

分类号: TP242.2

密 级: 公开

学校代码: 10363

学 号: 2220110117



安徽工程大学

Anhui Polytechnic University

硕士学位论文

题 目 基于数字孪生的工业机器人
电机故障监测

论 文 作 者 孙笑笑

校 内 导 师 江本赤 教授

校 外 导 师 李公文 高级工程师

专业学位类别 机械

研究方向(领域) 数字孪生

论文提交日期: 2025 年 5 月 20 日

分 类 号： TP242.2
密 级： 公开

单位代码： 10363
学 号： 2220110117

基于数字孪生的工业机器人电机故障监测
FAULT MONITORING OF INDUSTRIAL ROBOT MOTOR
BASED ON DIGITAL TWIN

学生姓名： 孙笑笑
指导教师： 江本赤 教授
校外导师： 李公文 高级工程师
专 业： 机械
研究方向： 数字孪生

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：

孙笑笑

日期：2025年5月9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：

孙笑笑

指导教师签名：

江萍萍

日期：2025 年 5 月 9 日

日期：2025 年 5 月 9 日

基于数字孪生的工业机器人电机故障监测

摘 要

随着机器人及相关技术的快速发展，工业机器人得到了日益广泛的应用。在制造领域，工业机器人作为生产系统的重要组成部分，其性能直接影响产品生产的效率与质量，而电机作为工业机器人的动力中枢，负责通过精密传动驱动机器人各关节运动，其运行状态直接影响机器人的可靠性和稳定性。

然而，电机本身结构复杂，在极限工况下容易出现转子失衡或轴承系统故障等问题，因此对机器人电机进行实时故障诊断与在线状态监测具有重要意义。针对传统电机故障监测方法存在实时性不足、诊断精度低与故障数据难以获取等问题，本文基于数字孪生技术，对工业机器人电机故障监测进行了如下研究：

（1）采用数字孪生技术进行工业机器人系统建模。对照数字孪生五维模型结构，首先使用 Unity 3D 虚拟现实软件等工具构建工业机器人系统的数字孪生模型；然后建立其与实体之间的数据通信系统，搭建机器人状态监测系统，通过数据采集系统采集机器人系统中与电机相关的实时状态数据，为电机实时运行参数和状态的可视化与故障诊断奠定基础。

（2）验证孪生数据与实测数据的一致性。基于 MATLAB/Simulink 功能模块构建电机系统的高保真数字孪生体，采集孪生系统中不同故障类型对应的孪生数据，并从时域和概率密度分布两个

维度对孪生数据与实测数据进行一致性对比，验证利用孪生数据替代实测数据进行电机故障诊断的可行性。

（3）构建基于卷积注意力时序网络（CATN）的电机故障诊断模型。为提升模型的诊断精度，首先基于卷积层结合注意力机制提取孪生数据的全局特征，并增大重要特征数据的权重；然后采用长短期记忆网络捕捉数据的时序特征，据此评估电机的运行状态和故障类型。最后通过实验验证，并与 CNN、LSTM 及 CNN-LSTM 模型进行对比分析，证明了本文算法的有效性。

关键词：工业机器人电机，CATN 神经网络，故障诊断，数字孪生，监测系统

FAULT MONITORING OF INDUSTRIAL ROBOT MOTOR BASED ON DIGITAL TWIN

ABSTRACT

With the rapid development of robots and related technologies, industrial robots have been widely used. In the manufacturing field, industrial robots are an important part of the production system, and their performance directly affects the efficiency and quality of product production. As the power center of industrial robots, motors are responsible for driving the movement of each joint of the robot through precision transmission. The running state directly affects the reliability and stability of the robot.

However, the structure of the motor itself is complex, and it is prone to problems such as rotor imbalance or bearing system failure under extreme conditions. Therefore, real-time fault diagnosis and online condition monitoring of the robot motor are of great significance. Aiming at the problems of insufficient real-time performance, low diagnostic accuracy and difficult acquisition of fault data in traditional motor fault monitoring methods, this paper studies the motor fault monitoring of industrial robots based on digital twin technology as follows :

- (1) Digital twin technology is used to model the industrial robot

system. According to the five-dimensional model structure of digital twin, the digital twin model of industrial robot system is constructed by using tools such as Unity 3D virtual reality software. Then, the data communication system between the robot and the entity is established, and the robot condition monitoring system is built. The real-time state data related to the motor in the robot system is collected by the sensor, which lays a foundation for the visualization and fault diagnosis of the real-time operating parameters and states of the motor.

(2) Verify the consistency of twin data and measured data. Based on the MATLAB / Simulink function module, the high-fidelity digital twins of the motor system are constructed, and the twin data corresponding to different fault types in the twin system are collected. The consistency of the twin data and the measured data is compared from the two dimensions of time domain and probability density distribution, and the feasibility of replacing the measured data with the twin data for motor fault diagnosis is verified.

(3) A motor fault diagnosis model based on convolutional attention temporal network (CATN) is constructed. In order to improve the diagnostic accuracy of the model, firstly, the global features of the twin data are extracted based on the convolutional layer combined with the attention mechanism, and the weight of the important feature data is increased. Then, the long short-term memory network is used to capture

the temporal characteristics of the data, and the running state and fault type of the motor are evaluated accordingly. Finally, through experimental verification and comparative analysis with CNN, LSTM and CNN-LSTM models, the effectiveness of the proposed algorithm is proved.

KEY WORDS: industrial robot motor, CATN neural network, fault diagnosis, digital twin, monitoring system

目 录

第 1 章	绪论.....	1
1.1	研究背景与意义.....	1
1.2	工业机器人电机故障诊断研究现状.....	2
1.2.1	基于信号分析的方法.....	2
1.2.2	基于模型的方法.....	2
1.2.3	基于数据驱动的方法.....	3
1.3	数字孪生研究现状.....	4
1.4	本文主要内容与章节安排.....	6
1.4.1	论文主要内容.....	6
1.4.2	论文章节安排.....	7
第 2 章	数字孪生技术及孪生系统构建.....	8
2.1	数字孪生技术.....	8
2.1.1	数字孪生系统框架.....	8
2.1.2	数字孪生关键技术.....	11
2.1.3	数字孪生系统设计原则.....	12
2.2	工业机器人及其电机.....	12
2.2.1	典型工业机器人结构.....	12
2.2.2	工业机器人常用电机.....	13
2.3	机器人的孪生模型构建.....	14
2.3.1	基于 SolidWorks 构建几何模型.....	15
2.3.2	基于 3D Max 轻量化模型.....	15
2.3.3	基于 Unity 3D 构建数字孪生模型.....	16
2.4	工业机器人系统数据通信构建.....	16
2.4.1	机器人相关的数据特征.....	17
2.4.2	数据采集方式.....	17
2.4.2	OPC UA 技术与串行通信.....	18
2.4.3	构建数据通信框架.....	18
2.5	机器人数字孪生系统的构建.....	19

2.5.1 本系统的功能需求.....	19
2.5.2 系统功能模块设计.....	19
2.6 本章小结.....	20
第 3 章 工业机器人电机数字孪生建模与故障分析.....	21
3.1 工业机器人电机及其故障类型分析.....	21
3.2 电机轴承结构与动力学特性.....	23
3.2.1 几何结构.....	23
3.2.2 滚动轴承动力学特性表征.....	23
3.3 电机系统数字孪生建模.....	26
3.3.1 物理试验台搭建.....	26
3.3.2 基于 Simulink 构建电机轴承孪生模型	27
3.4 数据一致性分析.....	29
3.4.1 时域对比分析.....	29
3.4.2 概率密度对比分析.....	33
3.5 本章小结.....	34
第 4 章 基于卷积注意力时序网络模型的电机轴承故障诊断.....	35
4.1 数据预处理.....	35
4.2 信号故障特征提取.....	35
4.2.1 振动信号故障特征提取.....	36
4.2.2 电流信号特征提取方法.....	36
4.3 卷积注意力时序网络（CATN）诊断模型构建	37
4.3.1 神经模型与算法的基本理论.....	37
4.3.2 卷积注意力时序网络故障诊断模型构建.....	43
4.4 故障诊断流程.....	45
4.5 模型验证与对比.....	46
4.5.1 实验样本设置.....	46
4.5.2 实验环境设置.....	46
4.5.3 性能参数指标.....	47
4.5.4 结果与对比分析.....	48

4.6 本章小结.....	49
第 5 章 总结与展望.....	50
5.1 总结.....	50
5.2 不足之处与展望.....	50
参考文献.....	52
攻读硕士学位期间取得学术成果.....	60
致谢.....	61

插图目录

图 1-1 工业机器人的广泛应用	1
图 1-2 论文章节安排	7
图 2-1 数字孪生五维模型	9
图 2-2 工业机器人物理实体	9
图 2-3 机器人结构图	12
图 2-4 直流与交流电机示意图	13
图 2-5 工业机器人整机数字孪生模型构建流程	14
图 2-6 工业机器人模型轻量化流程	16
图 2-7 工业机器人数字孪生模型	16
图 2-8 数据通信框架原理图	18
图 2-9 数字孪生系统登录界面	19
图 2-10 工业机器人状态可视化	20
图 3-1 永磁同步电机结构示意图	21
图 3-2 滚动轴承结构图	23
图 3-3 滚动轴承简化模型	24
图 3-4 电机性能测试试验台	26
图 3-5 轴承故障设置示意图	27
图 3-6 PMSM 模块参数设置	28
图 3-7 负载转矩的参数设置	28
图 3-8 电机转速参数设置	29
图 3-9 电机轴承数字孪生模型	29
图 3-10 滚动轴承实测与孪生振动信号时域波形	30
图 3-11 滚动轴承实测与孪生电流信号时域波形	31
图 3-12 滚动轴承在不同健康状态下的概率密度分布图	33
图 4-1 卷积神经网络结构图	38
图 4-2 激活函数示意图	39
图 4-3 LSTM 网络结构图	40

图 4-4 注意力机制结构图	42
图 4-5 卷积注意力时序网络模型框架图	44
图 4-6 诊断流程图	46
图 4-7 CATN 测试样本故障诊断准确率与混淆矩阵图	48
图 4-8 不同模型准确率对比图	48

插表清单

表 3-1 电机典型故障	22
表 3-2 滚动轴承常见故障	22
表 3-3 振动传感器参数	27
表 3-4 时域统计特征	31
表 3-5 振动实测和孪生信号时域统计指标计算值及其相对偏差	32
表 3-6 电流实测和孪生信号时域统计指标计算值及其相对偏差	32
表 4-1 训练及测试样本分布	46
表 4-2 故障诊断实验条件	47
表 4-3 不同模型性能参数对比	49

第1章 绪论

1.1 研究背景与意义

近年来，随着第四次工业革命的深入推进，与 5G、物联网、大数据及人工智能等新一代信息技术的迅猛发展^[1]，工业机器人作为智能制造体系的核心装备，正在全球制造业中发挥着日益重要的作用^[2]。工业机器人凭借其高精度、高效率及强稳定性，使其广泛应用于喷涂、焊接、搬运等自动化生产领域中，能够显著提升生产效率、减少人工数量、节约生产成本，已然成为智能制造领域的核心装备^[3-4]，图 1-1 分别为工业机器人在喷涂和焊接领域的应用。



图 1-1 工业机器人的广泛应用

作为工业机器人的核心动力单元，驱动电机的运行状态直接决定着整个机械系统的性能表现，其故障类型主要有绕组过热、轴承磨损、转子偏心与永磁体失效等典型故障^[5]。这些故障若未能及时发现，不仅会导致设备停机而造成直接经济损失，更可能引发连锁性生产事故，威胁操作人员安全^[6]。在高度自动化的现代工厂中，传统基于阈值的被动式监测方法已难以满足需求，亟需发展新型智能监测技术。

数字孪生技术作为一种能够把物理世界和数字世界相结合的新型技术^[7]，其通过物理实体参数构建并驱动数字孪生模型，孪生模型通过映射准确反映物理实体，实现实时数据的交互和反馈，进而使得对机器人状态的监测更加精准和动态^[8]。这种方法不仅能在故障发生前进行提前预测，还能在故障发生后迅速分析故障原因，能够有效提高工业机器人在复杂环境下的运行可靠性与安全性，所以基于数字孪生技术开展工业机器人电机相关研究具有重要意义。

1.2 工业机器人电机故障诊断研究现状

随着工业机器人日益广泛的应用，对其电机实施运行状态实时监测已成为保障生产安全与可靠性的重要手段^[9]。该领域研究始于二十世纪，以英国为代表的发达国家率先建立了专业化的故障诊断研究机构^[10]，而我国自 20 世纪 80 年代起逐步开展相关研究工作^[11]，目前已形成较为完善的技术体系。在电机故障诊断方法学层面，当前国际主流技术可归纳为三大类别：基于信号分析的方法^[12]、基于模型的方法^[13]以及基于数据驱动的方法^[14]。

1.2.1 基于信号分析的方法

在电机故障诊断技术中，核心思路在于实时获取电机运行状态的多维信息，如电压、电流、温度、转速及转矩参数等^[15]，通过应用模态分解、小波变换、傅里叶变换等先进信号处理技术^[16]，实现特征参数的分离提取。

魏勇召等^[17]人针对非线性模拟信号的处理，使用变分模态分解（VMD）对电机定子电流信号进行分析，通过将其分解为趋于平稳的信号分量，实现电机轴承早期的故障诊断。茅宇等^[18]人采用 VMD 去除杂波分量，然后使用双对数频谱分析法分析信号频谱完成，通过实验验证，该方法对电机匝间故障的有效性。Alameh 等^[19]人通过对永磁同步电机振动信号时域与频域分析，实现对电机转子偏心与永磁体退磁故障的有效诊断。王宇清等^[20]人通过计算电机轴承三相电流信号的 Park 矢量模平方函数，经小波包分解得到故障特征频率对应的 RMS 值，经实验验证了 RMS 值对电机轴承故障的有效性。姚丹等^[21]人通过使用鲁棒经验模态分解（REMD）算法分解得到电机轴承故障信号的 IMF，然后使用解析能量算子（AEO）体取这次的故障故障特征频率，实现电机轴承的故障诊断。张业成等^[22]人通过提取转子同相与异相电流幅值之间的波动特征，有效实现对定子匝间短路故障与转子局部退磁故障的诊断。

1.2.2 基于模型的方法

基于模型的诊断方法根据电机的运转流程、系统参数、故障机理物理模型建立电机系统的动力学方程或状态空间模型，对电机故障进行诊断分析^[23]。

李宏等^[24]人基于最小二乘法构建对转无刷直流电机故障诊断模型，通过电机的输入参数，以及运行参数，实现对电机工作状态的监测。张永强等^[25]人通过对转子不对中、裂纹等故障搭建对应故障模型，并对扩展卡尔曼滤波进行扩

