

分类号: TH202

密 级: 公开

学校代码: 10363

学 号: 2220110167



安徽工程大学

Anhui Polytechnic University

硕士学位论文

题 目

基于集成学习的工业机器人用

谐波减速器故障诊断方法研究

论 文 作 者

赵恒

校 内 导 师

刘永明（副教授）

校 外 导 师

李明峻（高级工程师）

专业学位类别

机 械

研究方向（领域）

故障诊断

论文提交日期: 2025 年 5 月 20 日

分类号：TH202

单位代码：10363

密 级：公开

学 号：2220110167

基于集成学习的工业机器人用谐波减速器故障诊断方法研究

RESEARCH ON FAULT DIAGNOSIS METHOD OF HARMONIC REDUCER FOR INDUSTRIAL ROBOT BASED ON ENSEMBLE LEARNING

学生姓名： 赵 恒

指导教师： 刘永明（副教授）

校外导师： 李明峻（高级工程师）

专 业： 机 械

研究方向： 故障诊断

论文答辩日期： 2025 年 5 月 9 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：赵恒.

日期：2025 年 5 月 17 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。

本学位论文属于

保 密 ☐，在 ____ 年解密后适用本版权书。

不保密 ☒。

学位论文作者签名：赵恒.

指导教师签名：刘永明

日期：2025 年 5 月 17 日

日期：2025 年 5 月 17 日

基于集成学习的工业机器人用谐波减速器故障诊断方法研究

摘 要

谐波减速器为工业机器人关键部件，其性能好坏直接决定机器人运行精度。基于电流信号对减速器进行故障诊断是应用较为广泛的一种方法，但减速器故障在电流信号中会受到电流调频频率调制干扰，进而影响故障精确诊断。为解决上述问题，本文以谐波减速器为研究对象，建立谐波减速器-驱动电机机电耦合数学模型，研究故障特征在电流信号中的表征特性，并进一步展开研究。具体工作如下：

（1）建立基于电流信号的谐波减速器-驱动电机机电耦合系统数学模型，通过仿真恒/变速工况下的电流信号，揭示了减速器故障频率会受到电机电流调频频率调制干扰的特性。为后续基于电流信号的谐波减速器故障特征解调方法提供理论基础。

（2）提出一种故障特征解调方法。在恒速工况下，分别对单一及多种频率叠加故障下的电流频域信号，采用解调方法进行解调，得到不受调制干扰的故障特征，并对解调前后的频域信号进行傅里叶逆变换，提取 15 种常用的时域特征并进行分析。

（3）提出了一种基于 D-S 证据合成理论（Dempster-Shafer evidence theory）的多策略集成学习方法，针对单一的机器学习方法，很难满足多工况、多故障类型的减速器故障诊断。通过融合决策树（DT）、支持向量机（SVM）、朴素贝叶斯（NB）和 K 最近邻（KNN）

4 种经典机器学习方法，构建基于 D-S 证据合成理论的集成学习诊断模型，并与基于 Stacking 及动态投票的集成学习方法故障诊断准确率进行对比。结果显示，基于 D-S 证据合成的集成学习方法在故障诊断的准确率上，相较于单一最优的机器学习方法提升了 3.73%，相较于其他集成学习方法，其准确率提高了 1%~2%，且解调后的特征分类准确率相较于未解调前提高了 1.82%。由此表明，经解调后的电流信号可以有效提升故障诊断的准确率，基于 D-S 证据合成理论的多策略集成学习方法在谐波减速器故障诊断中具有更好的识别效果。

(4) 搭建了谐波减速器试验台，分析谐波减速器在柔轮磨损、波发生器磨损和无故障下的电流频域特征，验证本文建立机电耦合模型的正确性，并通过特征解调方法进行解调，得到不受电流调频频率调制的故障特征，进一步提取特征后，通过多策略集成学习方法进行故障诊断。结果表明，基于 D-S 证据合成的集成学习方法相较于基于 Stacking 及动态投票，其准确率提高了 1%~3%；解调后故障识别的准确率相较于未解调提升 1.66%。为实际工程应用中的工业机器人用谐波减速器进行故障诊断及状态监测提供理论指导。

关键词：谐波减速器，集成学习，D-S 证据合成，故障诊断，故障特征解调

RESEARCH ON FAULT DIAGNOSIS METHOD OF HARMONIC REDUCER FOR INDUSTRIAL ROBOT BASED ON ENSEMBLE LEARNING

ABSTRACT

Harmonic reducer is the key component of industrial robot, and its performance directly determines the accuracy of the robot. Fault diagnosis of reducer based on current signal is a widely used method, but the reducer fault will be interfered by the current FM frequency modulation in the current signal, which will affect the accurate diagnosis of the fault. In order to solve the above problems, this paper takes the harmonic reducer as the research object, establishes the electromechanical coupling mathematical model of the harmonic reducer-drive motor, and studies the characterization characteristics of fault features in current signals, and carry out further research. The details are as follows:

(1) The mathematical model of harmonic reducer-drive motor electromechanical coupling system based on current signal is established, the characteristic that the fault frequency of the reducer will be disturbed by the frequency modulation of the motor current is revealed. It provides a theoretical basis for the subsequent harmonic reducer fault feature demodulation method based on current signal.

(2) A fault feature demodulation method is proposed. Under the condition of constant speed, the current frequency domain signals under

single and multiple frequency superposition faults are demodulated by demodulation method, and the fault characteristics without modulation interference are obtained, the frequency domain signals before and after demodulation are transformed by inverse Fourier transform, and 15 kinds of common time domain features are extracted and analyzed.

(3) A multi-strategy ensemble learning method based on Dempster-Shafer evidence theory is proposed. For a single machine learning method, it is difficult to meet the multi-condition and multi-fault type of reducer fault diagnosis. By fusing four classical machine learning methods, decision tree (DT) , Support vector machine (SVM) , Naive Bayes (NB) and K-nearest neighbor (KNN) , an ensemble learning diagnosis model based on D-S evidence combination theory is constructed, compared with the fault diagnosis accuracy of the ensemble learning method based on Stacking and dynamic voting. The results show that compared with the single optimal machine learning method, the ensemble learning method based on D-S evidence synthesis improves the accuracy of fault diagnosis by 3.73%, compared with other ensemble learning methods, its accuracy is increased by 1%-2% , and the accuracy of demodulated feature classification is increased by 1.82% compared with that before demodulation. The results show that the demodulated current signal can effectively improve the accuracy of fault diagnosis, the multi-strategy ensemble learning method based on D-S evidence combination theory has better recognition effect in fault diagnosis of harmonic reducer.

(4) A harmonic reducer test bench is built to analyze the current frequency domain characteristics of the harmonic reducer under flexspline wear, wave generator wear and no fault. The correctness of the electromechanical coupling model established in this paper is verified, the

feature demodulation method is used to demodulate the fault features that are not modulated by the current frequency modulation. After further extracting the features, the multi-strategy ensemble learning method is used for fault diagnosis. Compared with the ensemble learning method based on Stacking and dynamic voting, the accuracy of the ensemble learning method based on D-S evidence combination is improved by 1%-3% . It provides theoretical guidance for fault diagnosis and condition monitoring of industrial robots with harmonic reducer in practical engineering applications.

Zhao Heng (Mechanical Engineering)

Supervised by Liu Yongming

KEY WORDS: harmonic reducer, ensemble learning, D-S evidence combination, fault diagnosis, demodulation of fault feature

目录

摘 要	I
ABSTRACT	III
第 1 章 绪论	1
1.1 课题来源	1
1.2 研究背景及意义	1
1.3 国内外研究现状	3
1.3.1 工业机器人用减速器故障诊断方法研究现状	3
1.3.2 集成学习方法研究现状	8
1.4 主要研究内容及章节安排	11
第 2 章 谐波减速器-驱动电机机电耦合数学模型建立与仿真	14
2.1 谐波减速器机构原理及传动方式简介	14
2.1.1 谐波减速器机构原理	14
2.1.2 谐波减速器失效形式	15
2.2 谐波减速器-驱动电机机电耦合数学模型的建立	16
2.2.1 谐波减速器-驱动电机机电耦合数学建模	16
2.2.2 谐波减速器-驱动电机机电耦合电流信号调制分析	18
2.3 谐波减速器-驱动电机机电耦合系统仿真	20
2.4 本章小结	22
第 3 章 机电耦合系统故障信号解调及特征提取方法研究	23
3.1 机电耦合系统故障信号解调方法研究	23
3.1.1 单一故障频率解调方法研究	25
3.1.2 多个故障频率解调方法研究	26
3.2 机电耦合系统故障信号特征提取方法研究	29
3.2.1 特征提取理论方法	29

3.2.2 单一故障解调前后特征提取对比分析	31
3.2.3 多故障解调前后特征提取对比分析	33
3.3 本章小结	37
第 4 章 基于多策略集成学习的谐波减速器故障诊断方法研究	38
4.1 基模型的构建	38
4.1.1 基于决策树模型预测方法的故障诊断	38
4.1.2 基于支持向量机模型预测方法的故障诊断	40
4.1.3 基于朴素贝叶斯模型预测方法的故障诊断	42
4.1.4 基于 K 最近邻模型预测方法的故障诊断	44
4.2 基于多策略集成学习的谐波减速器故障诊断方法研究	46
4.2.1 集成学习方法的选型	46
4.2.2 结果分析	48
4.3 本章小结	49
第 5 章 实验验证	50
5.1 谐波减速器试验台的搭建	50
5.2 实验验证	52
5.2.1 谐波减速器不同故障下的电流信号分析	52
5.2.2 通过特征解调方法解调谐波减速器故障特征并提取	57
5.2.3 基于多策略集成学习方法的谐波减速器故障诊断	60
5.3 本章小结	61
第 6 章 结论与展望	63
6.1 结论	63
6.2 展望	64
参考文献	65
攻读硕士学位期间发表学术论文及参研项目	71
致谢	72

第 1 章 绪论

1.1 课题来源

本课题来源于 2023 年度芜湖市“赤铸之光”重大科技成果工程化项目——工业机器人精密减速器高加速寿命测试装备开发及产业化（2023zc05）。

1.2 研究背景及意义

随着全球制造业向智能化和自动化转型，机器人技术在工业生产中的应用日益广泛。谐波减速器作为机器人关节的关键部件^[1]，主要用于传递动力和调整速度及扭矩^[2-4]，以精确控制机器人的动作，因其高精度、大扭矩、紧凑结构和高效传动等优点^[5]，广泛应用于工业机器人、航空航天、精密机床、医疗器械等多个领域，如图 1-1 所示。谐波减速器通过其独特的柔性齿轮结构，能够实现高精度的位置控制和稳定的动力传递，其性能直接影响工业机器人的精度和稳定性，所以，对工业机器人用减速器进行故障诊断至关重要^[5]。



图 1-1 谐波减速器的应用领域

谐波减速器在实际运行中面临着诸多挑战。由于其工作环境恶劣、负载变化频繁且长时间连续运转，谐波减速器内部零件容易发生磨损、疲劳和老化等问题，导致性能下降甚至失效。特别是在工业机器人中，减速器的可靠性直接影响到整个机器人的运动精度和使用寿命。因此，如何有效监测谐波减速器的健康状态，及时发现潜在故障并进行

维护，成为了提升机器人可靠性和延长使用寿命的关键问题。

研究减速器故障诊断的方法有很多^[6-10]，近年来，随着传感器技术和数据驱动方法的高速发展，基于电流信号的故障诊断技术逐步成为研究的热点。电流信号作为表征电机及减速器运行状况的关键参量，能够提供丰富的故障信息。通过对电流信号的实时监测和分析，可以提前预警减速器的异常情况，避免因突发故障导致的停机和经济损失。采集电流信号时，只需要将霍尔传感器直接套在驱动电机输入电流的线缆上即可完成，无需额外的传感器安装空间，并且电流信号可以在工业信号中轻松获取，这使得它们对传感器位置不敏感，也不会侵入被监控的机器人系统，此外，电流数据通常作为工业机器人使用企业的备份数据，会被上传至云端，以用于工业机器人设备故障诊断。

工业机器人用谐波减速器结构复杂，难以进行精细化建模，导致基于模型的故障诊断方法难以完全实现减速器故障准确诊断，因此数据驱动方法是当前用于工业机器人用谐波减速器故障诊断的主流方法。数据驱动的方法，如机器学习方法，其性能极大地依赖于数据质量。采用电流信号对工业机器人用谐波减速器进行故障诊断过程中，为提高数据质量，现有技术在电流信号预处理阶段，往往更注重数据对齐、归一化和滤波，其中滤波通常采用常规的低通或高通滤波器，难以消除电流信号中转速对减速器故障信息的调制干扰。常规滤波方法仅能消除电流信号中的低频干扰或者高频噪声，而电流调频频率调制的干扰依然存在。这导致在基于电流信号的减速器故障特征信息提取过程中，对于同一减速器故障类型，不同的转速工况下，提取的减速器故障特征并不一致，甚至相差很大，严重影响基于数据驱动的减速器故障准确识别。

与此同时，推动智能制造的发展是助力制造业升级转型的关键举措^[11]，智能维护和预测性维护已成为智能制造体系中不可或缺的核心组成部分。基于电流信号的故障诊断技术为实现智能维护提供了有效的手段，有助于构建更加智能、高效的生产系统，提升企业的竞争力。在一些关键领域，尤其是在医疗设备和航空航天应用中，谐波减速器的故障可能会直接威胁到人员的生命安全。基于电流信号的故障诊断技术可以实时监测减速器的运行状况，提前预知潜在风险，有效防止重大事故的发生，从而保障人员安全。此外，当前高端谐波减速器市场主要被国外企业所占据，国内企业在核心技术方面仍存在较大差距。通过深入研究谐波减速器的故障诊断技术，可以积累宝贵的技术经验，提升国内企业的自主研发能力，逐步打破国外技术垄断，推动我国工业机器人产业的自主

发展。这不仅满足了设备健康运营的需求，还有助于提升我国制造业的国际竞争力。

本文以谐波减速器为研究对象，旨在开展基于电流信号的故障诊断方法研究，揭示谐波减速器故障在电流信号中的表现形式，探索有效的特征提取、故障监测及诊断方法，确保谐波减速器在运行过程中的安全性和可靠性。为实际工程应用中机器人用谐波减速器故障诊断提供理论指导。

1.3 国内外研究现状

工业机器人用减速器作为精密传动系统的核心部件，其运行状态直接影响机器人整机的定位精度、动态性能以及使用寿命。随着工业自动化场景复杂度的提升，减速器长期承受变载荷、高频率的工况冲击，易引发齿轮磨损、轴承失效等渐进性的故障。一旦减速器发生故障，轻则导致机器人重复定位精度超差、运动轨迹偏移，造成精密加工产品批量报废；重则可能引发传动链卡滞甚至整机停机，特别是高速运动关节的突发性失效可能导致机械臂失控碰撞，威胁人员安全和生产环境稳定。因此，对减速器进行故障诊断和状态监测就显得尤为重要。当前针对工业机器人用减速器的故障检测方法有很多，不少学者针对不同的信号类型以及不同的神经网络方法开展工业机器人用减速器的故障诊断，实现对谐波减速器故障的高效识别。

本文将围绕以下两个方向展开论述：（1）工业机器人用减速器的研究现状，重点分析振动信号、电流信号等监测数据的研究进展与应用边界；（2）针对当前主要的集成学习方法研究现状进行探讨，分析基于 Bagging、Boosting 等经典框架及其在各大领域的迁移应用潜力。

1.3.1 工业机器人用减速器故障诊断方法研究现状

工业机器人用减速器作为高精密传动系统的核心部件，其运行状态直接决定了机器人系统的定位精度、动态性能与可靠性。近年来，随着工业机器人应用场景的复杂化与负载需求的多样化，减速器故障诊断技术逐渐从传统阈值报警向多源信号融合分析的方向发展。现有研究主要围绕振动信号、电流信号、温度信号及声发射信号等物理量的特征提取与模式识别展开^[12]，如图 1-2 所示，从不同的信号类型里挖掘故障之间的潜在关联性。




图 1-2 工业机器人用减速器的主要研究方式架构图

（一）基于振动信号的工业机器人用减速器研究现状

振动信号主要包括振动加速度信号，因其对齿轮啮合异常、轴承损伤等机械故障具有高敏感性。目前针对振动信号开展减速器故障诊断的研究已经相对成熟。雷亚国等^[13]提出了一种基于稳态工况数据截取的 RV 减速器故障诊断方法，利用 RV 减速器往复运动振动数据验证了该方法能够克服转速变化的影响提取故障信息。李旭阳^[14]针对机器人抖动的问题，基于振动信号提出一种改进传递路径分析的方法，并利用经验模态分解和希尔伯特(Hilbert)包络法得出机器人抖动问题根本原因并做出改进，以提升机器人的振动性能。韩特等^[15]基于振动加速度信号构建了一种融合图标签传播与判别特征增强技术的 RV 减速器半监督故障诊断模型。得出该方法在处理无标记样本及少量标记样本时，能够显著提升故障诊断的识别准确率。针对 RV 减速器振动信号中存在高斯噪声和非高斯噪声的问题^[16]，JIANG K S 等^[17]提出了一种改进的深度卷积神经网络（DNCNN）结合 CBAM 注意力机制模块的噪声去除算法，从而提升了 RV 减速器主轴承故障模式在噪声干扰下的故障识别率。E Y K 等^[18]为研究 RV 减速器在摆线轮和针轮局部故障状态下的振动特性建立了动力学模型，并通过傅立叶边带分析和包络谱分析诊断出摆线轮和针轮的局部故障。KOMORSKA I 等^[19]基于摆线针轮减速器的振动信号提出一种多重分形分析，并采用小波领袖法（WLMF）对实验台上的摆线齿轮损伤进行故障诊断。

（二）基于声发射信号的工业机器人用减速器研究现状

声发射信号作为近些年的研究热点，目前也已经取得显著的研究进展，现阶段已有不少学者基于声发射信号对工业机器人用减速器的相关分析进行研究。此外，声发射信号凭借对高频冲击事件（如齿面微裂纹、剥落）的捕捉能力，成为早期故障预警的新兴研究方向，但其信号处理复杂度高且易受环境噪声干扰，实际工程应用仍面临挑战，为

