

分类号: TH132.46

密 级: 公开

学校代码: 10363

学 号: 2210120153



安徽工程大学

Anhui Polytechnic University

硕士学位论文

题 目 摆线针轮传动系统故障振动特性
研究

论 文 作 者 任英虎

校 内 导 师 王风涛 副教授

校 外 导 师

专业学位类别 机械 工程硕士

研究方向(领域) 齿轮故障振动特性研究

论文提交日期: 2024 年 5 月 30 日

分类号: TH132.46
密 级: 公开

单位代码: 10363
学号: 2210120153

摆线针轮传动系统故障振动特性研究

RESEARCH ON THE VIBRATION CHARACTERIZATION OF FAULTS IN CYCLOID DRIVE SYSTEMS

学生姓名: 任英虎

指导教师: 王风涛 (副教授)

专 业: 机 械

研究方向: 齿轮故障振动特性研究

论文答辩日期: 2024 年 5 月 25 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：任其虎

日期：2024年5月30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：任英虎

指导教师签名：王风涛

日期：2024 年 5 月 30 日

日期：2024 年 5 月 31 日

摆线针轮传动系统故障振动特性研究

摘 要

高精度的旋转机械传动系统在国防、航空航天、交通运输、工业生产等诸多关键领域起到重要作用。摆线针轮传动系统是一种常见的旋转机械传动系统，因其具有结构紧凑、传动比范围广、传动精度高、传动平稳等优点，故在现代机械设备中广泛应用。由于摆线针轮传动系统中的齿轮长时间在低速、高负载的工况下工作，系统内齿轮故障频繁发生，严重影响了机械设备的寿命和可靠性。轮齿剥落作为齿轮系统中常见的故障形式之一，其发生不仅会影响机械设备的正常运行，情节严重甚至会引发重大安全事故。因此，开展摆线针轮传动系统的剥落故障振动特性研究并将研究成果应用于系统的故障监测具有重要的工程意义。

摆线针轮传动系统是少齿差行星齿轮传动系统的一种，系统内部多对齿轮的啮合旋转以及行星架的自传、公转等会产生诸多独特的振动信号，若系统内出现剥落故障，将进一步增加其振动特性研究的难度。本文以摆线针轮、针齿壳为主要研究对象，为总结出摆线针轮传动系统剥落故障振动特性规律展开了一系列研究，研究所得结果为摆线针轮传动系统的故障监测奠定了方法基础。主要研究成果如下：

(1) 选取摆线针轮作为研究对象，考虑了材料属性、接触刚度、摩擦磨损等因素，并利用有限元软件建立了单故障系统模型，对比分析了正常运行和单一故障状态下的仿真结果，得出：当系统产生剥落故障时，摆线针轮和针齿壳的加速度幅值随故障的产生而变大；

故障轮齿的啮合频率周围会产生大量边带，啮合周期、振动响应信息幅值增大。

(2) 选取摆线针轮和针齿壳为研究对象，考虑相关物理属性因素的影响，利用有限元软件建立了复合故障系统模型，对比分析无故障、单一故障和复合故障状态下的仿真结果，得出：当系统产生复合剥落故障时，摆线针轮和针齿壳的加速度幅值会随着故障演变程度加深、故障数量增多而增大；边带间的间隔频率、啮合周期、振幅峰值较于单剥落故障情况均显著增大。

(3) 搭建摆线针轮传动系统性能检测实验台，并在摆线针轮传动系统中植入剥落故障，进行系统剥落故障振动响应测试实验。对比分析实验结果和仿真结果，验证了有限元仿真分析的准确性和可靠性。

(4) 分别使用传统 CNN、LSTM、小波降噪结合 LSTM、注意力机制结合 LSTM 的神经网络处理实验采集的振动信号，对比分析不同神经网络处理振动信号的结果，得出：注意力机制结合 LSTM 神经网络的训练时间较短，其能够自动提取输入序列中的重要特征信息并在处理存在干扰噪声的数据时获得了较高准确率，是提高摆线针轮传动系统故障监测准确率的理想模型。

关键词：摆线针轮传动系统，剥落故障，振动特性，信号处理，故障监测

RESEARCH ON THE VIBRATION CHARACTERIZATION OF FAULTS IN CYCLOID DRIVE SYSTEMS

ABSTRACT

High-precision rotating mechanical transmission system plays an important role in many key areas such as national defense, aerospace, transportation, industrial production and so on. Cycloid transmission system is a common rotating mechanical transmission system, because of its compact structure, wide range of transmission ratios, high transmission accuracy, smooth transmission and so on, it is widely used in modern mechanical equipment. As the gears in the cycloid transmission system work for a long time at low speeds and under high loads, gear failures occur frequently in the system, seriously affecting the life and reliability of mechanical equipment. As one of the common failure forms in the gear system, the occurrence of gear tooth spalling not only affects the normal operation of mechanical equipment, but also causes serious safety accidents. Therefore, it is of great engineering significance to carry out the research on the vibration characteristics of spalling faults in the cycloid gearing system and apply the research results to the fault monitoring of the system.

Cycloid pinwheel drive system is a kind of less differential planetary gear drive system, the system internal multiple pairs of gears mesh rotation

as well as the planetary frame of the self-transmission, rotation, etc. will produce a number of unique vibration signals, if there is a spalling fault in the system, it will further increase its vibration characteristics of the study of the difficulty. In this paper, the cycloid pinwheel, needle tooth shell as the main object of study, in order to summarize the vibration characteristics of the spalling failure of the cycloid pinwheel drive system to carry out a series of studies, the results of the study for the cycloid pinwheel drive system failure monitoring laid the foundation for the method. The main research results are as follows:

(1) The cycloid pinwheel was selected as the research object, and the material properties, contact stiffness, friction wear and other factors were considered, and a single-fault system model was established by using finite element software, and the simulation results under normal operation and a single fault state were compared and analyzed, and it was concluded that: when the system produces a spalling fault, the acceleration amplitude of the cycloid pinwheel and pinion shell becomes larger with the generation of the fault; a large amount of the faulty gear teeth around the mesh frequency will be generated sidebands, and the amplitude of the meshing period and vibration response information increases.

(2) Selecting the balance wheel and needle gear housing as the research object, considering the influence of relevant physical property factors, using finite element software to establish a composite fault system model, comparing and analyzing the simulation results of no fault, single fault and composite fault state, it is concluded that: when the system produces a composite spalling fault, the acceleration amplitude of the balance wheel and the needle gear housing will increase with the deepening of the fault evolution degree, the number of faults increase; the frequency of the interval, the engagement period, the amplitude peak value of the side

bands are significantly increased compared with the single spalling fault case. The interval frequency, meshing period, and amplitude peak value of the sidebands increase significantly compared with the single spalling fault case.

(3) The performance testing experimental bench of the cycloid pinwheel drive system is built, and the spalling fault is implanted in the cycloid pinwheel drive system, and the vibration response test experiment of the system spalling fault is conducted. Comparatively analyze the experimental results and simulation results to verify the accuracy and reliability of finite element simulation analysis.

(4) The traditional CNN, LSTM, wavelet noise reduction combined with LSTM, and attention mechanism combined with LSTM neural networks were used to process the vibration signals collected from the experiments, and the results of the different neural networks were compared and analyzed, and it was concluded that: the training time of the attention mechanism combined with the LSTM neural network is shorter, and it is able to automatically extract the important feature information in the input sequence and obtain a higher accuracy rate when dealing with data with interfering noises. It is an ideal model to improve the accuracy of fault monitoring of the cycloid drive system, as it can automatically extract the important feature information in the input sequence and obtain high accuracy in processing the data with interference noise.

KEY WORDS: Cycloid drive train, Spalling faults, Vibration characteristic, Signal processing, Fault monitoring

目 录

第 1 章 绪论.....	1
1.1 论文来源、研究背景和意义.....	1
1.1.1 论文来源.....	1
1.1.2 研究背景和意义.....	1
1.2 行星轮系故障特性研究现状.....	2
1.3 基于深度学习的机械故障监测研究现状.....	4
1.4 论文主要研究内容及研究路线.....	5
第 2 章 摆线针轮传动系统单故障振动特性研究.....	7
2.1 本章引言.....	7
2.2 摆线针轮传动系统结构及工作原理.....	7
2.2.1 结构组成.....	7
2.2.2 工作原理.....	8
2.3 摆线针轮传动系统三维建模.....	9
2.3.1 摆线针轮参数化方程.....	9
2.3.2 单故障系统三维模型.....	10
2.4 单故障系统有限元模型.....	12
2.4.1 材料属性.....	13
2.4.2 网格划分.....	13
2.4.3 求解器和连接关系.....	13
2.4.4 位移边界条件.....	14
2.5 仿真结果分析.....	15
2.5.1 Mises 应力分析.....	15
2.5.2 振动特性分析.....	16
2.6 本章小结.....	20
第 3 章 摆线针轮传动系统复合故障振动特性研究.....	21
3.1 本章引言.....	21
3.2 复合故障系统三维模型.....	21
3.3 复合故障系统有限元模型.....	21
3.4 仿真结果分析.....	22
3.4.1 Mises 应力分析.....	22
3.4.2 振动特性分析.....	24
3.5 本章小结.....	28
第 4 章 摆线针轮传动系统剥落故障振动特性实验.....	29
4.1 本章引言.....	29
4.2 摆线针轮传动系统性能检测实验台及实验条件.....	29
4.3 实验结果分析.....	31
4.4 本章小结.....	32
第 5 章 基于深度学习的摆线针轮传动系统的故障监测.....	33
5.1 本章引言.....	33
5.2 基于深度学习的理论基础.....	33

5.2.1 小波降噪.....	33
5.2.2 LSTM 神经网络架构	36
5.2.3 注意力机制.....	37
5.3 实验流程设计.....	38
5.4 基于 CNN 和 LSTM 的摆线针轮传动系统的故障监测	39
5.5 基于小波降噪和 LSTM 的摆线针轮传动系统的故障监测	42
5.6 基于注意力机制和 LSTM 的摆线针轮传动系统故障监测	45
5.7 噪声干扰下的摆线针轮传动系统故障监测.....	46
5.7.1 验证设计.....	47
5.7.2 验证过程.....	47
5.7.3 验证结论.....	50
5.8 本章小结.....	51
第 6 章 总结与展望.....	53
6.1 研究总结.....	53
6.2 研究工作展望.....	54
参考文献.....	55
附录.....	62
致谢.....	63

第 1 章 绪论

1.1 论文来源、研究背景和意义

1.1.1 论文来源

本论文来源于安徽省芜湖市埃夫特智能装备股份有限公司委托安徽工程大学机械工程学院项目：“RV 减速器分析与检测数据处理技术开发”（合同编号：HX-2021-08-009）。

1.1.2 研究背景和意义

进入 21 世纪，我国的经济与科技飞速发展，无论是人们日常生活所用的工具还是企业生产制造所用的设备，传动装置都不可或缺，传动装置中的齿轮、曲轴、连杆等的制造标准日益向着高安全性、高精度及高效率发展。在正常情况下，传动系统承受着重大负荷，任何故障都可能导致设备失效，从而引发人员伤亡和财产损失。因此，传动装置的可靠性至关重要。精准的故障监测是预防传动装备引发不良事故的重要手段。

本文研究的摆线针轮传动系统属于少齿差行星轮系。与一般定轴齿轮系统相比，行星齿轮系统具有体积小、传动比范围广、效率高、运行平稳和速度范围宽广等优势；其缺点有结构复杂、制造精度高和组装繁琐等。行星轮系虽存在上述优点，但其通常在低速高负荷环境下运行，如果核心传动构件发生故障或失效会显著影响行星齿轮系统的性能，长时间的停机维修也将会带来巨大的经济损失^[1]。

随着《中国制造 2025》的推动和实施，我国智能制造产业正处于快速发展阶段。在智能制造装备领域，特别是以工业机器人为核心的设备，被认为是推动制造业升级改革的重要驱动力。在工业机器人领域，摆线针轮传动系统已成为全球研究的热点之一，齿面剥落是摆线针轮传动系统中一种典型多发的故障形式，由剥落故障引发齿轮失效将严重影响设备的安全性和工作可持续性。摆线针轮传动系统的振动频谱包括轮齿间的啮合频率及其谐波分量。当齿轮出现故障，其振动频谱应发生显著变化，但目前尚不完全清楚摆线针轮传动系统内部剥落故障引起的特征振动与外部安装的振动传感器监测到的振动信号之间的

关系。

为了防止剥落故障引发人员安全事故和企业经济损失, 本文将着重研究摆线针轮传动系统存在单剥落故障、复合剥落故障状态下, 系统内部的故障激励与安装在外部的振动传感器测得的振动响应信息之间的特性规律。研究成果将为摆线针轮传动系统的状态监测奠定方法基础。

1.2 行星轮系故障特性研究现状

由于摆线针轮传动系统内部结构的复杂性和多对齿轮啮合所产生的激励, 该系统具有多种独特的振动特性。这些特性包括行星架的自转和公转运动、太阳轮与多个行星轮之间的啮合等。每对齿轮啮合引起的振动信号在某种程度上相似, 而啮合相位的差异可能导致振动信号的削弱或增强^[2], 它们都加剧了摆线轮传动系统振动响应分析的难度。