展,实现对电机转子的故障诊断。He^[26]提出了一种基于磁场重构的 d 轴磁网络模型的 PMSM 稳健退磁故障 (DF) 诊断的方法,其方法采用磁场重构来获得开路条件下的径向气隙磁通密度。随后,建立了一个 d 轴磁网络来求解 DF 状态下的退磁系数矩阵。最后,通过实验验证了该方法的有效性。Chen^[27]提出了一种基于混合动力系统模型 (HSM) 的 PMSM 驱动系统三相电压源逆变器 (VSI) 开路 (OC) 故障诊断方法,在相电压分析的基础上,建立了永磁同步逆变器系统的 HSM,并在其基础上构建了一个电流估算器,可以更准确地描述系统和快速诊断故障是否发生。通过欧几里得距离法实现对 HSM 所生成的模拟故障类型与相似性对比,从而进行故障隔离,通过实验验证了所提方法诊断速度快、鲁棒性强等优点。徐琛杰等^[28]人将电机和逆变器视为一个系统,建立了统一模型,然后通过分析电机健康模型与实际输出的电流残差,实现对表贴式永磁同步电机的故障诊断。

杜嘉晨等^[29]通过混合逻辑动态模型 (MLD) 估算模型与实际电流之间的电流残差,通过对各故障下电流残差的特征分析与提取,最后通过实验证明,该方法对电机开关管开路故障的有效性。Yang^[30]提出了一种基于观测器解决检测和隔离电流传感器中不同扭矩和速度下的加法和乘法故障的方法,针对 (PMSG) 的风电系统电流传感器故障诊断和隔离 (FDI) 问题,通过机电动力学与电流动力学纸卷的转换,将永磁同步发电机 (PMSG) 系统模型重新表述为线性参数变化 (LPV) 模型并引入多位分解设计 LPV 残差生成器和故障估计器最后基于构建的风能转换系统的 MATLAB/Simulink 模型,证明所提方法可以实现对多个传感器故障以不同的输入扭矩和机械功率同时隔离。赵洪山等^[31]人基于 Simulink 搭建了偏航系统电机模型,实现电机故障的模拟,然后基于输出变量残差均值构建故障检测变量,结合均值与方差设计动态阈值,实现快速故障检测。

1.2.3 基于数据驱动的方法

近年来,随着机器学习发展迅速,数据驱动方法通过机器学习算法从历史数据中挖掘故障模式,近年来成为研究热点^[32]。该方法可以从大量数据中自动学习复杂工况下的故障特征映射关系,对故障进行诊断及分类^[33-34],常见的机器学习算法有:BP 神经网络、卷积神经网络,循环神经网络与支持向量机等。

Kumar^[35]通过叠加多个批量归一化加快 CNN 特征提取,结合自适应梯度优

化器实现电机轴承轴承与转子杆故障诊断。Chang^[36]首先使用自编码器对 PMSM 检查是否发生退磁现象，然后使用 K-means 聚类算法对退磁程度进行判断，最后通过实验验证了该方法对电机退磁故障诊断的可行性。Shifat 等^[37]人通过对定子与转子进行制造人为故障，然后提取传感器采集的电机电流和振动信号中的关键特征，然后使用主成分分析法（PCA）对其进行降维，最后基于人工神经网络（ANN）诊断模型，实现对电机不同故障的诊断。樊红卫等^[38]人将时变信号通过角域重采样法转换为角域信号，然后经小波包软阈值法对其去噪，将经过去噪后信号输入到改进深度卷积神经网络中，实现电机转子-轴承系统的故障诊断。

综合上述文献，在电机故障诊断领域研究虽取得一定的进展，但是仍存在一些问题。信号分析方法在处理非线性信号时，容易产生适应性不足、特征提取精度低的现象，进一步导致故障可辨识度下降；模型方法则比较依赖精确的数学模型；数据驱动方法需要大量数据，而且容易产生可解释性较差的问题。

1.3 数字孪生研究现状

数字孪生是在 CPS^[39]（Cyber-Physical Systems）概念的基础上发展起来的，在数字空间中创建一个与物理实体一对一实时映射的数字模型，更加强调对物理实体的实时映射与数据交互能力^[40]。数字孪生集成多领域学科技术，通过构建物理实体的虚拟对象映射其运行状态，并借助虚实系统间的双向交互和智能算法分析等手段，实现物理实体功能的拓展与优化。

数字孪生概念最早可追溯到 20 世纪美国 NASA“阿波罗计划”，应用于航天器的健康管理^[41]。随后 Grieves 教授^[42]于 2003 年给出了数字孪生三维模型的概念，重点阐释了物理实体与虚拟模型间的数据映射机制及实时交互。Li 等^[43]基于数字孪生技术，通过构建动态贝叶斯网络，实现了对机翼的健康监测及预测裂纹增长的概率。Lee 等^[44]通过构建耦合模型，使在云平台中运行的数字孪生体和真实机器同步运行，并通过使用数据分析和驱动算法等方法，实现了对生产系统不同生命周期阶段健康状态的分析。Schroeder 等^[45]人在使用数字孪生概念完成虚拟模型构建，使用 Web 服务架构反对数据进行访问，最后节后增强现实技术实现可视化。Madni 等^[46]人通过数字孪生技术、仿真技术与物联网的技术融合策略，系统论证了该技术融合对基于模型的系统工程（MBSE）的关

键支撑作用，并提出物理实体数字化映射的渐进式发展阶段：预孪生基础层、标准孪生层、自适应孪生优化层及智能孪生决策层。Li 等^[47]人基于数字孪生构建了飞机机翼孪生模型，并对动态贝叶斯网络进行优化，使其能够精确预测裂纹增长的概率。Singh^[48]利用多个物理场和数据驱动建模构建了感应电动机的数字孪生系统，实现了对电机的故障诊断和预测性维护。Sampedro 等^[49]人集成 3D-AmplifAI 模型构建 3D 打印机数字孪生系统，结合机器学习实现了对 3D 打印机的故障诊断。Lopes^[50]基于数字孪生技术模拟构建感应电机故障数据库，对其中故障电流进行时域和频域特征分析，结合人工神经网络实现对电机转子的故障诊断。Velazquez^[51]将混合自动机嵌入到数字孪生系统中，实现对自动存储和检索系统在线监测和故障诊断的功能。Palak 等^[52]人开发了一个用于分布式光伏系统故障诊断的数字孪生系统，实现了对电源转换器故障诊断。

国内对数字孪生的研究以高校为主导，北京航空航天大学陶飞教授等在领域取得突破性进展，其早期研究系统构建了数字孪生车间理论体系，不仅明确定义了核心概念，更从系统架构、运行机理、核心技术等维度展开深度解析，创新性地建立了虚实空间双向交互机制^[53-54]。该团队后续提出的五维架构模型突破传统三维框架，通过物理实体、虚拟映射、服务系统、数据资源、连接通道五个核心要素的有机整合，为行业应用提供了标准化实施路径^[55]。针对制造业数字化转型中的数据治理难题，庄存波等^[56]人研究发现数字孪生技术可以通过信息的双向交互，有效推动产品制造智能化和灵活性的发展。丁华等^[57]开创性地将深度学习算法与数字孪生技术融合，成功构建采煤装备运行状态的数字镜像系统，通过实时数据驱动的高精度仿真建模，实现了设备状态的动态可视化监控，为后续的故障预测和决策支持奠定了技术基础。马兴瑞等^[58]通过构建轴承数字孪生模型，并向其注入虚拟故障，得到轴承故障虚拟数据，通过实验验证虚拟数据的可信度并基于虚拟数据实现了轴承的故障诊断。任巍曦等^[59]人基于数字孪生技术构建风电机组的数字孪生系统，使用希尔伯特黄变换对孪生数据进行分析处理结合 CNN 实现风电轴承的故障诊断。卢家欢等^[60]人通过构建动力电池的数字孪生模型，得到其全生命周期点行为仿真数据，为动力电池在实际应用中的衰减研究提供模型基础。张希等^[61]人根据电机轴承物理属性构建电机轴承数字孪生体，结合深度学习实现对电机轴承的故障诊断。周杨等^[62]使

用 Simulink 建立了动车组牵引电机的数字孪生模型，基于孪生数据与实测数据，采用深度学习与迁移学习方法构建并训练数据分析模型，最后通过故障分析模型实现了对动车组电机的故障识别。付洋等^[63]人提出基于数字孪生驱动的航空发动机涡轮盘剩余寿命预测的方法，通过动态贝叶斯网络对模型状态空间时间演化规律的描述，构建了涡轮盘退化状态数字孪生模型，最后通过融合实测数据，经贝叶斯推理使孪生模型实现了动态更新。

综上所述，随着数字孪生技术的逐渐成熟与发展，采用数字孪生技术构建电机多物理场耦合的高保真虚拟模型，实现了物理实体与数字空间的动态映射与交互迭代，为故障诊断提供了虚实联动的创新范式。

1.4 本文主要内容与章节安排

1.4.1 论文主要内容

针对传统电机故障监测方法存在实时性不足、诊断精度低与故障数据难以获取等问题，本文基于数字孪生技术，对工业机器人电机故障监测进行了如下研究：

（1）采用数字孪生技术进行工业机器人系统建模。对照数字孪生五维模型结构，首先使用 Unity 3D 虚拟现实软件等工具构建工业机器人系统的数字孪生模型；然后建立其与实体之间的数据通信系统，搭建机器人状态监测系统，通过传感器采集机器人系统中与电机相关的实时状态数据，为电机实时运行参数和状态的可视化与故障诊断奠定基础。

（2）验证孪生数据与实测数据的一致性。基于 MATLAB/Simulink 功能模块构建电机系统的高保真数字孪生体，采集孪生系统中不同故障类型对应的孪生数据，并从时域和概率密度分布两个维度对孪生数据与实测数据进行一致性对比，验证利用孪生数据替代实测数据进行电机故障诊断的可行性。

（3）构建基于卷积注意力时序网络（CATN）的电机故障诊断模型。为提升模型的诊断精度，首先基于卷积层结合注意力机制提取孪生数据的全局特征，并增大重要特征数据的权重；然后采用长短期记忆网络捕捉数据的时序特征，据此评估电机的运行状态和故障类型。最后通过实验验证，并与 CNN、LSTM 及 CNN-LSTM 模型进行对比分析，证明了本文算法的有效性。

1.4.2 论文章节安排

论文的章节安排如图 1-2 所示。




图 1-2 论文章节安排

第2章 数字孪生技术及孪生系统构建

工业机器人是一个复杂的多学科耦合系统，本章为准确捕捉电机运行状态与机器人整体行为间的关联性，选择基于数字孪生技术，围绕物理实体、虚拟模型、数据交互、服务功能与连接关系五位模型架构构建机器人数字孪生系统。

2.1 数字孪生技术

数字孪生技术通过构建物理对象的动态数字镜像，依托多源异构数据融合与算法驱动，实现实体全生命周期的全流程仿真与决策优化。其核心特征体现在四个维度^[56]：

(1) 互操作性。建立物理域与虚拟域的双向数据通道，实现状态参数的动态映射。

(2) 实时性。虚拟实体要求实时反映物理实体的外观、状态、内在机理等变化。

(3) 保真性。涵盖几何结构、物理特性及行为逻辑的多维度高度仿真。

(4) 闭环性。形成"感知→分析→决策→执行"的自主优化环路，驱动实体系统持续迭代升级。

2.1.1 数字孪生系统框架

Grieves^[42]首先建立了 DT 模型的通用标准结构，在该结构中，DT 从物理实体、虚拟模型和连接三个维度进行建模，并以物理实体与虚拟模型的双向交互为特征。在此基础上，陶飞等^[55]人所提出了一种数字孪生通用的五维模型被目前各行各业广泛使用，如公式（2-1）所示。工业机器人的数字孪生五维模型如下图 2-1 所示。

$$M_{DT} = (PE, VE, Ss, DD, CN) \quad (2-1)$$

式中， PE ：物理实体；

VE ：虚拟实体；

Ss ：服务；

DD ：孪生数据；

CN ：各部分之间的连接。




图 2-1 数字孪生五维模型

(1) 物理实体 (PE)

物理实体 PE 是工业机器人本体，是构建数字孪生模型的基础，如图 2-2 所示，其由物理设备、传感器和执行器等组成。



图 2-2 工业机器人物理实体

(2) 虚拟实体 (VE)

虚拟实体 VE 是对物理实体的映射，其由物理模型、几何模型、规则模型、行为模型等组成，关系见公式 (2-2)。通过传感器等设备采集的数据，对虚拟实体进行数据驱动，实现虚实映射与交互，并生成孪生数据等功能。

$$VE = (G_v, P_v, B_v, R_v) \quad (2-2)$$

式中：VE：虚拟实体；

G_v ：几何模型；

P_v ：物理模型；

B_v ：行为模型；

R_v ：规则模型。

(3) 孪生数据 (DD)

孪生数据 DD 由来自物理实体的历史数据和实时数据 (D_p)、来自虚拟实体的数据 (D_v)、来自服务 Ss 的数据 (D_s)、领域内的知识 (D_k) 以及这四个方面的融合数据 (D_f) 五部分组成，如公式 (2-3) 所示。

$$DD = (D_p, D_v, D_s, D_k, D_f) \quad (2-3)$$

式中：DD：孪生数据；

D_p ：物理实体的历史数据和实时数据；

D_v ：虚拟实体的数据；

D_s ：服务的数据；

D_k ：领域内的知识；

D_f ： D_p 、 D_v 、 D_s 和 D_k 的融合数据。

(4) 服务 (Ss)

SS 为 PE 和 VE 的服务，其可以通过在 VE 模拟运行中校准参数优化 PE 的运行，保证 VE 的实时性、高保真度，并可以通过数据图表和三维模型进行不同维度的可视化。Ss 由公式 (2-4) 中的元素组成，描述了服务的功能、输入、输出、质量和状态四部分。

$$Ss = (Function, Input, Output, Quality, State) \quad (2-4)$$

式中：Ss：物理实体和虚拟实体的服务；

Function：服务的功能；

Input：服务的输入；

Output：服务的输出；

Quality：服务的质量；

State——服务的状态。

(5) 连接 (CN)

CN 是物理实体 PE、虚拟实体 VE、服务 Ss 和孪生数据 DD 两两之间的双向连接，关系如公式 (2-5) 所示。

$$CN = (CN_{DS}, CN_{PS}, CN_{PD}, CN_{PV}, CN_{VD}, CN_{VS}) \quad (2-5)$$

式中：CN：连接；

CN_{DS} ：服务和孪生数据之间的连接；

CN_{PD} ：物理实体和孪生数据之间的连接；

CN_{VD} ：虚拟实体和孪生数据之间的连接；

CN_{PS} ：物理实体和服务之间的连接；

CN_{VS} ：虚拟实体和服务之间的连接；

CN_{PV} ：物理实体和虚拟实体之间的连接。

2.1.2 数字孪生关键技术

(1) 数字化建模技术

数字化建模技术是数字孪生技术的基础，其要求主要包括高精度几何建模和语义建模。高精度几何建模要求模型的几何形状能够精确反映物理实体的外观和结构，其尺寸误差应控制在极小范围内，并且能够处理复杂的几何形状。同时，模型应包含物理实体的所有关键部件和结构，能够对物理实体进行多尺度建模，以满足不同应用场景的需求。