此,不少学者提出新的解决方案。赵永强等^[20]基于声发射信号提出一种基于 PCA 异常点累计指标的性能退化评估方法,通过对比传统的算法,完成对谐波减速器早期性能退化的评估。安海博等^[21]为了研究 RV 减速器在不同磨损工况下的声发射信号变化,通过分析不同频段的时频分量特征,建立了声发射信号与减速器状态之间的数学传递模型,并通过实验结果进行了验证。苟东荣等^[22]针对声发射信号在齿轮箱故障诊断领域展开研究,并总结了当前研究所存在的问题和进一步的研究方案。YANG JW 等^[23]对声发射信号进行压缩,通过频域分析,采用 softmax 分类器对 RV 减速器进行故障诊断,并实验验证了该方法具有高效的识别能力。LIU L S 等^[24]基于声发射信号,采用小波区域相关阈值去除原始信号中的噪声,并通过操作模态分析(OMA)和变分模态分解(VMD)相融合的方法实现谐波减速器的故障检测。AN H B 等^[25]基于声发射信号提出了一种基于隐马尔可夫模型的 RV 减速器故障检测方法,该方法相对于传统的故障检测方法在更复杂的减速器故障场景中能够表现更加优异的识别效果。ZHANG JJ 等^[26]基于声发射信号研究游乐园大摆减速器随摆锤运动的声发射特性,得到了转速变化和负载变化对减速器声发射信号的影响。强调了声发射技术在游乐设备减速器健康监测中的重要性。

(三) 基于温度信号的工业机器人用减速器研究现状

当前,温度信号则通过监测减速器运行中的温升趋势,为润滑失效或局部过载等缓变故障提供辅助判据,但其动态响应滞后性限制了其在实时诊断中的应用,当前基于温度信号研究减速器主要集中在其在传动过程中齿面磨损以及发热的情况。刘国春等^[27]提出了一种动态温度场数值分析方法,通过计算齿面温度从而避免齿面过热引起的传动系统及润滑失效的问题,并通过实验验证了该方法计算结果的准确性。庞大千等^[28]基于不同工况下的行星齿轮,采用有限元法分析了其瞬态温度及齿面发热情况,结果表明,齿根面和齿顶面的最高温度随转速的变化而改变。乔帅等^[29]基于热力学原理建立数学模型,研究风电机组齿轮传动系统的动态温度场分布特性,运用有限元法进行求解后并加以实验验证,得到该模型在不同转速及不同共振类型下的温度变化。张小强等^[30]基于温度校正和冲击负荷下对减速器进行可靠性分析,通过有限元仿真分析了在不同温度下滤波降低的热变形。并使用 ADAMS 对修订模型的运动进行分析,最后得出温度不会导致故障,但会影响传播的精度结论。GAN L 等^[31]提出了一种结合混合弹性流体动力润滑模型与基于热分析的有限元方法的数值方法,用于研究螺旋锥齿轮在混合润滑状态下的热效

应,推断出其齿根周围温度最高,齿顶周围由接触摩擦导致发热量高,且混合润滑比边界润滑降温效果更明显。WANG S S 等^[32]首次提出了单滚子包络环面蜗杆 (ASEHW) 齿轮的热功率计算方法,对齿轮传动过程进行热力学分析,通过仿真四种不同转速工况下齿轮分析了 ASEHW 齿轮温升的主要因素,并实验验证了仿真结果和理论方法的准确性。

(四) 基于电流信号的工业机器人用减速器研究现状

电流信号作为电机负载状态的直接表征,近年来逐渐受到关注,其优势在于无需额外安装传感器,即可通过电机驱动电流的谐波分量间接反映减速器内部扭矩波动与传动效率变化。近年来,研究者们开始探索通过电流信号分析减速器的性能和健康状态。目前针对电流信号对工业机器人用减速器的研究主要集中在对减速器和驱动电机之间的建模及仿真、对电流信号的特征提取、故障诊断以及状态检测等。王嘉等^[33]提出了一种基于电机电流诊断谐波减速器故障的信号采集装置,利用信号连接的电流检测模块、数据采集模块以及数据处理单元对电流信号数据进行采集和预处理。柳杨等^[34]建立了谐波减速器-伺服电机的机电耦合数学模型,并仿真分析了驱动电机电流与减速器间隙之间的内在关系,并通过改进的机器学习方法对其性能优劣进行评价。陈仁祥等^[35]基于电压信号识别谐波减速器的健康状况,通过连续小波变换将电压信号转换为时频图,并利用卷积神经网络的深度学习方法实现了对谐波减速器健康状态的有效识别。RAOUFI 等^[36]重点探讨了齿轮裂纹和其与电机定子电流之间关系的模型,为深入研究减速器故障的特征提取及故障诊断提供理论指导。CHEN X W 等^[37]针对电机定子电流信号中相对较弱且时变的故障特征难以揭示和呈现的问题,采用自适应迭代广义解调方法,将电机电流特征分析技术用于行星齿轮箱实现故障诊断。ROHANA 等^[38]对减速器的故障电流特征采用多种改进的特征提取方法进行提取,该方法能够适应不同复杂工况下多个故障特征,具有良好的鲁棒性和准确性,在使用机器学习方法进行故障诊断时能提高训练模型的准确性。

近年来,部分学者指出单一传感器在信号采集时可能面临信息不全面的问题,因此提出了信号融合方法来探索更有效的解决方案。柳杨^[39]基于电流信号和振动信号提出多种不同的特征提取方法,均采用支持向量机和概率神经网络对特征向量实现对传动误差故障程度进行有效的分类。胡淼等^[40]基于多源数据融合的方式设计了电液车辆减速器监

测系统,该系统整合液位、压力、换向阀、温度、电信号、位置表示信息等多源数据,通过神经网络和机器学习算法进行训练和分类,以达到提升故障识别精度的效果。康守强等^[41]针对谐波减速器在单一传感器下采集的数据可能存在信息缺失的问题,提出一种信息融合子域的方法,对谐波减速器在不同工况下进行故障诊断,并通过实验验证其方法在分类过程中准确率较高的特性。XIE W S 等^[42]基于电流信号和振动信号,利用小波分解变换获得的瞬时频率趋势图,并截获了振动信号的稳态相,通过选择 VMD 的参数后设置最大峰度标准用于完成敏感成分的提取,最后成功分离 RV 减速器的故障特征。YE Q 等^[43]利用多通道振动数据的多个模态中获取深度代表性特征,通过随机森林将深度信念网络(MDBN)获取的深度代表性特征进行融合,构建多深度信念网络融合模型,并通过对比得出数据融合可以有效提高故障诊断的识别率。ZHANG K L 等^[44]基于多源信息融合学习,提出了一种改进的图卷积网络-可信多源信息融合(MGCN-TMIF)框架,用于挖掘深度敏感的故障特征。利用改进的图卷积网络深入挖掘原始信号中的样本间关系,实验验证结果表明,分类精度达到了 100%。

尽管多源信息融合方法通过整合异构信号的互补性缓解了单一信号的信息缺失局限,但其在工程应用中面临多重挑战。工业机器人的紧凑结构对传感器部署提出了严格要求:振动、声发射等信号采集需额外安装高精度传感单元,不仅占用有限空间,还可能因附加质量影响传动系统的动态特性与定位精度。此外,多源信号固有的物理缺陷可能导致特征交互产生协同干扰,降低诊断可靠性。更重要的是,处理高通量异构数据需要高性能计算单元,导致系统功耗与硬件成本增加,难以满足工业现场对经济性和实时性的需求。这些因素共同制约了多源信息融合方法在工业机器人故障诊断中的规模化应用,促使研究者转向更具工程适配性的单一信号深度挖掘方向。

综上所述,工业机器人用减速器故障诊断技术正逐步从单一信号分析向多源信息融合方向演进。振动信号凭借对机械冲击的高灵敏度,在齿轮啮合异常、轴承损伤等典型故障的识别中占据主导地位;声发射信号依托高频事件捕捉能力,为早期故障预警提供了新途径;温度信号则通过温升趋势分析,成为润滑失效与局部过载等缓变故障的关键判据。然而,单一信号的应用受限于其物理特性:振动信号易受环境噪声干扰,声发射信号处理复杂度高且环境适应性不足,温度信号因动态响应滞后难以满足实时诊断需求。相比之下,电流信号无需附加传感器即可间接表征减速器内部扭矩波动与传动效率变化,

具有无侵入式监测特性和工业现场数据兼容性，展现出独特的工程实用价值。

尽管多源信息融合方法提升了诊断鲁棒性，但其实际应用仍面临严峻挑战，如异构信号特征尺度差异导致的算法复杂度增加和动态负载工况下的模型泛化能力不足。在此背景下，电流信号的优势进一步凸显：其与电机控制系统的天然集成使得低成本连续监测成为可能，并且部分企业已建立历史电流数据的长期备份机制。因此，基于电流信号的谐波减速器故障诊断研究不仅规避了多源融合的技术瓶颈，还具备快速工程转化的潜力，是一种兼具高效性和实际应用价值的可靠研究方向。

1.3.2 集成学习方法研究现状

集成学习技术凭借基分类器多样性优化与决策融合机制，广泛应用于众多领域，在复杂系统故障诊断中展现出显著优势。集成学习方法主要分为基于 Bagging 的方法、基于 Boosting 的方法、基于 Stacking 的方法和混合动态集成等，如图 1-3 所示。集成学习成功的关键在于基分类器的多样性和准确性^[45]，现已有不少学者基于不同的集成学习方法在各个领域进行分类及应用。




图 1-3 集成学习方法的主要分类

（一）基于 Bagging 类方法的研究现状

基于 Bagging 的集成学习方法作为经典的集成学习方法之一，目前仍有许多学者基于此方法进行研究。在工业上，康英哲等^[46]基于 Wasserstein 距离和随机森林对特征进行跨域选择，并将其与进化 Bagging 集成学习相结合的方式提出了一种超短期风电功率预测的新方法，相对于单一机器学习模型在分类过程中准确率得到明显提高。杨龙蛟等^[47]为检测用电异常的问题，针对具有明显异常特征的数据集采用多数投票法作为决策合成的策略，结果表明相对于单一的模型在准确率和召回率上预测能力均得到有效提升。在农业上，马荔瑶等^[48]为提高苹果自动分级分拣系统的性能，提出一种基于证据有序极

限学习机 Bagging 集成的无损苹果分级模型,通过 D-S 证据合成理论构造证据编码在基学习器中作为输出的证据,并通过 Bagging 算法实现集成学习。这种方法在分类结果中准确率得到了有效提升。Ngo G 等^[49]提出了一种进化 Bagging 集成学习,通过进化算法来优化 Bagging 的方法,最终结果得到在某些约束条件下进化集成 Bagging 方法在几个基准数据集上优于传统的集成方法。在气候上预测上, XU S B 等^[50]基于 Bagging 集成学习算法来预测地磁活动强弱,将人工神经网络、支持向量回归和长短期记忆网络三种算法相结合,以精确地实现对地磁活动强弱指数提前 1~6 小时的预报。LIU X L 等^[51]将梯度提升决策树方法引入到 Bagging 框架的基学习器训练过程中,提出了一种基于 Bagging 集成学习框架的预测模型(Bagging-GBDT)来预测城市空气污染物浓度,与传统的 SVR 和随机森林算法相比预测效果得到有效提升。

(二) 基于 Boosting 类方法的研究现状

基于 Boosting 的集成学习方法同样作为经典的集成学习方法之一,在不同领域分类的过程中也展现出显著优势。罗爽等^[52]提出一种基于 Boosting 的超分辨率算法来处理复杂多样的自然图像,对复杂图像进行重构时,能够提升图像边缘的清晰度及纹理细节,从而实现图像整体的质量的提升。李润祥等^[53]提出了基于双树复小波分解的 Boosting 集成学习分类方法,用于减小噪声对模型的影响,并通过多种分类方法进行对比从而实现滤波后的 Boosting 集成学习分类方法能够提高分类精度。周孟然等^[54]提出一种基于外界因素干扰下的集成优化的空调负荷预测方法,通过筛选相关性较高的特征后使用机器学习模型对参数进行优化,并结合自适应 Boosting 算法构建提升预测的精确程度。KARTHIK M 等^[55]研究了基于 Boosting 的土壤特性估计方法,提出了额外梯度增强方法(XGBoost)。实验结果表明,与传统的神经网络相比,XGBoost 在土壤特性预测的准确性方面有显著提升。YANG S Y 等^[56]为解决短期交通预测的问题,提出一种基于梯度提升决策树(GBDT)短期交通预测的集成学习方法,并通过对比单一的学习方法验证其预测准确率得到明显的提高。ZAHOR M M 等^[57]提出了一种基于深度学习的新型两阶段框架来预测和分类磁共振图像(MRI)中的脑肿瘤概率,通过静态和动态特征以及 ML 分类器对不同肿瘤类型进行分类,并与当前先进的预测方法相比,表明该方法在模型识别的召回率、精确率、准确率等方面都得到明显提高。

（三）基于 Stacking 方法的研究现状

Stacking 集成学习方法基于自身稳定性的优势,已成为大多数学者常用的集成模型,郑一鸣等^[58]结合主成分分析(PCA)和多层堆叠集成算法(Multi-layer Stacking)对盾构施工中地表最终沉降模型进行预测,结果表明,其在地表隆起、沉降变化高度都具有良好的预测能力。郭志强等^[59]提出了一种基于近红外光谱技术和 Stacking 集成学习方法的无损预测猕猴桃含糖量的方法。通过对比五种数据预处理方法的集成效果,根据预测精度确定了最佳的集成组合模型。慈铁军等^[60]为预测新能源发电功率,提出了一种基于自适应性的变分模态分解(VMD)的 Stacking 集成模型,并与传统的预测方法进行对比表明其准确率得到明显提高。CUI S Z^[61]为解决地震预测精度的问题,提出了一种基于 Stacking 集成学习和改进群体智能算法的预测方法,通过对比分析表明其可以有效地预测结果,进而提高预测精度。YANG Y F 等^[62]为能准确的分类帕金森病,提出了一种融合多模态特征的两层堆叠集成学习框架,通过识别早期帕金森病并与健康状态进行对照,并对比传统的机器学习的分类方法从而体现该方法的优越性。GUO X F 等^[63]提出一种基于 Stacking 集成学习方法的光伏功率预测模型,并将其模型结果与 XGBoost 的预测结果进行对比,体现该算法在光伏功率预测中的准确性。

（四）基于混合动态集成的研究现状

基于单一的集成学习方法可能依旧存在模型结构简单,用途局限等问题,目前,已有学者尝试将多种集成学习算法进行融合或自适应地应用于特征分类。王之腾等^[64]基于软投票、硬投票、自适应加权等不同集成学习策略来识别雷达工作模式的性能,并基于小样本数据对模型的识别性能进行研究,与传统的方法对比体现该混合集成方法的优越性能。荆澜涛等^[65]针对当前变压器故障识别方法在处理不平衡故障数据时存在较大偏差的问题,提出一种结合梯度调和损失函数和交叉熵损失函数的改进轻量级梯度提升机(GCLight GBM)的混合集成模型,并通过实验证明该方法在小样本和不均匀的数据集识别的准确率均较高。彭飞等^[66]针对当前机器人电池剩余电量识别不精准的问题,利用电源电压数据提出了一种基于状态-动作-奖励-状态-动作(Sarsa)强化学习算法的多学习器混合集成方法,在对电池余电预测鲁棒性、准确性和适应性上取得新进展。SIBINDI R 等^[67]提出一种混合 LGBM 和 XGBoost 模型用于预测未来房价发展趋势变化,并通过 4 种经典的集成学习方法进行比较,结果显示基于混合集成方法的识别的准确率明显高于

其他模型。NAGASSOUM 等^[68]提出一种基于轻梯度增强机 (LightGBM) 和基于梯度提升决策树 (CatBoost) 的混合模型用于预测 II 型糖尿病, 并通过多种机器学习模型对比评估, 表明基于混合集成模型具有最佳的召回率以及准确率。部分学者将两种集成方法在处理问题时进行自适应选择, AGARWALS 等^[69]提出一种 Stacking 和 Bagging 的自适应算法用于对不同的指纹进行分类, 并通过实验结果表明该自适应的集成学习方法在平衡和不平衡数据集上都能提供具有竞争力的结果。

尽管多源信息融合方法通过挖掘不同信号间的互补性特征, 在一定程度上突破了单一信号的局限性, 但其在实际应用中仍面临诸多挑战。与此同时, 集成学习方法凭借基分类器多样性优化与决策融合机制, 已在众多领域展现出显著优势。通过整合多个基学习器的结果, 集成学习能规避单一机器学习算法自身的局限性。

然而, 尽管集成学习方法取得了广泛的应用和显著的成果, 但在工业机器人用减速器故障诊断这一特定领域的应用却相对较少。目前, 针对减速器的集成学习分类研究较为匮乏, 这主要体现在以下几个方面: 首先, 现有集成学习策略虽在其他领域表现出色, 但在工业机器人用减速器故障诊断中的探索尚处于初级阶段, 缺乏系统性的研究; 其次, 集成学习方法的成功关键在于基模型的准确性和多样性, 若基模型性能不佳, 集成学习的效果可能适得其反, 因此选择合适的基模型对于提高减速器故障诊断的准确性至关重要; 此外, 如何有效地结合工业机器人用减速器的具体工况特点, 设计出适合该应用场景的集成学习框架, 也是当前研究亟待解决的问题之一。

因此, 本文旨在探讨基于集成学习方法的工业机器人用减速器故障诊断技术, 力求通过深入分析现有集成学习方法的优势与不足, 提出一种适用于减速器故障诊断的高效集成学习框架, 以期为工业机器人用减速器的状态监测与故障预测提供新的思路和技术手段。

1.4 主要研究内容及章节安排

本文主要工作内容如图1-4所示, 具体如下:

第1章, 首先给出课题来源, 并介绍研究背景及其意义, 然后分别对工业机器人用减速器及集成学习方法的国内外研究现状进行了系统性的分析与综述, 最终给出了本文的结构布局与内容安排。

第2章，基于电流信号对工业机器人用谐波减速器机电耦合系统的建模方法进行研究，通过仿真恒/变速工况下电流信号，揭示谐波减速器故障信号在电流信号中的表征特性，为后续基于电流的故障特征解调方法提供理论基础。

