有重要理论价值和现实意义^[1]。

在工业机器人多自由度关节系统中，减速器作为动力传递的核心机构，其性能参数直接影响着机械臂的动态性能优化。该部件采用紧凑型结构设计并具备高传动比特性，其振动模态特征与磨损演化规律直接关联着末端执行器的运动轨迹精度。研究表明，传动系统运行过程中的非线性误差累计会导致机器人位姿重复精度衰减，而减速机构关键啮合面的疲劳损伤阈值更是决定了设备整体服役周期的长短。基于此，构建面向减速装置的在线状态监测体系与剩余寿命预测模型，已成为提升工业机器人运行可靠性的重要技术路径^[2]。目前，常用的无损检测方法包括超声检测^[3]、热像技术^[4]等。当前主流的无损检测技术在实际应用中普遍面临技术适配性挑战：超声波探伤技术在应对几何约束型结构时存在空间可达性限制，其有限的波束入射角度易形成检测盲区，难以实现异形构件内部缺陷的三维重构；红外热成像检测系统在机电设备状态监测中受制于热辐射干扰与多物理场耦合分析的复杂性，需通过微型化集成设计与多模态数据融合算法提升其工业

现场适用性；磁粉探伤法是一种典型的无损检测方法，磁粉探伤法的检测深度局限使其仅适用于表面缺陷识别，且受检工件几何特征复杂度与人工判读的主观偏差显著影响检测置信度；

声发射无损检测通过捕获材料内部能量释放产生的弹性波，可在高温、辐射等极端工况下实现全寿命周期监测。相较于依赖周期性抽检的传统方法，AENT技术展现出连续监测能力、微损伤早期预警优势及全结构覆盖特性，为复杂机电系统的状态评估提供创新解决方案^[5]。

因此，本论文将工业机器人减速机作为研究对象，通过采集工业机器人减速机在不同状态下运行的声发射信号，并深入研究声发射信号中蕴含的工业机器人减速机的运行状态信息，进而提出了基于声发射信号的工业机器人减速机故障识别研究。通过对比不同实验方案的结果，以及在不同分析方法的情况下对相同的实验方案进行分析比较等途径，对所提出的基于声发射信号的工业机器人减速机故障识别研究方法的可靠性予以证实。本研究通过实验结果证实了基于声发射信号的工业机器人减速机损伤检测研究方法的可靠性。本论文的研究成果不仅推动了声发射技术在工业机器人损伤监测领域的进一步应用和发展，还为实现工业机器人的健康监测提供了重要的理论依据和技术支持。此外，本研究进一步完善了工业机器人的健康监测方法，对工业机器人系统的安全性评估提供了重要的理论指导和实际应用价值。

1.2 国内外研究现状

1.2.1 工业机器人故障诊断研究现状

故障识别技术最初在 Mehra 等人^[6]的研究里出现，而针对工业机器人的故障识别技术，则最早现身于 Lee 等人^[7]的研究当中。刘伟等对工业机器人的 RV 减速器的声发射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^[8]。Long J 等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，进而实施关节故障识别操作，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识别的精准度^[9]。

Elangovan 等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^[10]。Rescalvo 等提出了一种基于支持向量机的机器人故障识别系统。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^[11]。

近年来，工业机器人故障诊断领域的研究整体呈上升趋势，五年内相关研究成果发文大幅上升，以工业机器人减速器为主题的研究内容占绝大部分，针对工业机器人减速器的故障诊断在其中起主导作用，相关文献的发文量如图 1-1 所示。总而言之，当前针对工业机器人结构故障的研究已然取得了良好的发展成果。立足现有的这些研究成果，若能引入恰当的无损检测方法，便可以构建起一套兼具高精度与高稳定性的状态监测系统。




图 1-1 工业机器人故障诊断研究现状统计图

1.2.2 声发射技术的应用现状

20 世纪 50 年代, 德国科学家凯 (J.Kaiser) 是声发射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, 才会产生明显的声发射信号^[12]。这一发现为利用声发射技术来监测材料的受力历史和故障程度提供了重要的理论基础, 随后, 美国在 1963 年和 1964 年相继成功的将声发射技术应用于火箭筒水压试验检测和北极星导弹检测^[13]。20 世纪 60-70 年代, 美国的 Dunegan 和 Harris 等学者在声发射检测技术的应用开发方面起到了关键作用。他们致力于将声发射技术应用于实际的工业检测中, 如压力容器和管道的检测^[14]。他们的研究推动了声发射传感器技术的改进, 提高了传感器的性能和可靠性。在这个阶段, 出现了专门用于声发射检测的传感器, 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声发射信号^[15]。

20 世纪 80-90 年代, 研究人员在声发射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声发射领域。这些学者利用计算机技术对声发射信号进行复杂的时频域分析, 以提取更准确的信号特征^[16]。自 20 世纪 70 年代初期, 我国科研机构逐步开展声发射技术的研究工作。中国科学院地球物理研究所、山东大学等高等院校和科研单位率先将该技术应用于岩石力学领域的研究, 不仅建立了与地震预测相关的理论体系^[17], 同时还将该技术拓展至复合材料损伤断裂特性的研究领域, 实现了对材料裂纹萌生和扩展过程的实时监测与预测^[18]。这些研究为声发射技术在我国工程领域的应用奠定了重要基础。与此同时, 部分公司研制出了一些便携式的声发射检测仪器, 此类仪器可用于工业现场对大型设备展开检测工作。

在声发射检测设备的发展历程中, 美国 PAC 公司于 20 世纪 80 年代中期率先研制出第二代声发射源定位检测系统。该设备具有结构紧凑、便于携带的优势, 同时集成了先进的检测与数据分析软件, 能够实现对被测构件声发射源的实时定位与分析, 为声发射技术的现场应用提供了重要技术支持^[19]。

随着技术的不断发展, 自 20 世纪 90 年代以来, 包括美国 PAC 公司、德国 Vallen Systeme 公司以及我国广州声华公司、北京软岛公司在内的多家企业相继开发出多通道声发射采集与分析系统。这些新型系统在设备小型化和处理速度方

面取得显著进步，其在工业领域的应用范围不断扩大^[20]。

声发射技术在多种领域都有应用，其中运用声发射技术进行故障诊断在现有研究中占主导地位，在管道泄露、压力容器、滚动轴承、混凝土、复合材料等研究对象中运用最为广泛。相关领域的研究发文量如图 1-2 所示。




图 1-2 声发射技术应用研究现状统计图

1.2.3 声发射信号的故障特征提取研究现状

时频分析是一种基于时间-频率联合分布函数的信号处理技术，其核心在于构建能够同时反映信号时间特性和频率特征的联合函数，从而准确描述信号能量在时频域上的分布特征^[21]。在相关研究中，蒋富康等人则将 CEEMDAN 与卷积神经网络联合用于轴承故障识别，达成了更高的准确率和更快的拟合速度的故障识别结果^[22]。尚海昆等人提出了一种基于 CEEMDAN 的变压器振动信号分析方法，该方法运用 CEEMDAN 对原始的变压器振动信号进行分解，利用相关系数提取有效的分量，并对信号进行重构，成功获取了消噪后的结果，进而提取出了变压器振动信号的有效信息^[23]。

张洪梅等人提出了一种基于最大相关峭度解卷积（Maximum Correlated Kurtosis Deconvolution, MCKD）和 CEEMDAN 的轴承故障特征提取方法，通过以特征能量比作为目标函数来探寻最优的滤波器长度，依据峭度准则选取 IMF 并进行信号重构，最后通过包络谱提取故障特征，实现了滚动轴承微弱故障特征

的提取^[24]。周浪等人鉴于 CEEMDAN 存在计算效率低、对内存要求较高等问题，提出了一种融合分段聚合近似（Piecewise Aggregate Approximation, PAA）与完全自适应噪声集合经验模态分解（Complete Ensemble Empirical Mode Decomposition With Adaptive Noise, CEEMDAN）的滚动轴承故障识别方法。通过 PAA 算法和 CEEMDAN 分解实现对滚动轴承故障特征的精确提取与识别。这一方法通过多步骤的信号处理与特征提取，有效提高了故障识别的准确性和可靠性^[25]。Wang L 等人针对高噪声环境下变压器声纹信号的去噪技术展开研究，对小波包变换和小波变换的去噪效果进行了比较，分别对声纹信号的高频部分进行三层分解，结果表明小波包去噪效果优于小波变换，这有利于后续故障信号的提取和识别^[26]。Jiang 等人利用小波包分解对工业机器人 AE 信号进行降噪处理，之后通过 CEEMDAN 分解进行特征提取，再结合支持向量机对信号进行分类和识别^[27]。王海龙等人针对隧道爆破振动信号，引入多尺度排列熵并结合 SG，提出了一种 CEEMDAN 和小波包联合降噪方法，显著提高了信号的降噪效果^[28]。

变分模态分解（Variational Mode Decomposition, VMD）是由 Dragomiretskiy 等人^[29]提出的一种创新性信号处理技术。该方法采用完全非递归的自适应计算框架，其理论基础建立在变分问题的构造与求解之上。VMD 的核心优势在于能够有效地将复杂非线性时间序列分解为多个具有不同中心频率的固有模态函数（Intrinsic Mode Functions, IMF）。与传统的信号分解方法相比，VMD 在处理非平稳信号时表现出显著的优势，不仅具有更强的自适应能力，还能获得更为精确的分解结果。这种特性使其在分析具有复杂频率成分的非平稳时间序列时展现出卓越的性能。

目前，VMD 方法已在众多领域广泛应用，涵盖机械系统损伤识别、轴承故障检测、机电设备寿命预测等领域。例如，王祖荫等研发出一种基于 VMD 和快速谱峭度的滚动轴承故障特征提取方法，有效攻克了从易受环境噪声干扰的信号中提取故障特征的难题^[30]。刘长良等运用 VMD 轴承早期故障信号进行预处理，依据峰度准则选取峰度值较高的分量实施重构，成功提取了轴承早期故障信号^[31]。相关研究显示，VMD 算法中的模式数 K 和惩罚因子 α 对分解结果有着显著的影响^[32]。如果 K 取值过大，很可能会引发过度分解的情况， K 值取值果小时又会造成不充分现象。同理， α 值若过大会致使频带信息缺失 α 值过小则出现信

息冗余的现象。由此可见，明确提出 $\{K, \alpha\}$ 的最优参数组合是达成有效分解的关键所在^[33]。

为提升 VMD 分析的精准度，研究人员研制出了自适应算法，以此来优化关键参数之间的相互作用。周翠红等运用最小包络熵当作优化函数，从而确定 VMD 的最优参数组合。他们借助粒子群优化（Particle Swarm Optimization, PSO）算法来设定惩罚参数和组件数量，接着运用优化后的参数对故障信号进行处理^[34]。Kopsinis 等采用遗传变异粒子群算法开展参数优化工作，并利用 VMD 对故障信号加以处理。基于滚动轴承的故障机理研究，研究者们进一步提出了一种结合样本熵的分析方法。该方法通过计算振动信号的样本熵值，有效量化了信号的复杂度特征。研究结果表明，通过样本熵测量得到的信号复杂度指标与故障机理分析具有高度一致性，这一发现验证了样本熵在故障识别中的有效性和可行性^[35]。何杰等提出了一种借助天鹰优化算法（Aquila Optimizer, AO）的优化方法，将各分量的最小样本熵选作为适应度函数来对 VMD 进行优化提取往向压缩机故障特征^[36]。

卷积神经网络是一种典型的前馈神经网络结构^[37]。目前，CNN 已在图像处理和自然语言处理等领域获得广泛应用^[38]。在机械设备状态监测与故障识别领域，基于信号处理的 1D-CNN（一维卷积神经网络）和 2D-CNN（二维卷积神经网络）均展现出显著优势。其中，1D-CNN 在传感器信号处理方面表现出巨大的应用潜力^[39]。在具体应用方面，张辉等提出了一种基于快速傅里叶变换和 CNN 的滚动轴承故障识别方法。该方法首先将振动信号转换为二维频谱图，随后利用 CNN 进行分类识别，实现了故障位置和严重程度的同步识别^[40]。

针对一维信号输入可能存在的特征提取不充分问题，赵志宏等创新性地提出了结合 CNN 和马尔可夫转移场的轴承故障识别方法^[41]。陈宇航等则开发了基于 1D-CNN 的故障识别模型，有效避免了传统人工信号处理过程中故障信息的丢失问题^[42]。在工程应用方面，赵浩天等基于 CNN 开发了一种数据驱动的控制力矩陀螺故障识别方案，该方案在不同滑动窗口参数下均能实现较高的训练精度^[43]。Chen Y 等提出了多信号 CNN 融合模型，通过整合多传感器信息，显著提升了风电机组故障识别的分类精度和模型稳定性^[44]。Guo P.f. 等则提出了基于多通道 1D-CNN 的水力加载系统故障识别方法，该方法实现了特征提取与分类的有机结合，

解决了健康状态误判问题，为复杂系统的故障诊断提供了新的解决方案^[45]。

在分类识别领域，普运伟等人提出了一种雷达辐射源信号识别方法，将模糊函数主脊坐标变换与 CNN-BiLSTM 相结合^[46]。在深度学习模型的应用与创新方面，研究者们提出了多种基于注意力机制和双向长短期记忆网络的改进方法。陈巧红等开发了一种用于语音情绪识别的混合模型，该模型结合了混合分布注意力机制与 CNN-BiLSTM 架构，在识别准确率方面优于传统方法^[47]。陶志勇等基于 BiLSTM 网络，提出了一种改进的注意力机制端到端短文本分类模型，提升了文本分类性能^[48]。