为了深入研究行星齿轮系统的振动特性, 学者们进行了动力学模型的建立和探索。Kahraman^[3]于 1994 年提出简化扭振动力学模型, 其通过弹簧和阻尼模拟集中质量间的相互作用, 进而推导出各阶次频率的表达式。随后 Kahraman^[4]又在 2001 年提出多级行星齿轮系统的扭转动力学模型, 并利用特征值求解法计算得出了系统的固有频率。2002 年, Lin 和 Parker^[5]基于扭振动模型, 研究了时变啮合刚度对系统参数非稳定性的影响。孙智民^[6]等研究中考虑了非线性激励对系统的影响, 通过使用拉格朗日方程推导出系统的扭转动力学模型。值得注意的是, 行星齿轮系统的扭转动力学模型并未考虑平移方向的振动对整个系统的影响。为了更准确地分析行星齿轮系统的动力学特性, Lin 和 Parker^[7]在研究中考虑了各个零件在平移方向上的两个自由度, 并建立了一个在随动坐标系下具有 $9+3N$ 自由度的模型。Cooley 和 Parker^[8]基于陀螺效应对系统振动特性的影响, 构造了包含平移和扭转的动力学方程。这些早期的专家学者通过建立行星齿轮系统动力学模型进行数学推导和理论分析, 但研究的重点主要放在健康状态下的行星齿轮系统上, 至于故障行星齿轮系统, 特别是存在剥落故障的情况, 其振动特性仍需要进一步研究。

齿轮系统运行时, 齿轮的局部损伤会导致显著的振动冲击, 这种情况通常发生在齿轮啮合旋转的过程中, 可以将单位时间内出现的周期性冲击频数定义为特征频率^[9-10], 这为齿轮系统的故障监测提供了分析指标。一些专家学者对

行星轮系的故障振动特性进行了研究，并提供了大量可靠的数据支持^[11-16]。研究方式是将加速度传感器安装在摆线针轮传动系统外壳上或行星齿轮箱箱体上来获取振动信号，如图 1-1 所示，并利用信号处理手段提取故障特征频率。朱良斌^[17]等人通过使用有限元软件，建立了轮齿接触的等效模型，并计算出摆线轮齿面的应力分布。通过这种方法可以预测在外部载荷下结构的寿命；汪久根^[18]团队建立了摆线针轮传动系统刚柔耦合动力学虚拟样机模型，并通过灰色关联度指标分析了整个系统的模态频率和振型等特性；谭晶^[19]等人预处理并分析了摆线针轮传动系统扭振动信号，最终成功地确定系统内可能存在故障的部件；Smith^[20]通过构造简化的振动信号模型探究齿圈固定的行星轮系的运行状态，最终揭示了由时变传递路径引发的调制现象；Feng^[21-23]针对行星轮系的局部故障，建立了行星轮传递路径的信号模型，并对故障状态下信号的特征展开了研究。因行星架具有公转运动，所以齿轮副啮合处的振动源到传感器的信号传递路径会周期性地随时间变化，MacFadden^[24]针对内部行星轮系统的故障状态难以准确识别的困扰，建立了简化的振动模型用于说明由传感器信号传递路径的时变性而引起的调制现象；雷亚国^[25-26]等人基于信号传递路径，建立了太阳轮在出现齿面剥落和齿面裂纹情况下的振动信号模型；李国彦^[27]则针对行星齿轮传动系统的复合故障诊断技术进行了更深层次的探究。




图 1-1 摆线针轮传动系统外壳体

目前针对齿轮故障信号的处理方法^[28-32]多是仅对故障特征进行提取，并没有深入分析行星轮系的故障机理，因此在提取和识别故障时存在盲点，缺乏全面性，进而导致故障的监测和预警效果不理想。除此之外，少有成熟的信号处

理方法能高效的滤除外部环境和系统内部产生的干扰噪声^[33-34]。一些学者使用傅立叶变换^[35-37]的方法研究了行星齿轮系统的振动特性，但是他们建立的模型均为健康的行星轮系，并未探究行星轮系内部故障激励与加速度传感器所测得的信号特征之间的关系。

对于摆线针轮传动系统的研究主要集中在传动精度和扭转刚度等方面^[38-39]，这些研究旨在解决摆线针轮传动系统在制造过程中的基本技术难题。摆线针轮传动系统零件数量多、结构复杂，单纯的理论数学模型缺乏与各种物理参数的联系，如材料属性、接触刚度、故障尺寸等，难以周到且有说服力解释故障对系统振动特性的影响。一般基于理论推导的摆线针轮传动系统模型需要通过诸多假设来简化模型^[40-42]，与实际工况存在差别不小差别。有限元分析方法在很大程度上克服了理论建模的限制，并且学者们已经成功地应用该方法进行了摆线针轮传动系统的模态分析和优化设计等研究^[43-45]。基于有限元分析法构建的非线性动力学模型能够考虑接触刚度、摩擦变形等因素，并对摆线针轮传动系统的零件运动进行有效模拟^[46-49]。

综上，国内外学者已针对行星轮系的振动响应特性进行了广泛而深入的研究。但在针对故障行星轮系，尤其是存在剥落故障的行星轮系方面的研究相对较少。因此，目前还无法清楚地了解剥落故障对摆线针轮传动系统振动特性的影响。

1.3 基于深度学习的机械故障监测研究现状

摆线针轮传动系统的故障种类繁多，如齿轮磨损、松动、断裂等^[50]，针对这些故障，系统的故障监测采用的传统方法有数据分析^[51]、时频分析^[52]、建立时变模型^[53]等。虽然传统方法对摆线针轮传动的故障监测已经能够达到较高的准确率，但需要进行的预处理工作较多，如对收集到的信号进行降噪^[54]、EMD分解^[55]、傅里叶变换^[56]、小波变换^[57]等。机械的故障监测多是基于振动信号，由于时域图谱中的故障特征不明显，需对原始振动信号数据进行傅立叶变换或者小波变换，将时域转换为频域，但傅立叶变换中的窗函数大小会直接影响时域到频域的特征转换^[58]；此外，小波变换中选取的小波函数也会使同一时域中的信号表现出不同的特征^[59]。传统方法的泛化能力较差，在处理大规模数据和高维度特征时效率较低，难以适应复杂多变的故障模式。此外，对于需要快速

响应和实时监测的场景来说，传统方法需要人工介入，对数据进行采集、处理和分析，导致监测结果由延迟性。

随着机器深度学习的发展，深度学习算法通过学习大量数据，可自动提取特征和模式，减少了对主观判断的依赖，其可以利用隐藏模式和关联关系来进行故障监测。此外，深度学习模型具有可扩展性、易维护性和实时性，可以快速适应新数据和复杂故障场景，并在较短的时间内完成监测任务。汪久根^[60]等人利用残差神经网络进行摆线针轮传动系统故障监测达到了 98.11%的准确率；任重^[61]等人为了实现摆线针轮传动系统自动进行故障监测，利用粒子群算法对向量机进行优化；毛君^[62]等人利用萤火虫算法优化了 BP 神经网络中的权值和阈值，解决了神经网络中的过拟合的问题；阮强^[63]等人为了减少噪声对深度学习模型的干扰，将时频分析中的小波变换等方法与深度学习相结合，建立多种网络架构，使摆线针轮传动系统的故障监测达到了更高的准确率。虽然深度学习在行星轮系故障监测方面具有广阔的应用前景，但仍存在一些缺点，如深度学习模型往往是黑盒模型，它们在决策的过程中缺乏透明性和解释能力，这表明很难理解模型是如何做出诊断决策的，使其在实际应用中不被接受和信任^[64-68]。

研究学者发现注意力机制可以让模型集中处理输入数据中的关键信息，从而忽略数据中不重要得到部分，其可以自动选择输入与当前任务相关的特征，使模型获得更准确的监测。注意力机制提供了一种解释模型决策的方式，其通过观察模型对输入关注权重的分布，理解模型在决策时的重视程度和决策依据，如此便具有很强的可解释性，对于故障监测和模型的调试都非常有价值^[69-70]。孟宏宇^[71]利用注意力机制结合了 CNN 和 LSTM 建立一种新的模型，在直流电网的小样本诊断下具有良好的诊断性能；张汉霖^[72]等人利用多重注意力机制优化了卷积神经网络，使得准确率提高了 1.8%；焦晓璇^[73]等人利用双重注意力机制优化了 S-BiGAN 网络，使得在标签缺少下的故障诊断问题得到了解决，这都表明注意力机制能够有效的提高机械故障监测的准确率。

1.4 论文主要研究内容及研究路线

本文以产生剥落故障的摆线针轮传动系统为研究对象，采用有限元分析、实验验证、神经网络处理实验振动信号等手段，探究其振动特性。主要研究内容如下：

(1) 利用有限元分析软件自带脚本功能建立摆线针轮剥落故障模型、摆线针轮-针齿壳复合剥落故障模型，模拟单剥落故障、复合剥落故障状态下摆线针轮传动系统的动态响应，对比分析不同状态下的云图、时频信号图，探究系统故障振动信号特征，为摆线针轮传动系统的故障监测提供分析依据。

(2) 搭建摆线针轮传动系统性能检测实验平台，收集健康和存在剥落故障的减速器振动信号，并进行对比分析不同状态下的振动信号频谱图，以验证有限元模型的准确性和可靠性。

(3) 基于深度学习理论，选用多种、多组合神经网络架构（传统 CNN、LSTM、小波降噪结合 LSTM、注意力机制结合 LSTM）处理实验采集的振动信号，根据振动信号数据处理结果的准确性、高效性和抗噪声干扰能力，甄选出最优的神经网络架构，并用于摆线针轮传动系统的故障监测。

本文的研究路线如图 1-2 所示。研究路线图揭示了本文依次经历的 4 个主要研究阶段、每个阶段的研究目的及具体研究内容。




图 1-2 研究技术路线图

第 2 章 摆线针轮传动系统单故障振动特性研究

2.1 本章引言

本章以摆线针轮为研究对象，在考虑材料属性、接触刚度、摩擦等因素的影响下^[74]，利用有限元软件建立了产生剥落故障的摆线针轮分析模型，并通过对比存在剥落故障和无故障状态的仿真结果，研究了系统在产生剥落故障时的振动特性。

2.2 摆线针轮传动系统结构及工作原理

2.2.1 结构组成

本文研究的摆线针轮传动系统的传动机构包括第一级圆柱齿轮行星减速装置和第二级摆线针轮行星减速装置。第一级圆柱齿轮行星减速机构由 1 个太阳轮和 3 个行星轮组成；第二级摆线针轮行星减速机构由 2 个摆线针轮、针齿壳和行星架组成。具体结构如图 2-1 所示。

1-太阳轮 2-行星轮 3-曲柄轴 4-摆线轮 5-针轮结构 6-针齿壳 7-箱体




图 2-1 摆线针轮传动系统结构图

2.2.2 工作原理

摆线针轮传动系统采用针齿壳固定、行星架作为输出机构，或者行星架固定、针齿壳作为输出机构的传动方式。在本文研究的摆线针轮传动系统模型采用了针齿壳固定、行星架作为输出机构的传动方式。如图 2-2 所示，电机提供的动力通过输入轴传递给太阳轮；太阳轮与行星轮啮合，行星轮公转的同时，也绕自身轴线自转，从而完成第一级减速。行星轮和曲柄轴联结在一起作为齿轮轴，故曲柄轴的自转和公转与行星轮保持同步；行星齿轮轴随着曲柄轴的旋转和公转运动，将动力传递到第二级摆线针轮，摆线针轮绕针齿壳上的针轮中心线旋转，并同时以反方向进行自转运动；摆线针轮的自转使得行星架转动，行星架的旋转速度与摆线轮的旋转速度相匹配，而摆线针轮的速度以 1:1 的传动比输出到行星架，从而完成了第二级减速传动。根据描述，摆线针轮传动系统第一级传动比计算见公式（2-1）：

$$i_{12} = \frac{n_1 - n_6}{n_2 - n_6} = \frac{z_2}{z_1} \quad (2-1)$$

式中： n_1 为太阳轮转速； n_2 为行星轮转速； n_6 为行星架转速； z_1 为太阳轮齿数； z_2 为行星轮齿数。第二级传动比计算见公式（2-2）：

$$i_{45} = \frac{n_4 - n_3}{n_5 - n_3} = 1 - \frac{n_4}{n_3} = \frac{z_{rp}}{z_c} \quad (2-2)$$

式中： n_3 为曲柄轴转速； n_4 为摆线针轮转速； n_5 为针齿壳转速； z_c 为摆线针轮齿数； z_{rp} 为针齿壳针齿齿数。曲柄轴与行星轮联接为一体，故曲柄轴转速与行星轮转速相同，见公式（2-3）：

$$n_3 = n_2 \quad (2-3)$$

又因行星架转速与摆线针轮自转的转速相同，见公式（2-4）：

$$n_6 = n_4 \quad (2-4)$$

由式(2-1)-(2-4)可得 RV 传动比计算，见公式（2-5）：

$$i_{16} = \frac{n_1}{n_6} = 1 + \frac{z_2 z_{rp}}{z_1 (z_{rp} - z_c)} \quad (2-5)$$




