

分类号: TB752+. 27

密 级: 公开

学校代码: 10363

学 号: 2210330166



安徽工程大学

Anhui Polytechnic University

硕士学位论文

题 目 分子泵故障诊断与预测
技术研究

论 文 作 者 周阳

校 内 导 师 江明（教授）

校 外 导 师 袁啸林（副研究员）

专业学位类别 电子信息

研究方向（领域） 检测技术与自动化装置

论文提交日期: 2024 年 5 月 31 日

分类号：TP752+.27

单位代码：10363

密类级：公开

学 号：2210330166

题 目 分子泵故障诊断与预测技术研究

题 目 RESEARCH ON FAULT DIAGNOSIS AND
PREDICTION TECHNOLOGY FOR
MOLECULAR PUMP

论 文 作 者：周阳

校 内 导 师：江明（教授）

校 外 导 师：袁啸林（副研究员）

专业学位类别：电子信息

研究方向（领域）：检测技术与自动化装置

论文答辩日期：2024 年 5 月 19 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：周阳

日期：2024年5月26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：

周阳

指导教师签名：

江志

日期：2024 年 5 月 26 日

日期：2024 年 5 月 26 日

分子泵故障诊断与预测技术研究

摘 要

EAST 是一个大型聚变实验装置，内部分子泵作为提供洁净真空环境的关键设备，对实验的顺利开展具有重要影响。它提供稳定的聚变反应环境，保障高强度、高温度和高密度的等离子体运行。然而，在 EAST 实验运行过程中，分子泵设备可能会遭受异物坠入或真空泄漏等故障，给装置造成次生危害，无法为 EAST 实验的顺利运行提供充分保障。因此，为了有效地避免相关问题的发生，寻找一种高效的故障诊断与预测方法，并建立完善的故障诊断保护系统具有极其重要的意义。

针对分子泵故障数据集不平衡导致故障诊断准确率低以及模型过拟合问题，提出一种基于时域频域预处理与改进 BP 相结合的方法，实现分子泵故障诊断。通过在 BP 神经网络的基础上，引入 PSO 并结合五折交叉验证优化模型。首先在模拟分子泵故障的破坏性测试平台上，采集正常态、真空泄漏以及异物坠入故障振动信号，然后对数据进行时域频域特征提取融合，将得到的特征向量集作为优化算法的输入，对模型进行训练，实现分子泵故障诊断。经实验验证，所提方法在诊断准确率上优于 SVM、KNN 和 BP 算法。

针对分子泵退化趋势与剩余使用寿命预测精度不高的问题，提出一种基于时域预处理，并引入分段线性退化模型结合 DE-Bi-LSTM 的方法，实现对分子泵高精度预测。通过在 LSTM 的基础上，将 DE-LSTM 与 Bi-LSTM 相结合，提出 DE-Bi-LSTM 算法，并引入分段线性退化模型应用于分子泵故障预测。首先，在分子泵故障模拟实验平台上，采集泄漏状态下分子泵运行至故障时间序列振动信

号，然后对数据进行时域特征提取，并利用数据标准化将得到的特征向量集作为优化算法的输入，对模型进行训练，实现分子泵故障预测。经实验验证，所提方法在预测效果上优于 LSTM、DE-LSTM 和 Bi-LSTM 算法。

针对 EAST 装置分子泵实现实时故障诊断的工程应用问题，本文通过部署数据采集与故障诊断分析系统解决。利用 LabVIEW 编写界面程序，并调用 Python 训练的故障诊断模型，实现对 EAST 装置分子泵时域频域振动信号的显示、存储、特征信号的提取以及故障诊断报警功能等。软件界面功能齐全，操作简单，有效地解决了分子泵故障诊断的实际应用问题。

通过以上工作内容，包括特征提取与网络框架算法的改进，成功提升了分子泵故障诊断与预测准确率。同时，在工程应用中完成对 EAST 分子泵故障诊断系统机制的部署，为 EAST 实验顺利开展提供了充分的保障。

关键词：托克马克，分子泵，时域与频域分析，机器学习，故障诊断与预测

RESEARCH ON FAULT DIAGNOSIS AND PREDICTION TECHNOLOGY FOR MOLECULAR PUMP

ABSTRACT

The EAST is a large-scale fusion experimental facility. As a crucial component that provides a clean vacuum environment, the internal molecular pumps play a vital role in the smooth progression of the experiment. It creates a stable environment for fusion reactions, ensuring the operation of plasma with high intensity, high temperature and high density. However, during the operation of the EAST experiment, the molecular pump equipment may experience failures such as foreign object drop, vacuum leakage and so on, which could result in secondary hazards to the device and could not provide sufficient guarantee for the smooth operation of the EAST experiment. Therefore, in order to effectively preclude the occurrence of associated issues, it is of great significance to develop an efficient fault diagnosis and prediction method and establish a comprehensive fault diagnosis and protection system.

Taking into consideration the problem of low accuracy in fault diagnosis and overfitting model due to the unbalance of molecular pump fault datasets, a method which is based on time domain and frequency domain preprocessing and enhanced BP was proposed to facilitate molecular pump fault diagnosis. Building upon the BP neural network, the PSO is incorporated and the optimization model is validated through the combination of five-fold cross-validation. Initially, vibration signals of normal, vacuum leakage and foreign object drop faults are collected on a destructive test platform simulating molecular pump faults.

Subsequently, the acquired data are extracted and fused in both time domain and frequency domain. The resulting feature vector set serves as the input for the optimization algorithm to train the model and realize molecular pump fault diagnosis. The experimental results demonstrate that the proposed method exhibits superior diagnostic accuracy compared to SVM, KNN and BP.

To address the issue of low prediction precision of molecular pump degradation trend and remaining useful life, the method based on time domain preprocessing and piecewise linear degradation model combined with DE-Bi-LSTM was proposed to achieve highly precision predictions of molecular pump. The DE-Bi-LSTM algorithm, which is based on the LSTM architecture, is proposed by combining DE-LSTM and Bi-LSTM. Additionally, the piecewise linear degradation model is employed for molecular pump fault prediction. Firstly, in the molecular pump fault simulation experiment platform, the vibration signals of the molecular pump running to the fault time series under the leakage state are collected, and then the time domain feature is extracted from the acquired data. The resulting feature vector set is employed as the input for the optimization algorithm, utilizing data standardization to train the model and facilitate molecular pump fault prediction. The experimental results indicate that the proposed method outperforms LSTM, DE-LSTM and Bi-LSTM algorithms in terms of forecasting effectiveness.

Targeting the engineering application challenge of realizing real-time fault diagnosis for the molecular pump in the EAST device, this study addresses the challenge by implementing a data acquisition and fault diagnosis analysis system. Utilizing LabVIEW for writing the interface program and invoking the fault diagnosis model trained by Python, the system can display, store vibration signals in time domain and frequency domain, extract characteristic signals and diagnose and alarm

faults of molecular pump in EAST device. The software interface boasts comprehensive functionalities and user-friendly operation, effectively resolving the practical application challenge of molecular pump fault diagnosis.

Through the aforementioned efforts, including the feature extraction and the enhancement of the network framework algorithms, the fault diagnosis and prediction accuracy of molecular pumps have been successfully elevated. Simultaneously, the implementation of the fault diagnosis system mechanism of the EAST molecular pump has been completed in the engineering applications, which provided ample assurance for the unhindered progression of the EAST experiment.

Zhou Yang (Electronic Information)

Supervised by Professor Jiang Ming

KEY WORDS: tokamak, molecular pump, time domain and frequency domain analysis, machine learning, fault diagnosis and prediction

目录

摘要.....	I
ABSTRACT.....	III
第 1 章 绪论.....	1
1.1 课题研究背景及意义.....	1
1.2 国内外研究现状.....	4
1.2.1 故障诊断研究现状.....	4
1.2.2 故障预测研究现状.....	6
1.3 主要研究内容.....	7
1.4 章节安排.....	8
第 2 章 分子泵故障诊断与预测相关基础理论.....	10
2.1 引言.....	10
2.2 分子泵故障诊断基础理论.....	10
2.2.1 BP 神经网络原理.....	10
2.2.2 粒子群原理.....	11
2.2.3 交叉验证原理.....	13
2.3 分子泵故障预测基础理论.....	13
2.3.1 LSTM 原理.....	13
2.3.2 Bi-LSTM 原理.....	15
2.4 本章小结.....	17
第 3 章 基于改进 BP 的分子泵故障诊断研究.....	18
3.1 引言.....	18
3.2 数据预处理.....	18
3.2.1 时域频域特征提取.....	18
3.2.2 数据标准化.....	20
3.3 基于改进 BP 分子泵故障诊断.....	21
3.3.1 改进 BP 算法流程图.....	21
3.3.2 故障诊断算法流程框架.....	22

3.3.3 分子泵故障模拟实验平台	22
3.3.4 数据集及样本生成	23
3.4 实验验证与分析	25
3.4.1 评价指标	25
3.4.2 实验结果分析	26
3.4.3 方法对比分析	28
3.5 本章小结	30
第 4 章 基于 DE-Bi-LSTM 的分子泵故障预测研究	31
4.1 引言	31
4.2 数据预处理	32
4.2.1 时域特征提取	32
4.2.2 数据标准化	32
4.2.3 分段线性退化模型	33
4.3 基于 DE-Bi-LSTM 的分子泵故障预测	34
4.3.1 网络模型的构建	34
4.3.2 故障预测算法框架	35
4.3.3 分子泵故障模拟实验平台	35
4.3.4 数据集及样本生成	36
4.4 实验验证与分析	37
4.4.1 实验结果与分析	37
4.4.2 方法对比与分析	38
4.5 本章小结	40
第 5 章 EAST 分子泵故障诊断模型设计与部署	41
5.1 引言	41
5.2 EAST 装置分子泵在线故障诊断系统测试	41
5.3 EAST 装置分子泵离线故障诊断系统测试	54
5.4 本章小结	57
第 6 章 工作总结与展望	58
6.1 工作总结	58

6.2 工作展望	59
参考文献	60
攻读学位期间发表的学位论文及参加的科研项目	66
致谢	67

第 1 章 绪论

1.1 课题研究背景及意义

EAST(Experimental Advanced Superconducting Tokamak)作为中国研发的首个大型全超导托卡马克聚变装置,被称为“中国人造太阳”^[1-2]。它通过磁约束进而实现受控核聚变^[3-4],为未来先进聚变堆的工程技术和物理基础做出重要贡献,为人类实际运用聚变能做出重要中国贡献^[5]。如图 1-1 所示,EAST 聚变装置旨在模拟太阳内部的聚变反应,将氢同位素聚变成氦从而释放巨大能量。它采用了超导技术,其中强大的磁场由超导磁体产生,以控制等离子体的运动和稳定性,超导电流环则用于维持等离子体的高温状态。这些技术使得 EAST 能够在高温和高压条件下维持稳定的等离子体,并进行长时间的聚变反应。这种聚变反应是未来清洁能源的一个潜在解决方案,因为温室气体和核废料不仅不会产生,而且会获得丰富的能源。众所周知,中国是世界上最大的能源消费国之一,能源资源供应相对紧张。中国的主要能源资源包括煤炭、石油、天然气和水力资源^[6],但其开采和使用也导致了严重的环境问题^[7]。一旦这种聚变反应能够成功实现,无疑在未来是跨越历史的一大步。在 2023 年 4 月 12 日 21 时,第 122254 次实验! EAST 创造新的世界纪录,成功实现等离子体运行 403 秒,对探索未来的聚变堆前沿物理问题,加快实现聚变发电具有重要意义^[8]。