在机械设备故障识别领域，靳莹等提出了一种基于多层 BiLSTM 的装甲车辆柴油机喷油器故障识别方法，实现了故障特征的准确识别^[49]。在模式识别与动作分析方面，张光锐提出了一种创新的人体动作识别算法，融合了图卷积神经网络和基于注意力机制的 BiLSTM 网络，提高了动作识别的准确性^[50]。张天琦通过在 BiLSTM 模型前端引入线性判别分析，有效降低了输入数据的维度，不仅加快了模型收敛速度，还提升了分类精度，其综合性能优于单一 BiLSTM 模型^[51]。韩广等提出了一种铁路行车事故文本等级分类方法，该方法采用双通道 BiLSTM 网络结合注意力机制，提高了事故文本分类的准确性^[52]。在声发射检测技术领域，研究者们积极探索将 BiLSTM 与声发射技术相结合的应用。这些研究包括：锅炉管泄漏检测^[53]、金属加工和铣削过程中的刀具磨损监测^[54]、基础设施损伤评估^[55]、天然气管道裂纹检测^[56]，以及天然纤维增强聚合物复合材料的性能测试^[57]。这些应用充分展示了 BiLSTM 在声发射信号处理和故障特征提取方面的优势，为工业检测提供了新的技术手段。

总而言之，针对声发射故障诊断的研究涉及到多种方法的运用，其中由于声发射信号在处理非线性非平稳信号中有显著的优势，在滚动轴承故障诊断中有较多运用，以特征提取为主题的研究也较为广泛，以特征频率、小波变换、经验分解、卷积神经网络为研究方法的运用也比较广泛。具体研究成果统计如图 1-3 所示。




图 1-3 声发射故障特征提取研究现状统计图

1.3 主要内容和章节安排

本论文以工业机器人减速器为研究对象,采用声发射技术对工业机器人减速器的机械结构故障识别进行研究,旨在为工业机器人减速器故障识别提供新思路并提高故障识别精度,从而为工业机器人稳定运行和人身安全提供保障,最大程度的避免生产事故的发生。本文包含自建平台和实际平台,以工业机器人为研究背景,减速器为分析对象,基于声发射信号对减速器故障进行进一步的研究分析,技术路线如图 1-4 所示。

本文具体内容如下所示:

第 1 章主要内容是介绍了论文的研究背景和意义,对现有针对工业机器人减速器故障识别问题的研究进行介绍,对声发射技术在工业机器人减速器故障识别领域的研究现状进行了全面总结和分析。

第 2 章介绍了论文所涉及相关理论知识。

第 3 章在传统信号降噪处理方法的基础上,通过融合 WT 和 CEEMDAN 方法,提出了一种声发射信号降噪流程,利用模拟信号验证并分析了所提方法的有

效性，并将方法应用在实际信号中，根据实验结果验证了提出方法在实际运用中的有效性。提出了一种采用 HO 算法优化的 VMD 的降噪方法用于声发射信号的降噪，并将 MFDFA 运用于减速器行星轮声发射信号的特征提取，最后通过多重分形参数波形分布进行故障识别。通过对实际减速器声发射信号的分析结果验证了提出方法在工业机器人减速器故障识别中有效性和优势。

第 4 章通过从一维时间和二维图像的角度对声发射信号故障辨识，提出了一种 CNN 和 BiLSTM 并行的故障识别网络。针对本研究所作降噪方法和识别方法在现实中的运用效果，通过真实场景对所提方法进行了验证；通过对实时运行的工业机器人减速器进行声发射信号采集，得到了真实场景中的故障声发射信号，并采用本文所提方法进行故障识别，结果验证了本文所提方法在真实场景中的有效性。

第 5 章总结论文的主要研究内容和创新点，并对后续研究工作进行了展望。




图 1-4 本文技术路线图

第2章 本文相关理论基础

2.1 声发射信号处理技术相关理论

2.1.1 连续小波处理方法基本原理

小波去噪（Wavelet Denoising, WD）的常见操作流程是借助离散小波变换对信号实施分解。在经过分解处理后，信号中不同维数的信息得以保留。随后，通过设定合适的阈值，并在此基础上进行小波重构，进而达成信号去噪的目的。关于离散小波变换（Discrete Wavelet Transform, DWT），其原理为：

$$DWT_x(a, b) = \int x(t) \cdot \Psi_{a,b}(t) dt \quad (2.1)$$

式中， 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， $x(t)$ 为给定信号。

对于降噪后的子小波，通过式（2.1）进行重构：

$$x(t) = \sum_{a,b} DWT_x(a, b) \psi_{a,b}(t) \quad (2.2)$$

连续小波去噪的定义为设 $x(t) \in L^2(R)$, $\psi(t)$ 是母小波， a 为尺度因子，且 $a > 0$, τ 反映位移，其值可正可负，标号*表示复数取共扼， $x(t)$ 在时域中的连续小波变换式如 F：

$$WT_x(a, \tau) = \frac{1}{\sqrt{a}} \int x(t) \bullet \psi\left(\frac{t-\tau}{a}\right) dt \quad (2.3)$$

频域实现的基础是连续小波变换的频域表达式，其定义式如下：设 $x(\omega)$ 是 $x(t)$ 的 Fourier 变换， $\psi(\omega)$ 是 $\psi(t)$ 的 Fourier 变换， a 以及 τ 的定义同上，则 $x(t)$ 在频域中的连续小波变换表达式如下：

$$WT_x(a, \tau) = \frac{\sqrt{a}}{2\pi} \int X(\omega) \bullet \psi^*(a\omega) \bullet e^{j\omega\tau} d\omega \quad (2.4)$$

2.1.2 完全集成经验模态分解方法基本原理

完全集成经验模态分解与自适应噪声是一种用于处理非线性和非平稳信号

的先进信号分解技术。它通过引入自适应噪声和多次迭代的方式，有效解决了传统经验模态分解中的模态混叠问题，提高了分解的准确性和稳定性。CEEMDAN 的核心思想是在每次迭代中，将白噪声添加到经验模态分解后的 IMF 中。这种逐步添加噪声的方式能够有效减轻白噪声对分解结果的影响，从而提高分解的精度和稳定性。与经验模态分解不同，CEEMDAN 在每一阶 IMF 分量获得后立即进行平均处理，而不是对所有 IMF 量进行总体平均。这种逐阶平均处理方式可以有效减少白噪声的影响。以下是 CEEMDAN 算法的详细步骤及公式：

信号为 $x(t)$ ，迭代次数设定为 N ，集成次数为 K 。高斯白噪声为 $\varepsilon_j \delta_i(t) (i=1,2,3,\dots,K)$ ， $\varepsilon_j (j=1,2,3,\dots,N)$ 为高斯白噪声权值系数， $\varepsilon_j \delta_i(t)$ 为添加的第 i 此白噪声。生成信号 $x_i(t)$ 。

$$x_i(t) = x(t) + \varepsilon_j \delta_i(t) \quad (2.5)$$

对扰动信号进行 EMD 分解，得到第一组模态分量并取其均值作为第一个分量并更新残余信号：

$$IMF_1(t) = \frac{1}{K} \sum_{i=1}^K IMF_1^i \quad (2.6)$$

$$r_1(t) = x(t) - IMF_1(t) \quad (2.7)$$

对分解后得到的第 j 阶段的残余信号添加白噪声后继续进行 EMD 分解。

$$IMF_j(t) = \frac{1}{K} \sum_{i=1}^K E_j(r_{j-1}(t) + \varepsilon_{j-1} E_{j-1}(\delta_i(t))) \quad (2.8)$$

$$r_j(t) = r_{j-1}(t) - IMF_j(t) \quad (2.9)$$

式中 $IMF_j(t)$ 为第 j 个 IMF， E_{j-1} 为对信号进行 EMD 分解后的第 $j-1$ 个 IMF， ε_{j-1} 为对 $j-1$ 段的残余信号加入噪声的权值系数。

重复添加白噪声，直到残余信号无法分解出有意义的 IMF，分解结束，此时原信号 $x(t)$ 可表示为：

$$x(t) = \sum_{j=1}^N IMF_j(t) + r_N(t) \quad (2.10)$$

2.1.3 变分模态分解基本原理

变分模态分解属于一种具备自适应特性且准正交的信号分解手段。凭借这一方法，多分量调幅调频信号能够被一次性拆解成多个单分量调幅调频信号。现假

定原信号 $x(t)$ 属于多分量信号，且该信号会被分解成为 k 个 IMF。同时，各个 IMF 所对应的中心频率为 ω_k ，在此情况下，所构建的约束变分模型如下：

$$\begin{aligned} \min_{\{u_k\}, \{\omega_k\}} & \left\{ \sum_k \left\| \partial_t \left[\left(\sigma(t) + \frac{j}{\pi t} \right) * u_k(t) \right] \exp(-j\omega_k t) \right\|_2^2 \right\}; \\ \text{subject to} & \sum_k u_k(t) = x(t) \end{aligned} \quad (2.11)$$

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。

为了把式 (2.11) 中的有约束最优化问题转化成无约束最优化问题，可引入一个二次惩罚函数项 α 以及拉格朗日乘子项 λ ，通过式 (2.12) 来实现这一转化过程：

$$\begin{aligned} L(\{u_k(t)\}, \{\omega_k(t)\}, \lambda) &= \alpha \sum_k \left\| \partial_t \left[\left(\sigma(t) + \frac{j}{\pi t} \right) * u_k(t) \right] \exp(-j\omega_k t) \right\|_2^2 \\ &+ \left\| x(t) - \sum_k u_k(t) \right\|_2^2 + \left\langle \lambda(t), x(t) - \sum_k u_k(t) \right\rangle. \end{aligned} \quad (2.12)$$

借助交替方向乘子算法对各个 IMF 以及中心频率不断进行更新操作，进而求解出上述式子中增广拉格朗日函数的鞍点。而这个鞍点就是我们所求解问题的最优解，基于此，便能够依据式 (2.13) 对原始信号分解处理：

$$\hat{u}_k^{n+1}(\omega) = \frac{\hat{x}(\omega) - \sum_{i \neq k} \hat{u}_i(\omega) + \frac{\hat{\lambda}(\omega)}{2}}{1 + 2\alpha(\omega - \omega_k)^2} \quad (2.13)$$

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。

当 IMF 分量及其中心频率更新后，可以利用式 (2.14) 来更新拉格朗日乘子 $\hat{\lambda}$ ，其计算公式表达如下：

$$\hat{\lambda}^{n+1}(\omega) = \hat{\lambda}^n(\omega) + \tau \left(\hat{x}(\omega) - \sum_k \hat{u}_k^{n+1}(\omega) \right) \quad (2.14)$$

最终，一旦满足式 (2.15) 所呈现的迭代收敛准则，信号的变分模态分解 (VMD) 过程便宣告结束，具体来说就是：

$$\sum_k \left\| \hat{u}_k^{n+1} - \hat{u}_k^n \right\|_2^2 / \left\| \hat{u}_k^n \right\|_2^2 < \varepsilon \quad (2.15)$$

式中, ε 的值一般会设置成 10.6, 且所有的 IMF 分量都可以通过上述步骤而得到。运用交替方向乘子算法对式 (2.15) 进行计算, 所得到的鞍点, 一般会被界定为该约束变分模型的最优解。

2.2 河马优化算法基本理论

河马优化算法 Mohammad Hussein Amiri 等人根据河马的三种固有行为方式提出的一种新型算法。

HO 的初始化过程涉及生成决策变量的向量, 公式如下:

$$X_i(:, i) = lb_i + r_1 \times (ub_i - lb_i) \quad (2.16)$$

式中, $X_i(:, i)$ 表示第 i 个候选解的位置, r_1 表示 [0,1] 之间随机数, ub 和 lb 分别表示第 i 个决策变量的下界和上界。

河马在通常情况下会以雄性河马为主导聚集在安全范围内, 成年后的雄性河马会被驱离安全区并建立自己的安全区域, 雄性河马在安全区内的位置有以下公式所示:

$$X_i^{Mhippo} = X(i, :) + r_2 \times (Dhippo - I_1 X(i, :)) \quad (2.17)$$

式中, X_i^{Mhippo} 为雄性河马, $Dhippo$ 为具有最佳适应度的河马。 r_2 是 [0,1] 之间随机数, I_1 表示 [1,2] 之间随机数。

当未成年河马远离母河马, 种群中河马在在群体中的位置为:

$$X_i^{Whippo} = \begin{cases} X(i, :) + r_3 \times (Dhippo - I_2 MG_i) & T > 0.6 \\ X(:, i) & else \end{cases} \quad (2.18)$$

式中, X_i^{Whippo} 为雌性或未成年河马的位置, r_3 表示随机向量, MG_i 表示随机选择河马的平均值, T 为选择概率; I_2 表示 [1,2] 之间随机数。