图 2-2 摆线针轮传动系统传动简图

2.3 摆线针轮传动系统三维建模

2.3.1 摆线针轮参数化方程

如图 2-3，摆线针轮的运动几何学分析是指定圆上一点沿着基准线做圆周运动。在笛卡尔直角坐标系中，假设半径为 r 的滚动圆 $O1$ 沿着半径为 R 的基准圆 O 滚动。点 $A1$ 位于滚动圆 $O1$ 上，也是基准圆 O 与滚动圆 $O1$ 的接触点。当滚动圆 $O1$ 从位置 $A1$ 运动到 $A2$ 时，它绕过的角度为 β 。如果以基准圆 O 作为参考点，则转过的角度为 θ 。




图 2-3 摆线形成坐标图

两圆所对应的弧长相等，见公式（2-6）：

$$\beta = \frac{R}{r} \theta \quad (2-6)$$

则A2对应的坐标表示，见公式（2-7）：

$$\begin{cases} x = (R + r) \cos \theta - \cos \alpha \\ y = (R + r) \sin \theta + \sin \alpha \end{cases} \quad (2-7)$$

其中 $\alpha = 2\pi - \theta - \beta$ 。

根据摆线的形成原理建立参数方程，见公式（2-8）：

$$\begin{cases} x = (R + r) \cos \theta - \cos(1 + \frac{R}{r})\theta \\ y = (R + r) \sin \theta - \sin(1 + \frac{R}{r})\theta \end{cases} \quad (2-8)$$

2.3.2 单故障系统三维模型

摆线针轮传动系统主要设计参数见表 2-1、2-2。

表 2-1 结构参数

参数名	参数值	参数名	参数值
太阳轮齿数	12	偏心距/mm	2.4
行星轮齿数	44	行星轮齿宽/mm	16
摆线轮齿数	59	针齿直径/mm	10
针齿齿数	60	针齿中心圆直径/mm	165
压力角/°	20	行星齿轮轴个数	3

表 2-2 质量特性参数

名称	材料	弹性模量(N · m ⁻²)	泊松比
行星齿轮轴	20CrMnMo	2.07E+11	0.254
摆线针轮	20CrMnMo	2.07E+11	0.254
针齿壳	GCr15	2.08E+11	0.300
行星架	ZG65Mn	1.98E+11	0.230
太阳轮	20CrMnMo	2.07E+11	0.254

本章采用有限元软件中自带的脚本功能对摆线针轮传动系统进行建模。基于软件的曲线表达式功能，将摆线针轮参数化方程稍作变化并输入相关参数便可得到摆线针轮得齿廓曲线；利用软件中“通过方程式驱动样条曲线”功能绘

制出摆线齿轮的齿廓曲线；在使用“拉伸”指令把生成摆线针轮齿廓曲线拉伸成实体；最后设定摆针线轮所需的几何尺寸约束和相关位置约束，完成摆线针轮在软件中的三维建模工作。构造剥落故障的方法是通过在无故障的摆线轮渐开线齿的边缘使用切削指令，将其切削深度达到 0.5mm，如图 2-4 所示。





图 2-4 摆线针轮模型图

摆线针轮传动系统其他零件的建模方法是去除那些对于仿真分析影响较小的倒角、凹槽、螺孔等细节，并将行星轮与曲柄轴的联接设计成齿轮轴，以减少仿真分析的计算负荷，具体的过程不做详细说明。其余零件三维模型如图 2-5 所示。






图 2-5 零件模型图

摆线针轮传动系统零件繁多，结构复杂，故采用模块化分步装配的方式装配减速器：首先将一些零部件组装在一起，形成一个子装配体，然后将这个子装配体添加到整体装配体中。在装配过程中将外壳与针齿组合成一个子装配体，并将曲柄轴与行星轮连接成另一个子装配体。最终完成摆线针轮减速器的虚拟装配，如图 2-6 所示。




图 2-6 摆线针轮传动系统模型图

2.4 单故障系统有限元模型

有限元模型的质量决定软件分析结果，建立质量优良的有限元模型主要分为如下 4 个步骤：

2.4.1 材料属性

材料属性参数见表 2-3。

表 2-3 零部件属性参数

属性	参数值
材料	Steel（结构钢）
密度 ρ	$7.85 \times 10^{-9} \text{ t/mm}^2$
弹性模量 E_1	$2.1 \times 10^5 \text{ MPa}$
泊松比 μ	0.3

2.4.2 网格划分

为保证有限元分析的一致性并获得稳定的网格质量，摆线针轮传动系统的各个零件在网格划分时都采用了四面体的统一形状，并将几何阶次设定为线性。根据结果显示，完整的减速器装配体被划分成了 225624 个网格单元和 52107 个节点；而剥落故障摆线针轮在故障位置处引起了网格的畸变，导致划分后的模型包含 55965 个网格单元和 12374 个节点。划分网格后的模型如图 2-7 所示。




图 2-7 模型网格划分图

2.4.3 求解器和连接关系

设定模型的求解器是通过创建分析步和场输出实现的，设定参数见表 2-4。

表 2-4 分析步和场输出参数

参数	参数值/类型
时间长度/s	0.5
线性体积粘性参数	0.06
间隔	1000
时间缩放系数	1
质量缩放系数	1000
频率	均匀时间间隔
分析步类型	显示动力学

构建模型的连接关系分为三个步骤。第一步是创建零件间的接触，接触对参数见表 2-5；第二步是创建零件的约束，相关约束类型见表 2-6；第三步是确定连接截面类型为铰。

表 2-5 接触对参数

太阳轮-行星轮接触对	参数值/类型	摆线轮-针齿壳接触对	参数值/类型
力学切向摩擦系数	0.15	力学切向摩擦系数	0.15
力学法向行为	硬接触	力学法向行为	软接触
—	—	接触刚度	500

表 2-6 零件约束类型

零件	约束类型
针齿壳和地	固定副
摆线针轮和针齿壳	转动副
行星齿轮轴和行星架	转动副
行星齿轮轴和太阳轮	转动副

2.4.4 位移边界条件

仿真分析的最后阶段需要为针齿壳、行星架和太阳轮设置适当的位移约束条件，相关参数见表 2-7。

表 2-7 位移边界条件参数

零件种类	类型	坐标系
针齿壳	对称/完全固定	完全固定
行星架	位移/转角	释 x 方向自由度
太阳轮	位移/转角	x 方向旋转 1 弧度

2.5 仿真结果分析

仿真过程全程采用显式动力学法。通过对比分析摆线针轮传动系统在无故障状态和剥落故障状态下的仿真结果，可以观察到系统中某个零件发生局部故障时振动信号频谱特征相应发生变化，故振动信号可作为摆线轮传动系统故障监测的载体。遵照上述有限元模型的设计过程，完成剥落故障状态和无故障状态下的摆线针轮传动系动力学仿真。在真实的信号采集环境中，由于摆线轮传动系统的零件之间配合紧密，加速度传感器无法被放置在故障摆线针轮上进行定位，故将加速度传感器放置在针齿壳外部，以测量系统的振动信号。因此，在仿真中，测量节点的位置被设定在针齿壳的任意位置上。

2.5.1 Mises 应力分析

针对存在剥落故障和无故障两种工况，分别对摆线针轮和针齿壳提取 Mises 应力：

(1) 如图 2-8 所示，当摆线轮绕着针齿中心旋转时，受到剥落故障影响的摆线针轮的 Mises 应力大于未受故障影响的摆线针轮，因为存在剥落故障的摆线针轮的啮合承载区域比未出现故障的摆线针轮少一个完整的啮合轮齿，导致承载能力减弱，从而使得应力增大。




图 2-8 摆线针轮应力云图

(2) 如图 2-9 所示，对比存在剥落故障的摆线针轮啮合针齿壳和无故障摆线针轮啮合针齿壳上的 Mises 应力，发现摆线针轮在承受转速载荷和径向载荷时，两者的 Mises 应力值相差不大。可能是仿真模型中的剥落故障体积较小，同时针齿壳内壁具有一定厚度，导致剥落故障对针齿壳受到的 Mises 应力影响有。




图 2-9 针齿壳应力云图

综上所述，当摆线针轮存在剥落故障时，Mises 应力明显高于无故障状态下的应力。然而，当分析对象转移到针齿壳时，由于剥落故障的体积较小，且轮齿间存在啮合阻尼，使得存在剥落故障和无故障的摆线针轮在与针齿啮合时，针齿壳受到的 Mises 应力变化不大。因此，针齿壳不适合作为摆线针轮传动系统故障监测的依据。

2.5.2 振动特性分析

根据存在剥落故障和无故障两种工况，分别对摆线针轮和针齿壳提取加速度：

(1) 如图 2-10 所示，当摆线针轮存在剥落故障时，其加速度数值将高于无故障状态下的摆线针轮，这表明出现剥落故障后，振动信号会变得更加激烈。




图 2-10 摆线针轮加速度云图

(2) 如图 2-11 所示，当针齿与有剥落故障的摆线针轮啮合并旋转时，针齿壳本身受到的振动冲击较为显著，其加速度数值明显高于与无故障摆线针轮啮合时的加速度。这表明在摆线针轮存在剥落故障时，针齿壳所经受的振动冲击比无故障状态下更加剧烈。






图 2-11 针齿壳加速度云图

在仿真过程中，选择针齿壳上的观测点 A，并分别记录两种状态下该点沿 x 方向的时域信号。如图 2-12 所示，前 0.05 秒的数据受到径向加载和转速加载的影响，导致摆线针轮运动不稳定，故将这部分数据舍弃。根据图 a 中显示的信息，大约在 0.28 秒时，针齿壳在与存在剥落故障的摆线针轮啮合时经历了一个显著的冲击，该冲击产生的加速度峰值约为相同时间段内无故障状态下针齿壳受振动产生的峰值的 10 倍。这表明当摆线针轮存在剥落故障时，传动系统的时域信号图谱中将呈现出一个明显的振动冲击波，且该冲击波的峰值远远大于无故障状态下的振动冲击峰值。



(a)单故障时域图谱




(b)无故障时域图谱


图 2-12 振动信号时域图谱

当摆线针轮传动系统产生剥落故障时，时域信号图谱虽然能反映出部分频谱特征，但要获取更清晰的振动频率结构以及幅值变化，应分析通过短时傅立叶变换得到的频域信号图频谱。如图 2-13 所示，若摆线针产生剥落故障，由故障造成的周期性冲击序列对于轮齿间的正常啮合会产生调制作用，导致振动信号的频谱出现频率偏移并产生额外的频率成分，进而形成了大量的边带。根据图 a 提供的信息，相邻边带之间的间隔约为 793Hz，这个数值实际上代表了摆线针轮上剥落故障的通过频率。

此外，若摆线针轮产生剥落故障，啮合频率的周期会显著地比无故障状态下的周期长，且波峰的幅值也会大于无故障状态下的幅值，从频域图谱中获取的多种振动特性信息用于摆线轮传动系统的故障监测更加准确可靠。



(a)单故障频域图谱



(b)无故障频域图谱

图 2-13 振动信号频域图谱

2.6 本章小结

本章建立了摆线针轮存在剥落故障的传动系统有限元模型，并对模型进行仿真分析，基于仿真得到的云图和频谱图中的振动响应信息，能够大致监测摆线针轮传动系统中是否处于健康状态，总结如下：

(1) 通过分析摆线针轮和针齿壳的 Mises 应力云图，得出针齿壳所受 Mises 应力值大小受剥落故障的影响较小，无法作为系统是否产生故障的依据；又因为在真实测量环境中，加速度传感器无法直接定位到摆线针轮上，可知 Mises 应力值不适宜作为故障监测的依据。

(2) 通过分析摆线针轮和针齿壳的加速度云图，可以观察到不论是摆线针轮还是针齿壳，存在剥落故障时加速度幅值都会受到较大影响。当存在剥落故障时，二者的加速度幅值明显大于无故障状态下的幅值。因此，通过比较摆线针轮和针齿壳加速度云图中幅值大小，可以初步判断系统是否出现故障。

(4) 通过分析传动系统时域图谱，得出当摆线针轮发生剥落故障时，针齿壳会在一定时间段内经历明显的振动冲击，并且在这个冲击期间产生的加速度峰值将远远大于无故障状态下的峰值。故通过分析时域图谱中波峰的变化和峰值的大小，可以初步判断系统是否存在故障。

(5) 通过分析传动系统的频域图谱，可以观察到当摆线针轮出现剥落故障时，故障轮齿参与啮合的频率周围会出现大量边带。相邻边带之间的间隔频率则代表了剥落故障的通过频率。此外，在剥落故障的影响下，啮合周期和振幅也会有所增加。这些从频域图谱中获得的振动特征规律可以更准确地显示系统是否存在故障。

第3章 摆线针轮传动系统复合故障振动特性研究

3.1 本章引言

本章以摆线针轮和针齿壳为研究对象，考虑了与第2章相同的材料属性、物理属性的影响，在有限元软件中建立了包括摆线针轮和与之啮合的针齿壳部位的复合剥落故障有限元模型。通过对比分析系统在存在复合剥落故障、单一剥落故障和无故障状态下的仿真结果，研究了摆线针轮传动系统在产生复合剥落故障时的振动特性。