第3章，针对谐波减速器故障信号在电流信号中受电流调频频率调制干扰的问题，提出一种故障特征解调方法，在电流频域信号中进行解调得到不受调制的故障特征，并对解调前后电流时域信号的15种特征进行提取，分析特征随转速和时间的变化趋势，以及各特征之间的相关性，为基于集成学习的故障诊断方法提供数据基础。

第4章，针对单一的机器学习方法，很难满足多工况，多故障类型的减速器故障诊断，提出一种基于D-S证据合成理论的多策略集成学习方法，将决策树、支持向量机、朴素贝叶斯和K最近邻4种经典机器学习方法作为基模型，并与基于Stacking和基于动态投票的多策略集成模型进行对比，完成故障解调前后的特征分类，进而提高预测精度，以探索高效故障诊断模型，满足工程化快速诊断的需求。

第5章，通过搭建的谐波减速器试验台，并采集柔轮磨损、波发生器磨损和无故障工况下的电流数据，对故障数据进行频域分析来验证本文建立机电耦合模型的正确性，并通过特征解调方法进行解调得到不受电流调频频率调制的故障特征，进一步提取特征后，基于不同的集成学习方法对解调前后的特征进行故障诊断，完成对解调前后的特征及基于D-S证据合成理论的故障诊断模型的准确率进行验证。

第6章，总结本研究的关键成果，同时也指出研究过程中遇到的挑战与不足之处。进一步地分析基于电流信号的谐波减速器的发展历程和当前研究现状，对未来的研究趋势和潜在领域进行分析，为接下来的课题探索勾画了清晰的研究方向。




图 1-4 论文总体结构流程图

第2章 谐波减速器-驱动电机机电耦合数学模型建立与仿真

减速器是工业机器人核心关键零部件之一，其性能的好坏会对机器人的运行精度产生重要影响。基于电流信号对减速器进行故障诊断是应用较为广泛的一种方法，为精确的识别减速器故障，首先需要知道减速器故障信号在电流信号中的表现形式，但针对减速器故障模式在电流信号中的表现特性很少有学者研究。谐波减速器作为工业机器人常用的减速器类型之一，本文以谐波减速器为研究对象，建立谐波减速器与驱动电机的机电耦合模型，揭示谐波减速器的故障特征在电流信号的表征形式；通过仿真多故障频率在恒速/变速工况下的电流信号，观察谐波减速器故障下的时/频域分布特性。

2.1 谐波减速器机构原理及传动方式简介

2.1.1 谐波减速器机构原理

谐波减速器是一种高效的机械传动装置，因其独特的结构设计和优越的性能而被广泛应用于工业机器人机械手臂中。如图 2-1 所示，谐波减速器的基本结构包括波发生器、柔轮和刚轮。波发生器通常由一个椭圆形的凸轮和一个柔性轴承组成，当波发生器旋转时，柔性轴承会使柔轮产生周期性的弹性变形，从而与刚轮啮合。




图 2-1 谐波减速器结构图

谐波减速器具有传动比高、体积小、重量轻、传动精度和效率高等优点，其独特的柔性传动原理使其在高精度和高负载的传动场合中表现出色。

谐波减速器的传动过程可以分为三个主要阶段：输入阶段、变形阶段和输出阶段。在输入阶段，驱动电机作为谐波减速器的动力源，驱动波发生器旋转，波发生器的椭圆形状迫使柔轮沿刚轮内壁发生弹性变形。由于柔轮的材料具有良好的弹性，它能够在波发生器的作用下产生连续的波形变化。在变形阶段，柔轮的波形变化导致其与刚轮之间的接触点不断移动，从而实现多点啮合。这种多点啮合方式不仅提高了传动的平稳性，

还大大减少了单点接触时的磨损，延长了使用寿命。在输出阶段，柔轮的变形通过与刚轮的啮合传递到输出轴上，实现减速和增扭的功能。由于柔轮和刚轮之间始终保持多点接触，因此即使在高速运转的情况下，也能保持较高的传动精度和稳定性。其运动传递方式，如图 2-2 所示。




图 2-2 谐波减速器运动传递方式

谐波减速器通过柔轮的弹性变形实现大传动比，通常可以达到 30 至 320。由于其传动误差小，回程间隙几乎为零，因此在需要高精度定位的场合表现出色。此外，谐波减速器能够承受较大的扭矩负载，适用于高负载、高扭矩的工作环境。其体积小、重量轻，有利于设备的小型化和轻量化设计，同时其传动效率通常在 80%以上，能量损失较小。

2.1.2 谐波减速器失效形式

在工业机器人中，控制的精确程度是衡量其性能优劣的关键指标，因此，对机器人各零部件的要求极为严格，以确保系统的高精度和高可靠性。然而，随着使用时间的延长，零部件不可避免地会经历疲劳损伤，尤其是关键部件如谐波减速器，其失效会导致传动效率下降，并引起振动与噪声。严重情况下，可能导致设备卡滞或完全失效，进而增加电机的机械应力，使驱动电机承受更大负载，需输出更高扭矩以维持正常运作。这一过程会直接导致驱动电机电流的增大及温度的升高，最终可能引发电机过载。不仅影响设备的整体性能与使用寿命，同时也显著降低了机器人的控制精度与运行稳定性。

谐波减速器失效形式主要包括柔轮疲劳失效、波发生器磨损、齿轮啮合失效和润滑失效。如图 2-3 所示，柔轮在长期的弹性变形过程中会产生疲劳裂纹，最终导致失效，这是谐波减速器最常见的失效形式之一。波发生器是谐波减速器的关键部件，其表面磨损会影响减速器的传动精度和使用寿命。由于谐波减速器的齿轮啮合方式特殊，齿轮在高负载下可能会出现磨损、点蚀等失效现象。此外，润滑不良会导致减速器内部摩擦增大，温度升高，进而引发一系列失效问题。




图 2-3 谐波减速器常见的失效形式

为了提高谐波减速器的可靠性和使用寿命，研究人员不断优化其设计和材料选择。例如，采用高强度、耐疲劳的材料制造柔轮，改进波发生器的表面处理工艺，以及优化齿轮的啮合设计等。这些改进措施不仅能够延长谐波减速器的使用寿命，还能提高其工作性能，满足各种复杂工况下的应用需求。同时对谐波减速器进行故障诊断及状态检测，准确的判断机械运行状态，及时发现早期故障，从而进行剩余寿命预测，也是保证工业机器人安全可靠运行的关键技术。

在谐波减速器故障诊断中，频率和幅值是影响故障分类的关键因素，相位角可以诊断故障发生的位置。因此，本文基于电流信号开展谐波减速器故障诊断的研究，从频率和幅值出发，构建减速器与驱动电机之间的机电耦合数学模型，不仅有助于揭示故障发生的内在机制，还能为故障特征的提取与分析提供理论基础，从而推动故障诊断技术的发展和完善。

2.2 谐波减速器-驱动电机机电耦合数学模型的建立

2.2.1 谐波减速器-驱动电机机电耦合数学建模

谐波减速器是工业机器人核心关键零部件，工业机器人机械臂一般包括驱动器、驱动电机、谐波减速器、传动轴等。控制器控制电机输出标准转速和转矩，经谐波减速器转换，再通过传动轴输出需要转速和转矩，其典型结构如图 2-4 所示。



图 2-4 谐波减速器与电机传递耦合系统

基于机电耦合原理，驱动电机输入电流信号中包含谐波减速器工作状态信息。驱动电机输出转矩 $T(t)$ 可表示为：

$$T(t) = T_0(t) + \sum_{n=1}^N T_n(t) \cos \left[\int 2\pi f_n(t) dt + \varphi_n(t) \right] \quad (2-1)$$

其中： $T_0(t)$ 表示驱动电机输出理想转矩； $T_n(t)$ 、 $f_n(t)$ 和 $\varphi_n(t)$ 分别表示由谐波减速器自身振动或碰摩引起的振荡转矩、振动频率和相位。

根据传输转矩 $T(t)$ 与负载转矩 $T_m(t)$ 之间的关系，有：

$$T(t) = J \frac{d\omega_r(t)}{dt} + \xi \omega_r(t) + T_m(t) \quad (2-2)$$

其中： J 表示谐波减速器转动惯量； ω_r 表示角速度； ξ 表示系统阻尼系数。

对式(2-1)两端积分，得到：

$$f_r(t) = f_0(t) + \sum_{n=1}^N A_n(t) \sin \left[\int 2\pi f_n(t) dt + \varphi_n(t) \right] \quad (2-3)$$

其中： $f_r(t)$ 为驱动电机输出实际转速频率； $f_0(t)$ 为驱动电机输出理想转速频率； $A_n(t)$ 为谐波减速器自身振动或碰摩引起的振动幅值，可表示为：

$$A_n(t) = \frac{T_n(t)}{4\pi^2 J f_n(t)} \quad (2-4)$$

驱动电机输入的理想三相电流 $I_a(t)$ 、 $I_b(t)$ 和 $I_c(t)$ 为：

$$\begin{cases} I_a(t) = I_o(t) \sin \left[\int 2\pi f_c(t) dt \right] \\ I_b(t) = I_o(t) \sin \left[\int 2\pi f_c(t) dt - \frac{2}{3}\pi \right] \\ I_c(t) = I_o(t) \sin \left[\int 2\pi f_c(t) dt - \frac{4}{3}\pi \right] \end{cases} \quad (2-5)$$

其中： $f_c(t)$ 为驱动电机电流调频频率； $I_o(t)$ 为总电流幅值。

根据驱动电机原理，电机电流调频频率与输出转速之间的关系为：

$$f_r = \frac{f_c}{P} \quad (2-6)$$

其中， P 为电机极对数，同一个电机里极对数为定值。

驱动电机输入电流与输出功率成正比关系，即：

$$I_o(t) \propto T(t) \cdot f_r(t) \quad (2-7)$$

为简化模型，采用比例系数 k 表征上述正比关系，结合式(2-1)~(2-3)，忽略二阶项

(通常可以忽略不计)，总电流信号的幅度可以近似为：

$$I_o(t) = k \left(T_0(t) \cdot f_{r_0}(t) + \sum_{n=1}^N \sqrt{T_0(t)^2 A_n(t)^2 + f_{r_0}(t)^2 T_n(t)^2} \sin \left(\int 2\pi f_n(t) dt + \varphi_n(t) \right) \right) \quad (2-8)$$

为进一步探究故障特征在驱动电机电流信号中的具体表现形式，将式(2-8)进行简化，令：

$$I_p(t) = T_0(t) \cdot f_{r_0}(t) \quad (2-9)$$

$$I_n(t) = \sqrt{T_0(t)^2 A_n(t)^2 + f_{r_0}(t)^2 T_n(t)^2} \quad (2-10)$$

其中：\$I_p(t)\$ 为正常电流幅值；\$I_n(t)\$ 为故障电流幅值。

结合式(2-8)、式(2-9)、式(2-10)，代入式(2-5)可得到谐波减速器-驱动电机机电耦合系统理想单相调制电流表达式：

$$I_a(t) = k \left(I_p(t) \sin \left(\int 2\pi f_c(t) dt \right) + \sum_{n=1}^N I_n(t) \sin \left(\int 2\pi f_n(t) dt + \varphi_n(t) \right) \sin \left(\int 2\pi f_c(t) dt \right) \right) \quad (2-11)$$

根据驱动电机的输出特性可知，在恒速工况下，转速频率 \$f_{r_0}\$ 和正常电流幅值 \$I_p(t)\$ 均为定值，结合式(2-3)和式(2-6)可知，恒速下电流调频频率 \$f_c\$ 也为定值，对式(2-11)进行简化：

$$I_a(t) = I + k \left(\sum_{n=1}^N I_n(t) \sin \left(\int 2\pi f_n(t) dt + \varphi_n(t) \right) \sin \left(\int 2\pi f_c(t) dt \right) \right) \quad (2-12)$$

其中，\$I\$ 为常数。具体表达式为：

$$I = k \left(I_p(t) \sin \left(\int 2\pi f_c(t) dt \right) \right) \quad (2-13)$$

由此得到谐波减速器-驱动电机机电耦合的简化数学模型。

2.2.2 谐波减速器-驱动电机机电耦合电流信号调制分析

由式(2-13)可以得出，由工业机器人用谐波减速器自身振动或碰摩引起的故障特征会被电机电流调频频率 \$f_c\$ 所调制，结合式(2-6)和式(2-7)可知，电流调频频率及其对应的幅值会随着转速变化而改变，选取任一故障，在式(2-12)内提取故障电流幅值 \$I_n(t)\$ 及其对应的相位，得到故障调制电流幅值 \$I_n^*(t)\$：

$$I_n^*(t) = I_n(t) \sin \left(\int 2\pi f_n(t) dt + \varphi_n(t) \right) \sin \left(\int 2\pi f_c(t) dt \right) \quad (2-14)$$

由三角函数的恒等变换 \$\sin(x)\sin(y) = 1/2 [\cos(x-y) - \cos(x+y)]\$，可以得到：

$$I_n^*(t) = \frac{1}{2} I_n(t) \left[\cos \left(\int 2\pi (f_n(t) - f_c(t)) dt + \varphi_n(t) \right) - \cos \left(\int 2\pi (f_n(t) + f_c(t)) dt + \varphi_n(t) \right) \right] \quad (2-15)$$

由上式可知，故障电流幅值受到转速调制后形成的两个不同的频率分量的故障调制电流幅值，其低频边带和高频边带分别为 $f_n(t)-f_c(t)$ 和 $f_n(t)+f_c(t)$ ，二者对应的电流幅值相等，并且均为故障电流幅值 $I_n(t)$ 的一半。故障频率 $f_n(t)$ 在经过电流调频频率调制后得到一对故障调制频率 $f_n(t)-f_c(t)$ 和 $f_n(t)+f_c(t)$ ，且幅值相等，均为故障电流幅值 $I_n(t)$ 的一半。假设谐波减速器存在两个故障频率，分别为 $f_{n1}(t)$ 和 $f_{n2}(t)+2f_c(t)$ ，并假设其幅值分别为 $I_{n1}(t)$ 和 $I_{n2}(t)$ ，经过电流调频频率调制后，调制后的两对故障调制频率分别为 $f_{n1}(t)-f_c(t)$ 、 $f_{n1}(t)+f_c(t)$ 和 $f_{n2}(t)+f_c(t)$ 、 $f_{n2}(t)+3f_c(t)$ ，由理论可以得出，两对故障调制电流对在频率为 $f_{n1}(t)+f_c(t)$ 处出现幅值叠加的情况，令故障调制信号 1 和故障调制信号 2 分别为：

$$I_{n1}^*(t) = I_{n1}(t) \sin \left(\int 2\pi f_{n1}(t) dt + \phi_{n1}(t) \right) \sin \left(\int 2\pi f_c(t) dt \right) \quad (2-16)$$

$$I_{n2}^*(t) = I_{n2}(t) \sin \left(\int 2\pi (f_{n2}(t) + 2f_c(t)) dt + \phi_{n2}(t) \right) \sin \left(\int 2\pi f_c(t) dt \right) \quad (2-17)$$

继续利用三角函数的恒等变换 $\sin(x)\sin(y) = 1/2 [\cos(x-y) - \cos(x+y)]$ 展开，可得：

$$I_{n1}^*(t) = \frac{1}{2} I_{n1}(t) \left[\cos \left(\int 2\pi (f_{n1}(t) - f_c(t)) dt + \varphi_{n1}(t) \right) - \cos \left(\int 2\pi (f_{n1}(t) + f_c(t)) dt + \varphi_{n1}(t) \right) \right] \quad (2-18)$$

$$I_{n2}^*(t) = \frac{1}{2} I_{n2}(t) \left[\cos \left(\int 2\pi (f_{n2}(t) + f_c(t)) dt + \varphi_{n2}(t) \right) - \cos \left(\int 2\pi (f_{n2}(t) + 3f_c(t)) dt + \varphi_{n2}(t) \right) \right] \quad (2-19)$$

二式相加可得：

$$\begin{aligned} I_{12}^*(t) &= I_{n1}^*(t) + I_{n2}^*(t) \\ &= \frac{I_{n1}(t)}{2} \left[\cos \left(\int 2\pi (f_{n1}(t) - f_c(t)) dt + \varphi_{n1}(t) \right) - \left(\cos \left(\int 2\pi (f_{n1}(t) + f_c(t)) dt + \varphi_{n1}(t) \right) \right) \right] + \\ &\quad \frac{I_{n2}(t)}{2} \left[\cos \left(\int 2\pi (f_{n2}(t) + f_c(t)) dt + \varphi_{n2}(t) \right) - \cos \left(\int 2\pi (f_{n2}(t) + 3f_c(t)) dt + \varphi_{n2}(t) \right) \right] \end{aligned} \quad (2-20)$$

由傅里叶变换可知，在提取频域特征时不考虑时间 t 和相位角 φ 的影响，所以由上式可知，叠加后的频率幅值主要分为三个频率分量，频率为 $f_{n1}-f_c$ 时，对应的余弦项是 $\cos \left(\int 2\pi (f_{n1}(t) - f_c(t)) dt + \varphi_{n1}(t) \right)$ ，其幅度为 $I_{n1}(t)/2$ ；频率为 $f_{n1}+f_c$ 时，对应的余弦项是 $\cos \left(\int 2\pi (f_{n1}(t) + f_c(t)) dt + \varphi_{n1}(t) \right)$ 和 $\cos \left(\int 2\pi (f_{n2}(t) + f_c(t)) dt + \varphi_{n2}(t) \right)$ ，其幅度分别为 $-I_{n1}(t)/2$ 和 $I_{n2}(t)/2$ ，因此总幅值为 $|I_{n2}(t)/2 - I_{n1}(t)/2|$ 。频率为 $f_{n1}+3f_c$ 时，对应的余弦项是 $\cos \left(\int 2\pi (f_{n2}(t) + 3f_c(t)) dt + \varphi_{n2}(t) \right)$ ，其幅度为 $I_{n2}(t)/2$ 。

2.3 谐波减速器-驱动电机机电耦合系统仿真

为研究故障特征在电流信号频域里的分布特性，基于谐波减速器-驱动电机机电耦合系统建立的数学模型，对机电耦合系统在恒速/变速工况下的电流信号进行仿真分析。为确保仿真参数与后续实验中驱动电机、谐波减速器及采集卡的参数一致，假设模拟仿真的电机极对数 $P=5$ ，减速器传动比 $i=100$ ，采样率 $f_s=60\text{ kHz}$ 。