河马收到攻击的主要防御手段为转向捕食者并通过叫声防止捕食者的接近, 采取防御行为时的位置表为:

$$X_i^{Hippo} = \begin{cases} \mathbf{RL} \oplus predator_j + \left(\frac{f}{c - d \times \cos(2\pi g)} \right) \left(\frac{1}{\mathbf{D}} \right), & F_{predator_j} < F_i \\ \mathbf{RL} \oplus predator_j + \left(\frac{f}{c - d \times \cos(2\pi g)} \right) \left(\frac{1}{2\mathbf{D} + r_4} \right), & F_{predator_j} > F_i \end{cases} \quad (2.19)$$

式中, X_i^{Hippo} 表示捕食者在河马领地中的位置, $\mathbf{RL}$ 为具有 levy 分布的随机向量,

$predator_j$ 表示捕食者在搜索空间中的位置， D 表示河马与捕食者之间的距离， c 为[1,1.5]间的随机数， d 为[2,3]间的随机数， g 为[2,4]间的随机数， r_4 为 $1 \times m$ 的随机变量。

河马在无法进行防御捕食者时，会离开并寻找另一安全区域以避免捕食者的伤害。

$$X_i^{hippo\epsilon} = X_{\min}(i, \cdot) + r_5 \left(\frac{lb_i}{t} + r_6 \left(\frac{ub_i}{t} - \frac{lb_i}{t} \right) \right) \quad (2.20)$$

式中， $X_i^{hippo\epsilon}$ 表示河马寻找安全区域过程中的位置， r_5 表示[0,1]间的随机数， r_6 为符合正态分布的随机数， t 为当前迭代次数。

2.3 多重分形去趋势波动分析原理

MF DFA 算法是一种典型的多重分形算法，该方法对一维时间序列具有良好的分析处理效果，处理速度快。本文采用 MF DFA 算法对去噪后的声发射信号进行处理，得到其分形结果。具体过程包括以下步骤：

假设非线性平稳信号为 $x(k)$ ， $k=1,2,\dots,N$ ；则去均值的和序列 $Y(i)$ 为：

$$Y(i) = \sum_{k=1}^i (x(k) - \bar{x}) \quad (2.21)$$

式中， $\bar{x}$ 表示 $x(k)$ 的均值。

将序列 $Y(i)$ 按照长度 $s(k+2 \leq s \leq N/4)$ 分割为互不重叠的分段，则共有 $m=N/s$ 个分段，由于 $Y(i)$ 长度未免是 s 的整数倍，为保证数据没有遗漏，从数据反方向在重复一次该过程，得到 $2m$ 个分段。

采用最小二乘法计算每个片段 $t=1,2,\dots,2m$ 的局部趋势得到多项拟合式 $y_t^{(i)}$ ，并计算每个片段与 $y_t^{(i)}$ 的方差，然后对所有分段的方差求均值，得到 q 阶波动函数：

$$F_q(s) = \left\{ \frac{1}{2m} \sum_{t=1}^{2m} [F^2(s, v)]^{q/2} \right\}^{1/q} \quad (2.22)$$

若信号存在自相似性，则波动函数 $F_q(s)$ 与 s 之间呈幂律关系：

$$F_q(s) \sim s^{h(q)} \quad (2.23)$$

式中，通过拟合 $F_q^{(s)}$ 和 s 的斜率可得到广义 Hurst 指数。 $\tau(q)$ 为质量指数：

$$\tau(q) = qh(q) - 1 \quad (2.24)$$

通过质量指数的变化可判断信号是否具有多重分形特征，若 $\tau(q)$ 随 q 的变化而变化，则信号具有多重分形特征，否则具有单分形特征。

经过 Legendre 变化，可得到奇异指数 α 和多重分形谱函数：

$$\alpha = h(q) + qh'(q) \quad (2.25)$$

$$f(\alpha) = q[\alpha - h(q)] + 1 \quad (2.26)$$

通过多重分形谱函数 $f(\alpha)$ 的值可以判断信号的多重分形特征，其中 $f(\alpha)$ 的峰值记作， $f(\alpha) \geq 0$ 的区间记为 $[h(q)_{\max}, h(q)_{\min}]$ 。 $h(q)$ 与 $f(\alpha)$ 之间的关系为：

$$f(\alpha) = q^2 h'(q) + 1 \quad (2.27)$$

2.4 卷积神经网络基本理论

在卷积神经网络的架构中，输出特征图的每个神经元仅与输入特征图的局部区域建立连接关系。具体而言，每个神经元通过其对应的权重参数，对局部感受野内的输入数据进行加权求和运算，并在此基础上添加偏置项，最终获得该神经元的激活值。这种局部连接和权值共享的计算模式本质上就是卷积运算，卷积神经网络也因此得名。图 2-1 展示了这种具有层次化特征提取能力的网络结构示意图，其中清晰地呈现了卷积层通过局部连接实现特征提取的核心机制。




图 2-1 CNN 网络结构图

卷积运算的核心机制在于将输入特征图的每个元素与卷积核对应位置的元素进行逐点相乘，并将所有乘积结果进行累加，从而生成新特征图的一个输出值。这一过程可以表示为数学上的加权求和运算。对于一维卷积层的计算原理，其数学表达式可参考公式（2.28）：

$$y_i^k = f_{\text{cov}}(w_k \otimes x_i + b_k) \quad (2.28)$$

图 2-2 直观地展示了卷积运算的过程。该图的第一部分显示了一个 5×5 的输入矩阵，第二部分则展示了一个 3×3 的卷积核结构。为了确保卷积核能够在特征图上充分滑动并提取完整的特征信息，输入矩阵被划分为网格形式。在滑动步长设定为 1 的情况下，如第三部分所示，卷积核沿着特征图从左到右逐步移动。在每次移动过程中，系统会执行矩阵元素的对应位置相乘运算，随后对乘积结果进行累加。当卷积核完成在整个特征图上的遍历后，最终生成如第四部分所示的输出特征图。



图 2-2 卷积操作图

特征图像中数值 A 的计算方式如公式 (2.29) 所示，具体如下：

$$A_{i,j} = f\left(\sum_{q=0}^{Q-1} \sum_{m=0}^{F-1} \sum_{N=0}^{F-1} w_{q,m,n} x_{q,i+m,j+n} + w_b\right) \quad (2.29)$$

式中， Q 、 F 、 $W_{q,m,n}$ 、 w_b 分别为输入、卷积核尺寸、通道对应参数值。特征的计算公式如公式 (2.30) 和 (2.31) 所示。

$$W_2 = \frac{W_1 - F + 2P}{S} + 1 \quad (2.30)$$

$$H_2 = \frac{H_1 - F + 2P}{S} + 1 \quad (2.31)$$

式中， W_1 和 W_2 为图像大小， W_2 和 H_2 是特征图像大小， F 、 P 、 S 分别卷积核的宽度、补零层数和滑动步长。

当滑动步长设定为 2 时，卷积核无法按照该步长完整滑动至输入图像的边缘区域，进而会出现信息遗漏的情况。为解决这一问题，可对输入图像执行数据填充操作（也就是补零操作，即 **Padding**），具体情形可参照图 2-3。进行补零操作的主要目的在于对输出尺寸加以调整，确保输出维度与输入维度保持一致，以此来降低因卷积操作而造成的边缘信息损失。




图 2-3 数据填充示意图

卷积操作通常包含三种不同的模式，每种模式对卷积核的移动范围和输出特征图的尺寸有不同的限制，具体如下：

Full Mode（全填充模式）是一种卷积操作模式，其特点是只要卷积核与原始图像有部分重叠，便开始进行卷积运算。在卷积核与图像边缘刚开始接触时，未重叠的部分会通过补零（zero-padding）的方式填充。这种模式下，输出特征图的尺寸等于原始图像的尺寸加上卷积核的尺寸再减 1。例如，对于一个 5×5 的原始图像和一个 3×3 的卷积核，按照 Full Mode 进行卷积后，输出特征图的尺寸为 $5+3-1=7$ ，即得到一个 7×7 的特征图。Full Mode 能够保留更多的边界信息，适用于需要完整提取图像特征的场景。

Same Mode（同尺寸模式）是一种卷积操作模式，其特点是卷积核的中心点（K）与原始图像的边缘对齐时开始进行卷积运算。与 Full Mode 不同，Same Mode 在卷积过程中会对超出图像边界的区域进行补零操作（zero-padding），以确保输出特征图的尺寸与原始图像的尺寸相同。具体而言，卷积核的移动范围比 Full Mode 更小，最终输出结果是 Full Mode 卷积结果中与原始图像尺寸相同的中心部分。例如，对于一个 5×5 的原始图像和一个 3×3 的卷积核，按照 Same Mode 进行卷积后，会从 Full Mode 生成的 7×7 特征图中截取中心的 5×5 部分作为最终结果。这种模式在需要保持输入输出尺寸一致的场景中非常实用。

Validate Mode（验证模式）是一种卷积操作模式，其特点是要求卷积核必须完全覆盖原始图像的每个有效区域才能进行卷积运算。与 Same Mode 相比，Validate Mode 的卷积核移动范围更小，因此生成的特征图尺寸也会相应缩小。具

体而言，输出特征图的尺寸计算公式为：原始图像的尺寸减去卷积核的尺寸再加 1。例如，对于一个 5×5 的原始图像和一个 3×3 的卷积核，按照 Validate Mode 进行卷积后，输出特征图的尺寸为 $5-3+1=3$ ，即得到一个 3×3 的特征图。这种模式通常用于需要精确控制输出尺寸的场景，同时能够减少边界效应对结果的影响。




图 2-4 卷积的三种模式

池化层即下采样层，它的作用是对输入进行下采样处理。通过下采样处理后的输入图像，其中的杂余信息被去除，输入图像中的有效信息被保留。并且优化网络的结构，降优化网络的程度，减少网络的计算压力，网络训练的时长也随之大幅减少，网络在训练过程中的过拟合也会随之优化。常用的池化处理有均值处理、最小处理、和最大处理。最大池化过程如图 2-5 所示。




图 2-5 池化操作示意图

激活函数 (Activation Function) 是神经网络中连接上层节点输出与下层节点输入的关键组件。它的主要作用是通过激活特定神经元并将信息传递到下一层，从而引入非线性特性，增强网络的表达能力。以下是几种常见的激活函数：

Sigmoid 激活函数：由于其单调递增且反函数同样单调递增的特性，Sigmoid 函数常被用作神经网络的阈值函数。它将输入的连续实数值映射到 $[0,1]$ 区间内，实现了对神经元输出的归一化处理。这种特性使得 Sigmoid 函数在二分类任务中

尤为适用。其数学表达式如公式（2.32）所示，函数曲线如图 2-6 所示。

$$Y = \text{sigm}(x) = \frac{1}{1 + e^{-x}} \quad (2.32)$$




图 2-6 Sigmoid 函数曲线图像

Tanh 激活函数是在 Sigmoid 函数的基础上改进而来，旨在解决 Sigmoid 函数输出均值不为零的问题。尽管 Tanh 函数的曲线形状与 Sigmoid 函数相似，但其输出范围在 $[-1,1]$ 之间，且以零点为中心对称，从而有效改善了 Sigmoid 函数输出不对称的缺陷。由于 Tanh 函数的输出值集中在零点附近，它能够更好地处理具有强负值、中性值和强正值的输入数据。与 Sigmoid 函数相比，Tanh 函数具有更快的收敛速度和更优的性能表现。Tanh 激活函数的数学表达式如公式（2.33）所示，其函数曲线如图 2-7 所示，直观展示了其对称性和非线性特性。

$$Y = \tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (2.33)$$




图 2-7 Tanh 函数曲线图像

ReLU 激活函数是最常见的激活函数。它可以有效的解决梯度消失问题，提

高网络在训练中收敛的速率和时长，计算的复杂程度也会随着降低。针对含噪声的输入，即使在缺失监督的条件下，也有很好的表现。ReLU 激活函数的数学表达式如公式（2.34）所示，其函数曲线如图 2-8 所示，直观展示了其简单而高效的非线性特性。

$$y = \text{ReLU}(x) = \text{Max}(0, x) = \begin{cases} 0, & x \leq 0 \\ x, & x > 0 \end{cases} \quad (2.34)$$




图 2-8 ReLU 函数曲线图像

全连接层（Fully Connected Layer, FC）在神经网络中承担着类似于“分类器”的功能。其主要作用是将网络中学习到的分布式特征表示映射到样本的标记空间。这一过程主要通过矩阵乘法运算实现，并结合激活函数（如 ReLU、Sigmoid 等）引入非线性映射能力。全连接层通过权值矩阵将前一层的局部特征进行全局整合，形成完整的特征表示，从而为后续的分类或回归任务提供支持。其具体结构如图 2-9 所示，清晰地展示了特征从输入到输出的转换过程。




图 2-9 全连接层

2.5 双向长短时记忆网络基本理论

长短时记忆网络（Long Short-Term Memory Network, LSTM）是由美国学者 Sepp Hochreiter 和 Schmidhuber Jurgen 等人为解决在训练过程中出现的梯度爆炸问题而做出的改进网络，其本质是循环神经网络，通过输入门、遗忘门、和输出门这种特有的结构提升对时间序列的处理能力。通过这种结构可以有选择性的对未来信息和历史信息进行筛选和清除，有效的优化了循环神经网络针对时间序列的处理能力。LSTM 的框架结构如图 2-10 所示，清晰地展示了其内部工作的机制。