图 1-1 EAST 全超导托卡马克

EAST 的研究旨在开发清洁、可持续的能源解决方案。但在聚变实验中，高真空环境是一个必要的条件，而分子泵是 EAST 装置产生高真空条件的必要设备。分子泵无法在大气压下启动，一般厂家建议在 10Pa 以下启动，起到保护作用^[9]。当气压低于分子泵真空限定值时，分子泵利用高速旋转的转子把动量传输给气体分子，使气体被压缩并驱向排气口，实现真空泵功能^[10]。随着分子泵的运转，出现真空泄漏或异物坠入等状况，分子泵的性能会随之下降，若不能及时检修维护会影响分子泵工作，进而间接影响 EAST 装置的平稳运行，甚至威胁科研人员的人身安全^[11]。因此，研究分子泵的状态，实现故障诊断与预测，维护分子泵运行是至关重要的，如图 1-2 所示是 EAST 装置分子泵实物图。




图 1-2 EAST 分子泵

传统人工的分子泵故障诊断效率低以及预测精度低等问题，无法给 EAST 装置长期平稳运行提供保障。因此，需要运用一种高效的故障诊断与预测方法解决。近年来，依托数据本身内在规律，通过人工智能的发展进行数据挖掘为故障诊断与预测提供了方法^[12]。随着科技的发展，人工智能越来越受到人们的重视，在社会众多领域展示出广阔的应用前景^[13]。其中机器学习方法作为人工智能的重要组成部分，它是将人对问题的处理方式赋予计算，让计算机拥有自我学习的能力的功能^[14]，通过不断地机器学习和迭代，最终实现基于人工智能的故障诊断与预测。

基于机器学习的故障诊断与预测方法以预测精度高和建模较易等优势成为近年来研究的主流。现阶段，对于分子泵的故障诊断与预测研究内容较少，其主要原因是关于分子泵的故障率低，数据收集比较困难，至今资料上几乎没有

公开关于分子泵的故障数据信息，所以导致在分子泵诊断与预测上的研究上不够深入。若将机器学习代替传统方法，应用于分子泵故障诊断与预测，不仅会提高时间效率，同时在准确率与精度上也会实现进一步的提升。本文针对分子泵故障信息获取困难，数据特征提取及融合等问题还不够完善，以及关于分子泵故障诊断与预测精度低等问题展开分子泵故障诊断与预测研究，将为 EAST 装置提供有意义的前瞻性技术探索，有助于推动分子泵诊断预测领域的发展，也是加强我国科技创新水平建设的体现。

设备在出现故障前，会有早期的一些故障信号产生^[15]。虽然设备保持正常运转，但随着时间的推移，将会产生不可逆的损坏。如果我们能够识别到早期信号，并进行甄别同时对设备退化趋势与剩余寿命进行评估，就可以有效实现设备及时维修与健康管理，提升有效工作时长^[16]。如图 1-3 是故障出现的全过程，从图可以看出，人工及时介入维护，设备损坏程度越低，维护成本越低，反之维护时间越晚，设备损坏程度越高，维护成本越高。




图 1-3 故障产生过程与维护成本示意图

目前，EAST 分子泵故障主要包括真空泄漏、异物坠入、机械故障、误操作、轴承失效等。其中真空泄漏与异物坠入是目前出现概率相对来说较高的故障类型。如图 1-4 分子泵故障类型比例示意图所示。

分子泵的正常运行状态对于 EAST 装置实验的开展意义深远，如何有效地甄别真空泄漏或异物坠入等其他故障以及预测相关故障引起分子泵性能退化的

趋势是目前需要解决的关键问题。本文通过搭建分子泵故障模拟试验平台，提出时域频域预处理结合改进反向传播(Back Propagation, BP)神经网络的分子泵故障诊断方法有效地实现对分子泵不同故障类型的快速甄别；同时提出时域预处理，并引入分段线性退化模型结合深度双向长短时记忆网络(Deep Bidirectional Long Short-Term Memory, DE-Bi-LSTM)的分子泵故障预测方法，有效地实现对分子泵退化趋势以及剩余使用寿命的高精度预测，并设计研发部署分子泵故障诊断系统，实现对分子泵预测性维护与健康管理，为 EAST 实验的顺利进行奠定坚实的基础。




图 1-4 分子泵故障类型比例示意图

1.2 国内外研究现状

1.2.1 故障诊断研究现状

设备运行状态决定能否保持良好的工作状态^[17]。目前故障诊断主要分为传统故障诊断方法、基于模型的故障诊断方法、基于专家系统的故障诊断方法以及数据驱动的故障诊断方法。传统方法的缺点是依赖于专家的经验，诊断结果可能存在主观性和不确定性。基于模型的故障诊断方法通过设备的数学模型进行诊断，这种方法的弊端在于需要事先建立准确的数学模型。专家系统是一种利用专家知识和规则来进行推理和决策的计算机系统，弊端在于依赖专家知识，难以进行准确的故障诊断。数据驱动的故障诊断方法依赖于大量实时数据进行

诊断,这种方法可以通过机器学习和数据挖掘等技术^[18],自动从数据中学习故障模式和规律,提高诊断的准确性和效率。在旋转类机械的故障诊断中,大量的振动运行状态信息由传感器采集获取,因此振动信号常常被用来作为模型的输入进行学习^[19]。故障诊断通过三个步骤实现,首先采集不同类型振动信号,然后对数据预处理实现特征提取,最后构建故障诊断模型,进行测试诊断。其中,故障特征提取比较重要,模型构建也是关键因素,都影响着诊断结果准确率高低。

目前,国内外学者基于数据驱动模型对故障诊断研究取得了一系列成果。钟辉等^[20]针对编码器瞬时角速度信号中滚动轴承故障特征提取困难的问题,提出一种参数自适应 SMHD 滚动轴承 IAS 信号特征提取方法,通过实验验证所提方法的有效性。熊剑等^[21]针对滚动轴承振动信号不稳以及不易提取等问题,提出短时傅里叶结合改进残差网络方法,实现更高的准确率诊断。贾凯等^[22]针对分子泵故障诊断率低问题,提出时域结合频域的数据预处理方法,最后输送到改进的 LightGBM 算法,有效实现分子泵高精度检测。慕晓冬等^[23]针对航天器故障诊断准确率低问题,提出了基于注意力残差网络(AM-ResNet)的故障诊断策略,使得航天器测控系统故障检测率得到有效提高。Qin 等^[24]针对如何有效提取轴承故障信息及提高诊断准确率问题,提出了一种基于集合复合多尺度色散熵和密度峰值聚类的故障诊断方法,实现有效诊断。Mahmoud 等^[25]针对噪声对电机诊断准确性影响,提出将迁移学习预训练残差神经网络与监督机器学习相结合,实验结果表明,该方法平均准确率在噪声工况下具有较高的鲁棒性。王骁贤等^[26]提出通过多传感器信号深度特征融合的方法,有效识别电机运行状态。邬春明等^[27]针对在变工况轴承故障诊断任务中问题,提出了一种两级混淆对抗域自适应网络,结果表明,平均诊断精度较高。Pham 等^[28]针对轴承故障诊断精度低问题,提出基于生成对抗网络(GAN)结合声发射监测信号的数据增强技术的故障诊断方法,在数据集上该方法取得了较好的诊断效果。Ghazali 等^[29]针对光伏系统非线性输出受日辐照度分布不均匀影响较大,提出随机森林算法对波形长度与自回归(RF-WLAR)对时间序列分析为主要的特征方法,通过数据库故障数据验证,实验结果准确率较高。林俊亭等^[30]针对轨道电路故障诊断精度低问题,提出一种基于 Gath-Geva 模糊聚类结合卷积神经网络和双向门控循环单

元进行故障诊断, 结果表明, 分类精度得到提高, 能够为轨道电路的多模式健康状态识别提供一种有效的方法。

目前机器学习诊断算法, 在数据集平衡的情况下取得了较好的成果。但面对工业实际运行状况, 分子泵故障数据是极少的, 数据集是不平衡的, 数据特征是复杂无序的, 导致故障诊断准确率低以及模型过拟合问题。针对上述情况, 本文提出一种基于时域频域预处理与改进 BP 相结合的算法, 实现高准确分子泵故障诊断。

1.2.2 故障预测研究现状

故障预测, 是指通过分析设备历史数据进行建模, 预测设备退化趋势以及剩余寿命。故障预测一般分为三种, 基于可靠性模型、基于物理模型和基于数据驱动模型^[31-32]。基于可靠性模型的故障预测与健康管理(Prognostics Health Management, PHM)方法侧重于统计特性进行故障预测; 基于物理模型的方法利用物理失效模型进行预测, 考虑不同失效规律; 基于数据驱动的方法利用历史数据和智能算法建立预测模型, 无需先验知识即可进行故障预测。

目前, 国内外学者基于数据驱动模型下在故障预测研究领域取得了一系列成果。Wang 等^[33]针对轴承模型预测精度低问题, 提出一种基于改进时间卷积网络和迁移学习的预测模型, 有效提高剩余使用寿命预测精度。Wu 等^[34]通过奇异值分解特征提取结合 Bi-LSTM 成功预测刀具磨损情况。Kizito 等^[35]开发了一个程式化的 LSTM 模型, 并将其应用于电机退化数据集诊断故障和预测, 并在指定时间范围内发生故障概率的目的作为预测原则, 取得了好的预测效果。Jafari 等^[36]针对电池的剩余使用寿命预测精度不高问题, 提出机器学习结合哈里鹰优化进行超参数调整, 所提方法在锂离子电池的数据集上, 取得较高的精度。Wang 等^[37]针对刀具特征提取困难以及剩余使用寿命预测精度低问题, 提出一种基于多通道特征融合的 CNN-LSTM-PSO 工具剩余寿命预测方法, 通过实验对比分析结果表明, 本文所提方法预测精度最高。Park 等^[38]针对预测电池剩余使用寿命来降低电池失效风险问题, 提出基于长短时记忆网络结合多对一结构的输入层与输出层匹配方法, 实验结果表明, 预测精度得到提高。罗毅等^[39]针对水轮机系统预测精度低等问题, 提出一种基于深度学习长短时记忆网络结

合深度置信网络的故障预测方法，在工程实验验证方法的有效性。王文波等^[40]针对滚动轴承故障预测中的专家知识依赖性和计算时间长等问题提出基于深度学习和增量更新的方法，在凯斯西储大学的轴承故障数据集上验证了有效性。申彦斌等^[41]针对轴承退化问题，设计改进函数的卷积自编码器，并提出双向长短时记忆网络学习轴承退化规律，实现更准确剩余使用寿命预测。丁显等^[42]针对轴承预测问题，提出维纳过程与粒子滤波相结合的滚动轴承剩余寿命预测方法，该方法在试验台轴承和风力发电机轴承测试数据上得到有效验证。

本文针对分子泵故障退化数据稀少以及数据特征复杂无序，导致故障预测精度低问题，对机器学习预测模型进行改进。开展研究分子泵在真空泄漏状态下，其正常运转到故障停机状态下全寿命退化过程，并对这一退化趋势做拟合与寿命预测。因为整个退化的时间序列过程中传感器采集的振动信号是复杂与非线性的，而神经网络可以很好地捕捉到数据间的非线性关系，并且多层次的网络结构可以学习到更有意义的模式与规律。所以，本文提出时域预处理并引入分段线性退化模型结合 DE-Bi-LSTM 的方法，实现高精度预测。

1.3 主要研究内容

本课题针对 EAST 装置真空设备分子泵故障诊断与故障预测存在的问题和未来发展的前景，研究了基于分子泵故障模拟实验平台的故障诊断与预测技术。本文技术路线如图 1-5 所示，主要包括：