3.2 复合故障系统三维模型

为构造复合剥落故障，使用有限元软件自带的切削指令，在无故障的摆线针轮渐开线轮齿边缘和针齿壳针齿边缘上切削 0.5mm 的深度，如图 3-1 所示。其余零件的建模方式及尺寸参数均与第2章节保持一致。




图 3-1 复合故障模型图

3.3 复合故障系统有限元模型

为保证分析的系统性，建立复合剥落故障有限元模型的过程中所需的材料属性参数、分析步和场输出参数、接触对参数、约束类型和位移边界条件均与第2章保持一致。

复合故障有限元模型中的摆线针轮及针齿壳针齿区域均存在剥落故障，为保证有限元分析的顺利和兼顾故障零件网格畸变的影响，故障摆线针轮和故障

针齿壳的网格划分需更加精细。为获得稳定的网格质量和更优的求解精度，针齿壳针齿区域网格单元形状选为六面体，除了针齿壳之外的其他零件仍然采用四面体形状的网格单元，并将几何阶次设置为线性。结果显示，整个系统共划分出 231142 个网格单元和 53332 个节点；摆线针轮划分出 55965 个网格单元和 12374 个节点；针齿壳划分出 14419 个网格单元，节点总数 6053。划分网格后的故障针齿壳、故障摆线针轮如图 3-2 所示。




图 3-2 故障模型网格划分图

3.4 仿真结果分析

模拟复合剥落故障的过程仍然使用显式动力学法进行仿真。通过对比分析无故障、单一剥落故障和复合剥落故障状态下的摆线针轮传动系统仿真结果，得出不同状态下的振动特性规律。为了模拟真实采集振动信号的实验条件，在本章中将振动信号测量节点仍定位于针齿壳上的任意位置。

3.4.1 Mises 应力分析

针对系统存在复合剥落故障、单剥落故障和无故障三种工况，分别对摆线针轮和针齿壳提取 Mises 应力：

(1) 如图 3-3 所示，在摆线针轮绕着针齿壳的针齿中心旋转时，系统中剥落故障数量越多，摆线针轮所受的 Mises 应力越大。单一剥落故障的结果是由于摆线针轮的啮合区域缺少一个完整的啮合轮齿。而复合剥落故障的结果是因为摆线针轮和针齿壳的啮合区域都存在不完整的轮齿。在相互啮合的过程中，这两种情况下都会有剥落故障引起的冲击区域存在。因此，复合剥落故障状态下

的摆线针轮受到的 Mises 应力相比其他两种状态更大，但与单一剥落故障情况相比，Mises 应力的增加并不明显。






图 3-3 摆线针轮应力云图

(2) 如图 3-4 所示，在摆线针轮传动系统中，当针齿壳承受转速和径向载荷时，在三种不同状态下，Mises 应力并没有明显的差异。这是因为有限元模型构建时构造的剥落故障体积较小、针齿壳内部存在一定厚度，以及轮齿间存在啮合阻尼，因此受到振动冲击的影响有限。因此，仅通过针齿壳上的 Mises 应力数值无法准确判断摆线针轮传动系统的工作状态。





(c)无剥落故障针齿壳应力云图


图 3-4 针齿壳应力云图

综上所述：分析对象选作摆线针轮，系统存在复合剥落故障或单剥落故障时，摆线针轮所受的 Mises 应力值相差不大，无法作为参考标准判断系统内部故障程度是否加深；但二者相较于无故障摆线针轮所受到的 Mises 应力值是明显的增大了，可作为初步判断摆线针轮传动系统内部是否产生故障的依据；由于所选的分析对象是针齿壳，在仿真模型中剥落故障体积较小且针齿壳内壁较厚，因此在系统存在复合剥落故障、单一剥落故障和无故障三种状态下，针齿壳所受的 Mises 应力变化不显著。因此，针对针齿壳的 Mises 应力值不适合用来判断摆线针轮传动系统是否存在故障。


3.4.2 振动特性分析

针对系统存在复合剥落故障、单剥落故障和无故障三种工况，分别对摆线轮和针齿壳提取加速度：


(1) 如图 3-5 所示，当摆线针轮传动系统存在剥落故障时，摆线针轮的加速度值比无故障状态下的摆线针轮加速度值大一个数量级。此外，在系统存在复合剥落故障时，加速度值明显高于系统仅存在单一剥落故障时的加速度值。这表明，在摆线针轮传动系统发生剥落故障后，振动信号会比无故障状态下更加激烈。另外，随着故障数量的增加，振动冲击也会更加明显。



(a)复合剥落故障摆线针轮加速度云图




(b)单剥落故障摆线针轮加速度云图




(c)无故障摆线轮加速度云图

图 3-5 摆线针轮加速度云图


(2) 如图 3-6 所示，系统存在剥落故障时针齿壳上的加速度值比系统无故障时针齿壳上的加速度值大一个数量级；系统存在复合剥落故障与存在单剥落故障比较，自身存在剥落故障的针齿壳产生的加速度值也要远远大于自身完好的针齿壳产生的加速度值。反映出当摆线针轮出现剥落故障时，针齿壳受到的振动冲击比正常情况下更为强烈。而当针齿壳本身也存在剥落故障时，其加速度值的增加幅度明显提高，进一步加剧了系统的振动状态。



(a)复合剥落故障针齿壳加速度云图



(b)单剥落故障针齿壳加速度云图




(c)无故障针齿壳加速度云图


图 3-6 针齿壳加速度云图

若要获得更精确的振动频率结构以及幅值变化，时域信号图谱有较大缺陷，无法满足要求，本章直接分析频域信图谱得出的结果。在仿真过程中，选择针


齿壳上任意一点作为观测点，标记为点 A'。针对三种不同状态，分别采集点 A' 沿着 x 方向的频域信号曲线。



(a)复合故障振动信号频域图谱



(b)单故障振动信号频域图谱



(c)无故障振动信号频域图谱

图 3-7 振动信号频域图谱对比图

如图3-7所示，系统发生剥落故障时，啮合频率附近产生大量的边带，根据第二章的仿真结果得出的结论，剥落故障将通过周期性冲击序列对无故障轮齿间的啮合引起的振动进行调制，在调制作用下，频率出现偏移产生额外成分，形成边带。

对比图 a、图 b 可知，当系统中出现复合剥落故障时，啮合频率相邻边带间的间隔约为 1454HZ；当系统中仅存在单剥落故障时，啮合频率相邻边带间隔约为 793HZ。通过横向数值对比，系统出现复合剥落故障时，相邻边带间隔数值大小约是单剥落故障情况下的 1.8 倍。除此之外，通过观察峰值间距可知当系统出现复合剥落故障时，啮合频率周期比单剥落故障状况下长；通过纵向数值对比，系统中出现复合剥落故障时，振动响应信息的幅值峰值约比单剥落故障情况大 1 倍。

综上所述，当摆线针轮传动系统产生剥落故障时，啮合频率的周期、幅值均比无故障状态下的数值大。随着系统中剥落故障数量增加，啮合频率周期延长，相邻边带间隔频率值和幅值峰值呈倍数增长。基于频域图谱，将多种振动响应信息综合分析，为摆线轮传动系统的故障监测提供更加可靠、全面的判断依据。

3.5 本章小结

本章利用有限元方法建立了包含复合剥落故障的摆线针轮传动系统模型，并进行了仿真分析。通过对不同状态下云图和频域图谱中的振动响应信息进行分析，总结了摆线针轮传动系统在故障振动特性方面的规律。这些规律为摆线针轮传动系统的故障监测提供了有效依据。总结如下：

(1) 以产生剥落故障的摆线针轮和针齿壳为研究对象，对比分析三种不同故障工况下的 Mises 应力云图，得出：摆线针轮传动系统由无故障演变到单剥落故障，再演变到复合剥落故障的过程中，故障摆线针轮上所受的 Mises 应力值不断增大。针齿壳由于故障体积微小以及内壁较厚，其所受的 Mises 应力值大小受剥落故障的影响较小，无法作为判断系统是否产生故障的依据。在真实的检测环境中，加速度传感器无法直接定位到摆线针轮上测量振动信号，仅通过仿真手段进行故障监测缺少实验论证依据，因此 Mises 应力值指标不适宜作为摆线针轮传动系统故障监测依据。

(2) 以产生剥落故障的摆线针轮和针齿壳为研究对象，对比分析三种不同故障工况下的加速度云图，得出：无论是故障摆线针轮还是针齿壳，随着系统故障演变程度加深，故障数量不断增多，二者的加速度值也会显著增大，剥落故障对加速度值的影响效果显著。因此，通过观察加速度云图中数值的大小，可以初步判断系统内是否存在故障。

(3) 以针齿壳外壳任意位置为监测点，对比分析三种不同故障工况下的频域图谱，得出当摆线针轮传动系统发生剥落故障时，摆线针轮与针齿之间的啮合频率周围会出现许多额外的频率成分，这些频率成分是由剥落故障引起的周期性冲击序列产生的振动调制效应所形成的。由单剥落故障到复合剥落故障的演变过程中，故障数量增加，啮合周期增长、相邻边带间的间隔频率和振动响应信息的幅值峰值均呈倍数增大。综合各类从频域图谱中得到的振动响应信息用于判断系统是否产生故障将更加准确可靠。

第 4 章 摆线针轮传动系统剥落故障振动特性实验

4.1 本章引言

振动信号是摆线针轮传动系统故障监测的载体，当系统中的零件出现故障时，其振动信号的频谱特征也会发生相应变化。尽管国内外学者已经对行星轮系的振动响应特性展开了大量的实验研究^[75-80]，但针对系统产生剥落故障后的振动特性研究还较少涉足。为验证有限元仿真结果的准确性，搭建了摆线针轮传动系统性能检测实验台，进行了摆线针轮传动系统剥落故障振动特性的验证实验，通过对比实验采集和仿真得出的振动信号中的故障特征，验证有限元分析结果的正确性。

4.2 摆线针轮传动系统性能检测实验台及实验条件

如图 4-1 所示，摆线针轮传动系统性能检测实验台（LY-XBRV-04）的组成部分包括平台底板、驱动电机、负载电机、转速转矩测试装置、编码器、滑轨装置和系统控制柜。其中，电机作为输入端和输出端，通过联轴器与待测摆线针轮传动系统连接。左侧电机作为输入电机，用于驱动存在剥落故障的摆线针轮传动系统以及无故障的摆线针轮传动系统旋转；右侧电机用于施加负载。控制柜系统用于控制主动电机的转速，并调节负载电机的加载力矩。实验台的具体使用条件及其配件参数见表 4-1。



图 4-1 摆线针轮传动系统性能检测实验台

表 4-1 实验台基本参数

参数	使用条件	平台底座(mm)	驱动系统	负载电机
环境温度	-10°~+50°	—	—	—
电源	380V±10%	—	—	—
材质	—	钢	—	—
尺寸	—	1800 * 600 * 100	—	—
伺服电机	—	—	台达	台达
额定电压	—	—	220V	220V
额定功率	—	—	750W	750W
额定转速	—	—	300rpm	300rpm
额定扭矩	—	—	239N · m	239N · m

实验过程中采用的无故障摆线针轮传动系统、剥落故障摆线针轮传动系统基础参数与表 2-1 中参数一致。摆线针轮传动系统性能检测实验台振动信号采集点位置如图 4-2 所示。考虑实验台测量的实际条件以及最大程度的接近振动源，将测点位置选在摆线针轮传动系统外壳框架上。实验台采集系统为 HD9200 多通道数据采集系统，相关参数见表 4-2；加速度传感为 IEPE 三向压电式加速度传感器，相关参数见表 4-3。




图 4-2 摆线针轮传动系统性能检测实验台简图

表 4-2 HD9200 多通道数据采集系统相关参数

参数	HD9200 多通道数据采集系统
工作电源	AC100—240V
输入通道	16 通道 AI
输入耦合方式	AC-DC
采样精度	16bit 同步采样
采样频率	Max 102.4KS/s
采样点数	Max250K
信噪比	96dB


表 4-3 三向压电式加速度传感器相关参数

参数	三向压电式加速度传感器
灵敏度	100mV/g
频率响应 ($\pm 1\text{dB}$)	0.5Hz~5KHz
工作电流	2~10mA
最大输出信号	$\pm 6\text{V}$
噪声	约 50 μV
重量	54g
输出方式	L5 同轴低噪音电缆


设定驱动电机输入转速为 500rpm、升降速率为 300rpm/s、负载扭矩为 60Nm、采点数为 32K、采点频率为 15K 后启动实验台开展实验。

4.3 实验结果分析

由针齿壳外框架上的三向加速度传感器 X 方向测得的振动信号频域曲线如图 4-3 所示。据图 a 所示，图中显示出两个明显的波峰，表明由剥落故障引起的振动冲击明显，且波峰附近存在大量由剥落故障引起的调制作用形成的边带。实验结果显示的特征频率的幅值较小，因为系统内植入的剥落故障体积小，且轮齿间存在啮合阻尼，致使振动激烈程度也较小。据图 b 所示，无故障状态下系统的振动冲击周期性不明显，且频率幅值相比存在故障状态下的幅值更小。



(a)存在剥落故障的实验频域图



(b)无故障的实验频域图

图 4-3 实验频域曲线图

4.4 本章小结

本章根据仿真结果的论证需要搭建了摆线针轮传动系统性能检测实验台，并进行了无故障摆线针轮传动系统振动信号采集实验、存在剥落故障的摆线针轮传动系统振动信号采集实验，根据实验采得的振动信号及相应频谱图特征，可得：