图 2-10 门结构框架图

当前时间步的输入数据 x 与前一个时间步的隐藏状态 $h_{(t-1)}$ 同时输入时，LSTM 中的各个门结构（包括遗忘门、输入门和输出门）都会被激活。Sigmoid 函数使用输入 x 作为先前输出 $h_{(t-1)}$ 。当遗忘门输出值接近 0 时，表示对应的信息将被遗忘；而接近 1 时，则表示信息将被保留。在这一机制中，模型更倾向于保留与当前时间步更接近的信息。遗忘门的具体计算过程如公式 2.35 所示，由当前输入、前一隐藏状态以及相应的权重和偏置项决定。

$$f_t = \sigma(w_f \cdot [h_{t-1}, x_t] + b_f) \quad (2.35)$$

式中， w 和 b 表示们单元的权重和偏差， σ 代表 sigmoid 的激活函数，激活函数的输入为当前得的输入 x_t 和之前的 $h_{(t-1)}$ 。

在 LSTM 的计算过程中，sigmoid 函数将当前输入和前一时刻的隐藏状态作为输入，并将其映射到 [0,1] 区间内。输入门通过 sigmoid 函数来决定哪些信息需要更新，其中接近 0 的值表示对应信息不重要，而接近 1 的值则表示信息非常重要。输入门的具体计算过程如公式（2.36）所示。

$$i_t = \sigma(w_i[h_{t-1}, x_t] + b_i) \quad (2.36)$$

式中, w 和 b 表示们单元的权重和偏差, σ 代表 sigmoid 的激活函数, 激活函数将当前的输入 x_t 和前一时刻的 h_{t-1} 作为输入。

接下来, 将当前输入和前一时刻的隐藏状态作为输入, 通过 $\tanh$ 双曲正切函数进行非线性变换。在此基础上, 开始计算当前时间步的单元状态。这一过程结合了输入门、遗忘门和候选记忆单元的信息, 通过加权和更新, 生成新的单元状态, 从而为后续的隐藏状态计算提供基础。在这一过程中, $\tanh$ 函数会对输入的数据进行变换处理, 为后续单元状态的计算提供基础数据。

$$C_t = \tanh(w_c[h_{t-1}, x_t] + b_c) \quad (2.37)$$

$$C_t = f_t * C_{t-1} + i_t * C_t \quad (2.38)$$

其中 $\tanh$ 为双曲线正切的激活函数。*是点乘, C_t 是新的存储单元。

在长短时记忆网络的计算过程中, 输出门扮演着至关重要的角色, 它负责控制当前时间步的隐藏状态的输出。具体而言, 输出门通过筛选和过滤记忆单元中的信息, 决定哪些内容将被传递到下一个时间步。最终, 更新后的记忆单元和隐藏状态会被传递到后续的时间步中, 其计算过程如公式 (2.39) 和公式 (2.40) 所示。这一机制确保了 LSTM 能够有效地捕捉和传递长序列中的关键信息, 从而提升模型对时间依赖关系的建模能力。

$$O_t = \sigma(w_o[h_{t-1}, x_t] + b_o) \quad (2.39)$$

$$h_t = o_t * \tanh(C_t) \quad (2.40)$$

式中, o_t 为输出门的值。

Schuster 等人提出的双向循环神经网络 (Bidirectional Recurrent Neural Network, BRNN) 解决了循环神经网络只能使用过去信息的劣势, 其过程是将时间序列通过逆转输入到两个循环神经网络中, 而且输出会叠加通过这种方法可以解决这个劣势。在训练过程中, 前向循环神经网络 (Recurrent Neural Network, RNN) 层和后向 RNN 层的参数更新分别遵循公式 (2.41) 和公式 (2.42) 所描述的规则。这种双向结构的设计使得 BRNN 能够更全面地捕捉序列数据中的历史信息和未来信息, 从而显著提升了模型的表达能力。

通过这种双向输入和更新的机制, BRNN 能够充分利用序列数据中过去和未来的信息, 相比 LSTM 和传统 RNN 在处理某些任务时具有更强的信息捕捉能力

和更好的性能表现，使得模型对序列数据的理解更加全面和深入。

$$h_t = g(w_{xh}x_t + w_{hh}h_{t-1} + b_h) \quad (2.41)$$

$$\vec{h}_t = g(w_{x\vec{h}}x_t + w_{h\vec{h}}h_{t-1} + b_{\vec{h}}) \quad (2.42)$$

式中，输出层激活函数表示为 g 。

在双向循环神经网络中，输出层的输出结果是通过将正向和反向两个 RNN 的结果进行叠加得到的。传统的 RNN 和 LSTM 模型通常只能利用历史信息，而无法捕捉未来信息。为了解决这一问题，BRNN 将输入序列分别以正向和反向的方式输入到两个独立的 RNN 中，这两个 RNN 共享同一个输出层。通过这种方式，BRNN 能够同时保留并利用序列数据的历史信息和未来信息，从而更全面地捕捉序列中的依赖关系。其具体的计算过程由公式（2.43）呈现。

$$y_t = f(w_{hy}h_t + w_{\vec{h}y}\vec{h}_t + b_y) \quad (2.43)$$

其中， f 代表输出层的激活函数。

双向长短时记忆网络（Bi-directional Long Short-Term Memory Network, BiLSTM）是传统 LSTM 的一种扩展形式，属于 BRNN 的范畴。其核心创新在于引入了两个独立的 LSTM 单元，分别以相反的方向处理输入数据序列。具体而言，正向 LSTM 单元负责从前向后分析数据，提取历史信息特征；而反向 LSTM 单元则从后向前处理数据，捕捉未来信息特征。图 2-11 展示了 BiLSTM 的结构示意图，直观地呈现了其独特的双向处理机制。




图 2-11 BiLSTM 结构图

单个 LSTM 仅在单一方向上对数据进行分析，这就导致它只能借助过去的信息来进行处理，在处理一些需要考虑未来信息的复杂序列问题时会存在局限性。

与之形成鲜明对比的是，BiLSTM 具有独特的结构，它由两层 LSTM 构成，一层按照正向顺序处理数据，另一层则以反向顺序处理数据。正向的 LSTM 能够接收并处理输入序列中过去时间步的数据，从中提取历史信息特征；反向的 LSTM 则可以接收并处理输入序列中未来时间步的数据，挖掘其中蕴含的未来信息特征。之后，将这两个隐藏层的输出进行合并操作。在当前时间点，BiLSTM 的隐藏状态是由前向和后向隐藏状态共同组成的，具体的计算方式由公式（2.44）给出。

$$h_t = \vec{h}_t \oplus \hat{h}_t \quad (2.44)$$

式中， $\oplus$ 表示求和。

在模型训练过程中，交叉熵函数常被用作反向传播的损失函数，它通过计算模型的实际输出向量与预测输出向量之间的差异来实现这一目标。为了持续提升模型的性能，通常会采用诸如 Sgdm、Adam、RMSProp、AMSGrad 等优化算法对模型参数进行迭代更新。在本文的研究中，Adam 优化算法被选为默认的优化方法，因其在收敛速度和稳定性方面的优异表现。Adam 算法通过整合多种优化算法的优势，不仅实现了更快的收敛速度，还能够有效控制训练过程中的波动。其核心机制在于，经过偏置校正后，每次迭代的学习率被约束在一个特定范围内，同时利用梯度的一阶矩估计和二阶矩估计动态调整学习率。这一过程的具体计算方式如公式（2.45）所示。通过这种动态调整策略，Adam 算法能够更高效地优化模型参数，从而显著提升模型的训练效果和整体性能。

$$\left\{ \begin{array}{l} m_t = \beta_1 m_{t-1} + (1 - \beta_1) g_t \\ v_t = \beta_2 v_{t-1} + (1 - \beta_2) g_t^2 \\ \hat{v}_t = \frac{m_t}{1 - \beta_1^t} \\ w_t = w_t - 1 + \frac{a}{\sqrt{\hat{v}_t + \epsilon}} m_t \\ g = \frac{1}{m} \nabla_m \sum (g(x^0; w_t), y^t) \end{array} \right. \quad (2.45)$$

式中， m_t 、 v_t 为一阶矩估计和二阶矩估计， m_t 是修正后的值， v_t 为训练集数据， g 为梯度， a 为学习率， ϵ 设置为 10^{-8} 。

在利用 CNN-BiLSTM 网络模型对车轴疲劳裂纹声发射信号进行识别时，该模型通过结合卷积神经网络的局部特征提取能力和双向长短期记忆网络的时序依赖建模能力，能够有效捕捉信号中的空间与时间特征。选择了“交叉熵函数”损失函数作为目标函数，其具体形式如公式（2.46）所示。

$$loss = -\sum i p_i' \log p_i \quad (2.46)$$

式中， p_i 为概率。

在 CNN-BiLSTM 网络模型中，损失函数用于衡量实际输出值与识别输出值之间的差异。当两者接近时，损失值趋近于零。其数学表达式如公式（2.47）所示。

$$loss = \frac{1}{n} \sum_i^n (y_i - \hat{y}_i)^2 \quad (2.47)$$

式中， n 为样本数目， $\hat{y}_i$ 为预测值， y_i 为真实值。当预测值和真实值一致时为 0。

在对模型训练后的识别分类效果进行评估时，召回率(Recall)和准确率(Accuracy)被用作重要的评估指标。召回率和准确率的具体计算分别依照公式（2.48）和公式（2.49）来进行。

$$Recall = \frac{TP}{TP + EN} \quad (2.48)$$

$$Accuracy = \frac{Na}{n} * 100\% \quad (2.49)$$

式中， TP 为模型正确预测的样本数， EN 为模型错误预测的样本数， Na 为被正确识别的样本数， n 为样本的总数。

2.6 本章小结

本章详细的介绍了工业机器人减速器声发射信号的诸多相关理论知识，其中包括连续小波处理、CEEMDAN 处理、变分模态分解、河马优化算法、卷积神经网络和双向长短时记忆网络。信号处理方法方面首先介绍了连续小波处理理论的原理、CEEMDAN 处理方法的原理，接着介绍了河马优化算法的基本原理，然后介绍了卷积神经网络的基本理论和其结构组成、双向长短时记忆网络的基本原理和其结构组成，最后介绍了网络模型的目标参数和评价网络模型的相关指标，通过对以上相关理论的介绍，为之后章节的声发射故障识别研究工作做好基础。

第3章 基于信号分解的减速器故障识别研究

工业机器人在运行过程中,由于载荷变化和长时间零部件之间的机械磨损会产生严重的结构性故障,特别是处理搬运工作和焊接工作的工业机器人,由于搬运机器人通常处于高负载环境下,减速器齿轮之间的磨损以及金属部件的金属疲劳现象会愈发严重,导致机器人出现结构性故障而失去搬运功能,焊接机器人由于需要高频率进行快速启动和急停操作,并且作业要求精度较高,在长时间作业后减速器会出现局部磨损和疲劳裂纹,严重的话会导致减速器失效进而发生安全事故,当产线上的机器人出现故障停止工作时,极易引发整个产线的工作效率甚至是产线失去工作能力,会给工厂带来极大的经济损失和人身安全威胁。声发射检测技术可以对故障减速器在运行过程中产生的声发射信号进行采集和处理,通过对这种特殊的振动信号的分析,可以检测出减速器当前健康状态,并且由于声发射信号可实时在线监测的特点,可以实现对减速器的无损检测,但在工业机器人实际运行环境中存在大量的干扰信号,例如撞击和敲击信号,会直接干扰通过声发射信号进行检测的结果。针对这个问题,本章节首先对信号进行降噪处理以最小化噪声信号对检测结果的影响。后续对声发射信号进行多重分形特征提取并识别减速器故障。

3.1 减速器声发射信号降噪

声发射技术因对材料微观故障具备高灵敏度,已成为工业设备早期故障识别领域的关键工具。在实际工程运用场景中,声发射信号采集环节易遭受多种繁杂噪声干扰,致使信号信噪比(SNR)大幅下降,对故障特征的精准提取以及识别精度产生直接的不利影响。工业机器人减速器多在高动态、多激励的复杂工况下运转,其产生的声发射信号不仅涵盖齿轮啮合、轴承摩擦等目标故障信息,还会混入环境电磁干扰、机械结构振动噪声($<20\text{kHz}$)以及传感器自身电子噪声(如热噪声、量化噪声)。而且,声发射信号呈现非平稳、非线性以及宽频带($50\text{kHz}-1\text{MHz}$)特性,其中微弱的故障特征常被强烈背景噪声掩盖,传统的时域或频域分析手段难以达成有效的特征分离。另外,噪声污染会在特征提取进程中引发模态混叠、能量泄露等状况,进一步致使深度学习模型出现过拟合或者欠拟合问题,

极大程度降低故障分类的准确性。鉴于声发射信号存在多源噪声特性，开发具备自适应能力、高保真的降噪算法，已然成为提升故障识别可靠性的必要前提。本章节提出了基于 CEEMDNA-WT 和 HO-VMD 的两种不同实验环境下的声发射信号降噪方法，其中前者采用折铅信号作为声发射故障信号源在健康状态下的减速器上做出模拟故障实验，后者在存在故障的减速器上做出实际测试，由于实验环境有所改变，因此在实际测试中采集到的信号中噪声特性也发生改变，为判断后续研究中哪种方法更适合当下环境的去噪，对两种方法在实际中的运用效果应做出对比，为后续基于神经网络的减速器故障识别做降噪基础。本章将借助基于声发射信号的处理方法，对声发射信号实施噪声抑制，同时开展故障特征提取与故障辨识工作。