图 1-5 技术路线图

1.针对分子泵故障诊断中，数据集不平衡，采集的振动信号规律复杂等问

题导致模型过拟合准确率较低，提出了时域频域预处理结合改进 BP 的分子泵故障诊断方法。由于分子泵故障数据稀少，所以获取故障数据集是第一步。本文通过搭建分子泵故障模拟实验平台获取不同类型故障信号，然后对原始信号进行时域频域特征提取，并进行特征融合形成特征向量集，最后输入到改进的 BP 模型，最终实现分子泵故障诊断。实验结果验证本方法在准确率上优于支持向量机(Support Vector Machine, SVM)、K 近邻(k-Nearest Neighbors, KNN)和 BP 方法。

2.针对分子泵退化趋势以及剩余使用寿命预测精度低等问题，本文提出时域预处理并引入分段线性退化模型结合 DE-Bi-LSTM 的分子泵故障预测方法。由于分子泵全寿命数据稀有，所以获取分子泵退化趋势数据是关键之一。本文通过搭建分子泵故障模型实验平台获取分子泵由正常运行到故障停机全寿命数据，并对原始信号进行时域特征提取，形成特征向量集，输入到改进后的 DE-Bi-LSTM 模型，最终实现分子泵故障预测。实验结果表明，本算法明显优于长短时记忆网络(Long Short-Term Memory, LSTM)、深度长短时记忆网络(Deep Long Short-Term Memory, DE-LSTM)和双向长短时记忆网络(Bidirectional Long Short-Term Memory, Bi-LSTM)算法。

3.针对 EAST 分子泵实际工程应用问题，开发分子泵故障诊断系统并进行部署。结合人工智能、信号处理、LabVIEW 编程和 Python 编程等技术，实现对 EAST 分子泵时域数据与频域数据的实时采集与存储，以及时域特征的提取和故障诊断界面的实时更新与显示，目前已成功应用于 EAST 装置分子泵，并取得较好的工程应用效果。

1.4 章节安排

本论文总共分为 6 章，章节安排如下：

第 1 章：绪论。首先概述了故障诊断与故障预测研究背景与意义，然后对国内外故障诊断与预测技术研究现状进行了总结，并面对当前 EAST 装置分子泵存在的问题，提出了相应的解决办法；最后给出了技术路线以及章节安排，介绍本文各章节的主要研究内容。

第 2 章：分子泵故障诊断与预测相关基础理论。阐述分子泵应用背景与研

究意义等，并引出相关的故障诊断与预测基础理论知识，为 3、4 章算法改进提供理论支撑。

第 3 章：基于改进 BP 的分子泵故障诊断研究。首先阐述旋转机械故障诊断的研究背景与现状等，随后分析基于 BP 的分子泵故障诊断方法，并提出改进算法。最后，通过平台的搭建到数据集的制作，验证所提方法的有效性。

第 4 章：基于 DE-Bi-LSTM 分子泵故障预测研究。首先讨论了故障预测的研究背景，随后详细分析本章数据预处理方式，并提出基于 Bi-LSTM 的改进算法 DE-Bi-LSTM 故障预测方法。最后，通过搭建平台和构建数据集，验证了该方法的有效性。

第 5 章：分子泵故障诊断模型设计与部署。针对现阶段实际工程应用搭建了 EAST 分子泵故障诊断系统，该系统功能包括时域频域数据的显示与存储，特征数据的提取以及不同故障类型诊断等功能，并完成了 EAST 装置分子泵故障诊断系统测试。

第 6 章：总结与展望。针对本文所涉及的分子泵故障诊断与预测所做研究工作进行相关总结，概述了本文的总体结构及创新之处，同时提出了对分子泵故障诊断与预测研究不足之处的展望，探讨了后续改进的方向。

第 2 章 分子泵故障诊断与预测相关基础理论

2.1 引言

分子泵是一种用于抽真空的高性能抽气设备，广泛应用于真空等领域。然而，在 EAST 装置实验开展时，由于分子泵在工作过程中受到高温、高压、高速等复杂环境下易出现各种故障，影响设备的正常运行。目前依靠人工经验进行诊断与预测，可靠性、时效性差。因此，开展分子泵的故障诊断与预测具有重要的理论和实际意义。本文通过引入机器学习算法相关理论完成对分子泵不同运行状态的诊断，实现对分子泵退化趋势的拟合预测，建立分子泵健康管理机制。

2.2 分子泵故障诊断基础理论

2.2.1 BP 神经网络原理

BP 神经网络是一种基于误差反向传播算法的人工神经网络模型^[43-44]。它可以解决非线性问题并具备智能特征^[45]。BP 神经网络在理论上可以逼近任何函数，是目前研究最深入、应用最广泛的神经网络模型之一^[46]。它的核心思想是通过调整网络中的权重和偏置来最小化输出与期望输出之间的误差。网络通过前向传播将输入信号逐层传递至输出层，然后通过反向传播将输出层的误差逐层反向传递至输入层，最后根据误差调整网络中的权重和偏置。这个迭代过程持续进行，直到网络的输出与期望输出的误差达到可接受范围。

BP 神经网络的训练包括前向传播和反向传播两个阶段。在前向传播中，输入信号经过神经元节点计算输出值并传递至下一层。反向传播阶段，根据输出层误差，通过链式法则将误差逐层反向传播至输入层，并调整每层的权重和偏置。网络可以通过调整结构和参数来适应不同的问题，具备灵活性和泛化能力。BP 神经网络还可通过并行计算加速训练过程，提高效率，但 BP 存在易陷入局部最优解的问题^[47]。

BP 神经网络作为一种常见的人工神经网络，同时也作为一种监督机器学习

算法，多用于训练神经网络以进行回归与分类任务^[48]。BP 神经网络是一个多层神经网络^[49]。图 2-1 为 BP 神经网络原理图，BP 神经网络包括输入层、输出层和隐含层^[50-51]。其中 $x_1, x_2, \dots, x_n$ 为输入变量， y 为输出变量， k_m 为隐藏神经元的输出，存在 f 为激活函数的映射关系。假设 v_{ij} 为第 i 个输入变量与第 j 个隐藏层神经元的权重； θ_j^k 为隐藏层 k 第 j 个神经元的阈值，即偏置项。可得 k_j 表达式如式(2-1)所示：




图 2-1 BP 神经网络原理图

$$k_j = f\left(\sum_{i=1}^n v_{ij} + \theta_j^k\right) \quad j=1, 2, \dots, m \quad (2-1)$$

假设 w_j 为第 j 个神经元与 y 连接的权重， θ^y 为 y 的偏置，存在 f 为激活函数的映射关系。可得输出 y 表达式如式(2-2)所示：

$$y = f\left(\sum_{j=1}^m w_j k_j + \theta^y\right) \quad (2-2)$$

2.2.2 粒子群原理

粒子群算法(Particle Swarm Optimization, PSO)是一种基于群体智能的优化算法，模拟了生物群体的行为，它通过迭代搜索寻找最优解。由 Eberhart 和 Kennedy 于 1995 年提出，广泛应用于优化问题、机器学习、图像处理等领域。

粒子群算法类比鸟群通过信息共享，实现群体在问题求解空间从无序到有

序的演化，求得最优解^[52-53]。算法模拟群体个体的行为来搜索最优解，每个个体被称为粒子，它们在解空间中随机生成，并根据自身的经验和群体的经验进行移动。每个粒子都有自己的位置和速度，位置代表解空间中的一个解，速度表示粒子在解空间中的搜索方向和速度。粒子根据自身的位置和速度进行移动，并根据目标函数的值来评估移动的效果。通过迭代更新粒子的位置和速度，最终找到最优解。粒子群算法具有优良的收敛速度和搜索效率^[54]。原理如图 2-2 所示，鸟相当于粒子；森林相当于求解空间；食物的相当于适应度值；每只鸟所处的位置相当于空间中的一个解；食物量最多的位置相当于全局的最优解。




图 2-2 粒子群算法原理图

假设 D 维的搜索空间中，单个群落包含 N 个粒子，单个 D 维向量由第 i 个粒子表示，记为式(2-3)：

$$X_{id} = (x_{i1}, x_{i2}, \dots, x_{iD}) \quad (2-3)$$

单个 D 维向量也可表示第 i 个粒子的飞行速度，记为式(2-4)：

$$V_{id} = (v_{i1}, v_{i2}, \dots, v_{iD}) \quad (2-4)$$

个体极值定义为第 i 个粒子群搜索到的最优位置，记为式(2-5)：

$$P_{best} = (P_{i1}, P_{i2}, \dots, P_{iD}) \quad (2-5)$$

全局极值定义为整个粒子群检索到的最优位置，记为式(2-6)：

$$P_{d,gbest} = (P_{1,gbest}, P_{2,gbest}, \dots, P_{D,gbest}) \quad (2-6)$$

在找到这两个最优值时，粒子需要根据如下公式来更新自己的速度和位置，记为式(2-7)、(2-8)：

$$v_{id}(t+1) = w \times v_{id}(t) + c_1 r_1 [p_{best}(t) - x_{id}(t)] + c_2 r_2 [p_{d,gbest}(t) - x_{id}(t)] \quad (2-7)$$

$$x_{id}(t+1) = x_{id}(t) + v_{id}(t+1) \quad (2-8)$$

N 代表粒子群规模, $i(i=1,2,\dots,N)$ 代表粒子序号; D 代表粒子维度;
 $d(d=1,2,\dots,D)$ 代表粒子维度序号; t 代表迭代次数; w 代表惯性权重; c_1 代表
 个体学习因子; c_2 代表群体学习因子^[55]; r_1, r_2 代表在 $[0, 1]$ 内的随机数^[56-57];
 $v_{id}(t)$ 代表粒子 i 在第 t 次迭代中第 d 维的速度向量; $x_{id}(t)$ 代表粒子 i 在第 t 次迭
 代中第 d 维的位置向量; $P_{best}(t)$ 代表粒子 i 在第 t 次迭代中第 d 维的历史最优位
 置, $P_{d,gbest}(t)$ 代表粒子在第 t 次迭代中第 d 维的历史最优位置。

2.2.3 交叉验证原理

交叉验证是一种统计分析方法, 也是机器学习中常用的模型评估方法。它
 通过反复划分数据集为训练集和测试集, 来评估模型的泛化能力和性能。 K 折
 交叉验证是将数据集分为 K 个子集, 依次将每个子集作为测试集, 其余作为训
 练集, 进行模型训练和测试, 再利用相关评价指标, 从而得到 K 个模型评估最
 终结果, 如图 2-3 所示。本文实验选取五折交叉验证来提高模型诊断精度。




图 2-3 交叉验证原理图

2.3 分子泵故障预测基础理论

2.3.1 LSTM 原理

LSTM 算法是一种改进的递归神经网络算法, 并解决 RNN 算法具有长期依

赖和梯度消失问题^[58-59]。通过引入门控机制，LSTM 能够更好地捕捉长期依赖关系，从而在处理长序列数据时表现出色。LSTM 网络具有长期保持记忆的能力，能够精确建模复杂多元序列的长期相关性。其网络单元结构如图 2-4 所示。

该网络每个记忆单元引入了输入门、输出门和遗忘门三个门控单元^[60-61]。信息的流动由这些门控单元通过学习参数来操控，从而控制了 LSTM 的记忆和遗忘过程。这些门控单元能够根据输入数据的不同情况，自动地决定是否将信息传递给下一个时间步，从而有效地解决了梯度消失和梯度爆炸问题。




图 2-4 LSTM 单元结构

x_t 为输入向量， f_t 为遗忘门， i_t 为输入门， C_{tx} 为新值， O_t 为输出门， C_{t-1} 是上一时刻的细胞状态信息， h_t 是上一时刻输出的序列信息； σ 为 *Sigmoid* 激活函数； $\tanh$ 为双曲正切激活函数； w 为权重矩阵； $\odot$ 为哈达玛积。