本文研究谐波减速器故障特征在电流信号里的表现形式，为简化分析，假设谐波减速器理想转矩 $T=1$ ，仿真谐波减速器故障状态时，假设由谐波减速器引起的故障频率分别为 $f_{n1}=3\ 200\text{ Hz}$ ， $f_{n2}=5\ 400\text{ Hz}$ 和 $f_{n3}=7\ 780\text{ Hz}$ ，并假设其对应的波动转矩分别占理想输出转矩的 $10\%\ T$ ， $15\%\ T$ 和 $12\%\ T$ 。减速机构经常按减速器传动比反比的平方计算转动惯量，所以本文中取转动惯量 $J=1\times 10^{-4}$ 。

仿真时，谐波减速器转速工况由 0 rpm 开始以加速度为 300 rpm/s 进行加速， 10 s 后加速至 $3\ 000\text{ rpm}$ ，并保持恒速运行 5 s ，再以加速度为 -300 rpm/s 减速至 0 rpm ，转速工况的仿真结果如图 2-5(a)所示。分别提取加速、恒速和减速工况的电流信号，绘制时域波形图如图 2-5 中(b)、(c)和(d)所示。




图 2-5 不同转速工况下谐波减速器故障的电流信号仿真

图中黑色曲线为谐波减速器故障状态下的电流波形，绿色曲线为正常情况下的电流波形，通过仿真波形可以看出，故障信号的频率远远高于正常电流信号的频率，在不同的转速下，电流调频频率受转速的影响，且电流信号的幅值随着速度的变化而改变，在高转速下，电流信号的幅值较大，因此相较于低转速情况，其抗噪性能更强。

为进一步研究减速器故障特征在电流信号频域里的分布形式，采用短时傅里叶方法（STFT）对谐波减速器故障的电流信号进行频谱分析，得到时频关系如图 2-6 所示。




图 2-6 谐波减速器故障状态下的电流信号时频关系图

由图 2-6 可知，频率较低处存在 1 条功率较高的电流调频频率 f_c ，频率较高处存在 3 对故障调制频率，且电流调频频率 f_c 的功率明显大于故障调制频率的功率，随着速度的变化，电流调频频率和故障调制频率也随之变化。

为更好展示假设的谐波减速器故障频率与故障调制频率之间的关系，在加速、恒速和减速工况下随机提取 6.54 s、12.57 s 和 22.54 s 的频谱分布参数，具体如表 2-1 所示。

表 2-1 谐波减速器故障状态下参数

时间 (s)	电流调 频频率 f_c (Hz)	调频频 率功率 (W)	原故障 频率 f_n (Hz)	频率 f_n-f_c (Hz)	功率 (W)	调制前 后频率 差(Hz)	频率 f_n+f_c (Hz)	功率 (W)	调制前 后频率 差(Hz)	绝对 功率 差(W)
6.54	165	90.89	3 200	3 035	63.61	165	3 365	64.55	-165	0.94
			5 400	5 235	68.40	165	5 565	68.39	-165	0.01
			7 788	7 615	66.14	165	7 945	65.21	-165	0.93
12.57	250	93.87	3 200	2 950	67.83	250	3 450	68.61	-250	0.78
			5 400	5 150	71.49	250	5 650	71.38	-250	0.11
			7 788	7 530	70.21	250	8 030	69.43	-250	0.78
22.54	60	82.4	3 200	3 140	56.08	60	3 260	55.10	-60	0.98
			5 400	5 340	59.91	60	5 460	59.91	-60	0
			7 788	7 720	56.70	60	7 840	57.67	-60	0.03

由表 2-1 可知, 故障调制频率对与假设故障频率之间正好相差 $\pm f_c$, 每一对故障调制频率之间的差值正好等于 $2f_c$, 且功率高度接近。

为研究故障调制信号出现叠加现象时的表现形式, 本文设定的故障频率如表 2-2 所示。在转速为 3 000rpm 恒速工况下, 根据表 2-2 中设定的故障频率采用傅里叶变换得到的频率叠加下的故障调制信号, 如图 2-7 所示。

表 2-2 仿真叠加情况下的故障调制频率时设定的故障频率

	故障 1	故障 2	故障 3	故障 4
频率(Hz)	3 200.3	3 700.3	15 900.2	16 400.2
幅值(A)	6	8	12	10




图 2-7 存在叠加频率的故障调制频率对

由设定的故障频率和幅值与仿真的故障调制频率和幅值对比能够得出, 设定的故障信号之间相差 2 倍的电流调频频率 f_c 时, 受到调制后的故障调制频率存在幅值叠加情况, 叠加处的幅值为 $|I_{n2} - I_{n1}|/2$, 为后续用于信号的特征解调提供理论基础。

2.4 本章小结

本章基于谐波减速器-驱动电机机电耦合系统建立数学模型, 研究谐波减速器故障信号在电流信号中的表征特性, 揭示故障信号在电流信号中会受到电流调频频率干扰的机理, 以及故障调制频率对存在叠加时频率对应的幅值关系, 通过仿真验证了建立模型的准确性, 并分析谐波减速器故障特征与在电流信号中受调制的故障特征之间频率和幅值的关系, 为后续故障特征的解调提供理论基础。

第3章 机电耦合系统故障信号解调及特征提取方法研究

数据驱动方法是当前用于工业机器人用谐波减速器故障诊断的主流方法，在电流信号中，减速器故障特征频率会受到转速调制，严重影响基于数据驱动方法的减速器故障特征提取环节。为解决这一问题，提出一种工业机器人用谐波减速器故障数据预处理方法，基于减速器故障信息与转速调制关系，实现减速器故障特征信号解调，消除转速信息干扰，同时，提取特征解调前后的三种故障模式下的 15 个故障特征，观察这些特征在相同频率不同转速以及相同转速不同频率下的分布规律。并通过皮尔逊相关性分析找到各个特征之间的关联程度，为基于电流信号的减速器故障特征准确提取提供数据支撑和技术支持。具体流程如图 3-1 所示。




图 3-1 信号特征提取过程

3.1 机电耦合系统故障信号解调方法研究

减速器故障数据特征解调时，在数据采样频率 f_s 确定的情况下，数据长度决定了数据频率分辨率。此外，考虑到减速器为圆周旋转运动，不同故障类型出现周期与减速器旋转角度直接相关。根据减速器机理，假设减速器输入端为转速 v ，减速比为 r ，当减速器输出端转过 θ 角时，其采样点数 N 可按下式计算，该式也是选择数据特征解调窗宽的主要依据：

$$N = \frac{\pi \cdot \theta \cdot f_s \cdot r}{180 \cdot v} \quad (3-1)$$

电流信号中虽然包含减速器的故障特征信息，但是会被转速调制。假设减速器故障特征频率为 f_n ，在电流信号中，用于驱动电机转速调频频率为 f_c ，减速器故障特征频率被调制后的频率为 f^* ，则三者存在如下关系：

$$f^* = f_n \pm f_c \quad (3-2)$$

$$A^* = \frac{1}{2} A_n \quad (3-3)$$

其中： A^* 为频率 f^* 对应的幅值； A_n 为频率 f_n 对应的幅值。

通常情况下，电流信号中的主要能量用于转速调频，因此在电流信号的频域中，最大幅值对应的频率成分即为电流调频频率 f_c ，所以可以基于电流信号频域中的能量分布情况，首先得到电流信号中的电流调频频率 f_c 和幅值 A_c 。

在实际的谐波减速器故障信息传至电机电流信号的过程中，因电机和谐波减速器试验台等部件的自身特性，电流信号中也会掺杂着本身不受电流调频频率 f_c 所调制的频率特征 f_b ，并且这些频率信息会伴随 $f_b \pm 4 f_c$ 范围内的幅值变动，但离 f_b 越远的频率其幅值也会越小，所以首先通过对比两种不同转速下的电流频域特征，对其周围不受电流调频频率调制干扰的特征信息进行对比，对其周围正好相差 $\pm 2 f_c$ 以及 $\pm 4 f_c$ 的位置不再进行统计，认为都是由该位置的特征或特性引起的叠带效应，为成功分离上述特征，本文将对其进行预处理，以免后续特征解调的过程中存在错误解调。在电流调频频率分别为 f_{c1} 和 f_{c2} 下，若存在频率和幅值同时满足如下条件：

$$f_{c1} \neq f_{c2} \quad (3-4)$$

$$f_{b1} = f_{b2} \quad (3-5)$$

$$A_{b1} > A_{c1}^* > A_{d2}^* \quad (3-6)$$

$$A_{b2} > A_{c2}^* > A_{d2}^* \quad (3-7)$$

其中： f_{b1} 、 f_{b2} 分别为 f_{c1} 、 f_{c2} 的频率， A_{b1} 、 A_{b2} 分别为 f_{b1} 、 f_{b2} 对应的幅值， A_{c1}^* 、 A_{c2}^* 分别为 $f_{b1} - 2 f_{c1}$ 和 $f_{b1} + 2 f_{c1}$ 对应的幅值， A_{d1}^* 、 A_{d2}^* 分别为 $f_{b1} - 4 f_{c1}$ 和 $f_{b1} + 4 f_{c1}$ 对应的幅值。

假设转速工况在为 1500rpm 和 3000rpm 时，由式(2-6)，得到对应的电流调频频率 f_c 为 125Hz 和 250Hz，分别假设两组故障特征信息，如表 3-1 所示，通过预处理方法进行筛选，仿真如图 3-2 所示。

表 3-1 假设的影响特征频率

	f_c	$f_{n1}-4f_c$	$f_{n1}-2f_c$	f_{n1}	$f_{n1}+2f_c$	$f_{n1}+4f_c$	$f_{n2}-f_c$	f_{n2}	$f_{n2}+f_c$
工况 1(Hz)	125	7 500	7 750	8 000	8 250	8 500	19 750	20 000	20 250
工况 2(Hz)	250	7 000	7 500	8 000	8 500	9 000	19 500	20 000	20 500
幅值	6	1	2	4	2	1	2	0	2




图 3-2 预处理前后的频率分布

由上图分别在 1 500rpm 和 3 000rpm 转速工况下的进行对比可以得出，不受电流调频频率调制特征周围的伴随特征均得到了有效的去除，而受调制干扰的特征不受任何影响。

3.1.1 单一故障频率解调方法研究

根据前文中提取到的电流调频频率 f_c ，假设 f_i^* ， f_j^* 是减速器原特征频率 f_{n1} 的一对特征调制频率，则频率和幅值应同时满足如下条件：

$$f_j^* = f_i^* + 2f_c \quad (3-8)$$

$$|A_i^* - A_j^*| \leq A_{th}^* \quad (3-9)$$

其中， A_{th}^* 为考虑噪声影响下的允许误差。

为进一步降低噪声干扰，本文以 A_i^* 和 A_j^* 的加权平均值作为减速器原特征频率 f_{n1} 的幅值 A_{n1} ：

$$f_{n1} = f_i^* + f_c \quad (3-10)$$

$$A_{n1} = A_i^* + A_j^* \quad (3-11)$$

根据谐波减速器-驱动电机建立机电耦合仿真模型，仿真的故障频率如表 3-2 所示，在电机转速为 3 000rpm 工况下分别对表中的故障数据进行特征解调，结果如图 3-3 所示：

表 3-2 假设的故障频率及幅值

故障类型	故障 1	故障 2	故障 3
频率(Hz)	3 200.6	13 700.1	19 200.8
幅值	6	8	10




图 3-3 特征解调前后的故障频谱图

由上表及图可知，3 000rpm 转速下，在故障调制电流信号中提取的最大幅值对应的频率为 250Hz，即电流调频频率 f_c ，由解调后的故障频率和幅值与假设的频率和幅值进行对比能够得出，该特征解调方法能够有效的解调谐波减速器具有的故障特征。

3.1.2 多个故障频率解调方法研究

考虑到减速器的原特征频率存在多个，因此减速器原特征频率被转速调制后的频率幅值可能存在叠加情况。假设 f_i^* 和 f_j^* 是减速器原特征频率 f_{n1} 的一对特征调制频率，且 f_j^* 和 f_k^* 是减速器原特征频率 f_{n2} 的一对特征调制频率，则 f_j^* 为二者共有频率，其幅值 A_j^* 存在叠加关系，则在满足公式(3-8)的同时，还应满足如下条件：

$$f_k^* = f_j^* + 2f_c \quad (3-12)$$

$$\left| A_i^* - A_k^* - A_j^* \right| \leq A_{th}^* \quad (3-13)$$

其中, A_k^* 为 f_k^* 对应的幅值。

此种情况下, 减速器原特征频率及幅值 (f_{n1} 按照式(3-10)计算) 计算如下:

$$f_{n2} = f_j^* + f_c \quad (3-14)$$

$$A_{n1} = A_i^* + (A_k^* - A_j^*) \quad (3-15)$$

$$A_{n2} = A_k^* + (A_i^* - A_j^*) \quad (3-16)$$

根据谐波减速器-驱动电机建立机电耦合仿真模型, 仿真的故障频率如表 3-3 所示, 在电机转速为 3 000rpm 工况下分别对表中的故障数据进行特征解调, 结果如图 3-4 所示:

表 3-3 假设的故障频率及幅值

	故障 1	故障 2	故障 3	故障 4
频率(Hz)	3 200.3	3 700.3	15 900.2	16 400.2
幅值	6	8	12	10




图 3-4 特征解调前后的故障频谱图

通过图 3-4(b)可知, 解调后的特征及幅值与假设的相同, 表明该方法能有效解调两对故障存在叠加频域下的特征。

考虑到当减速器三个原特征频率被调制后幅值存在相互叠加的关系, 假设 f_i^* 和 f_j^* 、 f_j^* 和 f_k^* 及 f_k^* 和 f_l^* 分别为减速器原特征频率 f_{n1} 、 f_{n2} 和 f_{n3} 对应的调制频率对, f_j^* 为 f_{n1} 和 f_{n2} 调制信号特征共有频率, f_k^* 为 f_{n2} 和 f_{n3} 调制信号特征共有频率, f_j^* 和 f_k^* 处对应的幅值均存在叠加关系, 应该同时满足公式(3-8)、公式(3-12)和如下条件:

$$f_l^* = f_k^* + f_c \quad (3-17)$$

$$|A_j^* + A_i^*| - |A_k^* - A_i^*| < A_{th}^* \quad (3-18)$$

其中, A_i^* 为 f_i^* 对应的幅值。

此时, 减速器原特征频率和幅值 (f_{n1} 和 f_{n2} 分别按照式(3-10)和式(3-14)计算) 计算如下:

$$f_{n3} = f_k^* + f_c \quad (3-19)$$

$$A_{n1} = A_i^* + (A_j^* + A_i^* - A_k^*) \quad (3-20)$$


$$A_{n2} = |A_k^* - A_i^*| + |A_j^* + A_i^*| \quad (3-21)$$

$$A_{n3} = A_k^* + |A_i^* + A_j^* - A_i^*| \quad (3-22)$$


根据谐波减速器-驱动电机建立机电耦合仿真模型, 仿真的故障频率如表 3-4 所示, 在电机转速为 3 000rpm 工况下分别对表中的故障数据进行特征解调, 结果如图 3-5 所示:

表 3-4 假设的故障频率及幅值

	故障 1	故障 2	故障 3	故障 4	故障 5	故障 6
频率(Hz)	3 200.3	3 700.3	4 200.3	16 400.2	16 900.2	17 400.2
幅值	6	8	12	10	8	6



(a) 仿真的故障调制信号频谱图



(b) 解调的故障信号频谱图

图 3-5 特征解调前后的故障频谱图

对比解调后的特征与假设的特征, 表明该方法能有效解调 3 对故障存在叠加频域下的特征。对于涉及更多减速器特征频率调制后幅值存在的叠加情况, 在实际工程中出现较少, 本章不再进行考虑。

3.2 机电耦合系统故障信号特征提取方法研究

电流信号作为谐波减速器运行状态的关键表征，能够反映出故障发生时特定频率分量和幅值的变化特征。因此，对谐波减速器故障电流信号进行精确的特征提取，不仅可以捕捉到设备运行状态中的细微变化，还能为快速准确地诊断故障类型及其严重程度提供重要依据。

3.2.1 特征提取理论方法

本文通过不同频率来假设不同的故障类型，而这些故障在电流频域信号中，不同转速工况下主要表现为调频频率差异，而信号幅值保持相对稳定，故探究其在电流时域信号中特征的变化规律，则能捕捉电流信号中的瞬态现象，进一步揭示故障的本质。因此将模拟的谐波减速器故障电流频域信号进行解调，将解调前后的电流均采用傅里叶逆变换还原为时域信号，并提取谐波减速器故障诊断方法中常用的 15 个特征进行提取，具体特征如表 3-5 所示，分别得到受电流调频频率调制的故障电流时域信号和不受调制的故障电流时域信号。通过提取更多的特征，可以更全面地反映电流信号的特性。

表 3-5 15 个常用的特征提取方法

特征	释义	计算方式
求和/Sum	整个数据集的数学总和	$I_{\text{Sum}} = \sum_{n=1}^N (x(n))$
平均值/Mean	指示信号的统计平均值	$I_{\text{mean}} = 1/N \sum_{n=1}^N x(n)$
最大值/Max	表示整个信号的最大值	$I_{\text{max}} = \max_{n=1, \dots, N} (x(n))$
最小值/Min	表示整个信号的最小值	$I_{\text{min}} = \min_{n=1, \dots, N} (x(n))$
均方根/RMS	信号振幅和能量可以用均方根来描述	$I_{\text{RMS}} = \sqrt{1/N \sum_{n=1}^N (x(n))^2}$
峰值/Pv	信号的最大值和最小值之间的平均变化	$I_{\text{Pv}} = 1/2 [I_{\text{max}} - I_{\text{min}}]$
峰峰值/P2P	信号在信号的最大值和最小值之间的最大变化	$I_{\text{P2P}} = [I_{\text{max}} - I_{\text{min}}]$
标准差/STD	衡量信号相对于其平均值波动的指标	$I_{\text{STD}} = \sqrt{\frac{1}{N-1} \sum_{n=1}^N x(n) - I_{\text{mean}} ^2}$
方差/Var	表示信号围绕其平均值的分布	$I_{\text{Var}} = (\sum_{n=1}^N (x(n) - I_{\text{mean}})^2)^2$