(1) 综合由实验采集的振动信号绘制成的频域曲线可知，当摆线针轮传动系统内部出现故障，频谱图会产生明显的波峰，波峰附近会产生密集的边带，啮合冲击周期延长。随着故障数量增多，由频谱图反映出的故障特征应更加明显。实验获得的系统故障振动频率特征与有限元仿真结果存在相似性，验证了存在剥落故障的有限元模型的正确性及仿真分析的可靠性。

(2) 实验采集的振动信号除了可根据频率结构、频率特征验证有限元仿真的可靠性，还可为下一章节中利用基于深度学习手段的神经网络模型处理振动信号提供数据来源。

第 5 章 基于深度学习的摆线针轮传动系统的故障监测

5.1 本章引言

为了解决大多数深度学习模型在决策的过程中缺乏透明性和解释能力，使其在实际应用中不被接受和信任的问题，本章引入一种注意力机制。为了验证传统的摆线针轮传动系统故障监测模型与引入注意力机制的模型后的区别，设计了两组实验：第一组实验先对原始数据使用了小波降噪后在输入到 LSTM 网络模型中；第二组则是直接将原始数据输入到已经被注意力机制优化后的 LSTM 网络中。对比使用传统 CNN、LSTM、小波降噪结合 LSTM、注意力机制结合 LSTM 的神经网络处理实验采集的振动信号的效果，再对比分析不同神经网络处理无噪声和有噪声环境的振动信号的效果，提出性能最佳的神经网络模型用于摆线针轮传动系统的故障监测，提高系统故障监测准确率。

5.2 基于深度学习的理论基础

5.2.1 小波降噪

机械设备在运行过程产生的故障会导致机械振动信号呈现非平稳的特征，通过获取信号在时域和频域上的信息，可以定位故障出现的位置^[81]。传统的傅里叶变换仅提供信号的频率成分，无法反映频率随时间变化的过程，为解决这一问题，短时傅立叶变换应运而生，该方法假设信号在短时间内是稳定的，且其中包含的频率是固定不变的，用一个连续且可平移的窗函数去截取，并在该时间段内用傅立叶变换处理原始信号。如果选择较窄的窗口，可以获得高时间分辨率但频率分辨率较低，相反选择较宽的窗口则会导致较低的时间分辨率。在同一次短时傅立叶变换中，已经选择的窗口是固定的，这将使得不能同时获得较好的时间和频率分辨率。

小波变化是用小波替代短时傅里叶变换的窗函数，小波可以在时间轴上进行自由的平移和缩放，它是一种小区域、长度有限、均值为 0 的波形。对于任一连续函数 $f(x)$ ，其连续小波变换见公式 (5-1)：

$$W_f(a, b) = |a|^{-1/2} \int_R f(t) \bar{\psi} \left[\frac{t-b}{a} \right] dt \quad (5-1)$$

其中， a 代表尺度因子， b 代表平移量， $\psi(t)$ 为一个平方可积函数。若 $\psi(t)$

满足公式，见公式（5-2），则称 $\psi(t)$ 为一个基本小波（小波母函数）。

$$C_\psi = \int_R \frac{|\psi(\omega)|^2}{\omega} d\omega < \infty \quad (5-2)$$

将 $\psi(t)$ 进行伸缩和平移，见公式（5-1）至（5-3）：

$$\psi_{a,b}(t) = |a|^{-1/2} \psi\left[\frac{(t-b)}{a}\right] \quad (5-3)$$

$$a = a_0^j, b = a_0^{-j/2} \psi[a_0^{-j}(t - kb_0)] \quad (5-4)$$

$\psi_{a,b}(t)$ 称为小波基函数，其中 $a, b \in R$ ，且 $a \neq 0$ 。连续时间小波的表达式子极为复杂同时计算量也很大，一般会先进行见公式（5-1）至（5-4）的离散化处理后（其中 j, k 为整数）再使用计算机计算，此时 $\psi_{a,b}(t)$ 的表达式见公式（5-5）。在实际应用中，离散二进小波使用较为广泛，即令 $a_0 = 2, b_0 = 1$ ，则公式（5-4）变为公式见（5-6）。

$$\psi_{j,k}(x) = a_0^{-j/2} \psi[a_0^{-j}(t - kb_0)] \quad (5-5)$$

$$\psi_{j,k}(x) = 2^{-j/2} \psi[2^{-j}(t - k)] \quad (5-6)$$

公式（5-1）至（5-6）对应的离散小波变换（DWT）见公式（5-7）：

$$W(j, k) = 2^{j/2} \int_R f(t) \bar{\psi}[2^{-j/2}(t - k)] dt \quad (5-7)$$

为提高计算效率，研究者在离散小波变换的基础上推出了快速小波变换方法。该方法基于离散小波变换，借鉴了快速傅立叶变换算法(FFT)的思想，通过矩阵运算和递归操作来加速小波变换过程。此外，快速小波变换能够更精确地还原原始信号，同时不会引入额外的噪声并且 FWT 的小波基在频域能量均匀分布，提供更多连续的系数，捕捉信号细节更准确，具有更好的滤波和去噪效果。FWT 可以分解信号为低频部分和高频部分，然后对每个部分继续进行递归分解，直到达到最小的尺度。假设将原始信号表示为向量，见公式（5-8）。

$$f = [f_0, f_1, f_2, \dots, f_{N-1}] \quad (5-8)$$

其中 N 表示信号的长度，那么快速小波变换（FWT）的递归公式可以定义为公式见（5-9）：

$$c = M \cdot f \quad (5-9)$$

其中， M 由公式见（5-10）计算得到， $M_{LL}, M_{LH}, M_{HL}, M_{HH}$ 是用于将输入信号分解为低频和高频系数的变换矩阵，见公式（5-10）。

$$M = \begin{bmatrix} M_{LL} & M_{LH} \\ M_{HL} & M_{HH} \end{bmatrix} \quad (5-10)$$

经过一次变换后，可以将原始信号分解为四个部分的系数，其中， c_{LL} 为低频部分的系数； c_{LH} 为高频部分的系数； c_{HL} 为垂直方向高频部分的系数； c_{HH} 为对角线方向高频部分的系数。

递归过程中，将信号分成两个部分，并分别对这两部分进行快速小波变换，直到处理到长度为2的小块。最后可以通过公式，见（5-11）的逆变换来重构原始信号：

$$f = M^{-1}c \quad (5-11)$$

小波降噪的原理基于小波分析的特性，其核心在于通过对信号进行小波分解和重构来实现噪声的去除。该方法首先通过快速小波变换对原始信号进行处理，在信号进行小波分解时，将其分解为不同频率范围的子信号，包括近似系数和细节系数。在这些系数中，近似系数反映了信号的低频信息，其类似于信号的平滑部分，细节系数表示信号的高频信息，类似于信号的细节或边缘部分。

通常情况下，噪声往往存在于信号的高频部分，而信号中有价值的信息通常更倾向于集中在低频部分^[82]。因此，小波降噪的关键步骤就是对高频系数进行阈值处理，以去除噪声。阈值处理基于以下原理：噪声系数通常分布在接近于零的范围内，而信号系数通常具有较大的幅值。根据这一原理，通过设定一个合适的阈值，可以将小于该阈值的系数置为零，以达到去除噪声的效果。而信号系数则能够保留较大的幅值，使得信号的有用信息能够得到保留和恢复。这样的阈值处理方法有助于提高信号的清晰度和准确性。针对设置的不同阈值，小波降噪一般分为硬阈值和软阈值。硬阈值将小于设定阈值的系数清零，而软阈值则对系数进行平滑处理，使得系数逐渐趋向于零。

小波软阈值的计算过程见公式（5-12）：

$$W_{soft} = \text{sign}(W) * \max(|W| - t, 0) \quad (5-12)$$

其中， W 是小波系数， t 是阈值，小波硬阈值的计算过程见公式（5-13）：

$$W_{hard} = W * (|W| \geq t) \quad (5-13)$$

小波软阈值和硬阈值是常用的小波阈值降噪方法。软阈值通过缩减小波系数，保留较小的系数但减小幅度，以保留信号细节特征为重点。相比之下，硬阈值直接将小于阈值的系数置为零，较小的系数被完全去除。软阈值处理后的信号较平滑，有助于减少噪声干扰，但在高噪声数据中可能无法完全去除噪声；

硬阈值可以有效去除噪声，但可能损失信号细节并引入伪像。软阈值适用于保留细节特征的场景，而硬阈值适用于噪声完全去除的场景。同时，需要调整适当的阈值大小以获得最佳的降噪效果。

经过小波阈值降噪后，需要对处理后的系数进行小波重构，以重建去噪后的信号。小波重构是通过将经过阈值处理后的近似系数和详细系数进行逆小波变换来实现的。这个过程可以使得信号恢复到原始的时间域表示。通过逆小波变换，重构后的系数会合并起来，生成降噪后的信号。

5.2.2 LSTM 神经网络架构

LSTM 是一种循环神经网络（RNN）的变体，专门用于处理序列数据和时间序列数据。相较于传统的 RNN，LSTM 具备更强的记忆能力，能够更好地捕捉到长时间依赖关系中的有用信息。LSTM 的核心在于记忆单元，又称为细胞状态，细胞状态承担着存储输入序列信息的重要职责，并在需要时更新并传递该信息至后续时间步。此外，LSTM 利用门控机制来管理信息的传递，其中包括输入门、遗忘门和输出门。这些门控单元可以调节信息的流动，从而提高模型对序列数据的建模能力，此外，这些门还决定了哪些信息应被纳入记忆、遗忘或输出。LSTM 在处理序列数据时非常实用，特别是存在长时依赖关系或需要捕捉到重要上下文信息的情况下，输入门(Input Gate)对当前时刻的输入信息进行加权，决定了新信息被纳入当前记忆的程度；遗忘门(Forget Gate)控制着历史记忆的权重，决定了应该遗忘哪些过去的记忆。记忆单元(Cell State)用于存储当前时刻的记忆信息，并将其传递至下一时刻。输出门(Output Gate)决定了当前时刻记忆信息的输出，即确定了哪些内容应该在当前记忆中被传递给外部。

LSTM 单元的操作流程如下：首先，根据当前输入和上一个时刻的输出计算输入门的值；其次，根据当前输入和上一个时刻的输出计算遗忘门的值；然后在输入门和遗忘门的调节下，更新当前时刻的记忆单元状态；接着根据当前输入和上一个时刻的输出计算输出门的值；最后通过输出门对当前记忆单元状态进行控制输出，从而得到当前时刻的输出。

整个 LSTM 网络由多个分支 LSTM 单元组成，其结构如图 5-1 所示，每个单元的输出作为下一个单元的输入^[83]。通过这种方式，LSTM 神经网络在处理时间序列数据时表现出色，具有优秀的记忆能力，能够有效捕捉序列中的长期依

赖关系。




图 5-1 LSTM 单元关联图

5.2.3 注意力机制

注意力机制最初源自神经机器翻译 (Neural Machine Translation, NMT) 领域,旨在提高神经机器翻译的性能。传统的神经机器翻译模型在每个时间步都只关注源语言的固定部分,而注意力机制允许模型根据源语言不同部分的重要性进行动态调整,从而更好地捕捉源语言和目标语言之间的对应关系。后来,注意力机制逐渐在其他自然语言处理任务中得到应用,如文本摘要、语言生成等,并取得了良好的效果。如今,注意力机制已经成为深度学习领域中被广泛应用的一项关键技术,被用于各种序列数据处理任务,发展出多种改进和变体的注意力机制。

注意力机制是神经网络处理序列数据时的一种机制,可以动态地聚焦于不同位置或部分信息。它通过学习权重或分数来评估不同位置的重要性,并将这些权重应用于序列数据的不同部分。首先,对当前时间步的隐藏状态进行线性变换,得到一个查询向量 Q ,然后对序列中的每个位置的隐藏状态进行线性变换,得到键向量 K 。然后通过计算查询向量 Q 和键向量 K 之间的相似度,生成一个得分矩阵 S 。常用的相似度计算方法包括点积(dot product)、缩放点积(scaled dot product)和双线性(bilinear)等。随后对得分矩阵 S 进行标准化处理,得到注意力权重矩阵 W 。常用的标准化方法是对得分进行 softmax 操作,以确保权重之和为 1,对于序列中的每个位置,将其隐藏状态进行线性变换,得到值向量 V ,最后将权重矩阵 W 与值向量 V 相乘,并对乘积进行求和,得到最终的上下文向量 C 。