(1) 遗忘门：LSTM 按时间序列对数据进行筛选，保留有用信息，直接遗弃无用信息。遗忘门通过一个 *Sigmoid* 函数来决定是否保留上一个时间步的状态，然后与候选值相乘，得到当前时间步的状态。如式(2-9)所示：

$$f_t = \sigma(w_f \cdot [h_{t-1}, x_t] + b_f) \quad (2-9)$$

式中： f_t 为遗忘门输出结果； w_f 和 b_f 分别为遗忘门对应的权重系数和偏置项。

(2) 输入门：通过遗忘门筛选的信息进入到输入门，输入门决定当前时间步的输入对当前状态的影响。输入门通过一个 *Sigmoid* 函数来决定是否接收当前

时间步的输入，然后通过一个 $\tanh$ 函数来将输入进行预处理，得到一个候选值。如式(2-10)所示：

$$i_t = \sigma(w_i \cdot [h_{t-1}, x_t] + b_i) \quad (2-10)$$

式中： i_t 表示输入门输出结果； σ 为 *Sigmoid* 的函数； w_i 和 b_i 为输入门对应的权重系数和偏置量； h_{t-1} 为前一时刻的输出； x_t 为当前时刻的输入。

(3) 新值输入计算，如式(2-11)所示：

$$C_{tx} = \tanh(w_c \cdot [h_{t-1}, x_t] + b_c) \quad (2-11)$$

式中： C_{tx} 为信息输入之后未与输入门计算之前的值； w_c 和 b_c 分别为对应的权重系数和偏置项。

(4) cell 最终获得结果，如式(2-12)所示：

$$C_t = f_t \odot C_{t-1} + i_t \odot C_{tx} \quad (2-12)$$

式中： C_t 为当前输入门的信息和经过遗忘门作用的上一时刻 cell 中的信息相加后，cell 的最终输出结果。

(5) 输出门：经过输入门和遗忘门筛选的信息到达输出门，输出门决定了当前时间步的状态对下一个时间步输出的影响程度。输出门通过一个 *Sigmoid* 函数来决定是否输出当前时间步的状态，然后通过一个 $\tanh$ 函数来将当前时间步的状态进行预处理，得到输出，如式(2-13)所示：

$$O_t = \sigma(w_o \cdot [h_{t-1}, x_t] + b_o) \quad (2-13)$$

式中： O_t 为输出门输出结果； w_o 和 b_o 分别为输入门和输出门对应的权重系数和偏置项。

(6) LSTM 记忆单元最终输出，如式(2-14)所示：

$$h_t = O_t \odot \tanh(C_t) \quad (2-14)$$

式中： h_t 为当前单元输出。

2.3.2 Bi-LSTM 原理

Bi-LSTM 模型是一种处理序列数据的深度学习模型，适用于自然语言处理和时间序列分析等任务。它是对传统的循环神经网络的扩展，通过引入双向性，

增加了对上下文信息的理解能力，从而在整个时间序列上获取更多的信息^[62]。

单向的 LSTM 网络只考虑过去的信息，无法利用未来的信息，缺乏前后逻辑性^[63]。Bi-LSTM 模型在 LSTM 的基础上增加了一个反向 LSTM 层，使得模型能同时从前向和后向两个方向捕捉序列数据的上下文信息，来解决序列问题^[64]。具体来说，Bi-LSTM 模型由两个 LSTM 层组成，一个按照正向顺序处理输入序列，另一个按照反向顺序处理输入序列。每个 LSTM 层都包含一个记忆单元和一组门控单元。正向 LSTM 层中，输入序列从左到右依次输入，每个时间步的输入被传递给 LSTM 单元，该单元根据当前输入和前一个时间步的隐藏状态来更新记忆单元和隐藏状态。类似地，在反向 LSTM 层中，输入序列从右到左依次输入，每个时间步的输入被传递给 LSTM 单元，该单元根据当前输入和后一个时间步的隐藏状态来更新记忆单元和隐藏状态。Bi-LSTM 模型的训练过程中，模型会自动学习到输入序列中的特征和依赖关系，并将其应用于预测任务中。

Bi-LSTM 将正反两个方向相结合学习，避免了单一方向学习信息的遗漏，同时改善了在序列学习中权重选择问题，其网络结构如图 2-5 所示。




图 2-5 Bi-LSTM 模型结构

其中 Bi-LSTM 计算原理都是基于单向的 LSTM，如式(2-15)、(2-16)、(2-17)所示。

$$\vec{h}_t = LSTM(x_t, \vec{h}_{t-1}) \quad (2-15)$$

$$\vec{h}_t = LSTM(x_t, \vec{h}_{t+1}) \quad (2-16)$$

$$y_t = f(W_{\vec{h}_y} \vec{h}_t + W_{\vec{h}_y} \vec{h}_t + b_y) \quad (2-17)$$

式中： $\vec{h}$ 为前向向量； $\vec{h}$ 为反向向量； y_t 为前向与反向向量作用输出； W

为权重参数； b 为偏差参数； f 为激活函数。

此外，如果模型过拟合，得到的模型几乎不能用。为了防止过拟合现象，提高网络模型的适用性，引入 Dropout 方法。此方法通过使部分神经元随机失去活性，减少了神经网络的复杂度，防止模型过度拟合数据，同时使得网络不会过度依赖某些特定的神经元，并且不同神经元之间也不会依赖彼此的特定特征，从而保证了模型的泛化能力^[65]。

2.4 本章小结

本章针对现阶段分子泵故障诊断与预测依靠人工经验可靠性差等问题，提出引入机器学习算法实现分子泵高准确诊断与预测。通过介绍 BP 神经网络分类的优越性、粒子群搜索最优参数的性能以及交叉验证提高模型诊断准确率的优势，完成分子泵故障诊断理论知识的说明。通过介绍 LSTM 基础模型以及 LSTM 模型的变体 Bi-LSTM 模型的优势，完成对分子泵故障预测理论知识的说明。综合上述诊断与预测理论知识的补充，为第 3 章、第 4 章模型的改进做好铺垫。

第3章 基于改进BP的分子泵故障诊断研究

3.1 引言

现代工业化生产过程中，对于设备故障类型的判别需求日益激增，且由于工人的个人原因，误诊断率偏高等问题也难以避免，所以为了更好地对社会生产过程中的设备做到及时准确的故障检测，人工智能机器学习算法的应用显得格外关键。它无需人工经验，只需要对设备运行过程中的数据进行模型的训练分析，就可以快速对设备出现的故障类型进行诊断输出，不仅节约了人工成本与时间成本，而且有效地避免了误判率与漏检率。通过提前甄别故障类型，从而对设备进行及时干预维护保养，大大延长了设备的使用寿命周期。

机器学习是一种基于数据和算法的人工智能技术，通过对数据学习和分析，能够发现数据中的复杂关系以及背后的本质规律。同时机器学习算法具有很强的适应性，能够根据新的数据自动更新模型，提高诊断的准确性，这使得机器学习在面对不断变化的环境和问题时具有很强的鲁棒性和灵活性。

目前机器学习故障诊断算法，在数据集是平衡的情况下取得了较好的成果。但面对工业实际运行状况，分子泵故障数据是极少的，数据集是不平衡的，导致诊断精度低以及模型过拟合问题。通过机器学习BP算法的引入，虽然可以有效地提高诊断准确率，但BP神经网络训练过程中，往往易陷入局部最优解，为解决这个问题，本文提出在BP神经网络原始的基础上引入PSO算法，保障BP神经网络在计算过程中，可以很大程度上避免局部最优解，同时结合五折交叉验证算法避免模型过拟合，从而寻找最佳适应度值，得到最优参数，训练出最优神经网络模型，提高在不平衡数据集的前提下，实现分子泵故障高准确诊断。

3.2 数据预处理

3.2.1 时域频域特征提取

振动信号的分析处理对于状态检测和故障诊断都至关重要^[66]，信号的分析

主要可分为时域分析、频域分析和时频域分析^[67]。但目前信号处理和机器学习的特征提取方法已普遍用于振动信号分析。机器学习算法通过自主学习大量数据中存在的规律，但在机器学习训练模型过程由于模型参数多，网络层次深，导致训练时间变长，对于分子泵故障诊断来说是非常不利的。相反，基于时域频域提取的特征，无需模型的反复训练，节约时间，同时直接对原始数据处理，最大程度保留数据特征，所以本文提出基于时域频域方法对数据进行预处理。基于传统的时频频域特征提取方法，可以提取最直接的信号特征，是一种快速且高效的特征提取计算方法。时域特征统计表达式如表 3-1 所示，其中 N 代表一个周期内采样点数， X 代表样本数据， x_i 表示当前周期内第 i 个数据样本。

表 3-1 时域统计特征

时域特征参数	表达式	类别
最大值	$X_{\max} = \max(x_i)$	有量纲
最小值	$X_{\min} = \min(x_i)$	有量纲
峰峰值	$X_{ff} = X_{\max} - X_{\min}$	有量纲
平均值	$X_{mean} = \frac{1}{N} \sum_{i=1}^N x_i$	有量纲
方差	$X_{var} = \frac{1}{N} \sum_{i=1}^N (x_i - X_{mean})^2$	有量纲
标准差	$X_{std} = \sqrt{\frac{1}{N} \sum_{i=1}^N (x_i - X_{mean})^2}$	有量纲
均方根	$X_{RMS} = \sqrt{\frac{1}{N} \sum_{i=1}^N x_i^2}$	有量纲
波形因子	$X_{ff} = \frac{X_{RMS}}{ X }$	无量纲
峰值因子	$X_{cf} = \frac{X_{\max}}{X_{RMS}}$	无量纲
脉冲因子	$X_{pf} = \frac{X_{\max}}{ X }$	无量纲

本文选取最大值、最小值、峰峰值等 10 种时域特征来描述振动信号状态信息。但仅仅依据时域统计特征，很难完整反映分子泵振动信号的特征，所以结合频域分析，更好反映数据隐藏的特征。傅里叶变换是一种常用的信号处理方

法^[68]。时域信号和频域信号参数通过快速傅里叶(FFT)相互转化, FFT 的数学表达式如式(3-1)所示:

$$X_k = \sum_{n=0}^{N-1} x(n) W_N^{nk} \quad (3-1)$$

其中 $k = 0, 1, \dots, N-1$, $W_N = e^{-j\frac{2\pi}{N}}$ 是旋转因子, X_k 代表频域值, $x(n)$ 代表时域采样点, n 代表时域采样点的序列索引, k 代表频域值的索引, N 代表转换的采样点数量。

本文选取频率均值、频率重心、频率标准差三种状态频域特征描述分子泵振动状态信息, 与时域特征结合, 多层面反应信号特征, 可以有效提高故障诊断准确率。具体表达式如表 3-2, 单个周期 FFT 变换频谱长度与基波对应频谱幅度分别由 L 和 f_j 代表。

表 3-2 频域统计特征

频域特征参数	表达式
频谱均值	$F_{mean} = \frac{1}{L} \sum_{j=1}^L f_j$
频谱重心	$F_{fc} = \frac{\sum_{j=1}^L f_j f_j}{2\pi \sum_{j=1}^L f_j^2}$
频谱标准差	$F_{std} = \sqrt{\frac{\sum_{j=1}^L (f_j - F_{mean})^2}{L}}$

3.2.2 数据标准化

对振动数据进行时域频域处理提取特征, 由于特征读数自身变异或数值相差较大, 直接使用会存在误差, 为了保证结果的可靠性, 需要对数据进行标准化处理, 让不同维度之间的特征在数值上有一定的比较性, 可以提高分类器的准确性。本模型使用最大最小值归一化对数据进行标准化, 如式(3-2)所示。

$$y = \frac{(y_{\max} - y_{\min}) * (x - x_{\min})}{x_{\max} - x_{\min}} + y_{\min} \quad (3-2)$$