续表(3-5)

特征	释义	计算方式
峰度/Kur	任何信号的四阶归一化描述了信号中的峰值	$I_{Kur} = \frac{\frac{1}{N} \sum_{n=1}^N (x(n) - I_{mean})^4}{\left(\frac{1}{N} \sum_{n=1}^N (x(n) - I_{mean})^2 \right)^2}$
偏度/Skw	给定电流信号围绕其概率密度函数的不对称趋势	$I_{Skw} = \frac{\frac{1}{N} \sum_{n=1}^N (x(n) - I_{mean})^3}{\left(\frac{1}{N} \sum_{n=1}^N (x(n) - I_{mean})^2 \right)^{3/2}}$
形状参数/SF	对象的形状会影响形状因子，而与其尺寸无关	$I_{SF} = \frac{\sqrt{\frac{1}{N} \sum_{n=1}^N (x(n))^2}}{\frac{1}{N} \sum_{n=1}^N x(n)}$
冲动参数/IF	它描述了信号的峰值与数据集均方根的绝对值之比	$I_{IF} = \frac{1/2[I_{max} - I_{min}]}{\frac{1}{N} \sum_{n=1}^N x(n) }$
间隙参数/CLF	表示信号峰值相对于平均值的变化	$I_{CLF} = \frac{1/2[I_{max} - I_{min}]}{\left(\frac{1}{N} \sum_{n=1}^N x(n) \right)^2}$
波峰因子/CF	表示信号的尖峰特征和显著性，其中峰值在周期之间变化	$I_{CF} = \frac{1/2[I_{max} - I_{min}]}{\sqrt{\frac{1}{N} \sum_{n=1}^N (x(n))^2}}$

其中， $x(n)$ 表示第 n 个采样点的电流大小。

在基于电流时域信号的谐波减速器故障诊断研究中，所提取的 15 个统计特征系统地表征了电流信号在幅值分布、波动强度及波形畸变等方面的动态特性，为机器学习模型构建高维特征空间提供了关键数据支撑。均方根、方差和标准差作为基础能量指标，能够量化电流信号整体能量分布的离散化趋势。峰峰值、波峰因子及冲动参数等幅值特征聚焦于瞬态冲击成分的表征，通过捕捉电流波形中突变的尖峰特性。形状参数与间隙参数通过量化信号包络的几何畸变程度，增强了模型对周期性调制干扰的辨识能力。偏度与峰度作为高阶统计量，分别描述信号分布的非对称性特征和尖峰锐度，能够敏感反映电流信号概率密度函数的非线性畸变特性。这些特征进行协同分析，可有效区分由不同机械状态引起的电流信号统计分布差异。传统统计量如平均值和求和虽单维度判别力有限，但其与峰峰值、方差等参数的非线性组合，在机器学习方法中能够为支持向量机的核空间映射提供互补信息，同时优化 K 近邻算法在高维特征空间中的距离度量精度。

3.2.2 单一故障解调前后特征提取对比分析

为忽略解调前后的时域特征在后续故障诊断中因噪声影响其准确率,因此,本文对仿真的故障电流信号不加噪声处理,以确保受调制和未受调制的故障特征在故障诊断中的准确性,假设单一的故障频率如表 3-6 所示,将其标记为故障 1 并进行解调,仿真中为保持和后续实验中的采样频率相同,将采样频率设为 $f_s=60\text{kHz}$,采样点数设为 600000。

表 3-6 故障 1 假设的故障频率及转速

频率(Hz)	3 200.6	13 700.1	19 200.8
转速(rpm)	1 200/1 800/2 400	1 200/1 800/2 400	1 200/1 800/2 400

将假设的故障电流信号和解调后的电流信号分别进行傅里叶逆变换,得到 5s 内受电流调频频率调制的电流时域信号和不受调制的电流时域信号,为方便记录特征变化趋势,将 5s 的数据每 0.5s 作为一段,得到 10 组时间连续的故障数据集,通过上述 15 种特征提取方法进行特征提取,结果如图 3-6 所示。




图 3-6 单一故障频率对应不同转速的 15 个特征解调前后分布结果

由上图可知,单一故障下解调前后的特征在均方根、方差和标准差上存在明显差异,但波峰因子没有明显的改变。且随着时间的变化,求和、平均值、偏度和形状参数随时间变化浮动最为明显,随转速工况的改变,每个特征均会受到不同程度的影响,随着转速的增大,特征的幅值都会出现小幅上涨,通过各特征解调前后对比可以得出,解调前的特征相较于解调后受转速变化影响更大,由式(2-6)和式(2-13)可知,造成该变化的原因一方面是由电流调频频率及幅值随转速的变化而改变,另外,未经解调的故障特征也会随不同转速的调制而变化。

在谐波减速器故障诊断中,不同特征能够从多个维度反映电流信号的特性,其统计特征对故障类型和程度的准确诊断具有重要意义。皮尔逊相关性分析是一种衡量特征间线性关系的有效方法,用于衡量谐波减速器电流信号每个特征之间的线性相关程度,揭示它们在诊断过程中的潜在作用。

为了系统地分析这些特征在不同转速工况下的表现,分别对 1200rpm、1800rpm 和 2400rpm 转速工况下的特征进行皮尔逊相关性分析,将三种转速工况在相关性矩阵中分别由工况 1、2、3 进行替代(本章节后续皮尔逊相关性分析亦是如此),在单一故障下,分别得到上述特征在解调后和解调前的相关性矩阵,如图 3-7 和图 3-8 所示。通过这些相关性矩阵,可以直观地观察到各个特征之间的以及在不同转速工况下的线性相关性强度及其变化规律。




图 3-7 单一故障解调后不同频率之间的特征相关性比较图



图 3-8 单一故障未解调不同频率之间的特征相关性比较图

从上述结果中可以看出，该矩阵直观地展示了解调信号中各个特征间的相关程度。解调前后的特征在相关性上表现极为相似，由上结果显示，求和、平均值、均方根、标准差、方差、峰度、偏度、形状参数之间具有很高的关联性，同时最大值、最小值、峰值、峰峰值、冲动参数、间隙参数之间也具有高的关联性，但前后相关性高的特征二者间基本无关联，且在不同转速下的特征相关性表现极为相似。

3.2.3 多故障解调前后特征提取对比分析

为了假设故障里有叠加的故障信号出现，本文分别假设了两对及三对故障特征存在频率叠加的情况如表 3-7 所示，通过假设复杂故障下的电流信号，观察各特征随时间和转速变化的表现形式及特征之间的关联。

表 3-7 假设存在多对叠加的故障频率及转速

转速(rpm)	故障 2			故障 3	
	频率 1(Hz)	频率 2(Hz)	频率 1(Hz)	频率 2(Hz)	频率 3(Hz)
1 200	15 500	17 500	19 900	20 100	20 300
1 800	15 500	18 500	19 800	20 100	20 400
2 400	15 500	19 500	19 700	20 100	20 500

对假设的故障电流信号和解调后的电流信号同样分别进行傅里叶逆变换，得到 5s 内受电流调频频率调制的电流时域信号和不受调制的电流时域信号，继续按上述方法进行分割区间，得到两个和三个的故障频率叠加后的特征结果如图 3-9 和图 3-10 所示。




图 3-9 2 个故障频率叠加对应不同转速的 15 个特征解调前后分布结果

由图 3-9 可以得出，整体特征表现形式与单一故障类似，与其不同的是，波峰因子在随时间的变化中与求和变化呈逆相关。同时，除标准差、方差以及波峰因子在解调前后没有明显差异外，偏度和形状参数在解调前后同样影响较小，二者随转速改变而呈现明显变化趋势。同时，由图 3-10 可知，三种频率叠加故障下的整体特征表现形式与前二者基本相同。受假设的故障频率和幅值的影响，仿真的故障可能存在冲击而引起特征峰值存在波动，进而导致波峰因子随时间呈现独有的变化，且在不同转速工况下的变化趋势也各有差异，并且，通过三种不同故障特征的表现形势对比可知，峰度、冲动参数和间隙参数特征在不同故障下大小基本相同，且随时间的变化趋势基本一致，并且随转速的变化其波动并不明显。




图 3-10 3 个故障频率叠加对应不同转速的 15 个特征解调前后分布结果

将上述特征变化趋势进行相关性分析，得到结果如图 3-11 至图 3-14 所示。




图 3-11 两种频率叠加故障解调后不同频率之间的特征相关性比较图

由上述结果可以得出,两种频率叠加下故障特征之间的相关性表现与单一故障下类似,不同则表现在波峰因子在该特征下与求和、平均值等特征呈现高的负相关,而冲动参数、间隙参数、峰值及峰峰值则呈现较低的相关性,并且最大值与最小值之间与各个特征之间的相关性均较低,但在不同转速下各特征之间的相关性表现极为相似。因此,在后续的故障诊断中,波峰因子、冲动参数、间隙参数、最大值、最小值这些低相关性的特征可以作为故障诊断中的重要参数。

[illegible]




图 3-14 两种频率叠加故障解调后不同频率之间的特征相关性比较图

对比图 3-13 和图 3-14 可知，解调前后的信号在各个特征之间的相关性高度一致，随转速的变化，波峰因子呈现不同规律的改变，整体特征的相关性与单一故障的结果类似。综上对比可以得出，因谐波减速器故障表型为非线性关系，引发信号中出现间歇性高频谐波和峰值波动，波峰因子可能呈现波动性变化，不同故障下波峰因子表现差异较大，每种故障中，求和、平均值、均方根、标准差、方差、峰度、偏度、形状参数之间呈现很高的关联性，意味着它们提供了相似的信息，在故障诊断中，有助于 SVM 通过核函数映射构建稳定分类超平面。这增强了模型对故障模式全局差异的捕捉能力。同时标准差、方差等统计量可以帮助决策树确定最佳分割点，优化模型结构。

3.3 本章小结

本章针对谐波减速器故障特征在电流信号中会受到电流调频频率调制干扰的问题，提出了一种故障特征解调方法，根据受调制的故障频率对之间的特征关系，解调得到不受电流调频频率干扰的谐波减速器故障频域信号，并对解调前后的信号通过傅里叶逆变换得到故障时域信号，利用故障诊断方法常用的 15 个特征进行特征提取，并进行相关性分析，结果显示，相较于解调后的特征，解调前的随转速的改变浮动会更大，波峰因子会在不同故障下存在明显差异，且在不同故障中受转速的变化的表现形式也不尽相同，因此仅仅依靠波峰因子识别故障类型是不可靠的，需要进一步通过融合其他特征，通过神经网络来划分其故障类型。为基于数据驱动的故障诊断方法提供数据基础。

第4章 基于多策略集成学习的谐波减速器故障诊断方法研究

在现代工业系统中，设备故障诊断与预测维护已经成为保障生产安全、提高生产效率的重要手段。故障诊断技术的发展促进了智能制造的应用，尤其是在减速器等机械系统中，故障诊断的准确性和及时性尤为重要。而针对谐波减速器进行故障诊断的方法多种多样，但众多改进的模型仅仅适用于某些特定模型，具有局限性，且单一的机器学习方法往往难以应对多种复杂的故障模式，因此，采用多策略集成学习方法结合多个模型的优势，能够显著提升诊断的准确性和鲁棒性。为了验证这一点，本文针对谐波减速器故障电流信号，提出了一种基于 D-S 证据合成理论的多策略集成学习故障诊断方法，结合决策树（DT）、支持向量机（SVM）、朴素贝叶斯（NB）和 K 最近邻（KNN）经典模型，通过多种集成学习方法进行对比，得到最终的故障诊断结论。

4.1 基模型的构建

由前文得到的特征关系可以得出，在故障诊断中，高相关特征有助于支持向量机（SVM）通过核函数映射构建稳定分类超平面，从而增强模型对故障模式全局差异的捕捉能力。同时，标准差、方差等统计量可以帮助决策树确定最佳分割点，优化模型结构。决策树擅长捕捉非线性关系，而支持向量机则擅长高维空间的数据分类。结合这两者的优点可以覆盖更广泛的数据特征，进而提高模型的准确性。因此本文首先基于上述两种方法对谐波减速器进行故障诊断。

4.1.1 基于决策树模型预测方法的故障诊断

（一）决策树的原理

决策树（Decision Tree）是一种常用的分类与回归算法，其核心思想是通过树状结构对数据进行决策。针对谐波减速器的故障特征存在较强的非线性关系，决策树模型具有较强的可解释性，并能够自动选择对分类有重要影响的特征。其直观的树状结构便于专家理解模型如何基于输入特征做出决策，这对于故障诊断尤为重要。在实际工业场合中谐波减速器的故障形式往往是多维度的，通过决策树能够构建不同层次的决策规则，处理复杂的决策边界。

在构建决策树时，常用的划分标准包括信息增益（Information Gain）和基尼指数（Gini

Impurity)。信息增益衡量的是特征划分数据集后，熵（Entropy）的减少量，具体公式如下：

$$\text{Information Gain} = \text{Entropy}(D) - \sum_{i=1}^n \frac{|D_i|}{|D|} \text{Entropy}(D_i) \quad (4-1)$$

其中， $\text{Entropy}(D)$ 表示数据集 D 的熵， $\text{Entropy}(D_i)$ 表示子集 D_i 的熵， $\frac{|D_i|}{|D|}$ 是子集在总数据集中的比例。

在决策树的构建过程中，算法会通过计算每个特征的信息增益或基尼指数，选择最优的特征进行划分，直到树的深度达到预设值或数据划分达到足够纯净的程度，进而对模型进行评价。

（二）模型的训练与预测结果

本研究将结合谐波减速器前文提取的 15 种特征，将特征解调后不受电流调频频率调制的故障特征构建数据集 A，受电流调频频率调制划分为数据集 B，通过每组特征循环 100 次总共得到 900 个样本，对前文仿真 3 种不同频率下的故障类型划分为 3 种故障特征标签，分别对应 3 种不同的故障。采用 20 次随机分层抽样划分训练集（630 样本）与测试集（270 样本），确保统计结果的稳健性。利用决策树模型进行训练与预测，验证其在机械设备故障诊断中的适用性。

为了提高决策树模型的训练效率和分类准确性，对输入数据进行了归一化处理，用于消除特征之间由于量纲不同所带来的影响。

训练过程中，模型根据训练集的特征和标签，通过自适应的分裂过程构建树结构。每个决策节点通过评估所有可能特征的分裂质量，选择最能减少信息增益或基尼指数的特征，递归地进行划分。

为量化决策树模型的分类性能，本文采用准确率（accuracy）作为主要评价指标。准确率是指模型正确预测的样本数量占总样本数量的比例，其计算公式为：

$$\text{Accuracy} = \frac{\sum_{i=1}^N \mathbf{1}(T_i = T_i)}{N} \times 100\% \quad (4-2)$$

其中， $\mathbf{1}(T_i = T_i)$ 为指示函数，若预测值 T_i 与真实标签 T_i 相同，则该函数值为 1，否则为 0； N 为样本总数。

由此，得到基于决策树模型的故障诊断结果如图 4-1 所示。




图 4-1 基于决策树特征解调前后的 20 次迭代故障诊断结果

将上述结果的测试集的准确率如表 4-1 所示：

表 4-1 决策树模型下解调前后的故障识别准确率

	特征解调后测试集准确率	未经解调的特征测试集准确率
最大值	87.41%	87.04%
最小值	79.63%	77.78%
平均值	84.26%	83.63%
方差	3.99%	4.60%

上述结果表明，特征解调后的测试集平均准确率与方差均优于未经解调的特征，表明经过特征解调后的谐波减速器电流信号在故障诊断的准确率及鲁棒性上均得到有效提升。

尽管决策树模型在谐波减速器故障诊断中展现出良好的可解释性，但其对噪声敏感性和高维数据处理能力的局限性限制了其在复杂工业场景中的应用。相比之下，支持向量机（Support Vector Machine, SVM）通过最大化分类间隔和核函数映射机制，能够有效克服非线性可分问题并提升模型泛化能力。

4.1.2 基于支持向量机模型预测方法的故障诊断

（一）支持向量机原理

支持向量机作为一种经典的监督学习算法，广泛适用于谐波减速器故障诊断领域。其优势在于泛化能力强，避免过拟合。通过构造一个最优超平面将不同类别的样本分开，从而实现数据分类。尤其是在小样本学习、非线性分类等问题中，表现尤为突出。

SVM 的目标是找到一个分割超平面，最大化该超平面两侧最近点的距离（即支持

向量到超平面的距离)。该超平面可以通过以下优化问题来求解:

$$\min_{\mathbf{w}, b} \frac{1}{2} \|\mathbf{w}\|^2 \quad (4-3)$$

$$s.t. y_i(\mathbf{w}^T \mathbf{x}_i + b) \geq 1, i = 1, \dots, N \quad (4-4)$$

其中, $\mathbf{w}$ 是超平面的法向量, b 是偏置, y_i 是样本的标签, $\mathbf{x}_i$ 是样本的特征向量, N 是样本的总数。

而针对非线性可分的数据集的处理这类问题, SVM 通过引入核函数, 将数据映射到更高维的空间, 实现在该空间中找到一个线性可分的超平面。

谐波减速器电流信号特征数据的分布具有明显的非线性特点, 因此本文选用高斯 RBF 核作为 SVM 的核函数, RBF 核能够通过其高斯分布特性将数据映射到高维空间, 实现对复杂模式的精确分类。

(二) 模型的训练与预测结果

SVM 的训练过程涉及两个主要的超参数: 惩罚因子 (BoxConstraint) 和核函数的尺度 (KernelScale)。惩罚因子控制误分类样本的容忍度, 而核函数的尺度决定了映射空间的复杂度。合理的参数选择对模型的性能至关重要, 通常通过交叉验证来选择最优参数。

同样选择决策树模型的数据集进行训练及测试, 并进行归一化。确保每个特征的值在相同的尺度范围内, 为了选择最优的 SVM 模型参数, 本文在训练过程中采用了交叉验证方法。通过网格搜索的方式, 在惩罚因子和核尺度的不同值范围内进行实验优化, 找到能够最大化分类准确率的最佳参数组合。具体的搜索范围如下:

惩罚因子 (BoxConstraint): $\{10^{-2}, 10^{-1}, 10^0, 10^1, 10^2\}$

核尺度 (KernelScale): $\{10^{-2}, 10^{-1}, 10^0, 10^1, 10^2\}$

通过交叉验证, 本文确定了最优的 SVM 参数。对于解调后的特征, 最佳惩罚因子和核尺度分别为 1.00 和 0.25, 对于未解调的特征, 最佳参数为 0.10 和 0.50。这些参数选择使得模型的性能得到了有效提升。同样基于式(4-4)使用准确率 (accuracy) 来评估模型的性能。得到解调前后的结果如图 4-2 中(a)和(b)所示。




图 4-2 基于 SVM 特征解调前后的 20 次迭代故障诊断结果

将上述结果的测试集的准确率如表 4-2 所示：

表 4-2 SVM 模型下解调前后的故障识别准确率

	特征解调后测试集准确率	未经解调特征的测试集准确率
最大值	92.22%	91.85%
最小值	86.67%	86.30%
平均值	90.08%	89.12%
方差	2.78%	3.19%

由图 4-2 和表 4-2 可得，基于支持向量机的模型相较于决策树模型在故障诊断的准确率上得到了有效的提升，经处理后的谐波减速器故障特征经过 SVM 模型在识别测试集的准确率上高于未经处理的特征，但方差略大，分类稳定性不如未经解调前。

尽管 SVM 在谐波减速器故障诊断中表现优异，但其固有缺陷，核尺度 γ 与惩罚因子 C 的微小变动可能导致分类性能显著波动、采用“一对多”（One-vs-Rest）策略解决三分类问题以及对大规模数据训练时，模型训练时间会显著延长，使其参数调整（如核函数选择）敏感，难以处理多分类问题。而谐波减速器的故障形式多种多样，针对当前数据量大且计算效率差，而且故障形式复杂的问题，引入更加高效的模型用于解决这一缺陷。

4.1.3 基于朴素贝叶斯模型预测方法的故障诊断

朴素贝叶斯（Naive Bayes）是一种基于贝叶斯定理的概率分类算法，它假设特征之间是条件独立的。基于朴素贝叶斯模型预测方法其优势在于计算效率高，适合大规模数据；输出概率解释性好；容易扩展，同时因其简单性和高效性，有效解决基于 SVM 训

练时间长难处理多分类的问题。

因此本文采用朴素贝叶斯算法，针对谐波减速器在运行过程中产生的多维度故障信号特征进行故障分类研究。构建基于概率统计的分类模型，旨在验证朴素贝叶斯在机械故障诊断中的适用性，并探究其在复杂工况下的鲁棒性。

（一）朴素贝叶斯原理

朴素贝叶斯分类器基于贝叶斯定理构建，其核心思想是通过特征的条件独立假设实现高维数据的快速分类。对于谐波减速器故障诊断问题，朴素贝叶斯能够有效捕捉谐波减速器故障特征的概率分布差异。通过给定特征向量 $X = (x_1, x_2, \dots, x_d) \in \mathbb{R}^{15}$ ($d=15$ 维特征)，分类决策函数可表示为：

$$P(y|x) = \frac{P(x|y)P(y)}{P(x)} \quad (4-5)$$

对连续特征进行等宽分箱（5 bins），将条件概率计算转换为频次统计；添加平滑因子避免零概率问题。

（二）模型的训练与预测结果

同样采用前文中的训练集、测试集划分以及归一化方案，并基于拉普拉斯平滑处理零概率问题。测试阶段通过比较后验概率实现故障模式判别，最终以准确率为评价指标：20 次独立实验结果如图 4-3 所示。




图 4-3 基于朴素贝叶斯特征解调前后的 20 次迭代故障诊断结果

将上述结果的测试集的准确率如表 4-3 所示：

表 4-3 朴素贝叶斯模型下解调前后的故障识别准确率

	解调后测试集准确率	未经解调的测试集准确率
最大值	89.26%	88.15%
最小值	81.11%	79.26%
平均值	85.48%	83.79%
方差	3.69%	4.11%

结果表明,上述特征基于贝叶斯模型的故障分类准确率均表现较好,经过特征解调后的谐波减速器故障特征,在基于朴素贝叶斯模型的故障诊断中,准确率明显优于未经解调前的,且方差较小,模型具有较好的鲁棒性。

4.1.4 基于 K 最近邻模型预测方法的故障诊断

针对谐波减速器故障复杂,各个特征之间存在非线性关系,并且波峰因子、冲动参数等低相关特征在不同故障类型下表现出显著差异。根据 K 最近邻算法针对非线性特征分类能力强的优势,本文采用 K 最近邻算法构建故障分类模型。通过分析电流特征中与转速无关的频谱特征,验证 KNN 在非线性故障模式识别中的有效性,并探究其在高维特征空间中的适应性。

(一) K 最近邻原理

K 最近邻 (K-Nearest Neighbors, KNN) 是一种简单且直观的监督学习算法,广泛应用于分类和回归任务。该算法的基本思想是,通过测量样本之间的距离,判断待分类样本与已知样本的相似性。对于分类任务, KNN 算法通过选择距离待分类样本最近的 K 个训练样本,采用多数投票机制决定该样本的类别。KNN 的性能在于选择适当的 K 值与距离度量方法。

KNN 是一种基于实例的惰性学习算法,其分类决策依赖于特征空间中样本的局部相似性度量。对于待分类样本 q ,算法计算其与训练集 $D = \{(x_i, y_i)\}_{i=1}^N$ 中所有样本的欧氏距离:

$$d(q, x_i) = \sqrt{\sum_{j=1}^m (q_j - x_{ij})^2} \quad (4-6)$$

选取距离最近的 k 个邻居,通过多数投票确定类别标签:

$$\hat{y} = \arg \max_{c \in C} \sum_{i=1}^k I(y_i = c) \quad (4-7)$$

(二) 模型的训练与预测结果

同样使用上述实验方法进行划分训练集及测试集。针对 KNN 对特征尺度敏感的特点，实施分级归一化：

$$x_{\text{scaled}}^{(j)} = \frac{x^{(j)} - \mu_{\text{train}}^{(j)}}{\sigma_{\text{train}}^{(j)}} \tag{4-8}$$

其中 $\mu_{\text{train}}^{(j)}, \sigma_{\text{train}}^{(j)}$ 分别为训练集第 j 维特征的均值与标准差。该处理消除高频段能量幅值主导问题，提升低频故障成分的区分度。

采用 20 次重复分层抽样验证，每次迭代随机划分 630 个训练样本与 270 个测试样本。通过网格搜索确定最优 $k=5$ ，平衡模型复杂度与泛化能力。20 次独立实验的结果如图 4-4 所示：




图 4-4 基于 KNN 特征解调前后的 20 次迭代故障诊断结果

将上述结果的测试集的准确率如表 4-4 所示：

表 4-4 KNN 模型下解调前后的故障识别准确率

	解调后测试集准确率	未经解调的测试集准确率
最大值	91.11%	90.74%
最小值	79.26%	80.37%
平均值	85.39%	84.39%
方差	9.97%	8.60%

由上述结果表明，经解调后的特征测试集平均准确率达 85.39%，相较于解调前的特征提升 1%，但同时也可以看出其准确率的最小值小于未解调前，且方差为 9.97%，鲁棒性较差。部分特征可能存在高度关联性，使训练时结果并不稳定，表明该模型在每次训

练分类的过程中会数据波动较大。

综上所述，在基于经典的机器模型进行谐波减速器故障诊断时，由于每个模型自身的局限性，对最终的故障结果也会因为数据的复杂程度识别率不统一的问题，由上述经典的机器学习方法，综合其优势和不足，探索一种高效的机器学习方法就显得尤为重要。

4.2 基于多策略集成学习的谐波减速器故障诊断方法研究

通过上述经典的机器学习方法在进行谐波减速器故障诊断时，可以得出单一机器学习模型因其固有局限性难以全面应对复杂工业场景的挑战。支持向量机虽在高维数据处理和小样本泛化中表现优异，但对参数敏感且多分类扩展性不足；K 近邻算法虽能捕捉局部非线性模式，却受限于噪声敏感性与高维计算效率；决策树虽具有强解释性和自动特征选择能力，但易因过拟合导致泛化性能下降；朴素贝叶斯虽计算高效且适合实时诊断，但其强特征独立性假设在实际多传感器数据中往往失效。这些局限性表明，单一模型仅能在特定数据分布或场景下发挥优势，难以适应谐波减速器故障诊断中噪声干扰、高维特征冗余及样本量不足的综合挑战。

为突破单一模型的性能瓶颈，集成学习通过协同多模型的互补优势成为潜在解决方案。然而，不同集成策略在数据复杂性、计算效率与不确定性建模方面存在显著差异。传统投票集成虽实现简单，却因平等对待所有模型的预测结果，可能在模型冲突或噪声干扰时放大误判风险；堆叠泛化（Stacking）通过元模型学习基模型输出的非线性关系，虽能提升高维异构特征的融合能力，但其计算复杂度和对小样本的敏感性限制了工业实时诊断场景的应用；动态加权投票虽通过滑动窗口机制实现权重自适应调整，但对模型特异性差异的忽视可能导致关键故障类型的漏检。因此，如何设计一种既能量化模型的不确定性、又能动态融合多源证据的集成框架，成为提升谐波减速器故障诊断鲁棒性与准确性的核心问题。

4.2.1 集成学习方法的选型

基于上述问题，本文提出基于 D-S 证据理论的异构模型集成方法，其核心在于通过冲突因子与基本概率分配（BPA）动态调整模型权重，实现高精确率的可靠决策。为验证该方法的优越性，本研究对比了三类主流集成策略：

D-S 证据理论（Dempster-Shafer Theory）通过基本概率分配（Basic Probability

Assignment, BPA) 描述多模型对故障类型的不确定性, 其核心在于合成规则对冲突证据的动态融合。设故障类型假设空间为 $\Theta = \{F_1, F_2, \dots, F_n\}$, 模型 M_i 输出的 BPA 为 $m_i: 2^\Theta \rightarrow [0,1]$, 满足 $\sum_{A \subseteq \Theta} m_i(A) = 1$ 。多模型证据合成通过 Dempster 规则实现:

$$m_{\text{合成}}(A) = \frac{\sum_{B \cap C = A} m_1(B)m_2(C)}{1 - K} \quad (4-9)$$

$$K = \sum_{B \cap C = \emptyset} m_1(B)m_2(C) \quad (4-10)$$

其中 K 为冲突因子, $1-K$ 用于归一化。

D-S 理论的优势在于能够明确表达“未知”区间 (如 $m(\Theta) > 0$), 并可以保留复杂环境下的传感器数据中的不确定性信息, 避免强行分类导致的误判。然而, D-S 理论对 BPA 的构建高度依赖先验知识, 若模型历史准确率估计不准确, 可能加剧合成结果偏差。

目前集成学习主流的方法包括基于 Stacking 的集成学习方法, Stacking 通过训练元模型 (Meta-Model) 整合基模型的预测结果, 其核心思想是将基模型的输出作为元模型的输入特征。设基模型集合为 $\{M_1, M_2, \dots, M_k\}$, 训练集 D_{train} 被划分为 $D_1, D_2, \dots, D_m$, 基模型 M_i 在 D_j 上的预测结果为 y_{ij} , 则元模型的输入特征为 $[\hat{y}_{1j}, \hat{y}_{2j}, \dots, \hat{y}_{kj}]$, 输出目标为真实标签 y_j 。元模型 G 的训练目标为最小化损失函数:

$$\min_G \sum_{j=1}^m \mathcal{L}(G([\hat{y}_{1j}, \dots, \hat{y}_{kj}], y_j)) \quad (4-11)$$

Stacking 的优势在于能够通过元模型学习基模型间的互补关系, 在高维特征上的分类能力与决策树对非线性关系的捕捉能力相结合, 提升谐波减速器复合故障的诊断精度。然而, Stacking 对基模型的多样性要求较高, 若基模型相关性过强, 元模型难以提取有效信息。

动态加权投票通过自适应调整模型权重应对数据分布变化, 其权重分配策略通常基于模型近期表现。设模型 M_i 在时间窗口 $[t-T, t]$ 内的准确率为 $A_i(t)$, 则其权重 $w_i(t)$ 可设计为:

$$w_i(t) = \frac{\exp(\alpha A_i(t))}{\sum_{j=1}^k \exp(\alpha A_j(t))} \quad (4-12)$$

其中 α 为平滑系数, 控制权重对准确率变化的敏感度。最终投票结果为:

$$\hat{y} = \arg \max_{F \in \Theta} \sum_{i=1}^k w_i(t) \cdot I(M_i(x) = F) \quad (4-13)$$

动态加权投票的优势在于计算效率高, 适合在线诊断场景。然而, 其局限性在于仅依赖历史准确率分配权重, 忽略模型在不同故障类型上的特异性表现, 可能导致局部误判。此外, 权重更新需依赖滑动窗口内的标注数据, 在样本量不足时易受偶然性误差影响。

D-S 证据理论在不确定性建模和冲突证据处理上具有显著优势, 尤其适用于谐波减速器多传感器数据存在矛盾的场景。Stacking 通过元模型自动学习基模型间的交互关系, 适用于高维异构特征的融合诊断。动态加权投票则以低计算开销实现模型权重动态调整, 适合设备长期运行中的故障模式演变。

4.2.2 结果分析

基于经典的机器学习方法对谐波减速器故障进行诊断时, 解调前后的特征在故障诊断种准确率均较高, 因此, 本文将融合前文所述的 4 种机器学习方法作为基模型, 相对于基于单一的集成学习, 多策略集成能够避免单个方法自身的局限性问题, 以提高适用性。因此, 对解调前后的特征, 分别基于 D-S 证据理论、Stacking 和动态投票的多策略集成学习模型进行融合训练, 得到准确率如图 4-5 所示, 并将准确率结果统计至表 4-5 中。




图 4-5 基于多策略集成学习方法的特征解调前后的 20 次迭代故障诊断结果

表 4-5 基于多策略集成学习方法解调前后的故障识别准确率

	解调后			解调前		
	D-S 证据合成	Stacking	动态投票	D-S 证据合成	Stacking	动态投票
最大值	97.04%	92.96%	94.44%	94.44%	92.59%	92.22%
最小值	91.85%	90.37%	87.41%	87.04%	90.74%	85.18%
平均值	93.81%	92.18%	91.86%	91.99%	91.46%	90.01%
方差	1.99%	0.60%	4.09%	3.07%	0.42%	4.69%




图 4-6 各故障类别在 20 次迭代下的平均准确率

上述结果表明，基于 D-S 证据合成理论的多策略集成学习方法在谐波减速器故障诊断中取得最高准确率，解调后的特征中在故障分类的平均准确率为 93.81%，同时多策略集成能够有效弥补单一算法的局限性，相较单一最优模型（SVM 90.08%）提升 3.73%；在故障解调前后的准确率对比可知，每种故障分类准确率基本都在 90%以上，解调后的特征较未解调前提升 1.82%，通过对比上述三种集成学习方法，可以得出，该方法的分类准确率相较于另外二者提高 1%~2%，但基于 Stacking 模型的多策略集成学习方法在稳定性上表现突出，也广泛适用于实际工程应用中。

4.3 本章小结

本文通过决策树、支持向量机、朴素贝叶斯和最邻近 4 种经典的机器学习方法对解调前后的故障特征进行诊断，结果表明，经过解调的特征在故障诊断中准确率明显提高，但单一的机器学习方法可能适应性较差，难以满足实际工程应用中复杂场景的需求，因此提出了一种基于 D-S 证据合成理论的多策略集成学习方法，基于上述 4 种经典的机器学习基模型，并对比传统基于动态投票和 Stacking 的多策略集成学习方法，结果表明，该方法的准确率得到明显的提高。因此，基于 D-S 证据合成的多策略集成学习方法在故障诊断中的应用具有较强的实用价值和推广前景。

第 5 章 实验验证

本研究首先通过建立谐波减速器-驱动电机机电耦合的数学模型并仿真，揭示了谐波减速器的故障特征在电机电流中会受到电流调频频率所调制的表现特性，根据受调制的特征与电流调频频率之间的内在关系，提出了故障特征的解调方法，解调的得到谐波减速器不受电流调频频率干扰的特征，并根据特征解调前后的谐波减速器故障电流数据均进行特征提取及相关性分析，进一步为基于数据驱动的机器学习方法奠定数据基础，最后通过集成学习方法提升单个机器学习模型的准确率，并通过多个集成学习模型进行对比，得出基于 D-S 证据合成的集成学习方法在谐波减速器故障诊断中识别的准确率更高，为此，本章通过实验验证全文理论和逻辑的准确性。

5.1 谐波减速器试验台的搭建

为验证本文建立数学模型及后续理论方法的准确性，搭建谐波减速器试验台，试验台主体部分主要由电机、扭矩传感器、转子轴系、滚动轴承座、传感器安装支架、谐波减速器、联轴器、平台底板、试验台控制系统组成，整个实验台基体尺寸为 1800mm×750mm×500mm，具体如图 5-1 所示。




图 5-1 谐波减速器试验台

驱动系统主要由 1kW 变频电机（220V 0-3 000rpm，极对数 P 为 5）提供动力源输入。同时负载端设置有带刹车的负载电机，用于模拟负载变化，其主要技术参数如表 5-1 所示。

表 5-1 负载电机技术参数

额定电压	额定功率	带减速器	额定转速	额定扭矩
220V	1 000W	减速比 $i=100:1$	30rpm	239N.m

输入轴扭矩传感器和输出轴扭矩传感器负责监测谐波减速器输入轴和输出轴的扭矩。霍尔传感器放置于试验台上，用于监测驱动电机的输入电流，具体技术参数如表 5-2 所示。

表 5-2 霍尔传感器技术参数

霍尔传感器型号	JLK-17
额定输入	10A
额定输出	5V
辅助电源	DC±12V
供电方式	双电源供电
响应时间	<20μs（跟随输出）；<250ms（平均值）
准确度	0.5%
线性度	0.5%
频带宽度	DC-5kHz

谐波减速器具体参数如表 5-3 所示。将谐波减速器的柔轮和波发生器进行打磨，得到柔轮磨损和波发生器磨损状态下的谐波减速器，磨损的样张分别如图 5-2(a)和(b)所示。