注意力机制在序列数据处理中具有许多优点。首先，注意力机制赋予神经网络动态关注序列不同位置的能力，使其能够捕捉到序列中的重要信息。通过计算不同位置的权重或分数，注意力机制指导网络集中注意力在对模型任务有意义的部分，从而提高对关键信息的理解和利用。这种动态关注的机制使得神经网络可以更加灵活地处理序列数据，并有效提升模型性能。相比于传统的固定权重或均匀分配注意力的方法，注意力机制可以根据任务的需要自适应地选择关注的位置，提高模型的性能和泛化能力。此外，注意力机制有助于解决长距离依赖的问题。传统的 RNN 在处理长序列时可能会遇到梯度消失或梯度爆炸的挑战，从而难以有效捕捉到远距离的依赖关系，即当序列长度增加时，传统的 RNN 模型可能会遇到梯度无法正确传播的问题，导致远处的信息无法充分参与当前时刻的计算，这限制了模型在处理长序列数据时的能力，而 LSTM 等改进模型则通过精巧的设计来解决这一问题，更好地捕捉到远距离的依赖关系。注意力机制通过查询和键的相似性计算，可以有效地捕捉到长期依赖关系，提高模型的记忆能力。传统的神经网络是一个黑盒，虽然能够实现良好的分类任务，但是难以解释其原理，但是注意力机制提供了一种机制来解释模型的决策过程，通过可视化注意力权重，可以了解模型在处理序列数据时关注的位置和重要信息，这有助于提高模型的可解释性和可信度。

5.3 实验流程设计

LSTM 数据处理实验的整体流程如图 5-2 所示，包括数据收集、数据预处理、模型训练和模型验证四个主要步骤。整体实验分为两个子实验，在数据预处理步骤中稍有不同，其后的模型训练及验证步骤相同，最后对两个实验的结果进行对比。




图 5-2 LSTM 处理实验数据流程图

实验首先利用第 4 章所示的摆线针轮传动系统性能检测实验台，对系统的故障、正常振动信号进行采集，采样频率设置为 16384，每个样本采样两秒，共收集 300 个样本；构建两个训练集，分别为对原始数据集进行小波降噪的训练集 1，和不进行任何处理的训练集 2；采用两个独立的数据集分别对 LSTM 网络模型进行训练，随后在测试集上评估已训练好的模型性能，并记录准确率。

5.4 基于 CNN 和 LSTM 的摆线针轮传动系统的故障监测

传统结构的 CNN 和 LSTM 架构对数据集进行分类以作为评价标准，首先按照 8: 2 的比例将数据集分为训练集和测试集。其中 CNN 结构如图 5-3 所示，选用“relu”激活函数、“adam”优化器和交叉熵损失函数来计算每次的损失，每层网络结构关键参数见表 5-1。Batch 设置为 32，共训练 10 个 epoch。




图 5-3 CNN 网络结构

表 5-1 CNN 每层网络参数

层数	类别	关键参数	输入大小	输出大小
1	Conv1D	32	$1 \times 16384 \times 1$	$1 \times 16384 \times 32$
2	Conv1D	32	$1 \times 16384 \times 32$	$1 \times 16380 \times 32$
3	Maxpooling	0.2	$1 \times 16380 \times 32$	8190×32
4	Flatten		8190×32	262080
6	Dense	2	262080	2

使用传统 CNN 架构对数据集的训练结果如图 5-4 所示，表 5-2 列出了每个迭代层的训练集和测试集的准确率。根据图表数据显示，CNN 经过几轮训练后在训练集上取得了较高的准确率，但在测试集上的准确率波动较大，这可能意味着存在过拟合现象。最终，在训练集上，CNN 的准确率达到 0.8881，在测试集上为 0.7643，显示出训练集和测试集之间性能差异的问题。表明传统结构的 CNN 在未经调整的情况下用于摆线针轮传动系统的故障监测可能存在问题。




图 5-4 CNN 的准确率随 Epoch 变化情况图

表 5-2 CNN 测试集和训练集的准确率

Epoch	Accuracy	Val_Accuuracy
1	0.4927	0.4562
2	0.5210	0.4776
3	0.6450	0.7228
4	0.7301	0.7607
5	0.6613	0.7657
6	0.6917	0.7400
7	0.7137	0.4369
8	0.7792	0.7650
9	0.7400	0.5327
10	0.8881	0.7643

LSTM 的网络架构如图 5-5 所示，该网络架构选用“adam”优化器、交叉熵损失函数来计算每次的损失，网络的每层参数见表 5-3。Batch 设置为 32，共训练 10 个 epoch。




图 5-5 LSTM 网络架构

表 5-3 LSTM 每层网络参数

层数	类别	关键参数	输入大小	输出大小
1	LSTM	50	1×16384×1	1×16384×1
2	LSTM	50	1×16384×50	1×16384×50
3	Dense	1	1×50	1×2

图 5-6 和表 5-4 为 LSTM 的准确率随 Epoch 的变化情况，由图表可见，LSTM 在训练开始便能达到较高的准确率，尽管准确率整体上有所波动，但最终训练集的准确率达到 87.48%，测试集的准确率达到 79.28%。由此可得，LSTM 网络架构用于摆线针轮传动系统的故障监测要优于传统 CNN 架构。




图 5-6 LSTM 的准确率随 Epoch 变化情况图

表 5-4 LSTM 测试集和训练集的准确率

Epoch	Accuracy	Val_Accuracy
1	0.5397	0.5012
2	0.6398	0.6649
3	0.6893	0.7700
4	0.7187	0.7593
5	0.8302	0.7607
6	0.7340	0.7793
7	0.7705	0.7199
8	0.7177	0.6342
9	0.8137	0.7700
10	0.8748	0.7928

5.5 基于小波降噪和 LSTM 的摆线针轮传动系统的故障监测

在这项验证中，首先需要对采集到的振动信号进行小波去噪处理，本研究采用了小波软阈值降噪方法，选用的小波函数为 Daubechies 小波，阈值采用基于局部方差的自适应阈值，其计算见公式（5-14）：

$$T_i = k \cdot \sqrt{\frac{1}{N} \sum_{j=i-w}^{i+w} (x_j - \mu)^2} \quad (5-14)$$

由图 5-7、图 5-8 可得，经过降噪处理后，噪声信号得到有效减少，信号变得更加平滑，同时也保留了原始信号的重要特征，有利于更好地监测故障特征。




图 5-7 无故障摆线针轮传动系统振动信号与降噪后的信号时域图




图 5-8 含剥落故障的摆线针轮传动系统振动信号与降噪后的信号时域图

将降噪完的信号数据按照 8:2 的比例分为训练集和测试集，接着使用训练集 1 训练构建好的 LSTM 模型，最后输出的准确率图如图 5-9，每个 epoch 对应的准确率见表 5-5。




图 5-9 小波降噪结合 LSTM 的准确率随 Epoch 变化情况图

表 5-5 小波降噪结合 LSTM 测试集和训练集的准确率

Epoch	Accuracy	Val_Accuracy
1	0.3643	0.4729
2	0.5071	0.5129
3	0.4904	0.5686
4	0.5319	0.6314
5	0.6342	0.7493
6	0.6419	0.6918
7	0.7718	0.7358
8	0.8124	0.7681
9	0.8395	0.8196
10	0.8713	0.8342

根据图表显示的训练结果，训练集准确率从初始的 0.3643 逐渐提高，在第 10 个 Epoch 达到了 0.8713，表明模型可以对训练数据进行准确的分类。验证集准确率从初始的 0.4729 也有所提高，在第 10 个 Epoch 达到了 0.8342，表明模型在处理未曾接触过的数据时表现出色，具备较强的泛化能力。然而从第二轮训练开始，训练集的准确率一直高于验证集的准确率，这可能是因为模型在训练数据上过拟合，没有很好地适应未见过的数据。

随着训练的进行，模型的性能逐渐提高，但在第 6 个 Epoch 和第 7 个 Epoch 之间出现了验证集准确率的下降，可能是因为模型在这个阶段发生了过拟合。总体而言，使用小波降噪后的 LSTM 模型在训练集和验证集上均取得了不错的

分类准确率。

5.6 基于注意力机制和 LSTM 的摆线针轮传动系统故障监测

采用注意力机制则无需对原始信号进行降噪和特征提取等预处理，因为注意力机制能够自动过滤掉其中的噪声部分并且提取特征。对图 5-5 所示的 LSTM 网络架构进行修改，在其中引入注意力机制后的网络结果如图 5-10 所示，每层依旧采用表 5-3 中的参数设置。




图 5-10 注意力机制结合 LSTM 的网络架构

使用训练集 2 并训练引入注意力机制的 LSMT 模型，模型在训练集和测试集上的准确率如图 5-11 所示，每个 epoch 对应的准确率见表 5-6。




图 5-11 注意力机制结合 LSTM 的准确率随 Epoch 变化情况图

表 5-6 注意力机制结合 LSTM 测试集和训练集的准确率

Epoch	Accuracy	Val_Accuracy
1	0.4359	0.5354
2	0.4637	0.8563
3	0.5638	0.6314
4	0.6374	0.5937
5	0.7012	0.6782
6	0.7458	0.7369
7	0.7721	0.7924
8	0.8513	0.8142
9	0.8907	0.8549
10	0.9147	0.8792

根据图表给出的数据可得，引入注意力机制后的 LSTM 网络在训练集和验证集上的分类准确率随着训练的迭代，整体呈上升趋势。经过训练，模型在训练集上的准确率从最初的 0.4359 提升到 0.9147，同时在验证集上的准确率也从最初的 0.5354 提升到 0.8792，差距不断缩小，表明模型具有一定的通用性和鲁棒性。

5.7 噪声干扰下的摆线针轮传动系统故障监测

在摆线针轮传动系统的故障监测过程中，噪声干扰问题不可忽视。噪声的来源包括电磁干扰、周围环境的干扰或者是系统内部件运动产生的干扰等。在一个充斥着相当强度且复杂的噪声环境中，传统的故障信号检测技术往往会受到严重影响，减小了故障监测的准确性和可靠性。目前，对于摆线针轮传动系统的故障监测研究主要集中在应用神经网络算法上。然而，在进行机器学习任务时，神经网络模型的性能很大程度上受到所使用训练和测试数据质量的影响。如果测试系统中包含噪声，其会掩盖一部分故障特征，导致神经网络难以捕捉到与故障相关的模式，降低了模型的准确度和可靠性^[84-85]。此外，如果训练数据中包含噪声，而这些噪声并不是测试集或实际使用场景中的特征，神经网络极有可能会学到错误模式，即对噪声本身过拟合，而非学习故障特征，这将很大程度降低模型的泛化能力。因此，含噪声的数据需要更复杂的网络结构或更多的训练数据来学习更具鲁棒性的特征，这大大增加了训练成本和计算资源。综上所述，噪声可以导致原本正常的模式被错误地识别为故障，或者故障模式被疏忽遗漏，这都会影响机械设备故障监测的精确度和可信度^[86-88]。为了解决

测试系统的噪声干扰问题，唐治尧^[89]等人针对强噪声背景下滚动轴承振动信号特征不平稳，引入了门控制方法，最后大幅度提高故障检测准确率；曲铎^[90]提出了一种利用贝叶斯优化 DratNet 进行滚动轴承故障监测的方法，并经过实验证实了该方法的有效性。

为了验证本章所提出的神经网络架构是否能够缓解噪声的影响，在前文所采集到的摆线针轮传动系统的无故障振动信号、故障振动信号中添加了高斯白噪声信号，再使用不同的算法进行分类，以选出分类准确率最高、抗噪声干扰能力最好的神经网络架构。

5.7.1 验证设计

本次验证在实验采集到的摆线针轮传动系统的振动信号中添加高斯白噪声，目的是模拟摆线针轮传动系统在真实工况下各种无法预测的随机干扰，包括传感器噪声、外部环境干扰以及系统内部的摩擦和磨损产生的噪声等，从而提高控制系统的设计精度、故障预测能力和信号处理算法的实用性。将这些随机因素纳入考量范围，可以增强摆线针轮传动系统故障预测的精准性。使用上文提出的神经网络架构对加入噪声后的摆线针轮传动系统的振动信号进行分类，验证提出模型的故障监测能力。

5.7.2 验证过程

在一般的通信系统的工作频率范围内高斯白噪声的功率谱密度服从均匀分布，幅度分布服从高斯分布，且其在任意两个不同时刻上的随机变量之间，不仅是互不相关的，而且还是统计独立的。

分别在 RV 减速器的无故障振动信号和故障振动信号中加入均值为 0，标准差为 1 的高斯白噪声干扰信号，如图 5-12 所示。根据图(a)可得：引入高斯白噪声后，原始无故障信号频谱中较平滑的曲线会变得凹凸不平；根据图(b)可得：引入高斯白噪声后，原始故障信号特征被明显掩盖住。故在以贴近真实监测环境为条件，在实验采集的两种不同状态的振动信号数据中引入高斯白噪声，将加剧神经网络模型处理振动信号的难度。反之，若 CNN、LSTM、小波降噪结合 LSTM、注意力机制结合 LSTM 中的一种神经网络模型在处理含高斯白噪声的实验振动信号数据时取得更高的识别准确率，令其作为摆线针轮传动系统故障监测优化方法将更具有说服力。




图 5-12 加入高斯白噪声的振动信号图

本节的验证只采用上文提出的单一的网络架构进行分类，使用上文提到的传统 CNN 和 LSTM 架构在未添加噪声的原始振动信号进行分类，结果如图 5-13 所示。由图可知，CNN 在训练集上的准确率达到 0.6459，在测试集上为 0.7295；而 LSTM 在训练集上的准确率为 0.8374，在测试集上为 0.7596。