(2) 数据采集与传输

高保真物理数据的采集与快速高质量的传输是构建数字孪生系统的前提。信息交互技术是数字孪生技术的关键，其要求主要包括实时性、双向性以及数据兼容性。实时性要求物理实体与虚拟模型间的数据同步，并支持数据动态更新。双向性要求能够全面采集物理实体的各种数据，包括传感器数据、状态信息等。数据兼容性和安全性则要求孪生系统能够兼容多种数据格式和通信协议，并且支持数据的导入和导出，方便与其他系统进行数据共享和集成。

(3) 虚实映射技术

虚实映射技术是数字孪生技术的核心，其要求主要包括精准映射和动态映射。精准映射要求能够将虚拟模型与物理实体在空间上进行精准匹配，并且虚拟模型的材料、物理参数等属性要与物理实体的属性准确对应。

2.1.3 数字孪生系统设计原则

工业机器人数字孪生状态监测系统基于以上所搭建的模型和数据通信系统进行搭建，为了该系统能够在实际运行中保持较高的可靠性，需满足以下设计原则：

（1）整体性。采用分层解耦设计策略，将系统划分为几个分层，通过标准化接口实现分层间低耦合协同，并保证数字孪生状态持续运行的稳定性。

（2）高效性。系统用于实时可视化监控工业机器人物理实体，须具备较高实时性，确保虚拟系统和物理实体可实时交互。

（3）可变性。实际使用中，系统功能会因物理实体更新、用户需求多样而变化，所以设计时就要注重可扩展性，以便后期功能拓展。

2.2 工业机器人及其电机

2.2.1 典型工业机器人结构

工业机器人作为智能制造的关键设备，其机械结构设计直接影响作业精度、负载性能与运动灵活性。其工业机器人机械系统主要由基座、腰部旋转关节、大臂摆动关节、肘部回转关节、腕部俯仰/偏转关节及末端法兰盘等组成，通过模块化设计实现复杂轨迹的精准执行，其结构如图 2-3 所示。





图 2-3 机器人结构图

基座内置伺服电机和谐波减速器，结合 RV 减速器实现腰部连续旋转；轻量化桁架结构的大臂在确保刚度的同时降低了转动惯量；腕部三个关节通过精密齿轮传动完成俯仰和偏转运动。分布式驱动系统为各关节配置独立伺服驱动器，通过总线与控制器实时交互。智能控制系统搭载运动学解算模块，可自动补偿机械臂柔性变形与关节间隙误差，确保高精度运动控制。

2.2.2 工业机器人常用电机

在工业机器人作为智能制造的核心执行单元，其动力系统采用的电机类型呈现出显著的多元化特征。目前市场上主流的电机按电源类型分为直流电机与交流电机，按控制方式则可分为步进电机与伺服电机等，如图 2-4（a）和（b）分别为 INSUNMOT 直流电机与 ABB 交流电机。



（a）直流电机

（b）交流电机

图 2-4 直流与交流电机示意图

直流电机具有良好的调速性能和较大的启动转矩，适用于需要稳定低速运行的场合，如机器人的关节驱动^[64]。交流电机则因其结构简单、成本较低且维护方便，在一些对精度要求不高的应用中被广泛采用^[65]。步进电机能够将电脉冲信号转化为角位移，控制简单且精度较高，适用于一些需要精确位置控制但对速度和力要求不高的任务^[66]。伺服电机按工作原理主要分为永磁同步伺服电机和异步伺服电机，其中三相永磁同步型凭借高功率密度、快速动态响应和高精度控制特性，成为工业机器人中应用最广泛的电机类型之一^[67]。

然而工业机器人对电机的要求极为严格，其性能直接决定机器人的精度、速度和可靠性。以下是主要要求及详细解析：

（1）高精度与高动态响应。在定位精度方面，需达到微米级甚至更高，确保如装配、焊接等重复运动的一致性；在动态响应方面，需要有适应高速运动

快速启停和加减速的能力。

(2) 高扭矩密度与功率密度。为机器人关节在有限空间内提供大扭矩，并且能够在短时承受 2-3 倍额定扭矩，以应对突发负载。

(3) 高可靠性与长寿命。通过结构刚性优化，有效抑制持续振动对系统的影响，保障其运行稳定性和使用寿命。

(4) 精准控制与兼容性。通过工业总线协议与智能控制算法的深度集成，实现多轴协同运动与复杂轨迹规划，同时采用机电一体化设计精简系统架构。

(5) 轻量化与小型化。通过轻量化材料与紧凑型封装技术优化结构空间占用，并结合模块化设计实现快速维护，显著提升部署灵活性与运维效率。

2.3 机器人的孪生模型构建

工业机器人的电机并非独立运行单元，其工作状态与机械传动系统、控制器指令逻辑、传感器反馈网络及外部负载环境深度耦合。如果仅针对电机构建，可以快速构建初期孪生模型并搭建孪生系统，但是无法反映电机在机器人整体工作流程中的间歇性负载动态行为，可能降低故障诊断准确性。因此本文针对机器人整体构建数字孪生系统，通过模拟机器人整体运动学和动力学行为，捕捉电机如减速器、末端执行器与控制器等其他部件的交互关系，更真实地反映电机的工作状态，提升故障监测的鲁棒性，同时也为未来研究其他部件故障研究提供基础框架。

工业机器人设备模型由多个部分组成，需要用三维综合软件绘制各部分，通过将设备转换为特定格式并将其导入建模软件，本文采用 SolidWorks、3D Max 和 Unity 3D 软件构建数字孪生模型，具体过程如图 2-5。




图 2-5 工业机器人整机数字孪生模型构建流程

本章构建了基于数字孪生技术的工业机器人三维建模流程：采用多软件协同架构实现几何模型构建、特征增强和系统优化的技术路线。在 SolidWorks 平台完成机械结构参数化建模后，通过 3D Max 进行多物理场特征渲染与材质贴图处理，显著提升模型视觉保真度。针对模型运算效率问题，实施拓扑结构优化与网格简化处理，有效降低数据冗余度。最终在 Unity 3D 引擎中重构机器人运动学模型，通过建立多关节运动学约束的"父子级联"驱动架构，实现基础运动仿真功能。

2.3.1 基于 SolidWorks 构建几何模型

工业机器人三维几何模型与其机械结构紧密关联，是实施数字孪生技术和实现运行状态可视化的重要前提条件。建模过程中通常将机器人组件简化为刚体系统，忽略惯性、阻尼等动力学参数，借助 SolidWorks2022 三维建模工具完成各零部件的数字化构建。

2.3.2 基于 3D Max 轻量化模型

在三维数字化建模过程中，复杂零件常呈现网格密度过高、多边形冗余等拓扑特征，直接影响孪生系统的实时交互性能。本研究针对该问题，在确保模型几何保真度与功能完整性的双重约束下，通过拓扑优化算法对三维模型进行结构化精简处理。具体采用自适应网格简化技术，对非关键区域的几何特征、数据属性和层级关系实施智能压缩，有效降低模型渲染时延与运算负荷，显著提升数字孪生系统的动态响应能力与可视化流畅度。优化流程涉及特征保留阈值设定、细节层级（LOD）控制等关键技术环节，完整实施方案参见图 2-6 所示技术路线。

本研究采用分阶段模型优化技术方案：

- 1) 在 SolidWorks 完成零件建模后，导出为.STL 格式时需激活"属性信息集成"选项，确保材质参数与几何数据同步封装；
- 2) 将.STL 文件导入 3D Max 三维处理平台执行拓扑结构诊断，通过顶点密度分析模块识别冗余几何元素，执行选择性剔除操作；
- 3) 实施多边形优化策略，对高密度网格区域选择性采用网格简化算法与参数化抽壳处理，智能保留特征边界的同时移除内部冗余结构；
- 4) 通过 UV 坐标校准系统对简化模型进行纹理映射重构，采用特征点对齐技术维持表面贴图的空间拓扑关系，保障视觉保真度。该技术路线通过几何-纹

理协同优化机制，实现模型轻量化与视觉效果平衡。




图 2-6 工业机器人模型轻量化流程

2.3.3 基于 Unity 3D 构建数字孪生模型

将在 3D Max 中处理完成的模型以.FBX 格式导出，逐一导入到 Unity 3D 新建的项目中。在 Unity3D 中，按照物理实体建立各个部件之间的约束和父子关系，完成模型装配，如图 2-7 所示。




图 2-7 工业机器人数字孪生模型

2.4 工业机器人系统数据通信构建

作为工业机器人数字孪生系统的核心数据层，运行数据驱动着虚实空间的动态映射与同步更新。当前制造装备领域存在设备通信协议异构化问题，主要表现为工业机器人本体、PLC 控制器与传感单元间因缺乏标准化接口协议，导

致多源异构数据集成面临互操作性障碍。本研究通过构建涵盖设备状态、运动学参数及环境感知数据的标准化信息模型，建立统一的元数据描述体系与通信接口规范。该框架通过采用 OPC UA 内置的地址空间建模技术完成多维度数据融合，最终达成全要素数据流在虚拟空间的高效重构与实时同步。

2.4.1 机器人相关的数据特征

工业机器人运行数据作为数字孪生系统的核心驱动要素，主要涵盖控制指令、物理状态及环境交互三类信息。基于数据获取方式的差异性，可将其划分为控制器与 PLC 等设备的内生数据与力觉、视觉等外部传感器的采集数据两类，主要有以下特征：

（1）多源异构性。由控制器、多模态传感器及电机、驱动器执行机构组成的复合系统，分别生成指令状态、扭矩与角度等动态参数及温湿度等环境信息。这种设备协议异构化导致数据结构呈现多维异质性，需通过标准化接口实现数据融合。

（2）实时性与高频性。为适应动态作业环境，控制系统以毫秒级频率生成运动控制数据，传感器同步实施高频采样，确保数字孪生系统具备亚秒级响应能力。

（3）数据量较大。单台设备日均产生数据量可达 TB 级，主要源于以下：高频采样产生的时序数据流；连续作业形成的长周期数据积累；多维参数同步记录形成的矩阵式数据结构。

（4）多维度。工业机器人运行数据涉及多个维度，如时间维度采用时间戳构建数据时序基准，实现运行过程的全生命周期追溯；运动维度上，基于机器人自由度数构建位姿参数体系，涵盖各关节的实时位置、瞬时速度及加速度等微分特征。

2.4.2 数据采集方式

数据通信系统的效能基础取决于采集技术的实现方式。针对工业机器人运行数据的异构特性，当前主流采集方案可分为以太网采集与硬件采集采集线式两类技术路线：

（1）通过以太网采集。基于控制器/PLC 内建的工业以太网接口，通过 OPC UA 中间件构建数据采集网络。采用 TCP/IP 协议栈实现跨平台通信，满足运动控制指令与状态反馈的实时性要求。

(2) 通过硬件采集。主要是指利用额外加装的传感器采集特定物理信息，包括加速度、力、温度与湿度等。这些数据一般通过 I2C、SPI 与 USART 等串行接口通信。

2.4.2 OPC UA 技术与串行通信

OPC UA（统一架构）技术作为工业自动化领域的核心通信框架，其演进历程标志着工业数据交互范式的重大变革。该技术体系起源于 OPC 标准，通过构建面向服务架构（SOA）的新型通信模型，实现了数控机床、PLC 与工业机器人等工业设备之间的语义互操作^[68-69]。其技术内核包含三个核心层面：在信息建模层面，采用节点化地址空间结构构建规范化信息模型，通过其引用关系实现数字化映射；在通信架构层面，客户端模块与服务器端通过通信协议栈进行数据交互，该协议栈采用分层设计实现 API 指令与底层网络报文的高效转换^[70-71]；在传输机制层面，突破传统串行通信的速率限制，通过二进制编码优化使有效载荷压缩率提升 40%，结合 UA-TCP 的协议实现较快工业以太网传输。相较于传统需手动配置波特率、校验位等参数点对点串行通信，OPC UA 通过内置的地址空间编译器自动完成设备功能抽象，形成包含多元数据标签的语义化描述体系，使异构系统间数据共享效率大幅提升^[72-73]。该技术在工业场景中已形成典型部署模式：客户端应用程序通过订阅服务器端的监控项（Monitoring Items），实时获取关节扭矩、末端位姿等多维度数据流，为数字孪生系统提供高保真数据支撑。

2.4.3 构建数据通信框架

本研究提出面向工业机器人数字孪生的混合通信架构，通过融合 OPC UA 技术与工业总线协议构建分层数据传输体系，架构原理见图 2-8 所示。




图 2-8 数据通信框架原理图

该方案采用 OPC UA 主导、串行通信补充的协同机制：核心关节角度、末端位姿等参数控制数据，通过 OPC UA 信息模型实现语义化传输。系统实现层部署 KEPServerEX 工业级数据集成平台作为统一服务端，其多协议驱动引擎实现与工业机器人控制器、PLC 等设备的异构连接，数据封装符合 OPC UA 节点规范。

2.5 机器人数字孪生系统的构建

2.5.1 本系统的功能需求

（1）三维可视化。根据所搭建的数据通信，捕捉工业机器人各关节及其驱动电机实时数据，并借此驱动孪生模型，实现虚实同步和可视化。

（2）状态监测及故障诊断。借助一维数据与二维动态曲线，对工业机器人处于不同工况、沿不同轨迹运行时的状态予以监测，包括伺服状态、关节及其驱动电机运行参数、各部位温度曲线变化、电机电流与振动信号等，并基于使用故障诊断模型对其健康状态进行诊断。

（3）运行操控。依托搭建的通信系统，实现对机器人本体行为的控制，像切换运行轨迹、控启停等。

2.5.2 系统功能模块设计

本系统为了实现工业机器人运行状态监测及其参数的可视化，设置了以下功能模块：系统登陆界面（如图 2-9）、数据管理模块以及状态监测可视化模块。



图 2-9 数字孪生系统登录界面

（1）数据管理模块

在数字孪生系统中，数据管理模块起着至关重要的作用，其主要通过数据采集网络采集工业机器人的运行数据，然后对采集到的原始数据进行清洗和预处理，最后将处理后的数据进行存储，完成对系统中的各类数据进行有效的管理和处理，为数字孪生模型的构建、运行和优化提供了坚实的数据基础。

（2）状态监测可视化模块

利用数字孪生模型和孪生数据，通过用户与系统交互的界面对工业机器人的运行状态进行实时监测和可视化展示，如图 2-10 所示。通过此模块可实时查看工业机器人的健康状态、以及当前机器人电机三相电流与振动等信号时域变化波形，便于及时采取相应的维护措施。