3.1.1 基于完全集成经验模态分解和小波处理的声发射信号降噪方法

减速器是工业机器人的重要组成部分，广泛应用于各种类型工业机器人的传动系统中，声发射信号可以反映工业机器人减速器内部部件因磨损产生的结构性变化，但是由于工业机器人工作环境中往往含有各种背景噪声。因此，在声发射技术的发展过程中，信号去噪起到十分重要的作用。

CEEMDAN 是在经验模态分解与集合经验模态分解的基础上发展而来的一种改进算法。该算法致力于解决原有算法的若干缺陷，该算法能够有效去除分解分量中残留的辅助白噪声，同时减少集合经验模态分解算法集合平均所需的次数。在有限次数的积分条件下，CEEMDAN 能够使重构误差逐渐趋近于零，从而显著提高信号分解的精度。采用 CEEMDAN 进行信号分解时，其优势尤为明显。通过在原始信号中引入正负白噪声对，该方法显著降低了重构信号过程中产生的残余误差，使得重构误差几乎可以忽略不计。这一特性使得 CEEMDAN 能够充分且精准地表征轴承的运行状态。不过，如同许多算法一样，CEEMDAN 并非十全十美，它依然存在着一些不足之处：其分解后的 IMF 分量仍无法完全摆脱部分残余噪声的干扰。而且，在真实的 IMF 分量里，还存在着与实际信号特征不符的虚假分量与之混杂的情况。

小波变换作为一种在时间和频率域上均具有局部化特性的分析方法，能够集中信号中的能量，对信号进行压缩操作，小波降噪的原理为：在信号经过小波处理后，有效信息的小波处理结果会远小于无用信息，通过对小波阈值进行适当的

选取设定，高于此值将被是为噪声并进行清零处理，通过此种方式可实现信号的降噪。

本章节针对小波分析法和 CEEMDAN 分解在声发射信号降噪应用中的不足，采用一种融合 CEEMDAN 算法和小波分析法形成的新的降噪方法，首先利用小波变换对含噪声的声发射信号进行分解，得到最具代表性的小波细节信号，然后利用 CEEMDAN 对代表性细节信号进行分解，得到分解后的 IMF 信号。最后通过频率分析结果对每个 IMF 信号进行评价并重构信号。最后对比重构信号中的噪声含量，证明降噪结果得到了明显的提升。基于小波变换和 CEEMDAN 的减速器声发射信号噪声消除方法。首先，该方法利用小波变换技术将信号分解为多个子信号，并提取具有代表性的子信号 i 和子信号 j ， $i, j=1, 2, \dots, N$ ；其次利用 CEEMDAN 技术对子信号进行处理，选择起主要作用的 IMF i_k 和 IMF j_k ， $k=1, 2, \dots, N$ 分量进行信号重构；最后，将所有代表性子信号的重构信号 Sk ， $k=1, 2, \dots, N$ 相加进行再次重构，即得到最终的去噪信号。具体过程如图 3-1。




图 3-1 WT-CEEMDAN 重构过程图

图中 DWT 表示小波分解的原理公式，IMF 表示经过小波分解后的信号分量，具体内容在第二章节做出解释， $x(t)$ 表示需要分解的输入信号， N 和 K 为 CEEMDAN

分解前需要设定的迭代次数和集成次数，其处理过程如第二章 CEEMDAN 原理过程中所示。

为了证明本文方法的有效性，降噪性能的衡量指标采用信号的信噪比，通过计算信号中的信号功率与噪声功率的比值衡量信号中噪声的含量，其值越大说明信号中噪声成分越低，计算公式为：

$$SNR = \frac{\sum_{i=1}^n s_i^2}{\sum_{i=1}^n n_i^2} \quad (3.1)$$

式中， s_i^2 为第 i 个采样点的幅值， n_i^2 为第 i 个采样点的噪声值。

3.1.2 基于河马算法优化变分模态分解的声发射信号降噪方法

随着制造业的快速发展，工业机器人已经成为智能制造的核心执行单元。行星轮作为工业机器人减速器的主要传动结构，其可靠性和稳定性直接影响机器人的性能和使用寿命，因此对机器人减速器行星轮进行故障识别具有重要意义。采用声发射设备对减速器信号进行采集时，电机和齿轮啮合产生的大量噪声容易淹没运行信号，难以进行有效的特征提取，因此对采集的 AE 信号进行降噪处理是一种有效且必要的方法，变分模态分解方法被广泛应用于信号降噪，音频检测等方面。然而，该方法过度依赖于模态个数 K 和惩罚因子 α 的选择。一旦参数选择不合适，就会造成过分解或欠分解，以及频带信息丢失或信息冗余等现象。河马优化算法是一种新型元启发式算法，其设计灵感来源于河马的三种固有行为方式，河马智能优化算法在 CEC2019 测试函数、CEC2014 测试函数、Zigzag Pattern 基准函数中的 115 个函数中获得了最佳值，表明了河马算法在开发和探索方面表现出的优势^[58]。其性能在大部分函数上超过了麻雀搜索算法、粒子群优化算法、灰狼优化算法等经典优化算法，通过河马算法可以更好的对变分模态分解中的模态个数 K 和惩罚因子 α 进行选择。因此，本文采用声发射设备采集减速器工作状态数据（包括正常信号和行星轮磨损信号），然后提出一种采用河马算法优化的变分模态分解降噪方法用于 AE 信号的降噪。

VMD 算法中分解模态个数 K 和惩罚因子 α 的取值会直接影响 VMD 的分解结果，为避免欠分解和过分解现象，利用 HO 优化算法搜索出最佳模态个数和惩

罚因子。首先以最小包络熵作为适应度函数，可以提高算法精度、提高算法鲁棒性并简化计算过程，然后按照河马的三种行为方式更新河马在搜索空间中的位置以及河马种群的数量，随后当算法达到最大迭代次数时终止迭代，并输出最佳参数 K 和 α ，最后 VMD 按照 K 和 α 的最优解对数据进行分解，具体过程如图 3-2 中所示。

3.1.3 工业机器人减速器声发射故障特征提取

多重分形作为分形理论的深入拓展领域，对分形理论进行了更为细致和全面的研究。在自然界中，存在着大量复杂的几何体，单一的分形维数由于其局限性，难以对这些复杂结构进行完整且准确的刻画。为了更全面地描述这些几何体的特征，采用多个维数同时进行表征就显得尤为必要。

多重分形是分形理论的进化理论，从维度的角度对信号进行描述，也可以将其视为分型问题的一个分支，通过标度参数对信号进行另一个维度的描述，通过多重分形谱对信号可以进行统一的表示。分形理论通过刻画时间序列的自相似性和尺度不变性，为复杂系统的非线性动力学分析提供了重要工具。传统单分形方法（如 DFA）仅能描述整体分形特性，而机械振动信号（如轴承故障）常表现出非平稳性和多重分形特征。MFDA 通过引入不同阶数 q 的广义 Hurst 指数 $h(q)$ ，能够量化不同幅值波动区域的分形差异，成为分析非平稳时间序列的有力工具。

MFDA 方法目前应用最广泛的领域集中在生物医学领域被广泛应用于解析脑电图、心电图等生理信号，用于辅助检测疾病识别；在金融领域用于股票价格分析、汇率和加密货币波动分析，用于评估市场风险和效率，而在工业机器人减速器声发射信号故障识别领域少有运用，MFDA 方法非常适合用于声发射信号的故障识别，其核心优势在于可以显示出声发射信号中隐含的非平稳特征、非线性特征以及多尺度分形特征，因此本章节将 MFDA 方法用于声发射信号的特征提取中，以实现工业机器人减速器声发射信号的故障识别。

本章节提出的 MFDA 声发射信号处理框架如下：

首先对信号预处理降噪，采用 HO-VMD 去噪消除高频噪声，包括对信号的分段截取，针对声发射信号的突发特性，截取包含典型故障事件的非平稳片段。然后对 MFDA 参数进行设置，多项式阶数根据声发射信号的局部趋势复杂度，选择 2 阶或 3 阶多项式拟合。尺度范围结合信号采样率，设定尺度 s 为 $10 \leq s \leq N/4$

(N 为信号长度)，覆盖短时微破裂至长时故障累积过程。 q 值在 MFDFA 中作为权重参数，通过调节对不同幅度波动的敏感性，揭示了时间序列的多重分形结构。 $q>0$ 强调较大的波动（如剧烈变化或极端值），此时结果主要受高方差区间的影响， $q<0$ 强调较小的波动（如细微变化或平稳段），此时低方差区间的贡献更显著， $q=0$ 对应信息熵的极限情况。 q 值选取采取扩展至 $q \in [-50, 50]$ 。广义 Hurst 指数 $h(q)$ 作用为分析不同值下 $h(q)$ 的曲率，反映信号的多重分形强度。质量指数 $\tau(q)$ 综合反映信号多重分形特征的可信度与算法分析的有效性。故障状态分类通过多重分形谱中多重分形谱最大值对应的 $h(q)_0$ 可以描述不同信号多重分形谱之间的差异，因此本文将对三种不同状态下的减速器声发射信号进行重复采集，每种状态采集 30 组数据，并计算相应的 $h(q)_0$ 。通过对比其分布进行故障辨识，故障辨识总体框架如图 3-2 所示：




图 3-2 故障辨识总体框架

3.2 减速器声发射信号故障识别

3.2.1 实验数据来源

本实验搭建的实验平台中减速器采用芜湖固高自动化有限公司的工业机器人 RV 减速器，通过与此公司的合作搭建实验平台，实验平台如图 3-3 所示，该减速器由一个太阳轮和三个行星轮组成。本次实验使用的声发射采集设备为北京软岛时代科技有限公司生制造的 DS5-16C 型号 AE 信号采集仪，采样速率设定为 3Mhz，转速为 300r/min，传感器为 RS-2A 型压电陶瓷传感器，前置放大器增益设定为 40dB。本实验分别对健康状态下和行星轮磨损状态下的减速器进行声

发射信号采集，行星轮磨损情况和传感器位置如图 3-3 所示。




图 3-3 硬件测试实验平台

本实验平台通过芜湖固高自动化有限公司自研控制软件对电机转速和运行时长进行控制，采集平台为虚拟仪器平台，通过虚拟仪器上位机可以对 DS5-16C 采集仪进行采集和存储等控制，采集到的声发射信号通过串口发送至计算机中，采用 MATLAB 软件对信号进行截取并分析。通过虚拟仪器上位机和电机控制软件可以实现对信号的实时采集。软件控制和采集平台如图 3-4 所示：





图 3-4 软件控制及信号采集实验平台

3.2.2 实验验证


(1) CEEMDAN 和小波处理信号降噪

本实验将压电陶瓷传感器放置于健康状态下的减速器的竖直方向上，使用铅信号作为故障源，在实际运行中的减速器上折铅模拟故障的发生，图 3-5 为减速器静止状态下在减速器上采集到的铅芯折断信号及其频谱，由频谱图可知，AE

信号的主要频率分布在 170kHz 附近。所以任意波频率采取 170kHz 的正弦信号。



(a) 折铅声发射信号波形




(b) 频谱图


图 3-5 静止状态下折铅信号及其频谱

电机以 900r/min 的平均速度带动减速器运转,通过声发射仪产生 170kHz 的正弦信号作为声发射信号源在减速器上进行模拟实验。将发射传感器放置于图 3-3 所示位置采集到如图 3-6 所示含噪声原信号。


对原信号进行小波处理,得到子信号的频谱和幅值谱。经过小波处理后,原信号 170kHz 频率附近成分主要集中在第二层和第三层和第四层子信号中,因此选择第二层,第三层和第四层子信号作为后续 CEEMDAN 处理的原始信号。信号如图 3-6 所示。




(a) 含噪声原信号



(b) 第二层子信号




(c) 第三层子信号




(d) 第四层子信号

图 3-6 原信号及其分量信号


将小波第四层子信号经过 CEEMDAN 处理后得到的 IMF 分量及其频谱。由图 3-7 可知, IMF1, IMF2 和 IMF3 的主要频段集中在 170kHz 附近, 如图 3-8 所示, 对三个 IMF 分量进行信号重构, 可得到去噪后的信号 S1。




(a) IMF1




(d) IMF1 频率




(b) IMF2



(e) IMF2 频率




(c) IMF3




(f) IMF3 频率

图 3-7 IMF 分量及其频谱




(a) 重构信号




(b) 重构信号频率

图 3-8 重构信号 S1 及其频谱


将小波第二层和第三层子信号通过相同的重构步骤可分别得到对应的重构信号 S2 和 S3，将 S1，S2，S3 相加进行重构得到降噪后信号，如图 3-9 所示。



(a) S1 信号




(b) S2 信号




(c) 重构信号

图 3-9 相加重构后的信号

为了更好的对融合方法的效果进行评价，将本文方法和单一使用小波方法和单一使用 CEEMDAN 方法进行对比。图 3-10 为单一方法处理后得到的去噪信号，结果表明，单一信号处理方法对含高噪声声发射信号去噪效果不理想；经过本文提出的方法去噪后，信号中噪声含量明显降低，表明本文所提方法去噪效果明显优于其他两种算法。