图 5-13 CNN 和 LSTM 在未添加噪声的数据集上的分类结果图

接下来使用相同模型对含噪信号进行分类。使用 CNN 和 LSTM 结构对添加高斯白噪声的振动信号进行分类，结果如图 5-14 所示。由图可知，CNN 在训练集上的准确率为 0.5687，在测试集上为 0.6342；而 LSTM 网络在训练集上的准确率为 0.8114，在测试集上为 0.6951。




图 5-14 CNN 和 LSTM 在添加噪声的数据集上的分类结果图

CNN 和 LSTM 在不添加噪声和添加噪声的测试集上的准确率对比，见表 5-7。由表中信息可知，在添加高斯白噪声后，CNN 和 LSTM 的准确率都大幅度下降。这说明原始的信号被高斯白噪声干扰后影响了神经网络的分类准确率。

表 5-7 CNN、LSTM 验证结果对比

网络架构	未添加噪声数据上的准确率	添加噪声数据集上的准确率
CNN	0.7295	0.6342
LSTM	0.8374	0.6951

为了应对噪声干扰并验证文中提出的神经网络模型对干扰的抗性，采用小波降噪结合 LSTM 模型和注意力机制结合 LSTM 网络模型，分别对添加噪声后的信号进行分类。为验证小波降噪与 LSTM 网络框架的结合效果。第一步需要使用小波降噪对添加噪声后的数据集进行预处理，接着输入到 LSTM 网络中进行分类，验证结果如 5-15 所示，最终该模型花费训练时间 59.654963 秒，在训练集上的准确率达到 0.8596，在测试集上的准确率达到 0.7934。




图 5-15 小波降噪结合 LSTM 网络架构的分类结果图

接下来将验证注意力机制与 LSTM 网络结合的框架。如前文所述，基于注意力机制的结构整合到了 LSTM 网络的框架中，无需预处理，直接将添加了高斯白噪声的 RV 减速器振动信号输入到注意力机制结合 LSTM 网络架构中，验证结果如图 5-16 所示，训练模型的时间为 34.789612 秒，在训练集上的准确率达到 0.8874，在测试集上的准确率达到 0.8557。




图 5-16 注意力机制结合 LSTM 的分类结果图

5.7.3 验证结论

所有神经网络架构验证结果的对比见表 5-8。由表可得，注意力机制结合 LSTM 表现最佳，准确率达到 0.8874；其次是小波降噪结合 LSTM，准确率为 0.8596；第三是普通的 LSTM 模型，准确率为 0.8374；最后是传统 CNN 模型，准确率为 0.7295。验证结果充分证明在无噪声情况下，注意力机制结合 LSTM 的模型在准确率方面优于其他模型。

当考虑添加高斯白噪声后，所有模型的准确率都有所下降，普通 LSTM 模型的准确率降至 0.6951；传统 CNN 模型的准确率降至 0.6342；小波降噪结合 LSTM 表现出了较好的抗噪声能力，准确率为 0.7934；即使在含有噪声的数据集上，注意力机制结合 LSTM 模型仍然表现出了最高的准确率，达到了 0.8557。验证结果证明其抗噪音能力强于其他模型。

从训练时间上看，注意力机制结合 LSTM 模型用时为 34.789612 秒，不仅比小波降噪结合 LSTM 模型的训练时间 59.654963 秒更短；此外在准确率方面，其无论是在有噪声还是无噪声的数据集上都表现得更好。二者均验证了注意力机制结合 LSTM 模型是效率和性能更优的神经网络模型。

综上所述，传统的 LSTM 的鲁棒性不如小波降噪和基于注意力机制的增强模型；单独使用传统 CNN 模型在上述任务中表现最差，尤其在处理含有噪声的数据时，准确率很不理想；小波降噪结合 LSTM 模型在处理噪声数据时表现出不错的性能，但其训练时间较长；注意力机制结合 LSTM 模型无论是在无噪声数据上还是在有噪声的数据上都表现出了较高的准确率，且训练时间最短，这使其成为考虑效率和性能因素的理想神经网络模型。上述对比验证为摆线针轮传动系统的故障状态监测提供了有效参考。

表 5-8 模型效果对比

网络架构	无噪声数据集准确率	有噪声数据集准确率	训练时间
CNN	0.7295	0.6342	—
LSTM	0.8374	0.6951	—
小波降噪结合 LSTM	0.8596	0.7934	59.654963
注意力机制结合 LSTM	0.8874	0.8557	34.789612

5.8 本章小结

引入注意力机制的 LSTM 网络在训练和验证阶段取得了更高的准确率，其使模型能够更专注于输入序列中的关键信息。此外，注意力机制使模型根据输入序列中不同位置的重要性进行加权处理，增强了模型的特征的提取能力。如此，模型可以自动学习在输入序列中找到关键的特征，无需事先进行人工选择。复杂的振动信号数据存在着大量的冗余、噪声信息，注意力机制的引入使得神经网络模型能够自动地忽略无关信息，并将重点放在对分类任务有用的特征上。训练集 2 并没有经过降噪等预处理操作，通过引入注意力机制，模型仍然能够取得较好的分类效果，表明注意力机制能够自动地对原始特征进行降噪和特征提取，在某种程度上取代了传统的预处理操作，简化了模型构建的过程。即使考虑外界环境产生的干扰噪声，注意力机制结合 LSTM 的网络架构依然表现优良，其在处理存在干扰噪声的数据时取得了较高的准确率，且训练时间相比于其他网络架构也最短，使其可作为摆线针轮传动系统在考虑效率和性能因素时的故障监测理想模型。

综上所述，引入注意力机制后，LSTM 网络在分类任务中展现出更出色的性能，该机制使得网络能够自动聚焦于输入序列中的重要信息，提升了模型分类的准确性。此外，注意力机制还具备特征提取和降噪能力，使模型能够更好

地利用原始特征进行分类，简化了模型构建的过程，这些优势均使得注意力机制在数据分类任务中具有广泛的应用潜力。

第 6 章 总结与展望

6.1 研究总结

本文以剥落故障摆线针轮传动系统的振动特性为研究目标，以存在剥落故障的摆线针轮、针齿壳为研究对象，建立了三种不同故障情况的摆线针轮传动系统有限元模型，分析了不同故障状态下系统的振动特性，并且通过搭建摆线针轮传动系统性能检测实验台进行了相关实验验证，证明了仿真结果的正确性和可靠性。提出了以有限元分析为基础、验证实验为保障，并基于深度学习理论，选出注意力机制结合 LSTM 神经网络架构处理振动信号的摆线针轮传动系统故障监测方法。研究主要成果及结论如下：

(1) 根据摆线针轮传动系统中不同零件间的运动关系，调整连接关系参数、接触对参数和位移边界条件参数，并针对故障零件独立划分网格，最终建立可以稳定运行的摆线针轮传动系统有限元模型。

(2) 以摆线针轮、针齿壳为研究对象，以无故障、单剥落故障、复合剥落故障为研究条件，以 Mises 应力云图、加速度云图、时频信号图谱为分析依据展开摆线针轮传动系统故障振动特性研究，得出：由于有限元软件构造的剥落故障体积微小以及针齿壳内壁较厚，Mises 应力值指标不适宜作为故障监测的依据；摆线针轮和针齿壳的加速度幅值受到剥落故障的影响显著，二者的加速度幅值会随着剥落故障演变程度加深、数量增多而增大；当系统产生剥落故障时，故障轮齿啮合频率周围会因振动冲击的调制作用形成边带，且随着剥落故障数量增多，相邻边带间的间隔频率、啮合周期及振幅峰值都不断增大。故可根据加速度幅值大小初步判断系统内部是否产生故障，在根据时频信号图谱中啮合冲击周期的长短、相邻边带的间隔频率以及幅值峰值大小对系统内部是否产生故障做进一步精确判断。

(3) 搭建摆线针轮传动系统性能检测实验台，分别开展了摆线针轮传动系统存在剥落故障和无故障情况下的振动信号采集实验。研究结果显示，实验得到的特征频率图谱与仿真结果较一致，验证了仿真结果的准确性和可靠性。

(4) 基于深度学习理论，选用并设计不同的神经网络架构处理实验采集的振动信号。对比传统 CNN 架构、LSTM 架构、小波降噪结合 LSTM 架构、注意力

机制结合 LSTM 架构识别系统故障的准确率、抗外界噪声的干扰能力，得出：注意力机制结合 LSTM 的网络架构能够自动识别输入序列中的有效信息，并利用其原始特征进行分类，减少了人为预处理的工作；引入注意力机制后，LSTM 神经网络架构在处理存在噪声干扰的振动信息数据时获得了较高的准确率且仍然保持了训练时间短的优势。故选用注意力机制结合 LSTM 神经网络能有效提高摆线针轮传动系统故障监测的准确率。

6.2 研究工作展望

本课题主要研究摆线针轮传动系统剥落故障振动特性，经过有限元仿真分析、实验验证以及神经网络处理振动信号等工作，取得了一定的研究成果。由于研究时间、个人精力以及科研水平等因素的限制，研究过程中仍然存在不足和缺陷，以下列整理的不足之处可为后续研究人员提供参考：

(1) 考虑到构建有限模型时设置摆线针轮传动系统零件间的约束参数、接触参数的工作量较大，本文建立的有限元模型不包含滚子轴承。为贴近摆线针轮传动系统的实际制造标准，应建立基于轴承特性的摆线针轮传动系统模型。摆线针轮传动系统在长时间高负荷运转情况下，滚子轴承外部会受到较大冲击载荷，很容易在轴承外圈表面产生故障，如能将轴承故障考虑在内，摆线针轮传动系统故障振动特性研究成果将更加丰富、更具有权威性。

(2) 本课题仅以齿面剥落为故障条件。对于裂纹等常见齿轮故障的研究并未涉足。若要使摆线针轮传动系统故障监测的方法更加健全，仍需完善其他故障种类对系统振动特性影响的研究。

参考文献

- [1] 张珂铭. 齿面剥落行星轮系故障激励与动态响应特性研究[D]. 重庆大学,2019.
- [2] RG Parker. A physical explanation for the effectiveness of planet phasing to suppress planetary gear vibration. *Journal of Sound & Vibration*,2000,236(4):561-573.
- [3] A Kahraman. Planetary gear train dynamics[J].*Journal of Mechanical Design*,1994,116(3):713-720.
- [4] A Kahraman. Free torsional vibration characteristics of compound planetary gear sets. *Mechanism & Machine Theory*,2001,36(8):953-971.
- [5] Lin J, Parker RG. Planetary gear parametric instability caused by mesh stiffness variation[J].*Journal of Sound and Vibration*,2002,249(1):129-145.
- [6] 孙涛,沈允文,孙智民,等.行星齿轮传动非线性动力学模型与方程[J].*机械工程学报*,2002,(03):6-10.
- [7] Lin J, Parker RG. Analytical characterization of the unique properties of planetary gear free vibration. *Journal of Vibration & Acoustics*,1999,121(3).
- [8] Cooley CG, Parker RG, Vibration Properties of High-Speed Planetary Gears With Gyroscopic Effects, *Journal of Vibration & Acoustics*,2012,134(6):061014.
- [9] 冯志鹏,褚福磊.行星齿轮箱齿轮分布式故障振动频谱特征[J].*中国电机工程学报*,2013,33(2):118-125.
- [10] 冯志鹏,赵镭镭,褚福磊.行星齿轮箱齿轮局部故障振动频谱特征[J].*中国电机工程学报*,2013,33(5):119-127.
- [11] B. Boguski, A. Kahraman, T. Nishino. A new method to measure planet load sharing and sun gear radial orbit of planetary gear sets[C].*Proceedings of the ASME 2011 International Design Engineering Technical Conferences & Computers and Information in Engineering Conference*, Washington DC, USA,2011.
- [12] H. Teruaki, T. Yoshio, N. Kazuteru. Dynamic behavior of planetary gear em dash 7th report, influence of the thickness of the ring gear[J].*Bulletin of the*

- JSME,22(170)(1979):1142-1149.
- [13] H Endo, RB Randall, C Gosselin. Differential diagnosis of spall vs. cracks in the gear tooth fillet region: Experimental validation, Mechanical Systems & Signal Processing,2009,23(3):636-651.
- [14] Xue Y, Li Z, Jia L, et al. Semi-supervised gear fault diagnosis using raw vibration signal based on deep learning[J].Chinese Journal of Aeronautics,2020,167(02):33-41.
- [15] Weber C. The deformation of loaded gears and the effect on their load carrying capacity[J].Sponsored Research (Germany), British Dept. of Scientific and Industrial Research, Report,1949(3).
- [16] Hou Z, Yang S. Remote performance evaluation, life prediction and fault diagnosis of RV reducer for industrial robot[J].Journal of Physics: Conference Series,2020,1676(1):012212(6pp).
- [17] 朱良斌.基于多齿啮合动态分析的摆线轮接触疲劳研究[D].昆明理工大学, 2021.
- [18] 汪久根,柯梁亮.RV 减速器振动特性分析[J].振动与冲击,2020,39(13):57-63.
- [19] 谭晶,刘海洋,王松,黄迪山.RV-C 型减速器扭振测试与分析[J].计量与测试技术,2021,48(10):42-44+48.
- [20] PD Mcfadden, JD Smith, An Explanation for the Asymmetry of the Modulation Sidebands about the Tooth Meshing Frequency in Epicyclic Gear Vibration. ARCHIVE Proceedings of the Institution of Mechanical Engineers Part C Journal of Mechanical Engineering Science,1985,199(13):65-70.
- [21] Feng Z, Zuo M J.Vibration signal models for fault diagnosis of planetary gearboxes. Journal of Sound and Vibration,2012,331(22):4919-4939.
- [22] Feng Z, Zuo M J, Qu J, et al. Joint amplitude and frequency demodulation analysis basedon local mean decomposition for fault diagnosis of planetary gearboxes[J]. Mechanical Systems and Signal Processing,2013,40(1):56-75.
- [23] Feng Z, Zuo M J.Fault diagnosis of planetary gearboxes via torsional vibration signal analysis[J]. Mechanical Systems and Signal Processing,2013,36(2):401-421.
- [24] PD Mcfadden, JD Smith, An Explanation for the Asymmetry of the Modulation Sidebands about the Tooth Meshing Frequency in Epicyclic Gear Vibration.