图 2-10 工业机器人状态可视化

2.6 本章小结

首先阐述数字孪生的核心架构与多物理场建模、虚实同步、数据融合等关键技术，随后详细说明基于 Unity 的机器人数字孪生系统设计方法，包括几何模型构建与轻量化处理方法、数据通信框架的构建及系统构建。通过建立工业机器人整体模型，能够有效模拟机器人位姿变换等行为，从而更真实地反映电机的工作状态。

第3章 工业机器人电机数字孪生建模与故障分析

工业机器人电机的稳定运行是智能制造系统高效作业的核心保障，其内部机械结构的复杂性与动态负载的交互作用易诱发多种故障，导致电机性能退化甚至工业机器人停机风险。因此首先对工业机器人电机的结构特征与典型故障模式进行动力学特性分析；然后基于 Simulink 构建电机系统的数字孪生模型，生成不同故障状态的孪生数据；最后通过时频域一致性分析与峭度指标验证其与实测信号的等效性。

3.1 工业机器人电机及其故障类型分析

三相永磁同步电机（PMSM）凭借其能效优势和紧凑设计，在工业机器人中得到广泛应用，但同时其可靠性保障已成为制约工业机器人系统效能的关键瓶颈^[74]。三相 PMSM 主要由定子、转子和轴承三部分组成，一般情况下定子是由定子铁芯和三相对称绕组等组成，处于静止状态；转子由永磁体和转子转轴组成，在运行时处于旋转状态；轴承则用于支撑转子的旋转^[75]，其结构示意图如图 3-1 所示。三相 PMSM 根据其内部永磁体转子上的位置，分为表贴式和内置式两种类型，其中表贴式引起结构相比简单，成本低而被更多应用。




图 3-1 永磁同步电机结构示意图

三相 PMSM 在工业机器人中的应用虽然具有显著优势，其可靠性保障已成为制约工业机器人系统效能的关键瓶颈。其在实际运行过程中可能出现的故障，不仅会影响电机本身的正常运行，还可能导致整个机器人系统的性能下降甚至损坏，因此保证机器人电机的可靠运行十分重要。对电机可能发生的故障类进

行统计分析，具体如表 3-1 所示。

表 3-1 电机典型故障

故障部位	故障原因
定子故障	定子绕组匝间短路、接地故障
转子故障	转子不平衡，气隙偏心，永磁体故障
轴承故障	点蚀、磨损、断裂

表中，定子绕组发生的匝间短路和接地故障是电机中较为常见的电气故障之一，绕组匝间短路与接地故障会导致电机的相电流不平衡，导致电机的控制精度和运行效率受到影响。

永磁体退磁故障是三相 PMSM 特有的一种故障类型。当电机在高温环境下运行或受到外加磁场的干扰时，永磁体可能会发生退磁现象，这将直接导致电机的转矩输出能力下降，转速出现波动，甚至可能引发电机的振动和噪音异常。

轴承发生点蚀、磨损和断裂属于三相 PMSM 常发生的机械故障类型之一。其中轴承作为电机中的关键部件，支撑转子的正常运转，其损坏不仅会导致电机运行时的振动和噪音增大，还可能进一步引起电机转子产生不平衡与气隙偏心的现象，从而影响电机的性能和寿命。根据统计，大约 40%的机电驱动系统和电机故障都是由轴承损坏引起的^[76]，因此本文选择电机轴承作为电机故障诊断的研究对象。

电机轴承的种类很多，其主要包含滑动轴承、滚动轴承和关节轴承等，其中滚动轴承具有启动灵敏、摩擦阻力小、受转速负载影响小等优点，因此在工业界中得到了广泛的应用^[77]。滚动轴承的主要故障如表 3-2 所示。

表 3-2 滚动轴承常见故障

部件	常见故障
内圈	剥落、断裂、腐蚀、磨损
外圈	剥落、断裂、腐蚀、磨损
滚动体	剥落、腐蚀、磨损
保持架	腐蚀、磨损

当三相永磁同步电机滚动轴承发生故障时，就不能保证电机的稳定运行，其内部转子和定子之间的气隙距离变化，导致电机电流出现不平衡的现象。同

时，轴承会由于故障的产生，使其在高速转动过程中，状态不稳定，产生位移。因此，可以从电流与振动信号中辨别轴承发生的故障，那么后续就可以根据电机轴承电流与振动信号中的故障特征，通过神经网络故障诊断模型对三相永磁同步电机轴承进行诊断。

3.2 电机轴承结构与动力学特性

3.2.1 几何结构




图 3-2 滚动轴承结构图

轴承主要由内圈、外圈、滚动体和保持架四部分组成，内圈和外圈之间装有滚动体，其形状大多为圆珠和圆柱体，保持架均匀隔开各滚动体，使其能够圆滑的滚动^[78]，其结构图如图 3-2 所示，它们之间的关系如下所示，

$$D_m = \frac{D_i + D_o}{2} \approx \frac{D + d}{2} \quad (3-1)$$

其中， D 为轴承外径， d 为轴承内径， D_i 为轴承内滚道直径， D_o 为轴承外滚道直径， D_m 为轴承节圆直径。

3.2.2 滚动轴承动力学特性表征

由于滚动轴承动态响应特性受载荷分布、接触非线性及结构参数等多因素耦合影响，其动力学行为呈现显著非线性特征，导致难以建立普适性动力学表征模型。现有研究多采用自由度缩减策略进行模型降阶处理，典型方案包括构建二自由度模型、三自由度模型及六自由度模型^[79]，其中二自由度动力学模型被广泛于各研究，模型如图 3-3 所示。




图 3-3 滚动轴承简化模型

基于滚动轴承的二自由度简化模型，根据滚动轴承的受力平衡可建立滚动轴承的动力学方程：

$$\begin{cases} m\ddot{x} + c\dot{x} + k_x x = f_x \\ m\ddot{y} + c\dot{y} + k_y y = f_y \end{cases} \quad (3-2)$$

式中， m 为轴承等效质量， c 为轴承等效阻尼参数， x 和 y 分别为是轴承沿 X 、 Y 方向所产生的振动位移， k_x 、 k_y 分别为 x 方向和 y 方向的等效刚度， f_x 和 f_y 为作用在轴承上 X 、 Y 方向的径向力。

当滚动轴承和传动轴同时旋转时，内圈和外圈就会与滚动体发生碰撞导致轴承部件发生振动，振动如果是在一定频率范围内，那么该振动就认为是正常振动，其频率称为固有频率^[80]。轴承的固有频率不受传动轴转速的大小影响，只与其本身的材料属性、质量及形状有关，因此不同的元件其固有频率不同，滚动体的固有频率：

$$f_b = \frac{0.848}{d_r} \sqrt{\frac{E}{2\rho}} \quad (3-3)$$

式中： d_r 为滚动体直径(m)， ρ 为材料密度(kg/m^3)， E 为滚动体的弹性模量。

内、外圈的固有频率：

$$f_n = \frac{n(n^2-1)}{2\pi} \times \frac{4}{D_m^2} \sqrt{\frac{EIg}{\gamma A}} \quad (3-4)$$

式中： n 为振动阶数， $n = 2, 3, \dots$ ， E 为弹性模量， I 为轴承圈的横截面所受的惯性矩， γ 为轴承材料的密度， A 为轴承圈的横截面积。

滚动轴承在运动过程中，外圈与轴承座固定在一起，其转速为 N_o ，内圈转速 N_i ，滚动体理论转速为 N_r ，保持架理论转速为 N_c 。当外圈固定，内圈旋转时，保持架的理论转速为：

$$N_c = \frac{1}{2} \left[N_i \left(1 - \frac{d_r}{D_m} \cos \alpha \right) + N_o \left(1 + \frac{d_r}{D_m} \cos \alpha \right) \right] \quad (3-5)$$

Z 则滚动体的理论转速可以计算出为：

$$N_r = \frac{D_m}{2d_r} (N_i - N_o) \left[1 - \left(\frac{d_r}{D_m} \right)^2 \cos^2 \alpha \right] \quad (3-6)$$

在滚动轴承运行过程中，由于滚动体位置不断变化，会使内外圈滚道与滚动体接触位置发生局部接触变形而产生振动，可以分析振动的变化情况，假设滚动体匀速转动，则第 j 个滚动体在 t 时刻的方位角 φ_j 为：

$$\varphi_j = \varphi_0 + \omega_c t + \frac{2\pi(j-1)}{N} \quad (3-7)$$

其中， φ_0 为滚动体的初始方位角， ω_c 为保持架转动角速度。

滚动轴承在转动过程中，滚动体与内外圈之间接触会产生形变 δ_j ，变形量可表示为：

$$\delta_j = x \sin \varphi_j + y \cos \varphi_j - C_r \quad (3-8)$$

其中， C_r 为滚动轴承径向游隙。

当滚动轴承在外圈、内圈和滚动体任一处发生缺陷故障，滚动体陷入故障缺陷区域时，接触形变发生变化，可描述为：

$$\delta_j = x \sin \varphi_j + y \cos \varphi_j - C_r - H \quad (3-9)$$

其中， H 为滚动轴承陷入缺陷区域的距离（m）。

当外圈存在故障缺陷时， H 计算公式为：

$$H = \begin{cases} 0, & \cos(\theta_i - \varphi_o) < \cos\left(\frac{\psi_o}{2}\right) \\ \frac{d_r}{2} - \sqrt{\left(\frac{d_r}{2}\right)^2 - \left(\frac{w}{2}\right)^2}, & \cos(\theta_i - \varphi_i) > \cos\left(\frac{\psi_o}{2}\right) \end{cases} \quad (3-10)$$

其中， w 为缺陷宽度， φ_o 为外圈却显得角位置， ψ_o 为外圈缺陷对应的角宽度。

当内圈存在故障缺陷时， H 计算公式为：

$$H = \begin{cases} 0, & \cos(\theta_i - \varphi_o) < \cos\left(\frac{\psi_o}{2}\right) \\ \frac{d_r}{2} - \sqrt{\left(\frac{d_r}{2}\right)^2 - \left(\frac{w}{2}\right)^2}, & \cos(\theta_i - \varphi_i) > \cos\left(\frac{\psi_o}{2}\right) \end{cases} \quad (3-11)$$

其中， w 为缺陷宽度， φ_i 为内圈却显得角位置， ψ_i 为内圈缺陷对应的角宽度。

当滚动轴承发生故障损伤时，损伤点与其他部件产生周期性碰撞，导致轴承系统表现出振荡，被称为故障特征频率，不同型号轴承的故障特征频率也不

相同的^[81]，其故障特征频率的理论计算公式如下：

滚动轴承内圈故障特征频率：

$$f_i = \frac{1}{2} m f_n \left(1 + \frac{d}{D} \cos \alpha \right) \quad (3-12)$$

2)滚动轴承外圈故障特征频率：

$$f_o = \frac{1}{2} m f_n \left(1 - \frac{d}{D} \cos \alpha \right) \quad (3-13)$$

3)滚动体的故障特征频率：

$$f_b = \frac{1}{2} f_n \left[1 - \left(\frac{d}{D} \cos \alpha \right)^2 \right] \frac{D}{d} \quad (3-14)$$

式中， D 为轴承节圆直径， d 为滚动体直径， α 为接触角， m 为滚动体个数。

3.3 电机系统数字孪生建模

3.3.1 物理试验台搭建

为了复现工业机器人电机的实际运行工况，并采集振动与电流多源数据，本章节通过搭建电机轴承故障模拟试验台，采集不同状态下的轴承信号，试验台如图 3-4 所示，包括驱动电机、振动盘、齿轮箱、磁粉制动器、制动器控制器、传感器。




图 3-4 电机性能测试试验台

试验台中将振动传感器放置在测试轴承座上，位于测试轴承 12 点方向，振动传感器为压电式传感器，其具体参数如表 3-3，利用数据采集系统进行振动信号的采集。所采用的测试轴承型号为 6005-2RS SKF，并通过线切割的方式分别在外圈设置 0.2mm 的故障，在内圈上人为设置 1mm 与 5mm 大小的 2 种故障，

如图 3-5 示。转速设置为 1000rpm，在健康电机、内圈故障 1mm 裂纹、内圈故障 5mm 裂纹与外圈故障裂纹的情况下获取电机实测振动与电流信号。

表 3-3 振动传感器参数

类型	内容	类型	内容
型号	SAED0005	重量 g	28
灵敏度 mV/g	100	壳体材料	不锈钢
横向灵敏度比%	<5	压电材料	陶瓷
量程范围 g	50	结构形式	剪切
分辨率 mg rms	1	输出极性	正极
频率范围(± 1dB)Hz	0.5~6K	绝缘电阻 Q	>10°
工作温度℃	-20~120	输出方式	顶端 L5



(a) 外圈故障



(b) 内圈 1mm 故障



(c) 内圈 5mm 故障

图 3-5 轴承故障设置示意图

3.3.2 基于 Simulink 构建电机轴承孪生模型

MATLAB 作为数学计算和工程仿真软件，提供了强大的数值计算能力与丰富的工具箱和函数库。本节将根据所搭建的试验台基于 Simulink 来构建电机-轴承数字孪生模型，以模拟电机轴承的运行状态。

对于试验台电机使用的是基于 PI 调节器的 PMSM 矢量控制，那么可以直接使用 Simulink 中已有的 PMSM 模块，根据电机的定子电感、转动惯量及极对数等参数对其设置，如图 3-6。