表 5-3 谐波减速器技术参数

速比	额定输出转矩	允许平均输入转速	背隙
100:1	158N.m	3 500rpm	≤20arcsec



(a) 柔轮磨损故障图



(b) 波发生器磨损

图 5-2 柔轮磨损故障图

采用的采集卡为阿尔泰公司的 3202N，其具体参数如表 5-4 所示。

表 5-4 采集卡技术参数

参数	性能指标
分辨率	16bits
通道数	8
量程	±10V
采样率	250kS/s（8 通道平分）
输入阻抗	1GΩ

在相同的实验工况下，分别进行谐波减速器在柔轮磨损、波发生器磨损以及正常状态下的实验，具体转速工况如表 5-5 所示，根据理论部分分析，电机三个端子输入电流仅存在相位不同，其他部分保持相同。因此，整个实验过程，采用 1 支霍尔传感器对电机输入电流进行实时监测。为能采集更大频率范围内的电流信号，将采样频率设为 60kHz，其他设备设置参数于 2.3 节仿真中的一致，驱动电机设置为正转且谐波减速器输出端保持空载。

表 5-5 数据采集工况表

故障形式	转速工况(rpm)	加速度(rpm/s)
无故障	1 200/1 800/2 400	0
	0~3 000~0	±150/±200/±300
柔轮磨损	1 200/1 800/2 400	0
	0~3 000~0	±150/±200/±300
波发生器磨损	1 200/1 800/2 400	0
	0~3 000~0	±150/±200/±300

5.2 实验验证

5.2.1 谐波减速器不同故障下的电流信号分析

由上述实验中采集的谐波减速器在柔轮磨损、波发生器磨损和正常状态下的电流信号，首先提取转速为恒/变速段的电流信号，采用短时傅里叶变换方法进行时频分析。为保证分析的数据长度能够涵盖谐波减速器柔轮旋转一周内所有位置下可能发生的故障，本实验设置短时傅里叶变换分析的窗格宽度为 2048，为提高频谱分析结果的连续性，窗函数之间的重叠长度设置为总窗口长度的 40%。为更清晰地展示故障调制频率对之间的关系,将占电流调频频率功率 20%以下的部分视为噪声进行滤除。得到特征变化的时频关系如图 5-3 所示。





图 5-3 恒变频工况下的短时傅里叶分析


由上图可知存在，在 8 000Hz 附近存在功率比较大的特征信号，该特征频率不受电流调频频率调制的干扰。由于电机本身的阻抗、反电动势和共振现象共同作用，导致电机在特定频率下的功率输出显著增加，故在 8 000 Hz 幅值较大的特征是由电机本身的电气特性所致^[70]，且该特征被电流调频频率调制为多组与中间最大的功率的频率相差 $\pm 2f_c$ 和 $\pm 4f_c$ 的衰减信号，从而验证本文中预处理分析的准确性。

分别提取其在 1 200rpm、1 800rpm 和 2 400rpm 恒速下的时间段进行时域分析，得到时域图如图 5-4~图 5-6 所示。




(a) 1 200rpm 下的电流时域图 (b) 1 800rpm 下的电流时域图 (c) 2 400rpm 下的电流时域图

图 5-4 谐波减速器无故障下的电流时域信号



(a) 1 200rpm 下的电流时域图 (b) 1 800rpm 下的电流时域图 (c) 2 400rpm 下的电流时域图

图 5-5 谐波减速器柔轮磨损故障下的电流时域信号



(a) 1 200rpm 下的电流时域图 (b) 1 800rpm 下的电流时域图 (c) 2 400rpm 下的电流时域图

图 5-6 谐波减速器波发生器磨损故障下的电流时域信号

由图 5-4, 图 5-5 和图 5-6 对比可知, 故障信号和噪声信号都叠加于电流信号之上, 故障信号的频率远远高于正常电流信号的频率, 谐波减速器在柔轮磨损、波发生器及无故障下转动时的驱动电机的电流时域信号表现极为相似, 两种故障下的电流信号相比无故障下的电流信号, 其高频躁动会明显增强, 波发生器磨损下的故障相比柔轮磨损的故障在电流信号里高频躁动更为明显, 另外, 由(a)、(b)、(c)三图对比可知: 电流信号的频率会随着电机转速的改变而改变。因此, 将三种故障模式下的电流时域信号进行快速傅里叶变换, 为更清晰地展示故障调制频率对之间的关系, 结果如图 5-7 和图 5-8 所示。




图 5-7 柔轮磨损频域分布






图 5-8 波发生器磨损频域分布

柔轮磨损会导致高频谐波幅值上升, 波发生器磨损会导致对中性降低, 引发转频倍频分量。由图 5-7 和 5-8 对比可知, 波发生器磨损相较于柔轮磨损, 频率的分布会更加

广泛，500Hz 和 2000Hz 附近明显存在更加明显的频率波动，但在各频率段的幅值差异表现较大，同一频率下，波发生器磨损故障下的幅值显著高于柔轮磨损，无故障下的频率和幅值基本不受影响，仅存在较低的噪声频率。将占电流调频频率功率 1%以下的部分视为噪声进行滤除，以便更好的在电流信号中解调故障特征，得到故障电流的频域信号如图 5-9~图 5-11 所示，将得到的特征参数统计至表 5-6 中，以便更精确的获取数据。




(a) 波发生器磨损下的电流频域图




(b) 柔轮磨损下电流频域图

图 5-9 1200rpm 谐波减速器不同故障类型下的电流频域信号




(a) 波发生器磨损下的电流频域图




(b) 柔轮磨损下电流频域图

图 5-10 1800rpm 谐波减速器不同故障类型下的电流频域信号



(a) 波发生器磨损下的电流频域图



(b) 柔轮磨损下电流频域图

图 5-11 2400rpm 谐波减速器不同故障类型下的电流频域信号

表 5-6 谐波减速器不同工况和不同故障类型下的电流频域信号的频率参数

故障类型	1 200rpm / 99.6Hz		1 800rpm / 149.4Hz		2 400rpm / 199.2Hz	
	频率	幅值	频率	幅值	频率	幅值
波发生器磨损	298.8	0.1731	488.2	0.1164	4 216.1	0.1009
	3 653.5	0.1151	\	\	\	\
	3 852.7	0.1253	7 371.5	0.1224	7 172.3	0.1406
	7 769.9	0.1435	7 670.3	0.1889	7 570.7	0.2335
	7 969.1	1.0601	7 969.1	1.0669	7 969.1	1.0574
	8 168.3	0.1034	8 268.0	0.1232	8 766.0	0.1236
	12 085.6	0.1526	12 035.8	0.1432	\	\
	12 284.8	0.1588	12 334.6	0.1463	\	\
	15 838.7	0.2311	15 788.9	0.2869	15 739.1	0.3195
	16 037.9	0.2825	16 087.7	0.3727	16 137.5	0.4430
	\	\	16 386.5	0.1008	16 535.9	0.1102
	\	\	\	\	19 357.5	0.1032
	20 154.3	0.01681	19 855.5	0.1051	19 755.9	0.1273
	\	\	23 608.6	0.1141	23 509.0	0.1374
	23 907.4	0.4195	23 907.4	0.3301	23 907.4	0.2137
	\	\	24 206.2	0.1050	24 305.8	0.1414
	28 023.9	0.1594	27 974.1	0.1767	27 924.3	0.1807
	28 223.1	0.1557	28 272.9	0.2249	28 322.7	0.2403
	\	\	\	\	7 570.7	0.1491
	7 969.1	0.7758	7 969.1	0.7908	7 969.1	0.7983
柔轮磨损	15 838.7	0.2194	15 788.9	0.2894	15 739.1	0.3376
	16 037.9	0.2521	16 087.7	0.3428	16 137.5	0.4220
	23 907.4	0.2907	23 907.4	0.2318	23 907.4	0.1444
	28 023.8	0.1743	27 974.1	0.1947	27 924.3	0.1761
	28 223.0	0.1442	28 272.9	0.1436	28 322.7	0.1512

由图 5-9 至图 5-11 及表 5-6 可知,在谐波减速器柔轮磨损状态、波发生器磨损以及无故障下,频率较低处均存在幅值较大的电流调频频率 f_c 。波发生器磨损相较于柔轮磨损,其频率存在的频率特征更加广泛并且幅值更高,从表 5-6 中可知,不同故障特征在不同转速下频率存在明显差异,此外,从上述特征中可以得到波发生器磨损和柔轮磨损都存在频率为 23 907.4 Hz 的特征信息,且不受电流调频频率的影响,周边并伴随有相差 $\pm 2f_c$ 的频率分布,认为这是由同一个特征信息受转速引起的叠带效应,故认为是一个特征,在特征解调时不针对其频率以及相差 $\pm 2f_c$ 的频率特征进行解调,7 969.1 Hz 附近的特征亦是如此。从而验证前文建立的谐波减速器-驱动电机机电耦合模型的准确性。

5.2.2 通过特征解调方法解调谐波减速器故障特征并提取

针对谐波减速器在不同转速下受电流调频频率的干扰的问题,对上述受电流调频频率调制的特征进行解调得到不受电流调频频率调制干扰的谐波减速器初始故障特征,不同转速下提取的结果分别如图 5-12~图 5-14 中的(a)和(b)所示。




图 5-12 1200rpm 谐波减速器不同故障类型下的电流频域特征解调




图 5-13 1800rpm 谐波减速器不同故障类型下的电流频域特征解调




图 5-14 2400rpm 谐波减速器不同故障类型下的电流频域特征解调

由上图分析可知，故障解调方法能够有效的分离出受电流调频频率所干扰的故障调制频率对，验证了本文的故障解调方法在解调真实的实验数据是可行的，将解调前后的电流频域信号经过傅里叶逆变换得到时域信号，并对其计算 15 个特征，由减速器减速比为 $i=100:1$ 可知，保证减速器输出端能够转动一周，使其能够啮合到故障位置，则至少要保证减速器的运行时间按下式计算：

$$t = \frac{60i}{v} \quad (5-1)$$

由此可知，减速器在 1200rpm 以上时，5s 即可保证谐波减速器完成输入端一圈的旋转，将 5 秒内的特征分割成 10 组分别统计特征变化如图 5-15 和图 5-16 所示，将同一转速（以 1200rpm 为例）下不同故障特征之间做相关性分析，结果如图 5-17 和图 5-18 所示。




图 5-15 特征解调前后波发生器磨损下的特征变化




图 5-16 特征解调前后波发生器磨损下的特征变化




图 5-17 特征解调后同一转速下不同故障特征的皮尔逊相关分析热图




图 5-18 未经解调的特征同一转速下不同故障特征的皮尔逊相关分析热图

对比图 5-15 及图 5-16, 结果表明: 受故障特征及实验环境的影响, 同一故障不同转速下电流的不同故障特征随时间的变化趋势表现得并不相同, 求和、平均值及形状参数随时间的变化差异较为显著, 而其他特征并无明显变化。由于理论中同一种故障在不同转速下, 各个特征表现的相关性极为相似, 因此, 结合图 5-17 及图 5-18 可以得出: 经解调到的特征之间相关性与未解调特征之间的相关性存在明显差异, 未经解调的特征在同一故障下最大值、最小值、均方根、峰值、峰峰值、标准差、方差、峰度、波峰因子之间存在高度相关, 反观解调后的特征仅求和、平均值、形状参数之间存在高度关联性, 正常情况下的谐波减速器特征之间的相关性未经解调的特征类似, 但其冲动参数和间隙参数的关联程度明显高于未经解调的特征, 而形状参数和波峰因子明显低于未经解调的特征, 在解调信号中, 正常信号相较于两种故障信号, 其求和、平均和形状参数等特征并不相关, 这些特征在解调信号内可以作为区分故障类型的重要依据, 由不同故障类型特征之间的关联程度, 对后续基于数据驱动的特征分类方法在进行谐波减速器这段中提供数据支撑。

5.2.3 基于多策略集成学习方法的谐波减速器故障诊断

将上述的特征结果每组生成 100 份, 总共得到 900 组数据样本, 将训练集和测试集以 7: 3(训练集 630:测试集 270)进行划分训练, 并带入上文所述的 4 种经典的机器学习模型中进行分类, 并采用本文中 3 种多策略集成学习方法对结果进行评估, 得到结果如

图 5-19 和图 5-20 所示。




图 5-19 经特征解调后的特征基于不同多策略集成学习方法的谐波减速器故障诊断




图 5-20 未经特征解调的特征基于不同多策略集成学习方法的谐波减速器故障诊断

表 5-7 基于多策略集成学习方法处理前后的故障识别准确率

	解调后			解调前		
	D-S 证据合成	Stacking	动态投票	D-S 证据合成	Stacking	动态投票
最大值	92.59%	90.37%	90.74%	90.00%	89.26%	92.22%
最小值	87.78%	86.67%	82.48%	84.81%	85.93%	84.07%
平均值	89.82%	88.19%	86.91%	88.16%	87.87%	86.87%
方差	2.37%	0.90%	3.97%	2.75%	0.82%	3.56%

由上述结果可以得出，基于 D-S 证据合成理论的多策略集成学习方法在谐波减速器中取得较高的准确率结果，相较于基于 Stacking 和动态投票的多策略集成学习方法，平均准确率提升 1%~3%。从上图中还可以看出故障特征解调后的准确率相较于未经解调提升 1.66%。同时，基于 Stacking 的集成学习方法准确率相对稳定，而动态投票因为其不稳定因素较大，并考虑测试数据的随机性，故障解调前后的准确率的平均值并未得到有效提升。从而验证本文中理论的准确性。

5.3 本章小结

本研究通过搭建谐波减速器试验台并采集谐波减速器在不同转速下的是电流数据，

对前文的理论模型进行验证，通过仿真实验结果、特征解调和提取及故障诊断，逐步对理论研究进行验证，试验结果成功验证了本文中理论及仿真的准确性，通过解调后的特征，并基于 D-S 证据合成理论的多策略集成学习方法在谐波减速器故障识别的准确率上得到了有效的提升，为实际工程用中的工业机器人用谐波减速器故障诊断提供新的理论指导。

第 6 章 结论与展望

6.1 结论

本文以谐波减速器为研究对象,针对谐波减速器故障特征在电机电流信号中的表现特性,提出了一种特征解调方法,并基于 D-S 证据合成理论的多策略集成学习方法分别对解调前后的特征进行故障诊断,本文主要工作总结如下:

(1) 揭示了谐波减速器故障特征在电流信号中的表现形式。首先,建立工业机器人用谐波减速器机电耦合数学模型,揭示了谐波减速器的故障特征在电机电流中会受到电流调频频率调制干扰的机理。其次,在恒/变速工况下,仿真分析了其具体的表现形式,并通过搭建谐波减速器试验台,对谐波减速器在柔轮磨损和波发生器磨损情况下的电流数据进行分析,验证建立模型的正确性,为后续研究故障解调方法提供理论基础。

(2) 实现了不受电流调频频率调制干扰的谐波减速器故障特征的提取。针对谐波减速器故障信号在电流信号中受电流调频频率的调制干扰,提出了一种基于电流信号的故障特征解调方法。首先,在恒速工况下,对电流信号中本身不受电流调频频率调制的故障特征进行预处理。其次,对受调制的故障特征采用解调方法进行解调,并通过实验验证该方法的准确性。最后,对解调前后的时域信号提取 15 个特征进行分析。为后续基于数据驱动的机器学习方法奠定基础。

(3) 实现了基于 D-S 证据合成理论的多策略集成方法的谐波减速器故障诊断。针对单一的机器学习方法存在自身局限性,提出了一种基于 D-S 证据合成理论的多策略集成学习方法。首先对解调前后的特征分别基于决策树、支持向量机、朴素贝叶斯和 K 最近邻 4 种经典的机器学习方法进行谐波减速器故障诊断,实现单一模型下的故障诊断结果。其次,将上述 4 种机器学习方法作为基模型,分别基于 D-S 证据合成理论、Stacking 和动态投票的集成学习方法对谐波减速器进行故障诊断。结果表明,基于 D-S 证据合成理论的集成学习方法相较于最优的单一机器学习方法在准确率上提升 3.73%,相较于其他集成学习方法提升 1%~2%,解调后的特征在故障诊断的准确率上相较于未解调前提升 1.82%。并通过实验结果验证了该方法的有效性。为实际工业应用中的工业机器人减速器故障诊断提供新的方法策略。

6.2 展望

本研究通过建立谐波减速器-驱动电机机电耦合的数学模型，揭示了谐波减速器故障特征在电流信号中会受到电流调频频率所调制的机理，在此基础上提出一种特征解调方法解调谐波减速器故障特征，进而提出基于D-S证据合成理论，融合多种经典的机器学习基模型进行集成学习，实现对谐波减速器的故障诊断，最后通过搭建谐波减速器试验台，验证本文理论模型的准确性，鉴于研究周期限制和个人学术能力的边界，本研究存在若干需要进一步探讨和改善的方面：

(1) 在本研究中找出了谐波减速器故障特征在电流信号里会受到电流调频频率的调制干扰，因此提出了基于电流信号的特征解调方法以解调谐波减速器受调制的故障特征，因快速傅里叶方法无法识别变速工况下的电流调频频率，因此，该解调方法是基于恒定转速工况下的电流信号进行特征解调，实际工业应用场合中的谐波减速器工况是不断变化的，未来可尝试使用短时傅里叶提取脊线的方法得到变速工况下的电流调频频率，以探索变速以及更复杂工况下的特征解调方法。

(2) 实际谐波减速器的运行工况异常复杂，且故障方式往往不止一种，由于环境的复杂性，采集的电流数据也伴随不同程度的噪声影响，本实验通过滤除噪声的基础上进行故障特征的解调，通过对比验证了原始的故障特征相比受电流调制影响的故障特征在进行故障诊断时精确程度得到了有效提升，但在滤除噪声的同时可能存在滤除部分特征的可能，对最后的研究结果有一定影响。并且本研究对谐波减速器的特征解调及故障诊断都是基于波发生器磨损以及柔轮磨损故障，实际工程应用中的谐波减速器故障形式存在多样性，本文的针对上述两种故障诊断方法为今后研究更复杂的故障诊断提供指导。

(3) 如今已经出现多种集成学习方法自适应或融合分类识别得到最终的准确率，因此，基于自适应集成学习方法的工业机器人用谐波减速器进行故障诊断及分类更有研究价值和工程意义，对故障识别的准确率有望提升一个新的台阶。

参考文献

- [1] 乔雪涛, 张力斌, 闫存富, 等. 我国工业机器人 RV 减速器发展现状分析[J]. 机械强度, 2019, 41(6): 1486-1492.
- [2] 杨海乐, 马安帮, 孙一杰, 等. 采棉打包一体机轮边减速机箱体结构优化与模态分析[J]. 安徽科技学院学报, 2024, 38(6): 104-110.
- [3] 马安帮, 苏阔, 李同杰, 等. 基于 ADAMS 的采棉机变速箱动力学研究[J]. 安徽科技学院学报, 2022, 36(6): 70-77.
- [4] 黄雅玫, 伍国梁. 机器人用精密减速器检测标准和认证发展现状与展望[J]. 机电工程技术, 2024, 53(10): 6-11.
- [5] 朱晴旺, 张靖, 谢发祥, 等. RV 减速器主轴承试验台研制与实验研究[J/OL]. 中国机械工程, 1-7[2025-03-23]. <http://kns.cnki.net/kcms/detail/42.1294.th.20240913.1052.005.html>.
- [6] 曾莉, 吴晨. 工程机械智能故障诊断技术的研究现状及发展趋势分析[J]. 现代制造技术与装备, 2020, 56(11): 162-163.
- [7] TAMA B A, VANIA M, LEE S, et al. Recent advances in the application of deep learning for fault diagnosis of rotating machinery using vibration signals[J]. Artificial Intelligence Review, 2023, 56(5):4667-4709.
- [8] EL BOUHARROUTI N, MORINIGO-SOTELO D, BELAHCEN A. Multi-rate vibration signal analysis for bearing fault detection in induction machines using supervised learning classifiers[J]. Machines, 2023, 12(1): 17.
- [9] 蔺梦雄, 焦博森, 杨琰, 等. 基于 VMD 降噪的 RV 减速器故障诊断[J]. 北京联合大学学报, 2023, 37(3): 7-13.
- [10] 韩森坪. 变工况下的谐波减速器故障诊断方法研究[D]. 重庆: 重庆科技学院, 2023.
- [11] 冯柯. 浅析国内外智能制造技术现状及发展趋势[J]. 科技与创新, 2024,(16): 68-70.
- [12] 黄昊. 基于多源信息融合的变工况谐波减速器故障诊断研究[D]. 吉林: 吉林大学, 2023.
- [13] 雷亚国, 何平, 乔煜庭, 等. 基于平稳工况数据截取的 RV 减速器故障诊断方法[J].