式中, $y_{\max}$ 期望归一化后矩阵每行的最大值为 1; $y_{\min}$ 期望归一化后矩阵每

行的最小值为 0； $x_{\max}$ 矩阵每一行最大值； $x_{\min}$ 矩阵每一行最小值。最大最小值归一化将矩阵的每一行处理成[-1,1]区间。

3.3 基于改进 BP 分子泵故障诊断

3.3.1 改进 BP 算法流程图

针对分子泵在不同故障类型状态下，由于数据集不均衡导致故障诊断精度低问题，提出在 BP 神经网络的基础上引入粒子群与五折交叉验证算法来优化诊断模型，提高分子泵故障诊断的精度。改进 BP 算法流程如图 3-1 所示。




图 3-1 改进 BP 算法流程图

首先，初始化 BP 神经网络结构和种群参数，通过五折交叉验证得到最小误差作为适应度值。在训练过程中，算法没有达到设定的最大迭代次数前，不断更新调整当前粒子的速度与位置，形成新的种群，并结合五折交叉验证计算最佳适应度值，直到迭代次数完成，输出改进 BP 算法的最优权值阈值参数，模型训练结束。

3.3.2 故障诊断算法流程框架

分子泵故障诊断流程如图 3-2 所示。首先，对实验平台采集的振动数据做预处理，提取时域频域特征，组成特征向量集，按一定比例提取训练集，输送到初始化状态的模型，通过五折交叉验证算法得到最小误差作为适应度值，根据是否达到最大迭代次数，不断更新粒子种群参数，并结合五折交叉验证计算最佳适应度值，完成模型训练；最后，将预处理好的测试特征向量集输入已经训练好的模型，通过相关评价指标判断模型诊断结果的好坏。




图 3-2 故障诊断流程图

3.3.3 分子泵故障模拟实验平台

此实验在搭建的分子泵故障模拟实验平台上开展，为 EAST 装置分子泵的前期模拟试验阶段，模拟 EAST 装置撒粉平台。分子泵主要由转子和固定壳体组成，转子上有一系列的叶片，通过高速旋转产生离心力，固定壳体内有一系

列的排气孔，形成分子泵的工作空间。分子泵的工作原理基于气体分子的碰撞和运动规律。在分子泵的工作空间中，流动的气体分子与电机驱动的旋转叶片或者转子发生剧烈碰撞，导致泵内气体分子不断失去动能，最终被抽出真空室，从而为后期实验提供高真空的运行环境。为了保护分子泵电机的正常工作，在开启分子泵前，首先启动机械泵，将装置内真空抽至 10Pa 以下，再打开分子泵继续抽真空。

分子泵破坏性测试平台示意图如图 3-3 所示。该系统主要由抽气系统，真空腔体、针阀、传感器、信号发生器、钨粉坠入系统以及上位机组成。系统涉及仪器设备型号：久泰真空分子泵、久泰真空分子泵电源、普发真空计、NI-9232 采集板卡、cDAQ-9189 以太网机箱、加速度传感器、RIGOL 信号发生器以及 Windows 11 64 位上位机系统环境，该系统有效地保障了故障诊断实验的顺利开展。




图 3-3 实验平台示意图

3.3.4 数据集及样本生成

此实验采集 4 种分子泵运行状态的振动信号。(1) 在分子泵处于正常状态运转时，采集分子泵正常振动信号；(2) 在分子泵正常状态运行下，打开泄气阀，泄气至 100Pa，采集轻度真空泄漏故障振动信号；(3) 在分子泵正常状态运行下，打开泄气阀，泄气至 250Pa，采集中度真空泄漏故障振动信号；(4) 在分子泵正

常状态运行下，采集钨粉坠入系统故障振动信号；

设置采样频率为 1KHz。在采集钨粉异物坠入实验时，信号发生器峰峰值设为 15V，频率设为 2.25KHz，采用手动触发信号，循环数设为 9000，通过多次触发，对钨粉进行流量标定，计算得每触发一次流量为 0.00618g，本实验共触发 352 次，共坠入 2.17536g。

采集正常数据 20000 个，真空泄漏 100Pa 故障数据 8000 个，真空泄漏 250Pa 故障数据 6000 个，钨粉坠入故障数据 4000 个。经过时域频域特征提取，得到 2000 组正常振动特征数据，800 组轻度真空泄漏故障数据，600 组中度真空泄漏故障振动特征数据，400 组钨粉坠入故障振动特征数据，训练集与测试集按 8:2 划分。实验平台如图 3-4 所示：




图 3-4 故障诊断实验平台

改进 BP 神经网络参数设置如表 3-3 所示。

表 3-3 改进 BP 神经网络参数

参数	设置	参数	设置
输入层	13	目标误差	0.00001
隐藏层	6	最大训练次数	500
输出层	4	最大迭代次数	75
学习率	0.002	种群数量	8

输入为 13 个特征，输入层节点数为 13；隐藏层节点数设为 6；输出为 4 分类，输出层节点数为 4；学习率设为 0.002；目标误差设为 0.00001；最大训练次数设为 500；最大迭代次数设为 75；种群数量设为 8。

3.4 实验验证与分析

3.4.1 评价指标

混淆矩阵在机器学习和统计学中常用作评估分类模型性能的工具。它是一个方阵，其中的每个元素表示模型预测结果与真实结果的对应关系。通过提供了对分类模型性能的直观理解和量化评估，帮助了解模型在不同类别上的分类表现，从而优化模型或选择更合适的模型。其原理如图 3-5 所示。

预 测 实 际	正例	负例
正例	TP	FN
负例	FP	TN

图 3-5 混淆矩阵原理图

其中，TP 表示模型将正例预测为正例的数量，FN 表示模型将正例预测为负例的数量，FP 表示模型将负例预测为正例的数量，TN 表示模型将负例预测为负例的数量。从混淆矩阵中引入评价分类性能的指标：准确率(Accuracy)，召回率(Recall)和精确率(Precision)，分别如式(3-3)、(3-4)、(3-5)所示。

$$Accuracy = \frac{TP + TN}{TP + FN + FP + TN} \quad (3-3)$$

$$Recall = \frac{TP}{TP + FN} \quad (3-4)$$

$$Precision = \frac{TP}{TP + FP} \quad (3-5)$$

受试者工作特征曲线(Receiver Operating Characteristic Curve, ROC)曲线是一种常用于评估分类模型性能的图形工具。它最早起源于二战期间雷达信号检测领域，后来被引入到医学诊断、机器学习等领域。在 ROC 曲线中，横轴表示的是模型的假阳性率(False Positive Rate, FPR)，纵轴表示的是模型的真阳性率(True Positive Rate, TPR)，分别如式(3-6)和(3-7)所示。FPR 是指实际为负例但被模型预测为正例的样本比例，而 TPR 是指实际为正例且被模型预测为正例的样

本比例。ROC 曲线的绘制过程是通过改变分类模型的阈值来计算不同 FPR 和 TPR 的取值。当阈值较低时，模型将更多样本预测为正例，导致 FPR 和 TPR 都较高；而当阈值较高时，模型将更多样本预测为负例，导致 FPR 和 TPR 都较低。改变阈值会导致不同的 FPR 和 TPR 值，从而绘制出 ROC 曲线。当 ROC 曲线完成位于对角线以下时，表示模型性能等同于随机猜测；当 ROC 曲线完全位于左上角时，表示模型的性能非常好。除了 ROC 曲线本身，还可以通过计算 ROC 曲线下方的面积(Area Under Curve, AUC)来评估模型性能，其取值范围在 0.5 到 1 之间，越接近 1 表示模型性能越好。

$$FPR = \frac{FP}{FP + TN} \quad (3-6)$$

$$TPR = \frac{TP}{TP + FN} \quad (3-7)$$

3.4.2 实验结果分析

在分子泵主体外部安装加速度传感器，全方位（X 轴、Y 轴、Z 轴）监测加速度传感器采集的分子泵振动信号。如图 3-6、图 3-7 所示，是分子泵在正常状态、钨粉坠入故障态以及真空泄漏故障态四种状态下运行的 Y 轴时域图、频域图。




图 3-6 时域图




图 3-7 频域图

由时域图可知，分子泵在故障态下，电机负载运行，振动幅度明显高于正常状态且故障态振动信号毛刺明显增加。由频域图可知，相较于正常态，在故障态下固有频率处幅度发生变化。

由图 3-8 迭代误差图分析可得，在迭代前期阶段，惯性权重 w 线性减小帮助粒子群算法快速探索解空间，加速从初始解向全局最优解的收敛过程。适应度值曲线下滑较快说明算法在搜索过程中迅速优化模型参数，但可能会陷入局部最优解。随着搜索的进行，惯性权重 w 逐渐减小至较小的值时，适应度值减小并趋于稳定，粒子在极值点周围可以进行更精细的搜索，有效克服局部最优解困境，提高了收敛到全局最优解的概率，平衡了全局搜索和局部精细搜索的能力，使得粒子群算法能够更好地调整网络的权值和阈值，进而训练出最优模型。

图 3-9 为 4 种分子泵状态分类可视化图，图 3-10 为 4 种分类的混淆矩阵。其中类别 1 代表分子泵正常状态；类别 2 代表分子泵钨粉坠入状态；类别 3 代表分子泵真空泄漏 250Pa 状态；类别 4 代表分子泵真空泄漏 100Pa 状态。由图可以分析出：类别 1 中 1 个识别为类别 4；类别 2 实现全识别；类别 3 中 20 个识别为类别 4；类别 4 中 3 个识别为类别 3，整体诊断准确率达 96.84%。实验结果表明，改进 BP 的神经网络模型，有效实现对分子泵故障的高准确分类。

图 3-11 为分子泵运行状态的 4 种类别 ROC 曲线图，曲线都靠近左上角，且曲线下方所围面积 AUC 值都接近 1，曲线 1 和曲线 2 的 AUC 值等于 1，充分说明改进的 BP 神经网络分类器性能优越，可以实现对分子泵运行期间产生的不同状态进行有效的诊断。




图 3-8 迭代误差图




图 3-10 混淆矩阵图




图 3-9 分类可视化




图 3-11 ROC 曲线图

3.4.3 方法对比分析

为了验证本文改进算法的有效性，将其与 SVM、KNN 和 BP 算法进行对比。引入 Accuracy, Recall 和 Precision 作为评价指标。

如表 3-4 所示，改进 BP 的神经网络算法在准确率上分别高于 SVM、KNN、BP，3.37%，3.37%，0.82%，表明改进的算法在整体分类准确性上表现优秀，具有更好的分类性能；在类别 1 的召回率高 KNN，0.26%；在类别 3 的召回率分别高 SVM、KNN、BP，37.89%，16.56%，11.57%；在类别 4 召回率分别高 KNN、BP，7.94%，0.65%，表明改进算法在特定类别的识别能力上有所提升，尤其在类别 3 和类别 4 上表现突出。在类别 1 的精度上高 SVM，2.55%；在类

别 2 的精度上高 BP，1.25%；在类别 3 的精度上分别高 KNN、BP，14.10%，1.18%；在类别 4 的精度上分别高 SVM、KNN、BP，13.09%，6.43%，2.33%，表明改进算法在各个类别的分类精度都有所提高，特别在类别 3 和类别 4 上提升明显。为了更好地说明本文算法优势，如图 3-12 可视化所示，可得改进的 BP 诊断算法相较于传统的算法有明显的优越性，更适用于分子泵故障诊断研究。