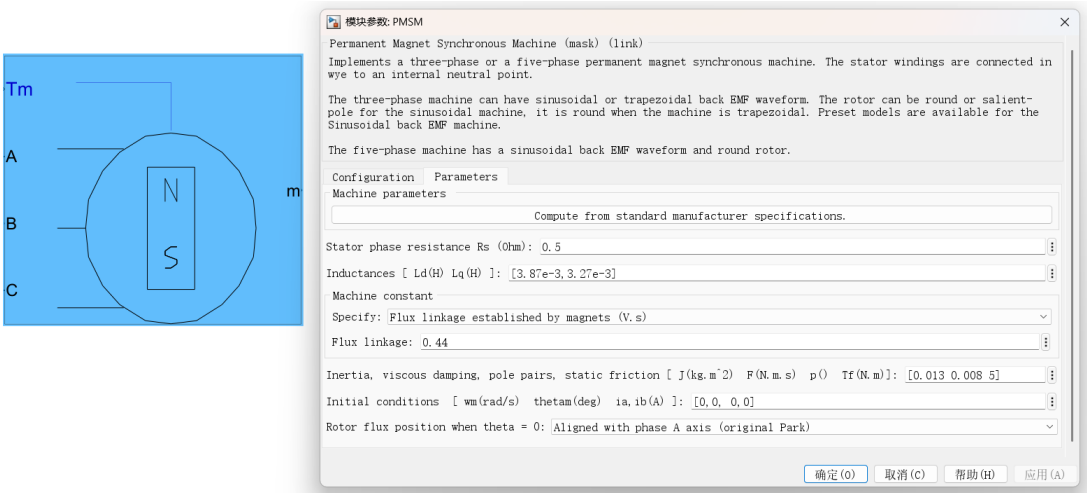


图 3-6 PMSM 模块参数设置

完成后，对电机实验条件转速和负载扭矩进行设置，分别如图 3-7 和图 3-8 所示。




图 3-7 负载扭矩的参数设置

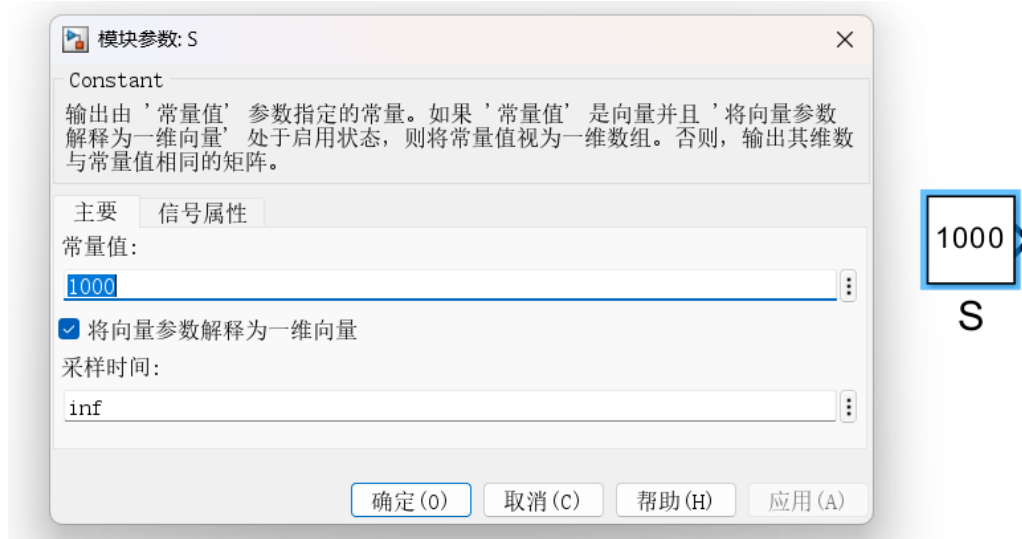



图 3-8 电机转速参数设置



3.4 数据一致性分析

3.4.1 时域对比分析

信号和其对应孪生信号进行对比分析，分别如图 3-10 与图 3-11 所示




图 3-10 滚动轴承实测与孪生振动信号时域波形




图 3-11 滚动轴承实测与孪生电流信号时域波形

从时域图中，无法直观比较孪生信号和实测信号之间的一致性，因此本文选取波形指标、脉冲指标、裕度指标和峭度指标等时域统计指标进行分析验证，表达式如表 3-4 所示。

表 3-4 时域统计特征

波形指标	脉冲指标	裕度指标	峭度指标
$x_s = \frac{x_{rms}}{ \bar{X} }$	$x_l = \frac{x_{max}}{ \bar{X} }$	$x_M = \frac{x_{max}}{X_r}$	$x_K = \frac{\frac{1}{n} \sum_{i=1}^n x_i^4}{X_{rms}^4}$

注： x_{rms} 为信号均方根， $|\bar{X}|$ 为信号绝对均值， x_{max} 为信号峰值， X_r 为信号方根幅值。

其中，波形指标用于反映信号的波形特征，脉冲指标用于检测信号冲击的严重程度，裕度指标可以反映设备的故障程度，峭度指标可以反映信号的冲击特征^[82]。

将图中的实测和孪生信号分别随机截取 10 段，由于振动信号与电流信号的

采样频率不同，因此电流信号每段数据点长度为 2000，振动信号每段数据点长度为 25600，对处理后的样本进行时域统计特征分析并取平均值，经过计算实测信号和孪生信号的时域统计指标值及其相对偏差如表 3-5 与表 3-6 所示。

表 3-5 振动实测和孪生信号时域统计指标计算值及其相对偏差

缺陷部位	类型	波形指标	脉冲指标	裕度指标	峭度指标
正常	实测	1.034	0.548	5.341	3.333
	孪生	1.068	0.545	5.311	3.369
	相对偏差(%)	3.29	0.54	0.56	1.08
外圈	实测	1.146	1.78	18.15	3.504
	孪生	1.186	1.765	18.204	3.512
	相对偏差(%)	3.49	0.84	0.3	0.23
内圈 1mm	实测	1.08	1.096	10.412	3.4
	孪生	1.061	1.105	10.507	3.425
	相对偏差(%)	1.76	0.82	0.91	0.74
内圈 5mm	实测	1.193	4.384	42.969	4.777
	孪生	1.185	4.591	42.547	4.558
	相对偏差(%)	0.67	4.72	0.989	4.58

表 3-6 电流实测和孪生信号时域统计指标计算值及其相对偏差

缺陷部位	类型	波形指标	脉冲指标	裕度指标	峭度指标
正常	实测	1.258	4.753	23.647	3.649
	孪生	1.328	4.999	23.881	3.727
	相对偏差(%)	5.56	5.18	0.99	2.14
外圈	实测	1.247	4.618	22.349	3.527
	孪生	1.335	4.64	22.683	3.578
	相对偏差(%)	7.06	0.48	1.5	1.45
内圈 1mm	实测	1.397	4.537	11.643	3.472
	孪生	1.332	4.702	11.385	3.649
	相对偏差(%)	4.65	3.64	2.22	5.1
内圈 5mm	实测	1.388	4.627	11.796	3.928
	孪生	1.335	4.836	11.414	3.663
	相对偏差(%)	3.82	4.52	3.24	6.75

经过计算得出，上述四种时域统计指标在孪生数据和实测数据之间的相对

偏差较小，最大相对偏差为外圈信号的波形指标，达到 7.06%，处于合理的偏差范围^[83]，而造成孪生信号和实测信号间存在相对偏差的原因如下：数据采样窗口的非平稳性特征导致统计量波动；模型未完全涵盖轴承游隙离散性、装配误差等微观工况要素。总体上，孪生信号与实测信号具有高度的一致性。

3.4.2 概率密度对比分析

由于受模型简化误差，导致电机故障轴承的孪生信号和实际信号的概率分布存在差异而不完全一致。本文通过构建基于核密度估计（KDE）的概率分布相似性评估模型，如式（3-15），对比分析实测信号和孪生信号在不同范围内的分布情况，孪生和实测振动信号概率密度分布如图 3-12 所示。

$$P(x) = \lim_{\Delta x \rightarrow 0} \frac{P[x < x(i) < x + \Delta x]}{\Delta x} \quad (3-15)$$

式中， $x(i)$ 为振动信号幅值，落在 x 和 $x + \Delta x$ 区间




图 3-12 滚动轴承在不同健康状态下的概率密度分布图

从图轴承在不同健康状态下的概率密度分布图可以看出，正常轴承的孪生和实测数据的相似度很高，而由于故障轴承在实际运行过程中存在各种随机因素，导致故障轴承的孪生和实测数据会存在一定的差异^[84]，但是可有效替代实测信号进行后续故障诊断研究。

3.5 本章小结

本章主要首先对工业机器人电机类型和主要故障分布进行分析，选择对主要故障多发处的轴承进行故障诊断；然后根据电机及其轴承参数使用 Simulink 构建电机轴承的数字孪生模型，生成与不同故障类型所对应的孪生信号，并通过时域与概率密度分析对孪生信号和实测信号进行一致性对比，验证了孪生信号的可用性和有效性。本章为后续故障诊断算法的设计与验证提供了可靠的数据支撑，下一章将基于此数据开发深度学习模型，实现故障类型的精准分类与状态评估。

第4章 基于卷积注意力时序网络模型的电机轴承故障诊断

在第三章中已经验证孪生数据可以代替实测数据进行电机轴承的故障诊断。本章节将使用第三章中的孪生数据进行后续电机轴承故障诊断。首先根据对孪生数据进行预处理，并提取孪生数据的特征；其次构建 CATN 故障诊断模型；最后，基于孪生数据故障特征对电机轴承进行故障诊断，并与其他常用网络模型进行对比分析。

4.1 数据预处理

在基于神经网络的故障诊断模型中，数据预处理与特征选择是确保模型有效性和准确性的关键步骤。因此，首先需要对电机轴承电流与振动的孪生数据采用中位数鲁棒插补法，处理缺失值；基于最小-最大归一化原理，将数据线性映射至[0,1]空间中，如式（4-1）：

$$x' = \frac{x - x_{min}}{x_{max} - x_{min}} \quad (4-1)$$

其中： x' 是归一化处理后的值； x 是原始值； x_{min} 和 x_{max} 分别是原始数据集中的最小值与最大值。

4.2 信号故障特征提取

信号故障特征提取在工业设备状态监测中具有多重必要性：首先，通过数据降维与信息浓缩，可从振动、电流等原始信号中滤除噪声与非敏感频段冗余信息，提取与故障强相关的关键参数（如峭度、特征频率幅值），显著降低后续诊断模型的计算复杂度；其次，基于故障物理机理的特征表征与模式区分能够量化不同故障类型的独特模式（如周期性冲击对应轴承剥落、谐波畸变反映绕组短路），实现正常与异常状态的可解释性分类；此外，特征提取通过聚焦故障敏感指标，可有效抑制负载波动、转速变化等工况干扰，提升诊断模型在复杂工业场景下的泛化鲁棒性；最终，在数字孪生框架下，特征提取构建了物理实体与虚拟模型间的统一健康指标，通过故障特征与孪生数据的精准映射，为虚实交互提供可量化、可追溯的决策依据，从而实现故障机理-数据-模型的高效闭环验证。

但是，由于振动信号于电流信号的频率范围、时域表现以及敏感故障类型的不同，因此对于振动信号于电流信号的故障特征常常采用不同的提取方法。

4.2.1 振动信号故障特征提取

(1) 希尔伯特变换

希尔伯特变换是一种时域卷积操作，它可以将一个实值时间信号转换为虚函数，并对信号的幅度和相位进行分离分析^[85]，如式（4-2）：

$$H[x(n)] = \frac{1}{\pi} \int_{-\infty}^{+\infty} \frac{x(\tau)}{n-\tau} d\tau \quad (4-2)$$

其中， $x(n)$ 是离散时域振动信号， $H[x(n)]$ 通过形成称为分析信号 $A[x(n)]$ 的复值时域信号来实现解调，该信号定义为：

$$A[x(n)] = x(n) + iH[x(n)] = a(n)e^{i\varphi(n)}, i = \sqrt{-1} \quad (4-3)$$

其中，

$$a(n) = \sqrt{x^2(n) + H^2[x(n)]} \quad (4-4)$$

和，

$$\varphi(n) = \arctan \frac{H[x(n)]}{x(n)} \quad (4-5)$$

$a(n)$ 和 $\varphi(n)$ 分别是复值时间信号 $A[x(n)]$ 的幅度和相位。

(2) 傅里叶变换

傅里叶变换（FT）将一个连续时间函数或离散时间序列转换成一个复数函数或复数序列^[86]。反之，傅里叶逆变换可把将复数函数或复数序列转换成原始的函数或序列，其基本变换原理如下，假设存在一个连续信号 $f(t)$ ：

$$F(\omega) = F[f(t)] = \int_{-\infty}^{+\infty} f(t)e^{-j\omega t} dt \quad (4-6)$$

$$f(t) = F^{-1}[F(\omega)] = \frac{1}{2\pi} \int_{-\infty}^{+\infty} f(\omega)e^{j\omega t} d\omega \quad (4-7)$$

使用傅里叶变换处理离散信号，将一个长度为 N 的信号拆分成两个长度为 $\frac{N}{2}$ 的子信号，同时计算复杂度也从 $O(N^2)$ 变成了 $O(N\log N)$ 。

4.2.2 电流信号特征提取方法

短时傅里叶变换^[87]是针对传统傅里叶变换在非线形信号分析中的局限性提出的改进型数字信号处理方法。传统傅里叶变换仅能提取信号的全局频域特征，且对非平稳信号适应性不足，而STFT通过时域加窗的分段处理机制，实现了信

号的时频联合分析。其技术原理是采用可移动的有限长窗函数对信号进行截取，将连续信号离散化为若干时域片段，并对每个片段独立实施傅里叶变换。这种处理方式不仅保留了各时间窗内的频域特征，还可通过窗函数滑移构建时频二维分布图，直观呈现信号频率成分随时间演变的动态特性。由此形成的时频矩阵可有效揭示非平稳信号的瞬态特征，为机械故障诊断、语音信号处理等领域提供多维度的分析依据^[88]。假设信号为 $x(n)$ ，则 STFT 的数学公式表达为：

$$X(m, \omega) = \sum_{n=0}^{N-1} x(n) \times \omega(n-m)e^{-j\omega n} \quad (4-8)$$

其中， $x(n)$ 为原始信号， $\omega(n-m)$ 为窗函数， m 为时间窗口的索引， ω 为频率， n 为窗口长度。输出 $X(m, \omega)$ 表示第 m 个时间窗口在频率 ω 处的幅度和相位信息。

当窗函数恒定为 1 时，短时傅里叶变换可以转换成傅里叶变换，若令

$$\omega(n-m)e^{-j\omega n} = g_{n,w}(\tau) \quad (4-9)$$

则公式（4-8）可转化为：

$$X(m, \omega) = \sum_{n=0}^{N-1} x(n) = g_{n,w}(\tau) \quad (4-10)$$

在工业机器人故障诊断中，电流与振动数据作为重要的传感信息，电流数据能够反映机器人电动机的工作负荷与电流波动，而振动数据则提供了设备运动过程中机械结构的动态响应特征。因此需要提取能够有效表征系统状态的时序信息，以提高故障诊断的准确性与可靠性。完成特征提取之后，分别得到电机滚动轴承在健康、外圈故障与内圈(1mm, 5mm)故障状态下的电流孪生数据故障特征向量矩阵 T_1 与振动孪生数据故障特征向量矩阵 T_2 ，使用公式（4-11）进行融合，组成故障特征向量库 T_i ，

$$T_i = [T_1 T_2] \quad (4-11)$$

然后电机轴承不同的故障类型，设置类别标签为 1、2、3、4，分别与电机滚动轴承的健康、外圈故障、内圈 1mm 与 5mm 故障共 4 种故障类型像对应，用于后续故障诊断模型的输入。

4.3 卷积注意力时序网络（CATN）诊断模型构建

4.3.1 神经模型与算法的基本理论

（1）卷积神经网络

卷积神经网络（CNN）由于其特征表示和提取能力方面的优异表现，在图像识别、分类等领域中得到广泛应用，卷积神经网络通过滤波级提取输入信号

的特征，再由分类级对学习到的特征进行分类^[89]，其结构如图 4-1 所示。




图 4-1 卷积神经网络结构图

卷积层使用卷积核来对上一层输入的局部区域进行卷积运算，并得到相应的特征。卷积层主要的两个特征是局部连接和权值共享^[90]，局部连接即卷积层节点仅仅连接到其前一层的部分节点，学习局部特征的同时，还极大减少参数数量，加快了学习速率；权值共享就是将同一个卷积核按照固定的步长遍历一次输入，并对网络层参数数量进一步优化减少，减少了系统所需要的内存，降低了过拟合的风险。对于输入特征 $X \in R^{C_{in} \times H \times W}$ 和卷积核 $W \in R^{C_{out} \times C_{in} \times K_H \times K_W}$ ，则输出特征 $Z \in R^{C_{out} \times H' \times W'}$ 卷积运算如式：

$$Z_k(i, j) = \sum_{c=1}^{C_{in}} \sum_{u=1}^{K_H} \sum_{v=1}^{K_W} W_k(c, u, v) \cdot X_c(i \cdot s + u - p, j \cdot s + v - p) + b_k \quad (4-12)$$