- 电子机械工程, 2023, 39(04): 1-7.
- [14] 李旭阳. 基于 TPA 和 EMD 的工业机器人振动分析与实验研究[D]. 湖南:湖南大学, 2020.
- [15] 韩特, 李彦夫, 雷亚国, 等. 融合图标签传播和判别特征增强的工业机器人关键部件半监督故障诊断方法[J]. 机械工程学报, 2022, 58(17): 116-124.
- [16] ZHOU H, YAN P, YUAN Y, et al. Denoising the hob vibration signal using improved complete ensemble empirical mode decomposition with adaptive noise and noise quantization strategies[J]. ISA Transactions, 2022, 131: 715-735.
- [17] JIANG K S, ZHANG C S, Wei B L, et al. Fault diagnosis of RV reducer based on denoising time-frequency attention neural network[J]. Expert Systems with Applications, 2024, 238: 121762
- [18] E Y K, LIU Z M, CHEN H Y, et al. Dynamic modeling and vibration analysis for fault diagnosis of rotate vector reducers[J]. Mechanical Systems and Signal Processing, 2025, 224: 111965.
- [19] KOMORSKA I, OLEJARCZYK K, PUCHALSKI A, et al. Fault diagnosing of cycloidal gear reducer using statistical features of vibration signal and multifractal spectra[J]. Sensors, 2023; 23(3): 1645.
- [20] 赵永强, 徐洋, 解国升, 等. 损伤源-异常点累计谐波减速器性能退化评估[J]. 中国测试, 2024, 50(2): 59-65.
- [21] 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 [C]// 2020 年中国仪器仪表学会年会论文集. 2020: 753-764.
- [22] 苟东荣, 沈功田, 宋凯, 等. 声发射检测技术在齿轮故障诊断中的研究与应用现状 [J]. 无损检测, 2023, 45(03): 29-34.
- [23] YANG J W, LIU C, XU Q T, et al. Acoustic emission signal fault diagnosis based on compressed sensing for rv reducer[J]. Sensors. 2022; 22(7): 2641.
- [24] LIU L S, ZHI Z, YANG Y F, et al. Harmonic reducer fault detection with acoustic emission[J]. IEEE Transactions on Instrumentation and Measurement. 2023. 72. 3522812.
- [25] AN H B, LIANG W, ZHANG Y L, et al. Hidden Markov model based rotate vector reducer

- p>
fault detection using acoustic emissions[J]. International Journal of Sensor Networks, 2020, 32(2): 116-125.
- [26] ZHANG J J, SHEN G T, SHEN Y N, et al. Research on the application of acoustic emission technology in the health monitoring of the reducers on amusement devices[C]// ASME 2021 International Mechanical Engineering Congress and Exposition, 2021: V001T01A01.
- [27] 刘国春, 章翔峰, 周建星, 等. 行星齿轮传动系统动态温度场数值分析与实验研究[J]. 西安交通大学学报, 2022, 56(12): 174-183.
- [28] 庞大千, 曾根, 李训明, 等. 不同工况下机电复合传动装置行星齿轮系统瞬态温度场[J]. 兵工学报, 2021, 42(10): 2268-2277.
- [29] 乔帅, 周建星, 章翔峰, 等. 风电机组中两级齿轮传动系统动态温度响应与实验研究[J]. 太阳能学报, 2022, 43(1): 116-124.
- [30] 张小强, 高会英, 付国忠, 等. Reliability Analysis of Filtering Reducers Considering Temperature Correction and Shock Load of Space[J]. Journal of Shanghai Jiaotong University(Science), 2018, 23(03): 456-464.
- [31] GAN L, XIAO K, WANG J X, et al. A numerical method to investigate the temperature behavior of spiral bevel gears under mixed lubrication condition[J]. Applied Thermal Engineering. 2019, 147: 866-875.
- [32] WANG S S, WANG S K, WANG J, et al. Temperature field simulation and experimental study of anti-backlash single-roller enveloping hourglass worm gear[J]. Chinese Journal of Mechanical Engineering, 2020, 33(4): 77-86.
- [33] 王嘉. 一种基于电机电流诊断谐波减速器故障的信号采集装置[P]. 中国专利: ZL202110447725.5, 2021-06-04.
- [34] 柳杨, 王凌, 高雁凤, 等. 工业机器人谐波减速器的传动误差超限故障诊断[J]. 机床与液压, 2021, 49(17): 185-190.
- [35] 陈仁祥, 张勇, 胡小林, 等. 基于电压信号深度特征学习的谐波减速器健康状态识别[J]. 仪器仪表学报, 2021, 42(7): 234-241.
- [36] RAOUF I, LEE H, KIM H S. Mechanical fault detection based on machine learning for robotic RV reducer using electrical current signature analysis: a data-driven approach[J].

- Journal of Computational Design and Engineering, 2022, 9(2): 417-433.
- [37] CHEN X W, FENG Z P. Induction motor Stator current analysis for planetary gearbox fault diagnosis under time-varying speed conditions[J]. Mech Syst Signal Process, 2020, 140: 106691.
- [38] ROHAN A, RAOUF I, KIM H S. Rotate vector (RV) reducer fault detection and diagnosis system: towards component level prognostics and health management (PHM)[J]. Sensors (Basel), 2020, 20(23): 6845.
- [39] 柳杨. 基于 SVM 与 PNN 的工业机器人谐波减速器传动误差超限故障诊断[D]. 中国计量大学, 2021.
- [40] 胡淼, 徐永新, 宋少鹏, 等. 基于多源数据融合的电液车辆减速器监测系统研究[J]. 铁道通信信号, 2025, 61(02): 6-13.
- [41] 康守强, 章炜东, 王玉静, 等. 基于信息融合子域适应的不同工况下谐波减速器故障诊断方法[J]. 仪器仪表学报, 2024, 45(03): 60-71.
- [42] XIE W S, ZHOU J, LIU T, et al. Characteristic enhancement of RV reducer under non-stationary condition based on WDT-IF-SS-VMD[J]. Measurement Science and Technology, 2023, 34: 105108.
- [43] YE Q, LIU C H. A multichannel data fusion method based on multiple deep belief networks for intelligent fault diagnosis of main reducer[J]. Symmetry, 2020, 12(3): 483.
- [44] ZHANG K L, LI H K, CAO S X, et al. Trusted multi-source information fusion for fault diagnosis of electromechanical system with modified graph convolution network[J]. Advanced Engineering Informatics, 2023, 57: 102088.
- [45] KADKHODAEI H R, MOGHADAM A M E, DEHGHAN M. HBoost: A heterogeneous ensemble classifier based on the Boosting method and entropy measurement[J]. Expert Systems with Applications, 2020, 157: 113482.
- [46] 康英哲, 田宇航, 梁世昌, 等. 基于 Evolutionary Bagging 集成学习的超短期风功率预测[J]. 东北电力大学学报, 2024, 44(05): 24-32+72.
- [47] 杨龙蛟, 谷超. 基于 Bagging 集成学习方法的用电异常检测方法研究[J]. 电子产品世界, 2024, 31(03): 56-59.

- [48] 马荔瑶, 卫鹏, 范肖辰, 等. 基于证据有序极限学习机 Bagging 集成的苹果分级方法[J]. 济南大学学报(自然科学版), 2025, 39(02): 263-271.
- [49] Ngo G, Beard R, Chandra R. Evolutionary bagging for ensemble learning[J]. Neurocomputing, 2022, 510: 1-14.
- [50] XU S B, HUANG S Y, YUAN Z G, et al. Prediction of the Dst index with bagging ensemble-learning algorithm[J]. The Astrophysical Journal Supplement Series, 2020, 248(1): 14.
- [51] LIU X L, TAN W N, TANG S. A Bagging-GBDT ensemble learning model for city air pollutant concentration prediction[C]// IOP Conference Series: Earth and Environmental Science. 2019: 237, 022027.
- [52] 罗爽, 黄辉, 张凯兵. 基于 Boosting 回归的单帧图像超分辨率重建[J]. 激光与光电子学进展, 2022, 59(08): 215-227.
- [53] 李润祥, 高小红, 汤敏. 基于双树复小波分解的 Boosting 集成学习土地覆被分类研究[J]. 遥感技术与应用, 2022, 37(02): 354-367.
- [54] 周孟然, 周光耀, 胡锋, 等. 一种基于数据驱动的空调负荷预测方法[J/OL]. 河南师范大学学报(自然科学版), 1-7[2025-03-05]. <https://doi.org/10.16366/j.cnki.1000-2367.2024.06.23.0001>.
- [55] KARTHIK M, MALLIKARJUNA R K. Application of boosting-based ensemble learning method for the prediction of compression index[J]. Journal of The Institution of Engineers (India), 2020, 101(3): 409-419.
- [56] YANG S Y, WU J P, DU Y M, et al. Ensemble learning for short-term traffic prediction based on gradient boosting machine[J]. Journal of Sensors, 2017: 7074243.
- [57] ZAHOR M M, QURESHI S A, BIBI S, et al. A new deep hybrid boosted and ensemble learning-based brain tumor analysis using MRI[J]. Sensors, 2022, 22(7): 2726.
- [58] 郑一鸣, 李刚, 季军, 等. 基于 Stacking 集成学习的盾构掘进地表沉降预测方法[J]. 隧道建设(中英文), 2024, 44(11): 2233-2240.
- [59] 郭志强, 张博涛, 曾云流. 近红外光谱结合 Stacking 集成学习的猕猴桃糖度检测研究[J]. 光谱学与光谱分析, 2024, 44(10): 2932-2940.

- [60] 慈铁军, 廖子恒, 任梦晨, 等. 基于 VMD-Stacking 集成学习的新能源发电功率预测模型[J]. 电力科学与工程, 2024, 40(09): 14-23.
- [61] CUI S Z, YIN Y Q, WANG D J, et al. A stacking-based ensemble learning method for earthquake casualty prediction[J]. Applied Soft Computing, 2021, 101: 107038.
- [62] YANG Y F, WEI L, HU Y, et al. Classification of Parkinson's disease based on multi-modal features and stacking ensemble learning[J]. Journal of Neuroscience Methods, 2021, 350: 109019.
- [63] GUO X F, GAO Y, ZHENG D, et al. Study on short-term photovoltaic power prediction model based on the Stacking ensemble learning[C]// 2020 7th International Conference on Power and Energy Systems Engineering, 2020, 06(9): 1424-1431.
- [64] 王之腾, 纪存孝, 刘畅, 等. 自适应加权混合集成学习的雷达工作模式识别方法[J]. 陆军工程大学学报, 2024, 3(06): 10-16.
- [65] 荆澜涛, 张野, 张彬, 等. 基于改进 Light GBM 混合集成模型的变压器故障识别方法[J]. 高电压技术, 2024, 50(12): 5289-5300.
- [66] 彭飞, 刘辉, 郑力. 一种用于机器人电池电量预测的 Sarsa 强化学习混合集成方法 (英文) [J]. Journal of Central South University, 2023, 30(11): 3867-3880.
- [67] SIBINDI R, MWANGI R W, WAITITU A G. A boosting ensemble learning based hybrid light gradient boosting machine and extreme gradient boosting model for predicting house prices[J]. Engineering Reports, 2023, 05(4): 1-19.
- [68] NAGASSOU M, MWANGI R W, NYARIGE E. A hybrid ensemble learning approach utilizing light gradient boosting machine and category boosting model for lifestyle-based prediction of type-II diabetes mellitus[J]. Journal of Data Analysis and Information Processing, 2023, 11(4): 480-511.
- [69] AGARWAL S, CHOWDARY C.R.A-Stacking and A-Bagging: Adaptive versions of ensemble learning algorithms for spoof fingerprint detection[J]. Expert Systems with Application, 2020, 146: 113160.
- [70] 李霏, 顾含, 董庆丰. 电特性检测在电机预防性检修和故障诊断中的应用研究[J]. 机电工程, 2018, 35(4): 402-406+413.

攻读硕士学位期间发表学术论文及参研项目

一、发表学术论文

[1] 第一作者， 工业机器人用谐波减速器机电耦合建模及仿真方法[J].安徽科技学院学报, 2025, 39(02): 96-103.

二、申请专利

[1] 第一作者， 一种基于柔性平台的 RV 减速器测试装置[P]. 实用新型：CN222124733U， 2024（已授权）。

[2] 第二作者， 一种工业机器人用关节减速器故障数据预处理方法[P]. 发明专利：CN119681959A， 2025（实审中）。

三、参与的科研项目

[1] 2023 年度芜湖市“赤铸之光”重大科技成果工程化项目——工业机器人精密减速器高加速寿命测试装备开发及产业化（2023zc05）（项目主要完成人）。

致谢

时光荏苒，行文至此，意味着我的研究生生涯即将画上句点。回首求学之路，既有探索未知的迷茫与艰辛，也有豁然开朗的欣喜与感动。这段旅程中，无数人给予我无私的帮助与支持，在此谨以最诚挚的谢意，向所有陪伴、指导、鼓励我的人致以衷心的感谢。

首先，感谢我的导师。能够师从刘永明副教授、刘志博老师和赵转哲教授，是我学术生涯中最大的幸运。从课题选择到论文框架设计，从实验方案优化到结果分析讨论，导师始终以渊博的学识、严谨的治学态度和敏锐的学术洞察力为我指明方向。导师不仅教会我如何做科研，更以身示范何为“板凳甘坐十年冷”的学术坚守，这些精神财富将指引我在未来的道路上砥砺前行。

其次，感谢实验室的同窗挚友。感谢曾恒、曹子旭、罗慧闯同门在实验设备调试与数据采集中的倾囊相授，是你们不厌其烦地演示谐波减速器拆装流程，帮助我快速掌握故障模拟的关键技术；同时感谢高玉洁、王秀、刘云凤、陈露同门在算法代码实现上的鼎力支持，那些为调试集成学习模型而并肩奋战的深夜，那些因一个参数优化成功而击掌欢呼的瞬间，已成为研究生涯最珍贵的记忆；感谢室友杨龙、邵传好在讨论中提出的宝贵意见，每一次思维碰撞都让我对“科研需兼容并蓄”有了更深的理解。实验室不仅是一个科研场所，更是一个充满温度与力量的集体，这段同舟共济的情谊我将永远铭记于心。

同时，感谢我的父母。求学二十余载，父母始终以无条件的支持为我筑起最坚实的后盾。他们或许不懂“集成学习”或“故障诊断算法”，但每次视频通话中那句“别熬夜，多吃点好的”的叮嘱，让我在异乡的孤独中倍感温暖。

此外，感谢学校与合作伙伴。感谢大学提供的先进实验平台与学术资源，图书馆的浩瀚藏书、重点实验室的高精度仪器为研究提供了坚实基础；感谢赛宝机器人产业技术研究院在工业现场数据采集与工程验证中的技术支持，同时感谢高级工程师李明峻、涂志健指导的实践经验，让我深刻认识到“纸上得来终觉浅，绝知此事要躬行”。特别感谢基金项目《2023 年度芜湖市“赤铸之光”重大科技成果工程化项目》——“工业机器人精密减速器高加速寿命测试装备开发及产业化”（2023zc05）的资助，这份信任与期

待激励我以更高标准完成研究。

最后，致敬所有深耕智能制造领域的科研工作者。在工业机器人核心部件“卡脖子”的困境下，是无数同行在故障诊断、精密传动等领域的默默耕耘，为本文提供了理论基石与技术启发。作为青年学者，我愿以本文为起点，继续投身国产减速器可靠性提升的研究中，为“制造强国”战略贡献绵薄之力。

人生如逆旅，我亦是行人。谨以此文献给所有在黑暗中为我点亮星光的人——前路漫漫，唯愿不负所托，以探索之心奔赴下一场山海。

尚德敏学 唯实惟新