(a) 单一小波处理



(b) 单一 CEEDMAN 处理

图 3-10 单一方法降噪结果

(2) HO-VMD 方法降噪

通过实验平台分别采集健康状态、轻度磨损、重度磨损三种状态下减速器的声发射信号，采用 HO-VMD 方法对三种原始信号进行分解，选用其中经过 HO 算法优化过后的的 VMD 参数 K 和 α 如表 3-1 所示：

表 3-1 HO 优化后的 VMD 参数

信号类型	K	α
健康信号	5	100
轻度磨损	6	230
重度磨损	9	570

原信号经参数优化后的 VMD 分解结果如图 3-11 到 3-13 所示：




图 3-11 健康信号 VMD 分解结果




图 3-12 轻度磨损信号 VMD 分解结果






图 3-13 重度磨损信号 VMD 分解结果


原信号经 VMD 分解, 得到固有模态分量 IMF, IMF 分量反映了信号的固有特性, 因此采用计算 IMF 分量与原信号的相关系数来确定重构所需分量, 图 3-14 为原始信号经 HO-VMD 分解后, 产生的 IMF 分量与原始信号的相关系数柱状图。



(a) 健康信号



(b) 轻度磨损信号



(c) 重度磨损信号

图 3-14 原信号与 IMF 相关系数

当相关系数大于 0.5 时，IMF 分量与原信号间呈现强相关，从图 3-14 中可以看出，健康信号的 IMF4 和 IMF5 与原信号间的相关系数大于 0.5，其余分量均小于 0.5 视为弱相关或无相关分量，保留 IMF4 和 IMF5 进行相加得到重构信号，

轻度磨和重度磨损信号按此过程可得到重构信号，图 3-15 为重构后各信号时域图与频谱图。

图 3-15 中时域图和频域图相比于图 3-11 到 3-13 中的原始信号，三种状态中心频率一致，去除噪声特征频率的基础上，保留了信号的主要特征。通过 HO-VMD 方法对原始信号进行处理，可以过滤信号中存在的大部分噪声证明了采用 HO-VMD 方法在声发射信号特征提取中的有效性。




图 3-15 重构信号的时域图和频谱图

(3) 不同去噪方法对比

为比较不同方法对声发射信号的降噪效果，用不同方法对健康状态和故障状态的声发射信号进行降噪处理，并计算降噪前后声发射信号的信噪比，通过对比信噪比体现不同方法的信号降噪效果，其中信号经过降噪处理后，信号的信噪比会增加。由于不同声发射信号中存在的噪声信号特性不同，针对本实验平台获取到的声发射信号做出噪声分析和不同方法的降噪性能对比，寻找最适合本实验平台声发射信号的降噪方法，表 3-2 为不同方法去噪后的声发射信号的信噪比。


表 3-2 不同方法去噪前后信噪比

降噪方法	降噪前信噪比	降噪后信噪比	性能排名
Ceemdan-WT	5dB	16dB	2
HO-VMD	5dB	18dB	1
EMD	5dB	9dB	4
VMD	5dB	11dB	3


由表可知，针对本实验平台采集到的声发射数据，声发射原始信号中的信噪比较低，噪声主要来自机械振动只有 5dB，经过本文提出的两种方法进行降噪后，降噪后的信噪比有明显提升，其中典型方法可将信噪比提升 5dB 左右，本文提出的方法可将信噪比提升 11dB 左右，相比于经典算法，对声发射信号的降噪效果更好，针对本文提出的两种降噪方法，HO-VMD 方法更适合本实验平台在实际运行中采集到的声发射信号，因此后续工作采用此方法进行信号降噪。

(4) 声发射信号特征提取及故障辨识


采用 MFDEFA 方法对 HO-VMD 处理，并对重构后的信号进行多重分形特征提取，得到广义 Hurst 指数和质量指数以及信号的多重分形谱。三种状态下的多重分形结果如图 3-16 所示：



(a) Hurst 指数




(b) 质量指数




(c) 多重分形谱

图 3-16 三种状态信号的多重分形结果


由图 3-16a 和图 3-16b 可知三种状态下，广义 Hurst 指数随着 q 的增大而减小，说明信号具有多重分形特征，其中轻度磨损 Hurst 指数与重度磨损 Hurst 指数明显整体高于或低于健康状态 Hurst 指数。三种状态下质量指数随 q 的变化如图 3-16b 所示，由图可知质量指数都随 q 变化，说明信号中存在多重分形特征，图 3-16c 为信号的奇异谱函数与 $h(q)$ 之间的关系。从图中可以看出三种状态下的多重分形谱呈倒 U 型，三种状态的峰形以及波明显不同。通过多重分形谱最大值对应的 $h(q)_0$ 可以描述信号之间的差异，因此本文将对三种不同状态下的减速器进行重复采集，每种状态采集 30 组数据，并计算相应的 $h(q)_0$ 。三种类型的各 30 组信号的 $h(q)_0$ 分布如图 3-17。



(a) 经 HO-VMD 分解的 $hq(0)$ 分布



(b) 经 VMD 分解的 $hq(0)$ 分布



(c) 原信号的 $hq(0)$ 分布

图 3-17 三种状态信号的 $h(q)0$ 分布图

为验证本文方法的有效性，将经 HO-VMD 处理后的三种信号进行快速傅里叶变换和小波变换，得到信号的主频和小波熵的分布，结果如图 3-18 所示：




图 3-18 三种状态信号的主频和小波熵分布图

从图 3-18a 中主频的分布可以看出, 经快速傅里叶变换后, 三种信号的主频出现明显重叠, 其中健康状态和重度磨损状态主频分布在 16kHz 和 48kHz 附近, 重叠现象严重不能进行故障识别。从图 3-18b 中小波熵的分布可以看出, 不能通过小波熵的分布进行故障识别, 三种信号的小波重叠在一起, 分布在 6.5 附近。从图 3-16 中广义 Hurst 指数、质量指数和多重分形谱结果来看, 三种状态的波形位置不同, 故障区分较为显著, 其中多重分形谱最大值用于描述波形位置的差异, 三种状态在多重分形谱最大时对应的 Hurst 指数 $h(q)_0$ 分布如表 3-3 所示。

表 3-3 不同方法处理的三种状态的 $h(q)_0$ 分布

	信号类型	最小值	最大值	中值
HO-VMD	健康	0.83	1.13	0.98
	轻度磨损	0.45	0.72	0.59
	重度磨损	1.20	1.38	1.29
VMD	健康	0.5	1.1	0.8
	轻度磨损	0.5	0.9	0.7
	重度磨损	0.8	1.3	1.05
原信号	健康	0.6	0.96	0.78
	轻度磨损	0.5	0.9	0.7
	重度磨损	0.46	0.76	0.61

从表 3-3 中数据可以看出, 经 HO-VMD 处理的三种状态的 $h(q)_0$ 分布区间没有重叠, 可通过故障信号的 $h(q)_0$ 分布对故障进行识别, 当 Hurst 指数低于健康状态时为轻度磨损, 高于则意味着出现重度磨损, Hurst 指数数值越小意味着信

号的相似度越小,信号可以在更低维度的空间中进行表达,结果表明,健康信号的 $h(q)0$ 指数范围区间为 1.83-1.13,区间范围接近于 1,在一维空间中可以更好的表示。此外,经 VMD 处理后的健康信号和轻度磨损信号的最大最小值范围区间分别为 0.5 到 1.1 和 0.5 到 0.9,由于惩罚因子和模态个数是由人工设定的,最大最小值范围区间出现重叠,不能准确对两种信号进行区分,同理重度磨损信号与其他两种类型信号也能不区分,从 $h(q)0$ 波形分布难以进行识别。从表中原始信号的结果可以看出,三种状态的 $h(q)0$ 分布亦出现重叠,不能对故障进行辨识。

三种状态的结果表明,由于噪声的影响,三种信号的 $h(q)0$ 的分布均出现变化,噪声对信号的相似度产生了影响,信号在一维空间中不能充分的表示,并且经过 HO-VMD 的优化后,降低了噪声对信号的影响,三种以通过 $h(q)0$ 的分布进行辨识,表明本文提出的优化降噪方法和故障特征识别方法可以进行故障识别。

3.3 本章小结

在声发射信号去噪过程中,使用 WT 和 CEEMDAN 存在对噪声信号敏感,去噪效果不好等问题。本文提出了一种基于 WT 和 CEEMDAN 的减速器声发射信号去噪方法。首先利用 WT 对含噪信号进行分解,得到子信号,并选择目标频率为主频的子信号;然后,将子信号 CEEMDAN 分解,并选择起主要作用的 IMF 分量进行信号重构;最后,将所有子信号的去噪结果进行相加重构。实验结果表明,本文所提方法对强干扰声发射信号的去噪效果显著,克服了声发射信号去噪中的问题。针对本实验平台的故障声发射信号,对比了不同降噪方法,HO-VMD 更适用于实际环境中的声发射信号降噪。

针对在工业机器人减速器工作环境中存在大量噪声、声发射信号故障特征不明显,且现有 VMD 处理方法需要人为选取适当参数导致出现过分解和欠分解等问题,本章节通过 HO 算法对 VMD 进行参数优化,避免 VMD 处理中 K 和 α 取值不当导致的过分解、欠分解和模态混叠,并运用 MFDFA 方法提取信号的多重分形特征用于故障识别,多重分形特征可以很好的体现信号在多重维度上的特征,通过多重分形参数分布可以实现对故障进行识别。

第 4 章 基于神经网络的减速器故障识别研究

在传统的声发射分类任务中,对领域专家的先验知识以及人工经验存在极大程度的依赖。以基于统计学习的方法为例,其需要人工筛选特征、设计阈值或者构建复杂规则集,整个过程极为耗时,且容易受到主观偏差的影响。神经网络能够借助多层非线性变换,自动从数据中提取抽象特征,进而实现端到端的分类建模。这种以数据驱动的模式,不仅避免了人工特征设计过程中对经验的依赖以及主观性问题,而且在多模态、高噪声的环境中展现出更为出色的鲁棒性。从图像识别领域到自然语言处理领域,神经网络已经充分证明了其通过自主学习构建分类的显著优越性,为智能化决策系统的搭建奠定了全新的方法论基石。由于不同实验噪声环境差异大,针对具体的含噪声发射信号应采用不同的降噪方法进行降噪处理,选用降噪效果较好的具有针对性的方法进行降噪,由于第三章中通过人工辨识信号的多重分形参数分布不可避免地存在一定的人为主观性,且识别效率相比于深度学习方法较低,因此针对 CNN 和 BiLSTM 在处理信号的二维特征和一维特征中的优势,本章节在第三章的降噪处理的基础上结合卷积神经网络和长短时记忆网络进行故障识别。

4.1 实验数据来源

用于研究的工业机器人来自奇瑞汽车股份有限公司的工业六轴机器人,具体参数如表 4-1 所示:

表 4-1 工业机器人主要参数

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

该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。本实验采用软岛 DS5-16C 声发射仪采集声发射波形,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。根据 ASTM 试验标准,模拟实验中采用铅芯折断的方式来产生声发射源,使用直径为 0.5mm 的 HB 铅笔,铅芯伸长量为 2.5mm,每次断铅时保证铅芯与本体表面夹角为 30°,并采用透明胶

布将声发射传感器固定在机器人本体上。实际实验中机器人处于运行状态，传感器位置和模拟实验时相同。传感器布置如图 4-1 所示。



图 4-1 工业机器人平台

传感器分别布置在机器人四个不同的关节上，由于每个关节的受力和使用频率不同，因此内部用于传动的减速器收到的故障类型和故障程度不一样，既四种不同的减速器故障类型，通过此平台，采集工业机器人在运行状态中的声发射信号。不同关节减速器负载不同，产生的故障也不同，四个关节具体如图 4-2 所示。



(a) 关节 1



(b) 关节 2



(c) 关节 3



(d) 关节 4

图 4-2 四个关节结构示意图

其中一号关机位于机器人焊头转动处，由内部减速器控制焊头平行于地面方

向的旋转，二号关节位于机器人焊接手臂转动处，由内部减速器传动，控制焊头垂直于地面方向的旋转，三号减速器位于二号关节于机器人本体连接处，由内部减速器控制，控制焊头处置于地面方向的旋转，四号减速器位于机器人本体连接处，加上底座上的两个旋转关节，形成六轴联动控制焊接机器人的整体姿态。

本文的数据集由声发射设备采集，采集到的数据经过 Matlab 软件进行截取，组成四类共 200 个样本的数据集，样本类型为时间序列数据，每个样本长度为 1000 个数据点。其中一号关节减速器数据对应标签为 1，二号减速器数据对应标签为 2，三号减速器数据对应标签为 3，四号减速器数据对应标签为 4。

4.2 声发射信号预处理

工业机器人由于工作环境中存在大量噪声，但传统时频分析法（如傅里叶变换和小波阈值去噪）存在对噪声敏感和模态混叠等问题，一方面噪声会影响信号的时频分布导致存在大量的虚假频率成分，另一方面，从单一维度（时域或者频域）难以更加全面的反应信号中存在的故障特征，通过优化变分模态分解，可以有效的抑制信号中的噪声成分的同时避免变分模态分解存在的模态混叠问题，而在进行连续小波处理时，噪声的干扰会使时频图出现不清晰，特征难以辨识等问题，经降噪后的信号时频图和未经降噪的信号时频图如图 4-3 所示。