其中， $Z_k(i, j)$ 为第 k 个滤波器的输出在位置 (i, j) 的值； W_k 为第 k 个滤波器的权重矩阵，尺寸为 $C_{out} \times C_{in} \times K_H \times K_W$ (K_H, K_W 为卷积核大小)； s 为步长，用于控制滑动步幅； p 为填充，用于调整输出尺寸； b_k 为第 k 个滤波器的偏置项。

激活层的主要功能是将前一层神经元的输出通过激活函数进行非线性变换，使得神经网络能够学习到更加复杂的模式和特征，显著增强了深度神经网络的表征能力。其核心作用体现在：将原始特征空间进行非线性重构，使网络能够构建分层递进的特征抽象体系。这一特性有效克服了传统线性网络结构的固有局限—单纯依靠线性组合无法有效建模现实世界中普遍存在的复杂非线性数据分布规律，从而极大拓展了神经网络对高维非线性关系的拟合能力。



图 4-2 激活函数示意图

三类典型激活函数如图 4-2 所示。其中 Sigmoid 函数使用最多，其优势是函数具有对称特性且输出介于 0, 1 之间。但该函数存在两个缺陷：其一，当输入绝对值增大时，导数趋近于零，梯度趋于饱和，训练过程中的梯度信号逐层衰减；其二，输出均值偏离零点，影响参数更新效率。Tanh 函数虽实现输出中心化，值域为[-1,1]，但仍存在与 Sigmoid 类似的梯度消失问题对于。对于 ReLU 函数而言，当输入值大于 0 时，其导数值始终为 1，避免了梯度消失的现象发生。

池化层在卷积层之后，用于对卷积层提取的特征进行下采样，以降低特征图的维度，实现降维、去除冗余信息、压缩特征、减少计算量并增强模型的鲁棒性和泛化能力。常见的池化函数是均值池化（ P_{AP} ）和最大值池化（ P_{MP} ）。

均值池化计算池化窗口内所有像素值的平均值，并将该平均值作为池化后对应位置的像素值，表达式如下：

$$P_{AP}(i, j) = \frac{1}{K_H \times K_W} \sum_{u=1}^{K_H} \sum_{v=1}^{K_W} X(i \cdot s + u, j \cdot s + v) \quad (4-13)$$

均值池化保留了局部区域的平均信息，对局部区域的整体特征进行概括。

最大值池化选取池化窗口内像素值的最大值，并将该最大值作为池化后对应位置的像素值，表达式如下：

$$P_{MP}(i, j) = \max_{u=1}^{K_H} \max_{v=1}^{K_W} X(i \cdot s + u, j \cdot s + v) \quad (4-14)$$

最大值池化保留了局部区域的最显著特征，突出局部区域中的关键信息。

全连接层是神经网络中实现分类功能的核心结构。在前端特征抽取结构中，卷积操作和池化处理将原始输入转化为高维特征表示，随后全连接层通过层级变换完成特征空间到类别空间的非线性映射。其技术实现过程包含两个关键步骤：首先将末端池化层生成的高维特征张量进行向量化处理，形成低维特征序

列；继而通过前馈连接建立输入单元与输出节点之间的非线性关联，最终实现模式分类的决策功能。

(2) 长短期记忆网络

长短期记忆网络（Long Short-Term Memory, LSTM）作为循环神经网络的改进架构，通过引入门控机制和细胞状态设计，有效缓解了传统 RNN 在长距离信息传递中存在的梯度异常问题。该模型通过选择性记忆与遗忘机制，克服了早期序列模型在时序关联特征捕捉方面的局限性，显著提升了神经网络对长程依赖关系的建模能力^[91-92]，其网络结构如图 4-3 所示。




图 4-3 LSTM 网络结构图

LSTM 神经网络主要由遗忘门、输入门和输出门组成，各个门状态可由公式（4-15）-公式（4-20）计算：

$$f_t = \sigma(W_{x_t, f_t} x_t + W_{h_{t-1}, f_t} h_{t-1} + W_{C_{t-1}, f_t} C_{t-1} + b_{f_t}) \quad (4-15)$$

$$i_t = \sigma(W_{x_t, i_t} x_t + W_{h_{t-1}, i_t} h_{t-1} + W_{C_{t-1}, i_t} C_{t-1} + b_{i_t}) \quad (4-16)$$

$$g_t = \sigma(W_{x_t, g_t} x_t + W_{h_{t-1}, g_t} h_{t-1} + W_{C_{t-1}, g_t} C_{t-1} + b_{g_t}) \quad (4-17)$$

$$C_t = f_t \odot C_{t-1} + i_t g_t \quad (4-18)$$

$$o_t = \sigma(W_{x_t, o_t} x_t + W_{h_{t-1}, o_t} h_{t-1} + W_{C_t, o_t} C_t + b_{o_t}) \quad (4-19)$$

$$h_t = o_t \cdot \tanh(C_t) \quad (4-20)$$

其中， x_t 为输入单元， h_t 为输出单元， f_t 为遗忘门状态， i_t 为输入门状态， o_t 为输出门状态， C_t 为细胞状态， g_t 为候选细胞状态， W 为权重系数， b 为偏置系数， $\sigma()$ 代表sigmoid函数，如下式所示：

$$\text{sigmoid} = \frac{1}{1+e^{-x}} \quad (4-21)$$

sigmoid 函数作为神经网络常用的阈值函数，将变量映射到 0 与 1 之间。

$\text{Tanh}()$ 代表双曲正切函数，如下式所示：

$$\text{tanh}x = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (4-22)$$

双曲正切函数定义域为开区间 $(-1,1)$ ，它在开区间 $(-1,1)$ 内是单调增加的奇函数。

(3) 注意力机制

在神经网络架构演进过程中，生物感知系统的启发性设计为平衡计算效率与特征表达能力提供了重要思路。人脑认知系统面临信息过载时，通过注意力机制^[93]（Attention Mechanism, AM）实现信息筛选：抑制冗余信号的同时强化关键信息处理，这一特性为深度学习模型优化提供了参考，即忽略无用信息，只关注重要信息。当神经网络面对高维输入时，可模拟生物神经系统的注意力选择机制——在计算资源受限条件下，优先分配算力处理具有显著特征的数据子集，从而实现高效信息加工。

相较于传统 CNN 的局部感受野限制和 LSTM 的时序门控特性，注意力机制通过动态权重学习实现了更优的全局特征建模能力。注意力机制通过动态生成的特征权重，在空间或通道维度对输入特征实施自适应加权处理，以此强化关键信息区域的表征能力^[94]。该机制基于神经网络自学习获得的参数矩阵，在特征图的通道或空间层面执行权重分配，进而实现对不同特征区域的差异化聚焦。其核心在于通过可学习的权重系数，自主调整特征图中各单元的重要性权重，从而提升模型对关键特征成分的捕捉能力。

注意力机制通常选用“查询-键-值”的模式生成不同连接之间的权重^[95]。现假设给定一组输入数据 $X = \{x_1, x_2, \dots, x_N\}$, $x \in R^{D_x \times 1}$ ，首先具体先将每一个输入数据样本 x_i ，通过线性映射分别获得查询向量 $q_i \in R^{D_x \times 1}$ 、键向量 $k_i \in R^{D_k \times 1}$ 和值向量 $v_i \in R^{D_v \times 1}$ ，其原理如图 4-4 所示。




图 4-4 注意力机制结构图

其映射过程如下：

$$Q = W_q X \in R^{D_k \times N} \quad (4-23)$$

$$K = W_k X \in R^{D_k \times N} \quad (4-24)$$

$$V = W_v X \in R^{D_v \times N} \quad (4-25)$$

式中 $W_q \in R^{D_k \times D_x}$ 、 $W_k \in R^{D_k \times D_x}$ 和 $W_v \in R^{D_v \times D_x}$ 分别为查询向量 q 、键向量 k 和值向量 v 的线性映射函数的参数矩阵； $Q = [q_1, q_2, \dots, q_N]$ 、 $K = [k_1, k_2, \dots, k_N]$ 和 $V = [v_1, v_2, \dots, v_N]$ 分别为查询向量 q 、键向量 k 和值向量 v 构成的矩阵。

注意力机制使用键对值 $(K, V) = [(k_1, v_1), (k_2, v_2), \dots, (k_N, v_N)]$ 的模式来表示输入数据信息，其中键向量 k 用来计算注意力分布 α_n ，值向量 v 用来计算聚合信息。对于每一个任务相关的查询向量 $q_n \in Q$ 时，通过式 (4-26) 注意力函数可以获得输出向量 h_n ：

$$\begin{aligned} h_n &= \text{att}((K, V), q_n) \\ &= \sum_{j=1}^N \alpha_{nj} v_j \\ &= \sum_{j=1}^N \text{softmax}(a(q_n, k_j)) v_j \end{aligned} \quad (4-26)$$

式中， n 与 j 分别为输出和输入向量的索引， α_{nj} 为第 n 个输出对应第 j 个输入的注意力权重， $a(\cdot)$ 为注意力评估函数。

注意力机制的评分函数根据设计差异对应不同的特征聚合策略，其中加性模型与点积模型为两种基础函数。当查询向量与键向量的维度存在差异时，加性模型评分函数因其参数化投影机制展现出更强的适应性，具体表现为通过可

学习的权重矩阵将不同维度的向量映射到统一隐空间，从而建立有效的跨模态关联计算。该机制通过调节隐层空间维度参数，能够灵活处理多维特征间的非线性关系，最终形成具有空间适应性的注意力权重分布。其计算公式如式（4-27）所示：

$$a(x, q) = v^T \tanh(W_q + U_k) \quad (4-27)$$

其中， W 、 U 和 v 均为可学习参数。由式可知加性模型依赖多层感知机的非线性变换，需逐元素计算，计算复杂。然而点积模型可以直接利用矩阵乘积，有效提高了计算效率，其计算公式如式（4-28）所示：

$$a(q, k) = k^T q \quad (4-28)$$

但是当输入向量维度较高时，那么点积模型的计算结果就会出现方差较大的现象，进而会使 Softmax 函数梯度变小。因此在点积运算基础上，将查询向量 q 和键向量 k 之间相似度计算结果缩小 $\sqrt{D_k}$ 倍就得到了缩放点积模型，其措施有效解决了结果方差较大的现象，缩放点积模型计算公式如式（4-29）：

$$a(q, k) = \frac{k^T q}{\sqrt{D_k}} \quad (4-29)$$

当采用缩放点积作为注意力评分函数时，输出数据 H 可通过式（4-30）计算获得，

$$H = V \text{softmax} \left(\frac{K^T Q}{\sqrt{D_k}} \right) \quad (4-30)$$

4.3.2 卷积注意力时序网络故障诊断模型构建

CNN 能够通过卷积核捕捉数据中的局部空间特征，适用于提取信号中的局部模式和趋势，LSTM 用于处理时间序列数据，并通过门控机制控制信息的流动，避免梯度消失问题。本文通过结合以上两者优势，并融入注意力机制，通过权重加权，构建 CATN 诊断模型，增强模型对重要特征的关注，有效地提升了故障诊断的准确性和效率，网络模型框架如图 4-5 所示。




图 4-5 卷积注意力时序网络模型框架图

假设输入为二维特征矩阵，其维度为： $X \in R^{B \times H \times W \times D}$ ，其中 B 为批量大小， H 为特征矩阵的高度， W 为特征矩阵的宽度， D 为输入通道数。

通过卷积层对输入特征矩阵进行局部空间特征提取：

$$H_{conv}^{t,i,j,c} = \text{ReLU} \left(\sum_{k_h=0}^{K_h-1} \sum_{k_w=0}^{K_w-1} W_{conv}[k_h, k_w, d, c] * X^{t,i+k_h,j+k_w,d} + b_{conv}^c \right) \quad (4-31)$$

其中， $W_{conv} \in R^{K_h \times K_w \times D \times C}$ 为卷积核权重， K_h ， K_w 为卷积核的高度和宽度， C 为输出通道数； $b_{conv} \in R^C$ 为偏置项。输出特征维度为 $H_{conv} \in R^{B \times H' \times W' \times C}$ ，经过全局池化层：

$$H_{GAP}^{t,c} = \frac{1}{H'W'} \sum_{i=1}^{H'} \sum_{j=1}^{W'} H_{conv}^{t,i,j,c} \quad (4-32)$$

$$H_{GMP}^{t,c} = \max_{i,j} H_{conv}^{t,i,j,c} \quad (4-33)$$

与池化融合：

$$H_{fusion} = \text{Concat}(H_{GAP}, H_{GMP}) \quad (4-34)$$

特征序列 $H_{fusion} \in R^{B \times H'' \times W'' \times C}$ 输入可通过注意力权重计算，

$$e_t = v_a^t \tanh(W_a h_t + U_k) \quad (4-35)$$

$$\alpha_t = \frac{\exp(e_t)}{\sum_{k=1}^T \exp(e_k)} \quad (4-36)$$

$$c = \sum_{t=1}^T \alpha_t h_t \in R^{B \times H} \quad (4-37)$$

输入到LSTM中更新，最后输出为：

$$y_{pred} = \text{Softmax}(W_f c + b_f) \quad (4-38)$$

通过在 CNN-LSTM 模型中引入通道注意力和空间注意力机制，模型能够更有效地提取和利用故障特征，从而提高故障诊断的准确性和鲁棒性。

Attention 机制的引入使得模型在关注序列中重要信息时具有更高的灵活性和选择性。通常在时间序列数据中，某些时间点的数据可能对故障诊断有更大的影响，而传统 LSTM 只能对整个序列进行均匀关注，导致信息忽视或冗余。因此，在构建 CATN 模型时，首先利用卷积层对输入的原始传感器数据进行特征提取，通过多个卷积层的堆叠，逐层提取更具抽象性的特征，并通过池化层减少数据维度。然后，将提取出的特征输入到 Attention 机制中，通过得分计算为各个时间步赋予不同的权重，从而增强与故障诊断相关的信息。

在特征提取和权重计算完成之后，Attention 机制输出的加权特征作为 LSTM 网络的输入。最后一个 LSTM 隐层的输出将通过全连接层进行分类，以确定工业机器人所处的健康状态或故障类型。