- ARCHIVE Proceedings of the Institution of Mechanical Engineers Part C Journal of Mechanical Engineering Science,1985,199(13):65-70.
- [25] 雷亚国,罗希,刘宗尧,等.行星轮系动力学新模型及其故障响应特性研究[J].机械工程学报,2016,52(13):111-122.
- [26] 雷亚国,汤伟,孔德同,等.基于传动机理分析的行星齿轮箱振动信号仿真及其故障诊断[J].机械工程学报,2014,50(17):61-68.
- [27] 李国彦.复合行星齿轮传动系统损伤建模与故障诊断技术研究[D].山东大学,2017.
- [28] Blunt DM, Keller JA. Detection of a fatigue crack in a UH-60A planet gear carrier using vibration analysis. *Mech Syst Signal Process*,2006,20:2095–111.
- [29] Lei Y, Kong D, Lin J, Zuo MJ. Fault detection of planetary gearboxes using new diagnostic parameters. *Meas Sci Technol*,2012;23(5):1–10.
- [30] Liu J, Wang W, Golnaraghi F. An extended wavelet spectrum for bearing fault diagnostics. *IEEE T Instrum Meas*,2008,57(12):2801–2812.
- [31] Jardine AKS, Lin D, Banjevic D. A review on machinery diagnostics and prognostics implementing condition-based maintenance. *Mech Syst Signal Process*,2006,20(7):1483–1510.
- [32] Y Lei, J Lin, MJ Zuo, Z He. Condition monitoring and fault diagnosis of planetary gearboxes. *Measurement*,2014,48(1):292-305.
- [33] Bntoni J. Blind separation of vibration components: principles and demonstrations. *Mech Syst Signal Process*,2005,19:1166–1180.
- [34] Zhang B, Khawaja T, Patrick R, et al. A novel blind deconvolution de-noising scheme in failure prognosis. *Trans Inst Meas Control*,2010,32(1):3–30.
- [35] M Inalpolat, A Kahraman, A theoretical and experimental investigation of modulation sidebands of planetary gear sets. *Journal of Sound & Vibration*,2009,323(3):677-696.
- [36] Feng Z, Zuo M J. Vibration signal models for fault diagnosis of planetary gearboxes. *Journal of Sound and Vibration*,2012,331(22):4919-4939.
- [37] M Inalpolat, A Kahraman, A dynamic model to predict modulation sidebands of a planetary gear set having manufacturing errors. *Journal of Sound & Vibration*,2010,329(4):371-393.
- [38] 何卫东.机器人用高精度 RV 传动的研究[D].哈尔滨工业大学,1999.

-
- [39] 张大卫,王刚,黄田等.RV 减速机动力学建模与结构参数分析[J].机械工程学报,2001,37(1):69-74.
 - [40] 陈国金,张云电.基于小波分析 ARMA 模型的气体压力识别[J].振动工程学报,2002,15(4):484-487.
 - [41] 高洪滨,欧阳光耀,张萍.基于 BP 神经网络的柴油机气缸压力重构[J].内燃机工程,2005,26(1):68-70.
 - [42] 刘建敏,李华莹,乔新勇.基于缸盖振动信号的气缸压力识别方法研究[J].内燃机工程,2013,34(4):32-37.
 - [43] Chen Z, Ou Y, Long S, et al.Vibration characteristics analysis of the new pin-cycloid speed reducer[J].Journal of the Brazilian Society of Mechanical Sciences & Engineering,2018,40(2):55.
 - [44] 洪嘉振,刘铸永.刚柔耦合动力学的建模方法[J].上海交通大学学报(自版)2008,42(11):1922-1926.
 - [45] 孟聪.RV 减速器动力学特性分析[D].天津大学,2017.
 - [46] Wu S, Tsai B, Chen J. Elastic-plastic finite element analyses for reducers with constant-depth internal circumferential surface cracks[J].International Journal of Pressure Vessels and Piping,2015,131:10-14.
 - [47] 王雷.基于流形学习的滚动轴承故障诊断若干方法研究[D].大连理工大学,2013.
 - [48] Suykens K, Gestel V, Brabanter D, et al. Least squares support vector machines[M].Singapore:World Scientific Publishing Company,2002.
 - [49] Ranaee V, Ebrahimzadeh A, Ghaderi R.Application of the PSO-SVM model for recognition of control chart patterns[J].ISA Transactions,2010,49:577-586.
 - [50] 涂志健,吴建,卫能等.RV 减速器故障知识图谱的构建[J].机器人技术与应用,2021,(06):40-44.
 - [51] 洪文雄.RV 减速器振动测试与故障分析研究[D].江汉大学,2023.
 - [52] 字玉.基于时频分析的机械故障特征提取方法研究[D].昆明理工大学,2022.
 - [53] 张大卫,王刚,黄田等.RV 减速机动力学建模与结构参数分析[J].机械工程学报,2001,37(1):69-74.
 - [54] 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(03):7-13.
- [55] 宋雷,游东东,郑振兴等.基于经验模态分解的 RV 减速器运动参数降噪研究[J].振动与冲击,2022,41(18):266-272+290.
- [56] 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.
- [57] 蔺梦雄,王爽,韦克吉等.阶次跟踪与改进小波阈值降噪的 RV 减速器故障诊断[J].制造技术与机床,2022,(11):9-14.
- [58] 李恒,张氢,秦仙蓉等.基于短时傅里叶变换和卷积神经网络的轴承故障诊断方法[J].振动与冲击,2018,37(19):124-131.
- [59] 叶昊,王桂增,方崇智.小波变换在故障检测中的应用[J].自动化学报,1997,(06):18-23.
- [60] 汪久根,柯梁亮.基于残差网络的 RV 减速器故障诊断[J].机械工程学报,2019,55(03):73-80.
- [61] 任众,张铁山.粒子群优化的支持向量机在截割部行星齿轮减速器故障诊断中的应用[J].机械强度,2018,40(06):1293-1296.
- [62] 毛君,郭浩,陈洪月.基于改进萤火虫算法神经网络的刮板输送机减速器故障诊断[J].机械强度,2019,41(03):544-550.
- [63] 阮强.基于时频分解降噪结合深度学习模型的 RV 减速器故障诊断研究[D].昆明理工大学,2023.
- [64] 刘全,翟建伟,章宗长等.深度强化学习综述[J].计算机学报,2018,41(01):1-27.
- [65] 孙志军,薛磊,许阳明等.深度学习研究综述[J].计算机应用研究,2012,29(08):2806-2810.
- [66] 王鑫,吴际,刘超等.基于 LSTM 循环神经网络的故障时间序列预测[J].北京航空航天大学学报,2018,44(04):772-784.
- [67] 任浩,屈剑锋,柴毅等.深度学习在故障诊断领域中的研究现状与挑战[J].控制与决策,2017,32(08):1345-1358.
- [68] 雷亚国,贾峰,周昕等.基于深度学习理论的机械装备大数据健康监测方法[J].机械工程学报,2015,51(21):49-56.
- [69] 任欢,王旭光.注意力机制综述[J].计算机应用,2021,41(S1):1-6.

- [70] 朱张莉,饶元,吴渊等.注意力机制在深度学习中的研究进展[J].中文信息学报,2019,33(06):1-11.
- [71] 孟宏宇,张建良,蔡兆龙等.基于 CNN-BiLSTM-Attention 的直流微电网故障诊断研究[J/OL].中国电机工程学报,1-12.
- [72] 张汉霖,王贞,吴志勇等.基于多重注意力机制优化的卷积网络故障诊断方法[J].现代电子技术,2023,46(21):68-75.
- [73] 焦晓璇,章余,景博等.基于双重注意力机制及 S-BiGAN 的机电设备故障诊断[J].航空工程进展,2023,14(05):162-168.
- [74] 任英虎,王风涛,熊元昊,等.RV减速器摆线轮剥落故障振动特性研究[J].淮阴工学院学报,2023,32(03):8-18.
- [75] B. Boguski, A. Kahraman, T. Nishino. A new method to measure planet load sharing and sun gear radial orbit of planetary gear sets[C].Proceedings of the ASME 2011 International Design Engineering Technical Conferences & Computers and Information in Engineering Conference,Washington DC,USA,2011.
- [76] H. Teruaki, T. Yoshio, N. Kazuteru. Dynamic behavior of planetary gear em dash 7th report, influence of the thickness of the ring gear[J].Bulletin of the JSME,22(170)(1979):1142-1149.
- [77] 王世宇.基于相位调谐的直齿行星齿轮传动动力学理论与实验研究[D].天津大学,2005.
- [78] 孙景惠,张久成,李渤仲.行星轮系回转振动实验研究[J].水利电力机械,1990,(06):29-33.
- [79] 孙景惠,张久成,李渤仲.行星轮机构及其轴系的扭转振动实验研究[J].机械工程学报,27(1)(1991):8-13.
- [80] 孙景惠,张久成,李渤仲.带有行星轮装置动力轴系扭转振动的试验研究[J].水利电力机械,5(1995):19-23.
- [81] 罗春艳.小波字典下齿轮箱复合故障瞬态特征的稀疏表示研究[D].苏州大学,2016.
- [82] 刘瑶,徐海平,初宁等.基于长短时记忆模型的风机故障诊断[J].工程热物理学报,2020,41(10):2437-2445.

- [83] 吴磊,康英伟.基于改进粒子群优化长短时记忆神经网络的脱硫系统 SO₂ 预测模型[J].热力发电,2021,50(12):66-73.
- [84] 周慧,孙成禹,刘英昌等.基于 DC-UNet 卷积神经网络的强噪声压制方法[J].物探与化探,2023,47(05):1288-1297.
- [85] 韩盈,安志国,底青云等.基于循环神经网络的大地电磁信号噪声压制研究[J].地球物理学报,2023,66(10):4317-4331.
- [86] 李佳蓉.基于新型卷积神经网络的地震勘探随机噪声压制[D].山西大学,2023.
- [87] 何锐彬.基于多目标学习的环境音噪声抑制算法研究[D].桂林电子科技大学,2023.
- [88] 任磊.噪声驱动的复值神经网络学习算法研究[D].大连海事大学,2023.
- [89] 唐治尧,李刚,李德苍.高噪声下改进卷积神经网络轴承故障诊断[J].中国设备工程,2024,(01):181-183.
- [90] 曲铎.基于贝叶斯优化 DratNet 的滚动轴承故障诊断方法研究[D].西安理工大学,2023.

附录

A.作者在攻读硕士学位期间发表的论文目录

[1]任英虎,王风涛,熊元昊等.RV减速器摆线轮剥落故障振动特性研究[J].淮阴工学院学报,2023,32(03):8-18. (已见刊)

B.作者在攻读硕士学位期间参与写作的专利目录

[1]任英虎,王风涛等.一种果园用采摘装置.【实用新型专利】申请号:CN202322284002.5、公开号:CN220402439U.

C.作者在攻读硕士学位期间参加的科研项目目录

[1]安徽工程大学校级科研项目:低速重载圆锥滚子轴承擦伤机制及检测方法研究(编号:Xjky2022012)

[2]横向课题:RV减速器分析与检测数据处理技术开发(编号:HX-2021-08-009)

致谢

白驹过隙，我即将结束为期三年的硕士学习生涯。在攻读研究生期间，我要特别感谢我的导师王风涛老师，他的悉心教导让我受益匪浅。自我入学以来，老师一直倾注大量心血培养我的学术能力，并在生活中给予我细致的关怀和照顾。导师严谨务实的科研态度、深厚的学术造诣以及对科研项目的敬业投入深深影响着我，培养了我合格的科研素养和务实的工作作风。正是在王风涛老师的无私帮助与积极鼓励下，我的毕业课题才能够顺利完成，完成课题过程中获得的成果、经验于我而言是无价的财富。在即将毕业交稿之际，我衷心向我的研究生导师王风涛表示诚挚的敬意和感激。

在平日的科研交流及毕业论文的撰写过程中，代鹏师兄、熊元昊师弟等课题组同门予以了我极大的支持与帮助，正是通过与他们的深度合作，才得以让我的科研实验、论文撰写等工作进展顺利，在此对各位表示衷心感谢，同时也祝愿安徽工程大学机械与汽车工程学院精密传动技术课题组未来学术成果丰硕，继续登攀科研高峰。

最后，诚挚感谢所有百忙之中参与论文评阅和答辩的专家和老师们！

任英虎

二〇二四年五月于芜湖

尚德敏学 唯实惟新