图 4-3 降噪前后的信号时频图

从图中可以看出，左侧经降噪后的信号的时频图中特征更加清晰，更易于故障辨识。因此本文在对声发射信号进行连续小波处理之前，对比典型降噪方法以及 WT-CEEMDAN 和 HO-VMD 的降噪效果，选择采用 HO-VMD 对原信号进行降噪。对比结果如表 4-2 所示。

表 4-2 不同降噪方法对比结果

降噪方法	降噪后信噪比	降噪方法	降噪后信噪比
EMD	18dB	WT-CEEMDAN	24dB
WT	14dB	HO-VMD	26dB
VMD	17dB		
CEEMDAN	20dB		

通过表中对比结果可知,针对此次实验的含噪声发射信号,典型的降噪方法有一定的降噪效果,但因算法本身存在的缺陷,相比于本文提出的混合处理降噪方法有一定的劣势,由于运行环境不同导致的噪声特性不同,HO-VMD 算法更适合于本实验平台的声发射信号降噪,因此本章节采用 HO-VMD 方法对原始含噪声发射信号进行降噪处理。

经过 HO-VMD 降噪后的信号已经去除了大部分无用噪声,信号的信噪比提升到了 26dB,然后通过连续小波变换处理,可以将一维时间序列转换为二维图像,能够最大限度的保留信号特征,避免特征丢失。针对此问题,本研究提出一种 HO-VMD-CWT 声发射信号预处理方法:首先利用 VMD 对原始信号进行噪声抑制,通过相关系数筛选有效 IMF 重构降噪信号;随后对降噪信号进行连续小波处理(Continuous Wavelet Transform, CWT),生成高分辨率的二维时频图。该方法兼具双重优势:一维模态分解角度, VMD 通过噪声分量剔除提升信号信噪比,二维时频分析角度, CWT 在降噪基础上提取的时频图更清晰,可量化表征信号的瞬时频率、能量熵等关键参数。

4.3 基于连续小波处理和并行神经网络的减速器故障识别


4.3.1 故障识别仿真实验流程

由第三章结果可知,惩罚因子与分解层数的设置 VMD 降噪性能的关键过程,通过河马优化算法对变分模态分解的两个参数进行优化;CNN 和 BiLSTM 是深度学习中处理不同数据的两种模型, CNN 擅长处理二维图像中的空间特征,也可以用于处理时间序列,但需将时间序列转换为图像结构;BiLSTM 擅长处理一维时间序列中的时间特征,但本身不擅长处理空间结构。为最大程度保留原信号中的一维和二维特征,本章节同时结合 CNN 和 BiLSTM 在处理图像和时间序列

的优势，提出基于 CWT 和并行 CNN-BiLSTM 的减速器故障识别方法。针对噪声环境下的声发射信号采用 HO-VMD 分解并通过相关系数对所有 IMF 分量筛选，对信号进行相加重构达到降噪目的；进一步将降噪信号经过连续小波处理转换为二维图像，最后将一维时间序列和二维时频图像分别输入至并 CNN-BiLSTM 中进行，识别具体步骤如下：首先选取不同机器人关节处的减速器作为研究对象，采集声发射信号作为输入样本，并将其分为训练组与测试组；然后采用 HO-VMD 对信号进行降噪分解，得到所有 IMF 分量，根据相关系数对分量进行筛选，对 IMF 进行相加重构得到降噪后的信号；然后将降噪后的信号进行连续小波变换处理，得到降噪信号的时频图，并将降噪信号和降噪信号的时频图划分为训练集和测试集，准备导入模型中进行训练。然后构建 CNN-BiLSTM 并行分类模型，将一维时间训练样本和二维图像训练样本分别输入至 CNN 和 BiLSTM 中进行特征提取。然后融合 CNN 和 BiLSTM 得到的特征进行特征融合，并输出识别结果。

4.3.2 模拟数据识别结果分析

将本文基于 HO-VMD 和并行 CWT-CNN-BiLSTM 故障识别方法进行模拟数据的验证，采用铅芯折断信号作为模拟故障信号，在工业机器人不同的四个关节处的减速器上进行声发射采集实验。选取一号关节、二号关节、三号关节、四号关节的减速器声发射信号样本各 50 组，将各信号样本进行 HO-VMD 分解、信号重构、连续小波处理、模型训练处理形成特征向量。将样本按照 70%和 30%的比例划分数据集并采用 CNN-BiLSTM 进行训练，分类结果如图 4-4 所示。



(a) 测试结果

(b) 混淆矩阵

图 4-4 HO-VMD-CWT-CNN-BiLSTM 分类结果

由图 4-4 可以看出，使用 CNN-BiLSTM 模型进行训练与测试，分类准确率为 98.33%。为了验证本文提出的故障识别方法的有效性，选用 CNN、BiLSTM 以及 CWT-CNN-BiLSTM 作为比较对象，4 种模型的准确率如表 4-3 所示。




图 4-5 CWT-CNN-BiLSTM 分类结果




图 4-6 单一 BiLSTM 分类结果




图 4-7 单一 CNN 分类结果

表 4-3 四种分类模型准确率

分类模型	训练样本数	测试样本数	准确率
CNN	140	60	86.66%
BiLSTM	140	60	91.66%
CWT-CNN-BiLSTM	140	60	95.00%
HO-VMD-CWT-CNN-BiLSTM	140	60	98.33%

由图 4-5 到 4-7 分类结果可得,将 200 个样本采用 CNN 进行训练与测试后,准确率仅有 86.66%;在采用 BiLSTM、CWT-CNN-BiLSTM 模型中进行训练后,准确率分别达到 91.66%与 95.00%,说明经 CWT 处理并经过并行网络的模型分类准确率更优。

但对比表 4-3 中的数据可知,与 HO-VMD-CWT-CNN-BiLSTM 相比的,CWT-CNN-BiLSTM 分类准确率有所降低,HO-VMD 区别于另外几种算法对信号进行了降噪处理。在经过 HO-VMD 降噪后,其准确率有明显提高,验证了该方法的有效性与优越性,可以应用于工业机器人减速器故障识别领域。

4.3.3 实例数据分析

通过对信号的降噪和故障辨识的研究,本文提出了基于声发射信号的工业机器人减速器故障识别方法,并结合奇瑞汽车三厂的焊接机器人进行实验。

为验证本文方法的实际效果,在汽车生产车间采集了出现减速器故障的机器声发射信号。选取四个不同关节减速器的声发射信号进行降噪,由于信号数目较多,每种状态仅展示一组 IMF 分量,其原始信号和 IMF 分量的相关系数如表 4-4 到 4-7 所示:

表 4-4 一关节相关系数结果

IMF 分量	相关系数	IMF	相关系数
IMF1	0.8644	IMF5	0.3546
IMF2	0.4563	IMF6	0.1576
IMF3	0.3578	IMF7	0.1684

IMF4	0.2458	IMF8	0.0453
------	--------	------	--------

表 4-5 二关节相关系数结果

IMF 分量	相关系数	IMF	相关系数
IMF1	0.7497	IMF5	0.2615
IMF2	0.4683	IMF6	0.1751
IMF3	0.3356	IMF7	0.1452
IMF4	0.2435	IMF8	0.0354


表 4-6 三关节相关系数结果

IMF 分量	相关系数	IMF	相关系数
IMF1	0.7354	IMF5	0.3156
IMF2	0.4537	IMF6	0.1687
IMF3	0.3673	IMF7	0.1345
IMF4	0.2543	IMF8	0.0537

表 4-7 四关节相关系数结果

IMF 分量	相关系数	IMF	相关系数
IMF1	0.7405	IMF5	0.1278
IMF2	0.4378	IMF6	0.0354
IMF3	0.3981	IMF7	0.1634
IMF4	0.2654	IMF8	0.167

通过表 4-4 到 4-7 中相关系数结果, 将相关系数最大的五个 IMF 分量进行相加重构^[59], 相加后可以得到降噪后的信号, 经降噪并重构后的信号如图 4-8 所示。






图 4-8 降噪后的信号

图 4-8 分别为关节 1 到 4 经降噪后的信号，经降噪后，通过 CWT 方法将一维时间信号转换为二维图像，部分时频图 4-9 所示。




图 4-9 部分 CWT 时频图

将按照预处理流程处理后的信号以及时频图集合为数据集，其中 70%样本作为训练集，30%样本作为测试集输入至 CNN-BiLSTM 进行故障识别，故障识别结果如图 4-10 到 4-14 所示：




图 4-10 HO-VMD-CWT-CNN-BiLSTM 分类结果




图 4-11 CWT-CNN-BiLSTM 分类结果




图 4-12 CNN-CNN 分类结果




图 4-13 单一 BiLSTM 分类结果




图 4-14 单一 CNN 分类结果

由图 4-10 可以看出，共有 58 组样本识别正确，分类准确率达到 96.66%，证明本文提出的基于 HO-VMD 与 CTW-CNN-BiLSTM 方法对于工业机器人减速器故障识别具有一定的有效性。为验证其实际有效性，选用 CNN、BiLSTM 以及 CWT-CNN-BiLSTM 模型作比较，五种分类模型的准确率如表 4-8 所示。

表 4-8 五种分类模型准确率

分类模型	训练样本数	测试样本数	准确率
CNN	140	60	76.66%
BiLSTM	140	60	86.66%
CNN-CNN	140	60	91.66%
CWT-CNN-BiLSTM	140	60	93.33%
HO-VMD-CWT-CNN-BiLSTM	140	60	96.66%

由表 4-8 可以看出，60 组测试样本进行识别后，CNN 的准确率为 76.66%，

由于 CNN 网络只提取了声发射信号在二维空间的特征，忽略了声发射信号在一维空间时序上的特征，因此准确率较低。针对一维空间时间序列，BiLSTM 至提取了声发射信号的一维特征，准确率与单一 CNN 网络类似，将一维时间序列和二维空间图像分别导入 CNN 网络中进行识别，由于 CNN 在提取空间特征方面的性能弱于 BiLSTM，因此使用并行 CNN 网络的准确率有所提升，但提升效果不显著。引入本文提出的并行 CNN-BiLSTM 后，准确率获得大幅提升至 93%左右，为对比降噪方法对实验结果的影响，将未经降噪处理的声发射信号直接进行 CWT 处理并导入并行 CNN-BiLSTM 中进行辨识准确率为 93.33%，将经过降噪后的声发射信号导入并进行辨识，准确率提升了 3.3%。由表中数据可以看出，本文所提出的 HO-VMD-CWT-CNN-BiLSTM 方法对于工业机器人减速器故障识别具有一定的有效性和可行性。

4.4 本章小结

本章采用河马优化算法优化变分模态处理 (HO-VMD) 作为声发射信号降噪算法。针对现场采集的信号，此算法更适用于本研究的声发射信号降噪。对工业机器人的四类不同关节处的故障减速器进行降噪和连续小波处理，得到由一维时间序列和二维空间图像组成的数据集，并按照七比三的比例划分为训练集和测试集，对比了四种不同组成的识别模型的准确率，分别是单一 CNN 网络、单一 BiLSTM 网络、并行 CNN 网络和未经降噪并行 CNN-BiLSTM 网络，结果表明，通过降噪并提取声发射信号的一维和二维特征，准确率达到 96.66%。验证了本文所提方法在工业机器人减速器故障识别领域中有一定的有效性和可行性。

第 5 章 总结和展望

5.1 本文总结

工业机器人是现代工业生产的重要组成部分,但机器人长期处于恶劣工作环境中,容易产生因过度疲劳而导致的故障,从而造成重大经济损失或严重人员伤亡。减速器作为工业机器人中最重要的传动结构,是故障发生概率最大的机械结构,针对工业机器人减速器故障识别的研究对预防出现经济损失和人员伤亡并保证工业机器人持续有效的运行具有重要的意义。

在实际环境下采集到的声发射信号一般是非线性和非平稳的,并且由于环境中的噪声影响,声发射信号中存在大量的干扰信息。因此在进行采用声发射技术对工业机器人进行故障辨识时必须针对声发射信号的降噪处理进行前置研究。本论文将工业机器人减速器作为研究对象,重点对声发射信号的降噪处理和辨识进行研究并依靠实际运行中的工业机器人进行实验分析和对比研究,对所提出的基于工业机器人减速器声发射信号故障辨识进行验证分析。

本文的主要研究工作和创新内容如下:

(1) 提出一种基于小波分解和自适应噪声完全集合经验模态分解相结合的声发射信号重构方法,为声发射信号故障识别提供早期准备。利用 WT 对声发射信号进行初步分解,选取频率范围处于稳定范围内的小波细节信号作二次分解的输入信号,然后利用 CEEMDAN 方法将小波细节信号进行二次分解,选取处于频率范围内的子信号进行波形重构,最终得到降噪后的信号。所提出的降噪与重构方法能有效的对声发射信号进行降噪。

(2) 提出一种基于河马优化算法的变分模态分解和 MFDFA 的工业机器人减速器行星轮磨损的故障检测方法。通过引入 HO 算法,有效的解决了传统 VMD 方法存在的模态混叠和端点效应问题,然后采用 MFDFA 方法对降噪后的信号进行多重分形特征提取,获得了声发射信号中存在的多重分形特征,通过分析特征提取结果验证了所提方法在从工业机器人减速器行星轮磨损的故障检测中的有效性。