表 3-4 诊断结果对比

诊断方法	类别	Accuracy	Recall	Precision
SVM	1	93.68%	100.00%	97.51%
	2		100.00%	100.00%
	3		64.06%	100.00%
	4		98.79%	77.99%
KNN	1	93.68%	99.49%	100.00%
	2		100.00%	100.00%
	3		75.78%	85.09%
	4		90.91%	82.87%
BP	1	96.05%	99.75%	100.00%
	2		100.00%	98.77%
	3		79.17%	95.96%
	4		97.50%	86.19%
改进的 BP	1	96.84%	99.75%	100.00%
	2		100.00%	100.00%
	3		88.33%	97.09%
	4		98.13%	88.20%




图 3-12 评价结果可视化

3.5 本章小结

本章利用分子泵故障模拟实验平台，采集不同状态下分子泵振动信号，模拟 EAST 分子泵故障类型。通过时域频域数据预处理，在 BP 神经网络模型基础上引入粒子群算法与五折交叉验证进行模型优化，实现对分子泵故障高准确诊断。

基于振动信号的传统时域频域特征提取方法，有效还原数据的真实原貌，而且提取效率高，适用于分子泵故障诊断研究。粒子群算法与五折交叉验证的引入，解决了 BP 神经网络容易陷入局部最小值及模型过拟合的问题，提高了诊断准确率。通过方法对比，结果显示所提基于改进 BP 的神经网络算法明显优于 SVM、KNN 和 BP 算法。充分说明，本文方法更适用于分子泵故障诊断研究，为 EAST 探索一种新的诊断方式，为核聚变装置中稳定可靠的真空泵系统铺平了道路，有助于推动分子泵故障诊断技术的进一步发展。

第 4 章 基于 DE-Bi-LSTM 的分子泵故障预测研究

4.1 引言

在第 3 章中，提出的一种时域频域预处理结合改进 BP 的分子泵故障诊断方法，有效地对不平衡数据几种分子泵不同故障类型进行了区分，为 EAST 分子泵故障诊断铺平了道路，为核聚变装置中稳定可靠的真空泵系统打下了坚实的基础。然而，由于分子泵的工作环境复杂，装置时常会出现泄漏状况，检漏不仅需要一定的时间而且会存在一定的漏检现象，所以分子泵长时间处于泄漏状态下运行，极易对其内部部件产生损害，导致其性能下降和重大故障的发生。因此，准确预测分子泵的退化趋势及寿命对于提高其可靠性和维护效率具有重要意义。

目前，对于分子泵的故障寿命预测，主要依靠传统的经验法和试验法。传统的经验法主要基于对分子泵的使用情况和维护记录进行分析，通过经验公式或统计方法来估计其寿命。然而，这种方法往往依赖于经验和直觉，缺乏科学性和准确性。试验法则是通过对大量的分子泵进行试验和监测，以得到其故障寿命的统计数据，然后根据统计规律来预测其他分子泵的寿命，但这种方法需要大量的人力物力资源，且预测精度有限。随着计算机技术和数据分析方法的发展，基于数据驱动的故障预测方法逐渐引起了人们的关注。这种方法主要基于分子泵运行过程中产生的大量数据，通过机器学习算法来分析这些数据，从而建立分子泵故障预测模型。相比于传统的方法，基于数据驱动的故障预测方法可以充分利用分子泵运行过程中所产生的大量信号，从而更深层次挖掘隐藏其中的规律，提高预测的准确性和可靠性，避免了传统方法中依赖经验的不足之处；并且随着后期实验的不断扩展，数据不断产生，模型可以不断被迭代优化，预测性能和精度也会逐步提升。

目前，关于 EAST 分子泵寿命预测存在一些问题，例如主要依靠人工经验、分子泵故障寿命数据不完全以及预测精度低等。为了解决这些问题，本文提出了一种基于时域预处理结合 DE-Bi-LSTM 算法的方案，通过搭建分子泵故障模拟实验平台，验证其对分子泵的高准确预测性能。

4.2 数据预处理

4.2.1 时域特征提取

对分子泵进行退化趋势拟合与剩余寿命预测，时域特征提取是必要的，它可以提供关于信号的统计和时序特征，反映出分子泵的工作状态。

本章通过引入最大值、最小值、均值等统计特征，如表 4-1 所示。它们反映出信号的整体变化趋势、幅度范围和分布情况。通过对这些统计特征的分析，了解分子泵的工作状态，为故障预测提供重要线索，提升分子泵的预测精度。

表 4-1 时域统计特征

时域特征参数	表达式	类别
最大值	$X_{\max} = \max(x_i)$	有量纲
最小值	$X_{\min} = \min(x_i)$	有量纲
峰峰值	$X_{ff} = X_{\max} - X_{\min}$	有量纲
平均值	$X_{mean} = \frac{1}{N} \sum_{i=1}^N x_i$	有量纲
方差	$X_{var} = \frac{1}{N} \sum_{i=1}^N (x_i - X_{mean})^2$	有量纲
标准差	$X_{std} = \sqrt{\frac{1}{N} \sum_{i=1}^N (x_i - X_{mean})^2}$	有量纲
均方根	$X_{RMS} = \sqrt{\frac{1}{N} \sum_{i=1}^N x_i^2}$	有量纲
波形因子	$X_{ff} = \frac{X_{RMS}}{ X }$	无量纲
峰值因子	$X_{cf} = \frac{X_{\max}}{X_{RMS}}$	无量纲
脉冲因子	$X_{pf} = \frac{X_{\max}}{ X }$	无量纲

4.2.2 数据标准化

对振动数据进行时域处理提取特征，但特征读数自身变异或数值相差较大，

直接使用会存在误差，无法在迭代过程中训练出最好的效果，为了提高模型的收敛速度和降低均方根误差，本模型使用 Z-score 标准化数据，使其符合标准正态分布，即均值为 0，标准差为 1，如式(4-1)所示。

$$X_i^* = \frac{X_i - X_{mean}}{X_{std}} \quad (4-1)$$

式中， X_i 是时序数据， X_{mean} 是时序数据的均值； X_{std} 是时序数据的标准差； X_i^* 是经过标准化的时序数据。

4.2.3 分段线性退化模型

分段线性退化模型是一种用于预测寿命的统计模型，适用于许多设备和系统的寿命评估和预测。它基于假设生物体的寿命可以被分为不同阶段，并且在每个阶段内，生物体的寿命以线性方式递减，广泛地应用于生物学与医学领域。在分子泵寿命预测中，分段线性退化模型可以用来描述分子泵在使用过程中的退化行为和寿命变化。系统的退化有一个发展的过程，通常故障前期运行数据对整体的预测精度影响较小，因此在系统开始退化之前估计剩余使用寿命 (Remaining Useful Life, RUL) 是不合理的。为解决这类问题，引入分段线性退化模型进行预测^[69]。模型如图 4-1 所示。




图 4-1 分段线性退化模型

在实际变化过程中，RUL 与时间步长始终保持线性关系。该模型假设分子

泵前期时间步是一个常数值，某一时间步长后，开始线性退化。经多次实验，当 RUL 值设定为 38 时，具有较好的预测效果。

4.3 基于 DE-Bi-LSTM 的分子泵故障预测

4.3.1 网络模型的构建

如图 4-2 所示，DE-Bi-LSTM 模型是对 Bi-LSTM 进行改进的神经网络模型，增加了神经网络的深度，通过叠加一层 Bi-LSTM 来进一步挖掘隐藏规律。叠加的原理是将每个输入对应的输出作为下一层 Bi-LSTM 神经网络相应节点的输入。DE-Bi-LSTM 模型的改进带来了多个优势。首先，它能够正向和反向捕获上下文特征信息，从而更好地理解输入数据；其次，通过增加网络的深度，模型可以学习更多的隐藏信息，使得整体结构更加完善。这种深度的网络结构有助于提高整个模型的性能，从而提高预测精度。




图 4-2 DE-Bi-LSTM 模型结构

关于深度学习的网络模型架构设计，对整个模型的训练效果以及预测效果性能有着重要影响。过多的超参数的设置，如网络层数的叠加，隐藏单元数的增加等都会改善模型的整体性能，但同时也会使模型的结构趋于复杂化，导致计算量和模型训练时长的增加。目前阶段，暂时还没有比较成熟的理论去有效选取这些超参数。本模型的构建通过反复对比来选取最优的超参数。DE-Bi-LSTM 最终参数选择结果如下：第一层为 Bi-LSTM，第二层为 Bi-LSTM，隐藏单元层数量均为 100，丢弃层概率均为 0.5，最大训练次数 500，最小批次 3。

4.3.2 故障预测算法框架

为了最大程度提高分子泵故障预测的准确性，提出基于时域分析的 DE-Bi-LSTM 模型分子泵预测算法。故障预测流程图如图 4-3 所示。




图 4-3 故障预测流程图

首先，对采集的实验数据进行预处理，提取时域特征，构建特征向量集，并为训练集和测试集贴上时间步长标签。通过数据标准化处理的特征向量集和时间步长标签作为模型的输入，根据是否达到最大迭代次数，不断更新神经网络权重参数，最小化损失函数值和均方根误差值，完成模型训练。已标记时间步长标签与特征向量集的测试集输入至已经训练好的模型，输出预测的剩余使用寿命，并与实际值进行对比，通过引入相关评价指标来评估模型预测效果。

4.3.3 分子泵故障模拟实验平台

此实验为 EAST 装置分子泵的前期试验阶段，模拟分子泵在真空泄漏状态

下，预测其退化性能与剩余使用寿命。启动前需先启动机械泵，确保真空低于 10Pa 然后启动分子泵继续抽气，有效地保护分子泵电机正常工作。系统涉及仪器设备型号：久泰真空分子泵、久泰真空分子泵电源、普发真空计、NI-9232 采集板卡、cDAQ-9189 以太网机箱、加速度传感器，以及 Windows 11 64 位上位机系统环境。故障预测实验平台如图 4-4 所示。




图 4-4 故障预测实验平台

4.3.4 数据集及样本生成

此实验为真空泄漏故障预测实验。如图 4-5 所示是实验数据采集架构图：




图 4-5 数据采集架构图

当分子泵处于正常状态运转时，打开泄气阀，通过真空计监测气压，泄气至 150Pa，让分子泵在泄压状态下持续负载运行，直到分子泵出现故障（此时

间点作为步长标签截止时间点)。传感器采集的数据,由采集板卡上传至上位机进行显示和存储。

每次实验过程采集数据量较大,为了降低数据处理的复杂性且保留原始信号的特征信息,每隔 2 分钟提取一次振动信号。系统采样频率设为 1KHz,每个样本包含 20000 个数据点,且每个样本作为一个步长时间点,贴上步长标签。共获得 4 组时间步长序列,时间步长分别为 59、69、53、45,前三组作为训练集,最后一组作为测试集。

4.4 实验验证与分析

4.4.1 实验结果与分析

在模型的训练过程中,如图 4-6 是 RMSE 误差图像,随着迭代次数的增加,前期 RMSE 下降比较迅速,说明模型对数据隐藏的规律快速地学习,训练的精度得到有效提高,随着后期迭代次数的增加,曲线下降缓慢最终趋于平行于横轴,表明模型已训练至最优状态,对数据的学习已经相对稳定。如图 4-7 所示是 Loss 函数图像,表现为早期下降迅速,随后趋于平缓的情况,说明模型对输入特征数据学习已经较为充分,开始集中学习数据中的一些稳定特征。当 Loss 函数曲线趋近平行于横轴时,表明模型已经完全收敛,即找到了最优参数配置,并在给定数据集上取得了最佳性能。综合考虑 RMSE 误差和 Loss 函数的变化趋势,更全面地评估模型的收敛情况,保证模型在训练过程中有效地学习数据特征并达到最佳状态。




图 4-6 均方根误差图像




图 4-7 损失函数图像

图 4-8 为基于 DE-Bi-LSTM 模型的预测效果,随着时间步长的推移,预测

曲线在测试曲线上上下波动，与测试曲线相靠近。虽中间下降趋势有所波动，但整体与预测曲线下降的趋势相符，较好地实现了拟合预测，说明模型有效地学习到基于原始数据的时序特征分布规律。