4.4 故障诊断流程

基于 CATN 模型，针对滚动轴承故障的详细诊断流程如图 4-6 所示：

(1)数据获取。同步获取物理传感数据与孪生数据。然后对孪生数据和实测数据一行对比分析，验证其可作为有效替代实测数据进行模型训练与故障诊断。

(2)数据预处理。采用 Hilbert 和短时傅里叶变化分析提取振动与电流孪生数据故障特征并进行特征融合，对融合后的数据按照对应工况分别添加标签，得到完整的多分类数据集。最后，将数据集划分为训练样本和测试样本。

(3)训练神经网络。先初始化网络模型参数；然后，将预处理所划分的训练样本输入到网络中进行训练，训练完成后保存模型参数。

(4)故障诊断。利用预处理后的测试样本对优化了模型参数的诊断模型进行测试，从而输出诊断结果。




图 4-6 诊断流程图

4.5 模型验证与对比

4.5.1 实验样本设置

对处理后的孪生数据集，划分如表 4-1 所示，其包括健康、外圈、内圈 1mm 与内圈 5mm 共 4 种不同故障类型下的数据信号和与故障类型对应的标签，并将数据集分为训练集与测试集。

表 4-1 训练及测试样本分布

故障类型	类型标签	训练集样本数	测试集样本数
健康	1	75	25
外圈	2	80	20
内圈 1mm	3	79	21
内圈 5mm	4	79	21

4.5.2 实验环境设置

本实验所用的计算机配置参数如表 4-2 所示。

表 4-2 故障诊断实验条件

序号	故障诊断试验条件	配置参数
1	中央处理器（CPU）	AMD Ryzen7 7735H
2	CPU 主频	3.20 GHz
3	操作系统	Windows 11 操作系统
4	显卡	RTX 4060 Laptop GPU
5	编程计算软件	MATLAB R2022a

4.5.3 性能参数指标

在基于神经网络的故障诊断模型中，准确率、精确率和召回率是评估模型性能的重要指标。准确率是指所有样本中被正确分类的样本数，其计算公式为：

$$Accuracy = \frac{TP+TN}{TP+TN+FP+FN} \quad (4-39)$$

其中，TP 代表模型正确预测为正类的样本数；TN 代表模型正确预测为负类的样本数；FN代表模型错误预测为负类的样本数；FP代表模型错误预测为正类的样本数。

精确率是指判断为正类的样本中，实际为正类的比例，用以衡量模型分类的正确性，其计算公式为：

$$Precision = \frac{TP}{TP+FP} \quad (4-40)$$

高精确率说明模型能够正确识别大部分样本，有效降低误报率。但在不平衡数据集的情况下，精确率可能无法全面反映模型的有效性，因此需要与其他评估指标结合使用。

召回率是指所有实际为正类的样本中，正确判断为正类的比例，用以衡量模型对故障样本的识别能力，其计算公式为：

$$Recall = \frac{TP}{TP+FN} \quad (4-41)$$

高召回率意味着模型能够成功识别并捕捉到大多数故障样本。这对于工业机器人健康状态监测尤为重要，因为漏报可能导致严重的安全隐患和经济损失。因此，精确率与召回率的权衡是模型评估中的关键问题，往往需要通过 F1 值来综合考量，即

$$F1 = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (4-42)$$

4.5.4 结果与对比分析

采用 CATN 故障诊断网络模型进行的故障诊断，基于数据样本集获得的诊断准确率为 97.0149%，如图 4-7 所示。




图 4-7 CATN 测试样本故障诊断准确率与混淆矩阵图

在本研究中，为验证所构建的基于神经网络的故障诊断模型的有效性，我们将 CATN 模型的诊断结果与现有的故障诊断方法进行了对比，包括 CNN、LSTM 及 CNN-LSTM。




图 4-8 不同模型准确率对比图

由图 4-8 可知，本文使用的 CATN 故障诊断模型的准确率达到 97.05%，相比单一神经网络 CNN 与 LSTM，准确率分别高 7.97% 和 2.49%；注意力机制的引入，使得模型准确率比 CNN-LSTM 融合模型的诊断准确率高 1.12%，证明该模型的有效性。同时，还使用了精确率、召回率和 F1 分数的对比，分析不同

模型在故障识别中的表现，结果如表 4-3 所示。

表 4-3 不同模型性能参数对比

模型种类	精确率 (%)	召回率 (%)	F1
CNN	92.625	89.35	0.916
LSTM	91.675	92.675	0.922
CNN+LSTM	95.89	96.17	0.96
CATN	97.05	97.5	0.973

由表 4-3 得知：

(1) 对于单一神经网络模型，CNN 与 LSTM 性能指标相近。但 CNN 着重局部信号特征提取，其精确率为 92.625%，略高于 LSTM 的 91.675%；LSTM 擅长捕捉全局时序特征，其召回率为 92.675%，高于 CNN 的 89.35%。

(2) 通过结合 CNN 的局部特征提取与 LSTM 的时序建模能力，构建 CNN-LSTM 网络模型，其精确率达到了 95.89%，相比 CNN 与 LSTM 模型分别提高了 3.265%与 4.215%；召回率分别提高了 6.82%和 3.495%；F1 分数分别提高了 0.044 和 0.038。表明在一定程度上，各性能指标均有所提高。

(3) 本文所构建的 CATN 模型在 CNN-LSTM 模型的基础上融合了注意力机制，通过对提取的特征添加权重分配，使显著故障特征得到聚焦，避免了重要故障特征丢失现象的发生，使各性能指标均得到有效提高。CATN 模型精确率相比 CNN-LSTM 模型，精确率、召回率与 F1 分数分别提高了 1.16%、1.33% 和 0.013。以上实验结果和对比分析验证了本文通过融合注意力机制、CNN 与 LSTM 所构建的 CATN 故障诊断模型，能够有效的实现对电机轴承故障的诊断。

4.6 本章小结

本进行 CATN 故障诊断神经网络模型的构建与验证。基于第三章中电机孪生模型所生成的孪生信号，通过对其预处理、信号故障特征提取与融合，最后使用 CATN 模型进行实验验证，并于 CNN、LSTM、CNN-LSTM 神经网络对比分析，证明本文所构建的方法在电机轴承故障诊断方面的有效性。

第5章 总结与展望

5.1 总结

本文以工业机器人电机为研究对象，面对传统电机故障监测方法存在实时性不足、诊断精度低与故障数据难以获取等问题，采用数字孪生技术与深度学习，搭建了工业机器人数字孪生系统，实现了对工业机器人电机运行状态可视化与智能诊断，本文研究内容如下：

(1) 采用数字孪生技术进行工业机器人系统建模。对照数字孪生五维模型结构，首先使用 Unity 3D 虚拟现实软件等工具构建工业机器人系统的数字孪生模型；然后建立其与实体之间的数据通信系统，搭建机器人状态监测系统，通过传感器采集机器人系统中与电机相关的实时状态数据，为电机实时运行参数和状态的可视化与故障诊断奠定基础。

(2) 验证孪生数据与实测数据的一致性。基于 MATLAB/Simulink 功能模块构建电机系统的高保真数字孪生体，采集孪生系统中不同故障类型对应的孪生数据，并从时域和概率密度分布两个维度对孪生数据与实测数据进行一致性对比，验证利用孪生数据替代实测数据进行电机故障诊断的可行性。

(3) 构建基于卷积注意力时序网络（CATN）的电机故障诊断模型。为提升模型的诊断精度，首先基于卷积层结合注意力机制提取孪生数据的全局特征，并增大重要特征数据的权重；然后采用长短期记忆网络捕捉数据的时序特征，据此评估电机的运行状态和故障类型。最后通过实验验证，并与 CNN、LSTM 及 CNN-LSTM 模型进行对比分析，证明了本文算法的有效性。

5.2 不足之处与展望

随着工业机器人在制造业中的广泛应用，对其驱动电机的健康状态监测和故障诊断的技术要求不断提高。数字孪生技术的进步为机器人电机更高效的状态评估与管理提供了可能，通过结合神经网络的深度学习算法与数字孪生模型，能够实现更为精确的故障预测与诊断。

本研究对机器人数字孪生模型建立的方面做出了有效的尝试，分别是对机器人系统及其电机两个方面的建模。在电机建模主要根据电机与轴承电气参数，

基于 Simulink 进行建模；工业机器人系统建模根据其物理实体相关属性，采用 Unity 3D 进行建模。由于工业机器人电机系统复杂，轴承故障发生形式是不规则的，孪生数据与实际工况下的运行数据之间还存在一定差异性，因此需要对所搭建的电机孪生模型进行进一步的优化。

在故障诊断方面，本文从机器人电机系统中轴承的重要性及故障高发性出发，完成了电机轴承的故障诊断，但是对电机其余故障类型，如永磁体失效、转子失衡与定子绕组故障等，尚未完成系统性的健康状态监测。

本文在搭建的工业机器人数字孪生状态监测系统功能尚不完善，主要实现了数据管理、状态监测可视化，后续可以此为基础构建工业机器人系统性的监测系统平台，实现机器人全方位，全角度的状态监测提供基础。

参考文献

- [1] Javaid M, Haleem A, Singh R P, et al. Substantial capabilities of robotics in enhancing industry 4.0 implementation[J]. Cognitive Robotics, 2021, 1: 58-75.
- [2] Arents J, Greitans M. Smart industrial robot control trends, challenges and opportunities within manufacturing[J]. Applied Sciences, 2022, 12(2): 937.
- [3] 潘平. 智能制造技术在制造业中的应用探讨[J]. 自动化技术与应用, 2023, 42(12): 1-4.
- [4] Barenji A V, Li, X, Guo H, et al. A digital twin-driven approach towards smart manufacturing: reduced energy consumption for a robotic cellular[J]. International Journal of Computer Integrated Manufacturing, 2020(1): 1-16.
- [5] 左启轩, 汪波, 陈静波, 等. 永磁同步电机故障诊断研究综述[J]. 机械研究与应用, 2024, 37(06): 161-167+171.
- [6] Van M, Kang H, Suh Y. A Novel Neural Second-Order Sliding Mode Observer for Robust Fault Diagnosis in Robot Manipulators[J]. International Journal of Precision Engineering and Manufacturing, 2013, 14(3): 397-406.
- [7] Tao F, Zhang H, Liu A, et al. Digital Twin in Industry: State-of-the-Art[J]. IEEE Trans. Industrial Informatics, 2019, 15(4): 2405-2415.
- [8] 吴雁, 王晓军, 何勇, 等. 数字孪生在制造业中的关键技术及应用研究综述[J]. 现代制造工程, 2021, (09): 137-145.
- [9] 郑建敏. 电动汽车永磁同步电机及驱动器故障诊断研究[D]. 济南: 济南大学, 2018.
- [10] 张笑齐. 基于卷积神经网络的永磁同步电机故障诊断研究[D]. 沈阳: 沈阳工业大学, 2022.
- [11] 程旺. 基于变分模态分解与卷积神经网络的齿轮箱故障诊断研究[D]. 石家庄: 石家庄铁道大学, 2022.
- [12] Wang B, Feng X, Wang R. Open-Circuit Fault Diagnosis for Permanent Magnet Synchronous Motor Drives Based on Voltage Residual Analysis[J]. Energies,

- 2023, 16(15).
- [13] Chowdhury M H. Modeling of faults in permanent magnet synchronous machines[C]// Transportation Electrification Asia-Pacific. IEEE, 2016.
 - [14] 胡启昊, 郝亮亮, 周艳真, 等. 基于励磁电流时序特征的核电多相旋转整流器二极管开路故障诊断[J]. 中国电机工程学报, 2023, 43(20): 8082-8094.
 - [15] 戴雪松. 基于特征信号识别的永磁同步电机的故障诊断方法[D]. 沈阳: 沈阳工业大学, 2021..
 - [16] 蹇清平. 信号处理技术在轴承故障诊断中的应用综述[J]. 内燃机与配件, 2019, (18): 172-173..
 - [17] 周艳玲, 杨德斌, 徐金梧, 等. 基于声信号的轴承故障诊断方法[J]. 振动与冲击, 2002, (02): 21-23+35+96.
 - [18] 魏勇召, 马龙. 基于定子电流信号分析的机车牵引电机轴承故障诊断方法[J]. 电力机车与城轨车辆, 2025, 48(02): 116-119.
 - [19] Alameh K, Cite N, Hoblos G, et al. Feature extraction for vibration-based fault detection in Permanent Magnet Synchronous Motors[C]// Technological Advances in Electrical, Electronics and Computer Engineering (TAECE), 2015 Third International Conference on. IEEE, 2015.
 - [20] 王宇清, 杨莘苑, 张折桂, 等. 异步电机轴承故障的诊断方法研究[J]. 微特电机, 2024, 52(04):3 3-37.
 - [21] 姚丹, 孙敏, 李睿敏, 等. 改进的经验模态分解方法和解析能量算子在电机轴承故障诊断中的应用[J]. 计算机测量与控制, 2024, 32(08): 72-77+85.
 - [22] 张业成, 刘国海, 陈前. 基于电流波动特征的永磁同步电机匝间短路与局部退磁故障分类诊断研究[J]. 电工技术学报, 2022, 37(07): 1634-1643+1653.
 - [23] E E ,T T ,Van W J G B .Fault Diagnosis approach based on a model-based reasoner and a functional designer for a wind turbine. An approach towards self-maintenance[J]. Journal of Physics: Conference Series, 2007, 75012078-012078.
 - [24] 李宏, 王崇武, 贺昱曜. 基于参数估计模型的对转永磁无刷直流电机实时故障诊断方法[J]. 西北工业大学学报, 2011, 29(05): 732-737.
 - [25] 张永强, 荆建平, 李亚伟, 等. 扩展卡尔曼滤波方法在转子典型故障诊断中的

- 应用[J]. 噪声与振动控制, 2018, 38(05): 198-203.
- [26] He W, Hang J, Ding S. Enhanced robust diagnosis of multiple - type demagnetisation fault for permanent magnet synchronous motor based on D - axis magnetic network model using magnetic field reconstruction[J]. IET Electric Power Applications, 2023, 18(3): 325-335.
- [27] Chen T, Pan Y, Xiong Z. A Hybrid System Model-Based Open-Circuit Fault Diagnosis Method of Three-Phase Voltage-Source Inverters for PMSM Drive Systems[J]. Electronics, 2020, 9(8).
- [28] 徐琛杰, 章玮. 基于统一模型的永磁同步电机故障诊断[J]. 电机与控制学报, 2022, 26(04): 9-17.
- [29] 杜嘉晨, 樊启高, 黄文涛. 基于混合逻辑动态模型的 PMSM 系统开路故障诊断方法[J]. 电机与控制学报, 2023, 27(08): 100-108.
- [30] Yang Z, Chai Y, Yin H, et al. LPV Model Based Sensor Fault Diagnosis and Isolation for Permanent Magnet Synchronous Generator in Wind Energy Conversion Systems[J]. Applied Sciences, 2018, 8(10): 1816.
- [31] 赵洪山, 董叶叶, 宋鹏, 等. 基于模型的风电机组偏航系统故障检测方法[J]. 太阳能学报, 2020, 41(05): 142-149..
- [32] Soomro A A, Muhammad B M, Mokhtar A A, et al. Insights into modern machine learning approaches for bearing fault classification: A systematic literature review[J]. Results in Engineering, 2024, 23102700-102700.
- [33] Alam M, Samad M D, Vidyaratne L, et al. Survey on deep neural networks in speech and vision systems[J]. Neurocomputing, 2020, 417: 302-321.
- [34] 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, 2020, 20(23): 6845.
- [35] Kumar P, Shankar Hati A. Convolutional neural network with batch normalisation for fault detection in squirrel cage induction motor[J]. IET electric power applications, 2021, 15(1): 39-50.
- [36] Chang L K, Wang S H, Tsai M C. Demagnetization Fault Diagnosis of a PMSM