(3) 提出一种基于 CNN 和 BiLSTM 并行的故障识别网络,针对汽车工厂因长期使用而产生故障的工业机器人减速器进行故障识别研究,通过对声发射信

号进行连续小波处理得到时频图，并与时序信号组成数据集进行故障识别，通过对比不同结构的识别网络准确率验证所提方法的有效性，结果表明，通过降噪并同时提取声发射信号的一维特征和二维特征，可以有效的对工业机器人减速器故障或进行识别。

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。声发射作为一种可针对恶劣环境下进行实时在线检测的无损检测方法，在工业机器人故障识别领域有广阔的应用前景。由于受到作者本身学术水平和科研时间和科研条件的影响，随着研究的不断深入认识到在后续研究过程中，还有几个方面的需要进一步深入探索。

(1) 声发射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，如基于深度学习神经网络算法，能够自动学习和识别声发射信号中的微弱故障特征，有效区分不同类型和程度的故障信号，从而显著提高故障检测的准确性和可靠性。

(2) 单一的声发射参数往往难以全面、准确地反映工业机器人的故障状况。未来，将声发射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，实现对故障的全方位、多角度监测。

(3) 传感器是声发射技术应用的关键部件，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声发射传感器，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。

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 Choi, et al. Near-surface defect detection in ultrasonic testing using domain-knowledge-informed self-supervised learning[J]. Ultrasonics, 2025, 147: 107528.
- [4] 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.
- [5] Świt G, Krampikowska A, Tworzewski P, et al. Non-Destructive Testing methods for In situ Crack measurements and morphology analysis with a focus on a novel approach to the use of the acoustic emission method[J]. Materials, 2023, 16(23): 7440.
- [6] Mehra K, Peschon J. An innovations approach to fault detection and diagnosis in dynamic systems[J]. Automatica, 1971, 7(5): 637-640.
- [7] Lee M, Barnes D, Hardy N, et al. Knowledge based error recovery in industrial robots[C]. 8th International Joint Conference On Artificial Intelligence (IJCAI-83). Morgan kaufmann publishers Inc, 1983: 824-826.
- [8] 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.
- [9] 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.
- [10] Elangovan K, Krishnasamy Y, Mohan R, et al. Fault diagnosis of a reconfigurable crawling-rolling robot based on support vector machines[J]. Applied Sciences, 2017, 7(10): 1025.
- [11] Rescalvo J, Suarez E, Valverde-Palacios I, et al. Health monitoring of timber beams

- retrofitted with carbon fiber composites via the acoustic emission technique[J]. Composite Structures, 2018, 206: 392-402.
- [12]Dunegan L, Tatro C A. Passive pressure transducer utilizing acoustic emission[J]. Review of Scientific Instruments, 1967, 38(8): 1145-1147.
- [13]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.
- [14]Dia A, Dieng L, Gaillet L, etal. Damage detection of a hybrid composite laminatealuminum/glass under quasi-static and fatigue loadings by acoustic emission technique[J]. Heliyon, 2019, 5(3): 1-23.
- [15]Zhou T, Zhang G, Lu N, etal. 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.
- [16]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.
- [17]方赛银, 邱荣祖, 李明, 等. 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.
- [18]Liu Z, Xing J, Wang H, etal. Fault diagnosis of rolling bearing based on VMD and fast spectral kurtosis[J]. Journal of Electronic Measurement and Instrument, 2021, 35(02): 73-79.
- [19]Saleem M, Shahul B, Arumugam V, etal. Damage and failure assessment of banana/ramie/epoxy composites using acoustic emission monitoring[J]. Construction and Building Materials, 2024, 449: 138489.
- [20]Dai X, Yi K, Wang F, etal. Bearing fault diagnosis based on POA-VMD with GADF-Swin transformer transfer learning network[J]. Measurement, 2024, 238: 115328.
- [21]Gao Z, Wang X, Lin J, etc. Online evaluation of metal burn degrees based on acoustic emission and variational mode decomposition[J]. Measurement ,2017, 103: 302-310.
- [22]蒋富康, 陆金桂, 刘明昊,等. 基于 CEEMDAN 和 CNN-LSTM 的滚动轴承故障诊断[J]. 电子测量技术, 2023, 46(05): 72-77.
- [23]尚海昆, 许俊彦, 李宇才, 等. CEEMDAN 在变压器振动信号提取中的应用[J].

- 控制理论与应用, 2022, 39(03): 459-468.
- [24]张洪梅, 邹金慧. 自适应 MCKD 和 CEEMDAN 的滚动轴承微弱故障特征提取[J]. 电子测量与仪器学报, 2019, 33(04): 79-86.
- [25]周浪, 王礼桂, 胡雷, 等. 基于分段累计近似与自适应噪声辅助集成经验模态分解的滚动轴承故障诊断方法[J]. 轴承, 2023, (02): 26-30.
- [26]Wang L, Li Z, Li J, et al. Research on transformer fault voice print information processing based on wavelet packet optimization transform[CA]. Proceedings of SPIE - The International Society for Optical Engineering, 2023, 12636.
- [27]Jing X. Improved CEEMDAN - wavelet transform de-noising method and its application in well logging noise reduction, [J], Journal of Geophysics and Engineering, 2018, 15(3), 775-787.
- [28]王海龙, 李帅, 赵岩, 等. CEEMDAN-小波包联合降噪的优化方法[J]. 爆破器材, 2021, 50(04): 48-53.
- [29]Dragomiretskiy K, Zosso D, et al. [J]. IEEE Transactions on Signal Processing, 2014, 62(3): 531-544.
- [30]Yu Q, Zhang Y, Xu J, et al. Intelligent damage classification for tensile membrane structure based on continuous wavelet transform and improved ResNet50[J]. Measurement, 2024, 227: 114260.
- [31]刘长良, 武英杰, 甄成刚, 等. 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.
- [32]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.
- [33]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.
- [34]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.
- [35]Kopsinis Y. Development of EMD-Based denoising methods inspired by wavelet thresholding[J]. IEEE Transactions on Signal Processing, 2009, 57(4): 1351-1362.
- [36]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: 1-8.

- [37] 闫河, 董莺艳, 王鹏, 等. 基于 CNN-LSTM 网络的声纹识别研究[J]. 计算机应用与软件, 2019, 36(04): 166-170.
- [38] Xu G, Ren T, Chen Y, et al. A one-dimensional CNN-LSTM model for epileptic seizure recognition using EEG signal analysis[J]. *Frontiers in Neuroscience*, 2020, 14.
- [39] Zhang X, Lu X, Li W, et al. Prediction of the remaining useful life of cutting tool using the Hurst exponent and CNN-LSTM[J]. *The International Journal of Advanced Manufacturing Technology*, 2021, 112(7-8): 2277-2299.
- [40] Zhang H, Li S, Cao Y. et al. A TFG-CNN fault diagnosis method for rolling bearing. *Mechanisms and Machine Science* [C]//Springer Science and Business Media deutschland GmbH, 2023, 117: 237-249.
- [41] 赵志宏, 李春秀, 窦广鉴, 等. 基于 MTF-CNN 的轴承故障诊断研究[J]. 振动与冲击, 2023, 42(02): 126-131.
- [42] Chen Y, Xiao L, Li Z. et al. Partial domain fault diagnosis of bearings under crossSpeed conditions based on 1D-CNN.[C]//2022 Global Reliability and Prognostics and Health Management Conference Institute of Electrical and Electronics Engineers Inc, 2022.
- [43] Zhao H, Liu M, Sun Y, et al. Fault diagnosis of control moment gyroscope based on a new CNN scheme using attention-enhanced convolutional block[J]. *Science China Technological Sciences*, 2022, 65(11): 2605-2616.
- [44] Chen Y, Zheng X, et al. Fault diagnosis of wind turbine based on multi-signal CNN-GRU model[C]//Proceedings of The Institution of Mechanical Engineers, Part A: Journal of Power and Energy. SAGE Publications Ltd, 2023.
- [45] Guo P, Peng J, Zhao W, et al. Fault diagnosis for hydraulic loading system of altitude simulation test facility based on multichannel 1D-CNN[C]//2022 13th International Conference on Mechanical and Aerospace Engineering Bratislava, Slovakia: Institute of Electrical and Electronics Engineers Inc., 2022: 490-495.
- [46] 普运伟, 刘涛涛, 吴海潇, 等. 基于卷积双向长短时记忆网络的雷达辐射源信号识别[J]. 激光与光电子学进展, 2022, 59(22): 361-368.
- [47] 陈巧红, 于泽源, 贾宇波, 等. 基于混合分布注意力机制与混合神经网络的语音情绪识别方法[J]. 计算机工程与科学, 2022, 44(12): 2246-2254.

- [48]陶志勇, 李小兵, 刘影, 等.基于双向长短时记忆网络的改进注意力短文本分类方法[J]. 数据分析与知识发现, 2019, 3(12): 21-29.
- [49]靳莹, 乔新勇 基于多层双向长短时记忆网络的装甲车辆柴油机喷油器故障诊断[J]. 兵工自动化, 2022 ,41(01): 34-38.
- [50]张光锐. 基于信道状态信息的人体动作识别算法研究[D]. 辽宁工程技术大学, 2022.
- [51]Zhang T.Q., Fei Q., Li N.N., etal. Fault diagnosis based on modified bilstm neural network[C]//ACM International Conference Proceeding Series. 2020: 21-26.
- [52]韩广, 卜桐, 王明明, 等. 基于双通道双向长短时记忆网络的铁路行车事故文本分类[J]. 铁道学报, 021, 43(09): 71-79.
- [53]Ramezani M.G., Hasanian M., Golchinfar B., etal. Automatic boiler tube leak detection with deep bidirectional LSTM neural networks of acoustic emission signals[C]//Proceedings of SPIE - The International Society for Optical Engineering,2020: 11534-11542.
- [54]Shah M, Vakharia V, Chaudhari R, etal. Tool wear prediction in face milling of stainless steel using singular generative adversarial network and lstm deep learning models[J]. International Journal of Advanced Manufacturing Technology, 2022, 121(1-2): 723-736.
- [55]Siracusano G., Garescì F., Finocchio G., etal. Automatic crack classification by exploiting statistical event descriptors for deep learning[J]. Applied Sciences, 2021, 11 (24), 12059.
- [56]Wang B, Guo Y, Wang D, etal. Prediction model of natural gas pipeline crack evolution based on optimized DCNN-LSTM[J]. Mechanical Systems and Signal Processing, 2022,12(7): 1468.
- [57]Wang Z, Dixit P, Chegdani F, etal. Bidirectional gated recurrent deep learning neural networks for smart acoustic emission sensing of natural fiber-reinforced polymer composite machining process[J]. Smart and Sustainable Manufacturing Systems, 2020, 4(2): 1698
- [58]Amiri, M, Mehrabi N, MontazeriM, etal. Hippopotamus optimization algorithm:a novel nature-inspired optimization algorithm[J].Scientific Reports(Nature Publisher Group),2024, 14(1): 5032.

- [59]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.

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] Hao Z, Guo L, Wang G, et al. Noise reduction and reconstruction of acoustic emission signals from industrial robot gearboxes based on wavelet transform and CEEMDAN[C].International Conference on Robotics, Control and Automation Engineering. Suzhou, China, 2023, 285-289.
- [2] 张浩, 郭黎, 李明, 等. 基于优化 VMD 和 MFDFA 的减速器故障识别[J]. 安徽工程大学学报(已发表)

致谢

时光荏苒，研究生学习生涯即将画上句号。回首这段充满挑战与收获的旅程，心中感慨万千。在这段旅程中，我不仅收获了专业知识，更收获了宝贵的人生经验和真挚的师生情谊。在此，我要向所有给予我帮助和支持的老师、同学、家人和朋友致以最诚挚的谢意。

首先，我要衷心感谢我的两位导师，郭黎教授和李明教授。郭老师学识渊博，治学严谨，在学术上给予我悉心指导和无私帮助。从论文选题到框架搭建，从研究方法到数据分析，郭老师都倾注了大量心血。她严谨的治学态度、渊博的学识和敏锐的学术洞察力，都深深地影响着我，激励着我不断追求卓越。李老师平易近人，亦师亦友，在生活上给予我无微不至的关怀。他耐心细致地解答我的疑问，鼓励我大胆尝试，并为我提供了许多宝贵的实践机会。两位导师的言传身教，不仅让我在学术上受益匪浅，更让我深刻体会到为人处世的道理。

感谢课题组的各位老师和同学，感谢你们在学习和生活中给予我的帮助和支持。感谢郭黎和李明老师在专业知识上的指导，感谢你们在实验设计和数据分析方面给予的宝贵建议。感谢我的同门师兄师姐师弟师妹们，感谢你们在实验过程中给予的帮助和鼓励，感谢你们在学术讨论中提出的宝贵意见，感谢你们在生活中给予的关心和陪伴。与你们一起度过的时光，将成为我人生中最美好的回忆。

感谢我的家人，感谢你们一直以来对我的理解、支持和鼓励。你们是最坚强的后盾，是我不断前行的动力源泉。感谢我的父母，感谢你们含辛茹苦将我抚养成人，感谢你们始终如一地支持我追求梦想。

最后，我要感谢所有参与我论文评审和答辩的专家和老师，感谢你们在百忙之中抽出时间审阅我的论文，并提出宝贵的意见和建议。

研究生阶段的学习生活即将结束，但求知的道路永无止境。在未来的日子里，我将继续秉承“求真务实、开拓创新”的精神，不断学习，不断进步，以优异的成绩回报社会，回报所有关心和帮助过我的人。