4.4.2 方法对比与分析

为验证本文方法的有效性，本节将与其他方法做对比实验。具体模型包括：
(1) 本文网络结构由基本的 LSTM 网络单元替换，模型参数设置相同。
(2) 本文网络中 Bi-LSTM 替换成 LSTM，构造 DE-LSTM，模型参数设置相同。
(3) 本文网络结构替换为 Bi-LSTM，网络参数设置相同。其三种方法预测结果如图 4-9、图 4-10、图 4-11 所示：




图 4-8 DE-Bi-LSTM 预测结果图




图 4-9 LSTM 预测结果图




图 4-10 DE-LSTM 预测结果图




图 4-11 Bi-LSTM 预测结果图

如图所示的三种方法预测曲线大致均在测试数据曲线上方，DE-LSTM 与 LSTM 模型预测曲线下下降趋势前期波动较大，相比之下 Bi-LSTM 模型的预测曲线下下降趋势与测试曲线较符合，但三种方法预测曲线与 DE-Bi-LSTM 模型相比，明显，本文所提方法更能很好地对测试数据进行拟合预测。

为了进一步评估本文提出的算法与另外三种算法的表现，引入平均绝对误差(MAE)，均方根误差(RMSE)，标准差(SD)，平均绝对百分比误差(MAPE)四种参数作为模型预测评价指标，其中 x_i 代表真实寿命， y_i 代表预测寿命， n 代表寿命步长，涉及相关参数定义如式(4-2)、(4-3)、(4-4)、(4-5)所示：

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - x_i| \quad (4-2)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - x_i)^2} \quad (4-3)$$

$$SD = \sqrt{\frac{1}{n} \sum_{i=1}^n \left((y_i - x_i) - \frac{1}{n} \sum_{i=1}^n (y_i - x_i) \right)^2} \quad (4-4)$$

$$MAPE = \frac{100\%}{n} \sum_{i=1}^n \left| \frac{y_i - x_i}{x_i} \right| \quad (4-5)$$

预测对比结果，如表 4-2、图 4-12 所示：

表 4-2 预测结果对比

预测方法	MAE	SD	RMSE	MAPE
LSTM	12.273	8.680	14.548	1.748
DE-LSTM	8.774	5.455	10.203	1.124
Bi-LSTM	8.559	6.285	10.619	0.586
DE-Bi-LSTM	2.511	2.247	3.170	0.312




图 4-12 预测结果可视化

相较于其他三种算法，基于 DE-Bi-LSTM 的 MAE、SD、RMSE 以及

MAPE 值均是最小的，Bi-LSTM 和 DE-LSTM 模型次之，LSTM 最大。DE-Bi-LSTM 的 MAE 相较于其他三种算法，分别下降 79.54%，71.38%，70.66%；SD 相较于其他三种算法分别下降 74.11%，58.81%，64.25%；RMSE 相较于其他三种算法分别下降 78.21%，68.93%，70.15%；MAPE 相较于其他三种算法分别下降 82.15%，72.24%，46.76%。结果表明本文算法在预测准确度、稳定性和泛化能力方面都表现出色，并在各项指标上的显著改善，显示算法在处理时间序列数据方面具有明显优势。且通过柱状图更直观看出，本文所提基于时域分析并引入分段线性退化模型结合 DE-Bi-LSTM 的算法预测效果最好，说明其可以更有效地捕捉数据的特征和规律，更适用于分子泵故障预测研究。

4.5 本章小结

为了给 EAST 装置提供良好的真空环境，本章实验为基于分子泵故障模拟实验平台的先前性预实验，对分子泵进行故障预测。提出基于振动信号的时域特征分析，引入分段退化模型结合 DE-Bi-LSTM 的预测模型方法，实现对分子泵故障预测。

基于振动信号的传统时域特征提取方法，能够有效还原整个时间序列数据的真实原貌，而且提取效率高，无需复杂的特殊处理过程，适用于分子泵故障预测研究。将深度长短时记忆网络与双向长短时记忆网络相结合，不仅学习了时序数据过去的信息，也学习了未来的信息，加强了对数据深层信息的挖掘，使模型对整个时间序列的表达能力更强，同时退化模型的引入能更好地学习故障后期信息特征，提高预测精度。实验结果表明在平均绝对误差、标准差、均方根误差和平均绝对百分比误差指标上都有良好的表现，说明所提方法可以更好地对分子泵退化趋势及剩余寿命进行较高精度的预测，可以及时发现分子泵的健康状况，并提前采取维护措施，合理安排分子泵的维护计划和更换计划，以避免分子泵的故障和停机对装置造成重要影响。同时有助于提高分子泵的可靠性和可用性，为 EAST 探索一种新的维护方式，为未来商业运行提供了一种新的解决方案，更为分子泵维护领域提供重要参考，进一步推动相关技术研究。

第 5 章 EAST 分子泵故障诊断模型设计与部署

5.1 引言

旋转机械在工业制造领域扮演着重要角色，被广泛应用于各个行业，包括能源、化工、汽车、航空航天等。旋转机械由于长时间使用、高速运转、恶劣的工作环境以及机械部件的磨损等原因，旋转机械的故障频繁发生，给生产安全和生产效率带来了巨大的威胁。

为了确保旋转机械的正常运行和生产安全，设备状态监测诊断是必不可少的。设备状态监测诊断是通过采集机械运行时的振动、温度、压力、电流等参数进行的，利用传感器和诊断系统进行实时监测和诊断分析，以判断机械是否存在故障以及甄别故障是哪种类型。通过设备状态监测诊断系统，可以提前发现机械的潜在问题，及时采取维修或更换措施，避免造成损失和危害。设备状态监测可以采用多种技术和方法，包括振动监测、红外热像监测、声波监测、电气监测等。振动监测是最常用的方法之一，通过监测机械振动信号的频率、幅值等参数，可以判断机械是否存在异常振动，进而判断是否存在故障。

在前面的章节，介绍了基于机器学习的分子泵故障诊断与预测技术研究的方法。提出了基于改进 BP 的分子泵故障诊断研究以及基于 DE-Bi-LSTM 分子泵故障预测研究的方法，并通过实验设计充分验证了所提方法的优越性。本章结合工程应用实际问题，针对 EAST 装置上的分子泵，提出并设计开发一套分子泵故障诊断系统，实现对 EAST 装置上分子泵运行状态实时监测及不同故障类型诊断功能。主要通过加速度传感器监测其振动的时域信号以及频域信号，并结合实际运行状态条件，引入 SVM 机器学习模型实现对分子泵不同故障类型实时诊断的初步部署。

5.2 EAST 装置分子泵在线故障诊断系统测试

分子泵是 EAST 装置中的重要组成部分，其正常运行对整个装置的稳定运行至关重要。本章旨在设计开发一套分子泵故障监测诊断系统，以解决 EAST

装置分子泵早期叶片破裂对系统造成的重要影响问题。该系统能够实时监测分子泵的工作状态，及时发现异常情况并进行故障诊断分析，提高设备可靠性，减少停机时间和维修成本，同时大大减轻值班工作人员的压力。系统涵盖数据采集，数据分析，数据存储和故障诊断等多方面，有效地实现对装置分子泵的监测与故障甄别功能，为 EAST 实验放电提供了设备的可靠性、安全性。整个故障监测诊断框架图如图 5-1 所示。




图 5-1 分子泵故障监测诊断框架图

EAST 装置分子泵目前采用的是加速度传感器，通过将其固定在外真空分子泵表面，从而对振动信号进行监测。采样率设置为 1000，后期为了不断完善装置功能，会继续引入电流、温度、压力等传感器进行数据采集。采集板卡采用的是 NI-9230，相应的以太网机箱采用的是 cDAQ-9185，然后利用 TCP/IP 进行信息通讯，获取分子泵三轴振动信号，上位机系统由 LabVIEW 2020 (32 位) 与 Python(32 位)编程，系统环境为 Windows 11 64 位系统。从而对分子泵运行状态全方位监测诊断，保障 EAST 实验的顺利开展。

此系统可以实现对分子泵运行期间，时域数据的实时显示存储、频域信号分析与存储、时域信号特征的提取以及故障诊断预警等功能。外真空共计四台分子泵，分别记为 P3.1、P3.2、P3.3、P3.4。

系统时域图与频域图界面如下所示。其中，图 5-2、图 5-3、图 5-4、图 5-5 可以清楚显示，在 EAST 放电实验期间，外真空对应四台分子泵实时运行有关的 X 轴、Y 轴、Z 轴时域状态信息，更加直观对分子泵运行状态做监测分析，EAST 实验放电期间，振幅未出现明显波动，与实验运行状况相符。图 5-6 是四台分子泵运行状态总和的实时时域状况，方便真空观察室人员对比分子泵振动幅度大小，从而有效地对实验运行状态的分子泵做故障监测。




图 5-2 P3.1 分子泵时域界面图




图 5-3 P3.2 分子泵时域界面图




图 5-4 P3.3 分子泵时域界面图




图 5-5 P3.4 分子泵时域界面图




图 5-6 分子泵时域界面图

时域图虽然可以有效地直接反映分子泵运行状态振幅随时间变化的波动状况，但无法直接展现信号的频率成分与频谱特性，尤其对于 EAST 装置放电期间，外真空分子泵振动信号复杂，时域图无法清晰地展示信号的隐藏特征，所以为了更好地帮助值班人员监测分子泵状态，系统包含频域分析功能，如图 5-7、图 5-8、图 5-9、图 5-10、图 5-11 所示。

频域图可以清楚显示外真空对应四台分子泵实时运行有关的 X 轴、Y 轴、Z 轴频域信息。通过四台外真空分子泵的频域图，可以清楚发现，在每一轴的固有频率处都出现相应的振幅，且在高频部分振幅明显高于低频部分，与分子泵正常运行状态频域信息相符，满足 EAST 实验放电期间需求。图 5-11 是四台分子泵运行状态总和的实时频域状况，方便真空观察室人员监测分析分子泵运行状态。

通过实时观察时域和频域信息，可以充分了解分子泵的运行状态，辅助工作人员完成对分子泵的状态监测。然而当实验放电期间，分子泵出现故障时，有效的故障诊断系统才更利于对分子泵做健康管理，进而更充分保障 EAST 实验的顺利开展。




图 5-7 P3.1 分子泵频域界面图




图 5-8 P3.2 分子泵频域界面图




图 5-9 P3.3 分子泵频域界面图




图 5-10 P3.4 分子泵频域界面图




图 5-11 分子泵频域界面图

故障诊断系统中，最关键的功能是实时诊断分子泵运行状态。其中图 5-12 诊断程序框图，实现采集信号的特征提取，再通过图 5-13 诊断程序框图实现已训练好机器学习模型的调入，对特征向量进行分析，最后通过数组与波形图的形式将诊断结果显示在前面板界面图上。

故障诊断系统，诊断结果以五行一列的数组格式显示，当第一个数字显示 0 则代表正常运行状态，前面板布尔灯显示绿灯；当第一个数字显示 1 则代表真空泄漏，前面板布尔灯显示红灯；当第一个数字显示 2 则代表异物坠入，前面板布尔灯显示黄灯；数组第二个数字代表样本中，系统识别为正常态的数量；数组第三个数字代表样本中，系统识别为真空泄漏的数量；数组第四个数字代表样本中，系统识别为异物坠入的数量；数组第五个数字代表输入系统的总样本数量。同时，四台外真空分子泵诊断结果也通过波形图进行实时更新显示，更加直观地辅助值班人员观察记录。