- Using Auto-Encoder and K-Means Clustering[J]. *Energies*, 2020, 13.
- [37] Shifat T A, Hur J W. ANN Assisted Multi Sensor Information Fusion for BLDC Motor Fault Diagnosis[J]. *Quality Control, Transactions*, 2021, 9(1): 9429-9441.
- [38] 樊红卫, 孟瑾, 任众孚, 等. 一种变转速电机转子-轴承系统故障智能诊断方法[J]. *电机与控制学报*, 2024, 28(11): 195-210.
- [39] Negri E, Fumagalli L, Macchi M. A Review of the Roles of Digital Twin in CPS-based Production Systems[J]. *Procedia Manufacturing*, 2017, 11939-948.
- [40] 陶飞, 戚庆林, 王力羣, 等. 数字孪生与信息物理系统——比较与联系[J]. *Engineering*, 2019, 5(04): 132-149.
- [41] Glaessgen E, Stargel D. The Digital Twin Paradigm for Future NASA and U.S. Air Force Vehicles[J]. 2012.
- [42] Grieves M. Digital twin: manufacturing excellence through virtual factory replication[J]. *Whitepaper*, 2014, 1: 1-7.
- [43] Li C, Mahadevan S, Ling Y, et al. A dynamic Bayesian network approach for digital twin[J]. *AIAA Journal*, 2017, 55(3): 1-12.
- [44] Lee J, Lapira E, Yang S, et al. Predictive manufacturing system-trends of next-generation production systems[J]. *IFAC Proceedings Volumes*, 2013, 46(7): 150-156.
- [45] Schroeder G, Steinmetz C, Pereira C E, et al. Visualising the digital twin using web services and augmented reality[C]//2016 IEEE 14th international conference on industrial informatics (INDIN). IEEE, 2016: 522-527..
- [46] Madni A M, Madni C C, Lucero S D. Leveraging digital twin technology in model-based systems engineering[J]. *Systems*, 2019, 7(1): 7.
- [47] Li C, Mahadevan S, Ling Y, et al. Dynamic Bayesian Network for Aircraft Wing Health Monitoring Digital Twin[J]. *AIAA Journal*, 2017, 55(3):1-12.
- [48] Singh R R, Bhatti G, Kalel D, et al. Building a digital twin powered intelligent predictive maintenance system for industrial AC machines[J]. *Machines*, 2023, 11(8): 796.
- [49] Sampedro G A R, Putra M A P, Abisado M. 3D-AmplifAI: An ensemble machine

- learning approach to digital twin fault monitoring for additive manufacturing in smart factories[J]. IEEE Access, 2023, 11: 64128-64140.
- [50] Lopes T D, Raizer A, Valente Júnior W. The use of digital twins in finite element for the study of induction motors faults[J]. Sensors, 2021, 21(23): 7833.
- [51] Velazquez A, Martell F, Sanchez I Y, et al. Cyberphysical System Modeled with Complex Networks and Hybrid Automata to Diagnose Multiple and Concurrent Faults in Manufacturing Systems[J]. Applied Sciences, 2023, 13(19): 10603.
- [52] Jain P, Poon J, Singh J P, et al. A digital twin approach for fault diagnosis in distributed photovoltaic systems[J]. IEEE Transactions on Power Electronics, 2019, 35(1): 940-956.
- [53] 陶飞, 刘蔚然, 刘检华, 等. 数字孪生及其应用探索[J]. 计算机集成制造系统, 2018, 24(1): 1-18.
- [54] 陶飞, 张萌, 程江峰, 等. 数字孪生车间——一种未来车间运行新模式[J]. 计算机集成制造系统, 2017, 23(01): 1-9.
- [55] 陶飞, 刘蔚然, 张萌, 等. 数字孪生五维模型及十大领域应用[J]. 计算机集成制造系统, 2019, 25(01): 1-18.
- [56] 庄存波, 刘检华, 熊辉, 等. 产品数字孪生体的内涵, 体系结构及其发展趋势[J]. 计算机集成制造系统, 2017, 23(004): 753-768.
- [57] 丁华, 杨亮亮, 杨兆建, 等. 数字孪生与深度学习融合驱动的采煤机健康状态预测[J]. 中国机械工程, 2020, 031(007): 815-823.
- [58] 马兴瑞, 马嵩华, 胡天亮. 基于数字孪生模型的故障特征生成与诊断[J]. 组合机床与自动化加工技术, 2022, (08): 94-98+104.
- [59] 任巍曦, 张文煜, 李明, 等. 基于数字孪生的风电机组轴承故障诊断方法研究[J]. 弹箭与制导学报, 2022, 42(03): 97-104.
- [60] 卢家欢, 徐宇航, 邓棋瀚, 等. 动力电池数字孪生体设计及其全寿命电行为仿真[J]. 西南大学学报, 2024, 46(12): 24-30.
- [61] 张希, 廖宇兰, 李沁逸, 等. 安全行驶下的车用电机轴承的数字孪生故障诊断[J]. 汽车安全与节能学报, 2023, 14(02): 232-238.
- [62] 周杨. 基于数字孪生技术的动车组牵引电机故障预测方法研究[D]. 北京: 北

- 京交通大学, 2020.
- [63] 付洋, 曹宏瑞, 郜伟强, 等. 数字孪生驱动的航空发动机涡轮盘剩余寿命预测[J]. 机械工程学报, 2021, 57(22): 106-113.
- [64] 郑笑咏, 邓锦祥, 胡荏, 等. 无位置传感器无刷直流电机控制技术综述[J]. 电气传动, 2022, 52(24): 3-11+66.
- [65] 程启明, 程尹曼, 王映斐, 等. 交流电机控制策略的发展综述[J]. 电力系统保护与控制, 2011, 39(09): 145-154.
- [66] Jain V. Stepper Motors[J]. IETE Journal of Education, 2015, 18(2): 58-64.
- [67] 袁继成, 徐松, 蔡华祥, 等. 机器人关节电机及其技术发展综述[J]. 微电机, 2022, 55(12): 89-95.
- [68] Pauker F, Frühwirth T, Kittl B, et al. A systematic approach to OPC UA information model design[J]. Procedia CIRP, 2016, 57: 321-326.
- [69] 余芸. 基于 OPC UA 技术的数据采集与信息系统设计[J]. 自动化仪表, 2022, 43(03): 92-95.
- [70] Schleipen M, Gilani S S, Bischoff T, et al. OPC UA & Industrie 4.0-enabling technology with high diversity and variability[J]. Procedia CIRP, 2016, 57: 315-320.
- [71] Pauker F, Frühwirth T, Kittl B, et al. A systematic approach to OPC UA information model design[J]. Procedia CIRP, 2016, 57: 321-326.
- [72] Zhen W, Dantao H, Yanjie G, et al. Multi-protocol Integration and Intercommunication Technology Based on OPC UA and MQTT[J]. Journal of Physics: Conference Series, 2022, 2173(1).
- [73] 孟宁, 孔宁, 韩峻峰等. 基于 OPC UA 技术的 T 型梁焊接机器人在线监测系统[J]. 造船技术, 2023, 51(02): 67-70.
- [74] 张文晶. 新型盘式横向磁通永磁同步电机的分析设计及其容错控制研究[D]. 山东: 山东大学, 2023.
- [75] 甘醇, 曲荣海, 石昊晨, 等. 宽调速永磁同步电机全域高效运行控制策略综述[J]. 中国电机工程学报, 2023, 43(07): 2496-2512.
- [76] 王子浩. 基于数字孪生的关节机器人健康状况评估技术的研究与实现[D].

北京: 北京交通大学, 2021.

- [77] Abbasi A M, Huang S, Khan S A. Fault detection and classification of motor bearings under multiple operating conditions[J]. ISA transactions, 2024, 15661-69.
- [78] 陈鹏. 滚动轴承故障诊断及性能退化评估方法研究[D]. 兰州: 兰州理工大学, 2021.
- [79] 吴兴国. 数模联合驱动的全寿命滚动轴承数字孪生模型研究[D]. 重庆: 重庆大学, 2022.
- [80] 万光海, 王全龙, 武美萍, 等. 高速滚动轴承振动特性及动刚度影响因素分析[J]. 噪声与振动控制, 2024, 44(04): 37-42.
- [81] Bultheel A. A two-phase implementation of the fractional Fourier transform[J]. Journal of Non Crystalline Solids, 2011.
- [82] Gong X, Qiao W, Zhou W. Incipient bearing fault detection via wind generator stator current and wavelet filter[C]// IECON 2010-36th Annual Conference on IEEE Industrial Electronics Society. IEEE, 2010: 2615-2620.
- [83] 陈露. 仿真数据驱动的滚动轴承深度迁移学习故障诊断方法研究[D]. 哈尔滨: 哈尔滨工业大学, 2020.
- [84] 张小华. 滚动轴承仿真数据驱动的加权自编码诊断方法研究[D]. 重庆: 重庆理工大学, 2024
- [85] Zhu P, Xu X, Peng S, et al. Research on intelligent identification algorithm of coal and rock strata based on Hilbert transform and amplitude stacking[J]. Geophysical Prospecting, 2024, 72(5): 1764-1777.
- [86] Li X, Yang Y, Pan H, et al. A novel deep stacking least squares support vector machine for rolling bearing fault diagnosis[J]. Computers in Industry, 2019, 110: 36-47.
- [87] Isabelle B, Nicolas R. Uniqueness of the discrete Fourier transform[J]. Signal Processing, 2023, 209.
- [88] Liu T, Li X, Sun J, et al. A post-processing method called Fourier transform based on local maxima of autocorrelation function for extracting fault feature of

- bearings[J]. *Advanced Engineering Informatics*, 2024, 62(PB): 102766-102766.
- [89] Muhashi A, Feng X, Onishi Y, et al. Enhancing Coincidence Time Resolution of PET detectors using short-time Fourier transform and residual neural network[J]. *Nuclear Inst. and Methods in Physics Research, A*, 2024, 1065169540-169540.
- [90] 胡海彬, 刘仁鑫, 刘日龙, 等. 卷积神经网络在机械故障诊断中的应用综述[J]. *机械工程与自动化*, 2024, (04): 221-223.
- [91] Xiong Z, Jiang H, Wang D, et al. Bearing Fault Diagnosis Method Based on Osprey–Cauchy–Sparrow Search Algorithm-Variational Mode Decomposition and Convolutional Neural Network-Bidirectional Long Short-Term Memory[J]. *Electronics*, 2024, 13(23): 4853-4853.
- [92] Wang W, Ngu S S, Xin M, et al. Tool Wear Prediction Combining Global Feature Attention and Long Short-Term Memory Network[J]. *Proceedings of Engineering and Technology Innovation*, 2024, 2801-14.
- [93] 刘国满, 罗玉峰, 盛敬, 等. 基于多尺度混合注意力机制卷积神经网络的伦理决策模型设计[J]. *重庆交通大学学报*, 2024, 43(12): 92-97.
- [94] 冯冠云, 付才, 吕建强, 等. 基于操作注意力和数据增强的内部威胁检测[J]. *网络与信息安全学报*, 2023, 9(03): 102-112.
- [95] 张玉华, 刚润振. 基于注意力机制的互特征融合旋转机械故障检测技术[J]. *计算机测量与控制*, 2024, 32(11): 146-152.

攻读硕士学位期间取得学术成果

1、发表的学术论文

- [1] 第一作者. 基于数字孪生与 BP 神经网络的 RV 减速器故障诊断[J]. 安徽科技学院学报, 2025.
- [2] 第一作者. Fault diagnosis of industrial robot RV reducer based on digital twin technology [J]. International Journal of Advanced Manufacturing Technology. (SCI, Under Review)

2、申请的知识产权

- [1] 第二发明人（导师第一发明人）. 一种集成融合多传感器数据的设备剩余寿命预测方法[P]. 中国专利: CN202410683502.2. （进入实审）

致谢

时光的笔，蘸着岁月的墨，在大学的素笺上绘就了我最绚烂的青春画卷。如今，站在毕业的渡口，回首过往，那些温暖的瞬间如繁星闪烁，照亮了我前行的道路。

感谢我的导师江本赤教授，您是我学业旅程中最为重要的引路人。您的悉心指导让我轻松从初入校园时的懵懂起步，到如今能够在学术的海洋中勇敢航行。您对每一个问题的深入剖析，如同光束穿透迷雾，让我在复杂的学术问题中找到清晰的方向。感谢我的校外导师李公文经理、同事任浩与王波波对于我大论文实验方面的指导与帮助。在这段旅程中，我学会了如何去探索知识的奥秘，更让我懂得了坚持与责任的重量。

同窗好友们，你们是我青春岁月里最美的风景。感谢王绪波、王宜红、曹子旭、许书恒、刘懿平与何欢等同学，在学习过程中，相互鼓励、相互陪伴、相互扶持，共同攻克难题，都成了我最珍贵的回忆。无论遇到多大的困难，我们总是并肩而行，用青春的热情驱散寒冷和阴霾。在学术的道路上，我们互相启发、共同成长，每一个取得的小小成就都凝聚着彼此的心血。

学校，这片充满希望的土地，是我梦想起航的地方。校园里的一草一木、一砖一瓦都见证着我的成长，每一缕阳光都洒满了我七年的回忆。这里的每一间教室都回荡着我们热烈的讨论声，每一条林荫道都留下了我们青春的脚步。学校为我们提供了广阔的舞台，让我们能够尽情地施展才华，追逐梦想。

我的家人，始终是我生命中最温暖的港湾。感谢我的父母与姐姐，你们的爱与支持，是我在这漫长岁月中不断前行的最大动力。无数个日夜，你们用耐心的陪伴和默默的付出，为我营造了一个充满爱的环境。在我遇到困难并感到迷茫时，你们的智慧与经验为我指引方向。

在即将踏入社会的这个新起点，我深知前方的道路充满挑战。但我会带着你们的期望，带着对未来的憧憬，勇敢地迈出每一步。愿未来的日子里，我们都能带着爱与责任，继续在人生的道路上坚定前行，书写属于自己的华章！

尚模敦学 唯实惟新