如图 5-14 是 EAST 装置放电期间，P3.1、P3.2、P3.3、P3.4 四台外真空分子泵实时运行状态诊断界面图。图中四台分子泵绿灯正常亮起，与实验实际运行状态相符。根据图中诊断界面数据分析可得，P3.1 分子泵诊断系统误将 7 组

正常态识别为异物坠入态，识别率达到 93.00%；P3.2 分子泵诊断系统误将 10 组正常态识别为异物坠入态，识别率达到 90.00%；P3.3 分子泵诊断系统误将 5 组正常态识别为异物坠入态，识别率达到 95.00%；P3.4 分子泵诊断系统误将 4 组正常态识别为异物坠入态，识别率达到 96.00%。四台分子泵总体诊断水平较高，总体平均准确率达到 93.50%，有效地减轻值班人员工作负担，同时更进一步保障实验放电顺利进行。




图 5-12 诊断程序框图 1




图 5-13 诊断程序框图 2




图 5-14 诊断界面图 1

实验放电期间，采集的分子泵振动信号复杂无序。为了更好地评估所部署故障诊断系统的稳定性与诊断模型的鲁棒性，持续监测另外四组分子泵运行状态信号，并做分析。

如图 5-15 诊断界面图 2 所示，四台分子泵绿灯均已亮起，与 EAST 放电实验期间分子泵实际正常运行状况相符，其中 P3.1 分子泵诊断系统误将 3 组正常态识别为异物坠入态，识别率达到 97.00%；P3.2 分子泵诊断系统误将 16 组正常态识别为异物坠入态，识别率达到 84.00%；P3.3 分子泵诊断系统误将 12 组正常态识别为异物坠入态，识别率达到 88.00%；P3.4 分子泵诊断系统误将 6 组正常态识别为异物坠入态，识别率达到 94.00%，总体平均准确率达到 90.75%。

如图 5-16 诊断界面图 3 所示，四台分子泵绿灯均已亮起，与 EAST 放电实验期间分子泵实际正常运行状况相符。其中 P3.1 分子泵诊断系统误将 3 组正常态识别为异物坠入态，识别率达到 97.00%；P3.2 分子泵诊断系统误将 10 组正常态识别为异物坠入态，识别率达到 90.00%；P3.3 分子泵诊断系统误将 15 组正常态识别为异物坠入态，识别率达到 85.00%；P3.4 分子泵诊断系统误将 4 组正常态识别为异物坠入态，识别率达到 96.00%，总体平均准确率达到 92.00%。




图 5-15 诊断界面图 2




图 5-16 诊断界面图 3

由图 5-17 诊断界面图 4 所示，四台分子泵绿灯均已亮起，与 EAST 放电实验期间分子泵实际正常运行状况相符。其中 P3.1 分子泵诊断系统误将 2 组正常态识别为异物坠入态，识别率达到 98.00%；P3.2 分子泵诊断系统误将 9 组正常态识别为异物坠入态，识别率达到 91.00%；P3.3 分子泵诊断系统误将 4 组正常态识别为异物坠入态，识别率达到 96.00%；P3.4 分子泵诊断系统误将 2 组正常态识别为异物坠入态，识别率达到 98.00%，总体平均准确率达到 95.75%。




图 5-17 诊断界面图 4

由图 5-18 诊断界面图 5 所示，四台分子泵绿灯均已亮起，与 EAST 放电实验期间分子泵实际正常运行状况相符。其中 P3.1 分子泵诊断系统误将 3 组正常态识别为异物坠入态，识别率达到 97.00%；P3.2 分子泵诊断系统误将 8 组正常态识别为异物坠入态，识别率达到 92.00%；P3.3 分子泵诊断系统误将 1 组正常态识别为异物坠入态，识别率达到 99.00%；P3.4 分子泵诊断系统误将 1 组正常态识别为异物坠入态，识别率达到 99.00%，总体平均准确率达到 96.75%。

分子泵故障诊断系统运行期间，一切功能正常，监测诊断结果与实验放电期间实际相符，说明系统具有较强的稳定性和有效性。同时由分子泵故障诊断连续监测的五组运行数据分析可得，如表 5-1 监测诊断结果所示。P3.1 分子泵

诊断系统总体平均正确识别率可达到 96.40%；P3.2 分子泵诊断系统总体平均正确识别率可达到 89.40%；P3.3 分子泵诊断系统总体平均正确识别率可达到 92.60%；P3.4 分子泵诊断系统总体平均正确识别率可达到 96.60%，外真空四台分子泵总体诊断平均准确率高达 93.75%，有效地保障了 EAST 实验的顺利开展。




图 5-18 诊断界面图 5

表 5-1 监测诊断结果

监测组数	P3.1 准确率	P3.2 准确率	P3.3 准确率	P3.4 准确率
第一组	93.00%	90.00%	95.00%	96.00%
第二组	97.00%	84.00%	88.00%	94.00%
第三组	97.00%	90.00%	85.00%	96.00%
第四组	98.00%	91.00%	96.00%	98.00%
第五组	97.00%	92.00%	99.00%	99.00%
平均准确率	96.40%	89.40%	92.60%	96.60%

系统实现对放电期间分子泵振动信号的全面监测，通过特征提取，实现故障诊断和报警功能的提示。全自动化系统的引入，取代了传统的人工经验作业，不仅提高了工作效率，更重要的是保障了工作人员的安全，意义重大。

5.3 EAST 装置分子泵离线故障诊断系统测试

EAST 装置分子泵在线监测诊断系统，在四台外真空分子泵实验运行期间，取得了较好的诊断效果，为 EAST 放电实验顺利开展奠定了坚实的基础。但放电期间，装置分子泵大部分状态下都处于正常运行状态，故障状态很少出现。为了更全面地评估诊断系统的可靠性和稳定性，对 EAST 装置分子泵离线状态进行测试，通过引入真空泄漏及异物坠入异常状态，模拟实际工作中可能出现的异常情况，更加全面地对诊断系统进行评估。测试结果如图 5-19、图 5-20、图 5-21、图 5-22 所示。




图 5-19 诊断界面图 6

由图 5-19 分析可得，对输入的 300 组正常态特征向量，P3.1、P3.2、P3.4 外真空分子泵诊断系统实现了全识别，P3.3 分子泵诊断系统将 1 组正常态识别为异物坠入态，正确率高达 99.67%，总体平均准确率达到 99.92%。由图 5-20 分析可得，对输入的 200 组真空泄漏故障特征向量，P3.1、P3.2、P3.3、P3.4 四台外真空分子泵诊断系统均将 2 组真空泄漏识别为异物坠入故障态，准确率高达 99.00%，总体平均准确率达到 99.00%。




图 5-20 诊断界面图 7

由图 5-21 分析可得，对输入的 100 组异物坠入故障态特征向量，P3.1、P3.2、P3.3、P3.4 四台外真空分子泵诊断系统实现了 100.00%全识别。

针对每一种分子泵运行状态的甄别，部署的四台外真空分子泵故障诊断系统有效地实现了对 EAST 放电期间存在的故障类型高准确识别。本章为了更进一步说明系统的性能，将三种状态的特征向量融为一体，作为系统的输入，共计 600 组特征向量，离线测试结果如图 5-22 所示。经过诊断界面数据分析可得，P3.1、P3.2、P3.4 三台外真空分子泵诊断系统对于正常态实现了全识别，将 2 组真空泄漏态识别为异物坠入态，对于异物坠入态实现了全识别，诊断准确率高达 99.67%。对于正常态、真空泄漏故障态、异物坠入故障态召回率分别为 100.00%、99.00%、100.00%，精度分别为 100.00%、100.00%、98.04%。同时，P3.3 外真空分子泵诊断系统将 1 组正常态识别为异物坠入态，将两组真空泄漏态识别为异物坠入态，对于异物坠入态实现全识别，准确率高达 99.50%。对于正常态、真空泄漏故障态、异物坠入故障态召回率分别为 99.67%、99.00%、100.00%，精度分别为 100.00%、100.00%、97.09%。由此可见，本章部署的分子泵故障诊断系统的优越性。




图 5-21 诊断界面图 8




图 5-22 诊断界面图 9

5.4 本章小结

针对 EAST 装置分子泵可能存在潜在故障，对放电期间造成重大影响，初步实现对 EAST 分子泵故障诊断系统的设计与部署，完成实时监测存储外真空分子泵时域频域信息，实现对监测数据的特征提取预处理，通过对机器学习诊断模型的训练，实现对输入特征向量集实时甄别，利用布尔灯的亮灭来显示分子泵运行状态，从而更好地提醒真空室值班人员保障装置安全放电。

本章通过在线与离线数据测试，从不同角度评估模型性能，并对不同状态分子泵运行特征进行数据分析与诊断评估，根据诊断界面结果显示，充分说明故障诊断系统的优越性。通过完善的诊断策略和保护机制，有效降低聚变装置在运行过程中发生重大事故的可能性，提高真空系统和整个装置的安全性，这为未来 ITER 运行和 CFETR 工程建设提供了有益参考和实际应用价值，为核聚变领域的发展和进步做出重要贡献，更为未来核聚变技术的推广和商业化应用奠定了坚实基础。

第 6 章 工作总结与展望

6.1 工作总结

针对 EAST 真空系统面对聚变装置不间断放电运行发展需要，而分子泵又是获得高真空的核心设备。本文依托 EAST 托卡马克装置背景，开展分子泵故障诊断与预测技术研究，同时面对聚变装置连续运行的需要，部署故障诊断连锁保护机制系统，避免现阶段主要依靠人员运行经验的操作模式，从而减少误操作的风险。为分子泵正常运转，EAST 实验期间顺利放电打下坚实基础。

针对在 EAST 实验运行过程中，分子泵设备可能会出现异物坠入或者真空泄漏故障，而分子泵故障数据相较于正常数据不均衡，模型容易过拟合导致故障诊断准确率低问题，开展分子泵故障诊断研究工作。提出一种基于时域频域预处理与改进 BP 相结合的算法，实现分子泵故障诊断。通过在 BP 神经网络的基础上，引入粒子群算法并结合五折交叉验证优化模型。首先在模拟分子泵故障的破坏性测试平台上，采集正常态、真空泄漏以及异物坠入故障振动信号，然后对数据进行时域和频域特征提取融合，得到的特征向量集作为优化算法的输入，对模型进行训练，实现分子泵故障诊断。经实验验证，所提方法在诊断准确率上可以达到 96.84%，优于支持向量机、K 近邻和 BP 算法。

针对分子泵内部件疲劳退化，可能会出现真空泄漏故障，在长期运行过程中对装置造成次生危害。为了提高对分子泵故障预测准确性，在 LSTM 的基础上，将 DE-LSTM 与 Bi-LSTM 相结合，提出 DE-Bi-LSTM 算法，并引入分段线性退化模型应用于分子泵故障预测。通过在模拟分子泵故障的破坏性测试平台上，采集泄漏于大气下，其运行至故障时间序列振动信号，然后对数据进行时域特征提取，最后通过数据标准化将得到的特征向量集作为 DE-Bi-LSTM 算法的输入，对模型进行训练测试，实现分子泵故障预测。经实验验证，所提方法在预测效果上优于 LSTM、DE-LSTM 和 Bi-LSTM。

针对 EAST 实验不断放电的需求，部署连锁故障诊断保护系统机制。利用数据采集设备与 AI 人工智能技术相结合，设计部署分子泵故障监测诊断系统。通过采集板卡获取外真空分子泵加速度振动信号，利用 LabVIEW 界面程序实

现时域和频域信息的存储与显示。通过时域特征提取，形成特征向量集，自动输入至训练好的机器学习模型，将诊断结果通过 LabVIEW 界面布尔灯进行实时显示，同时数组与波形图将分类结果进行实时呈现，更加方便放电实验期间工作人员的操作与管理。

6.2 工作展望

本文在研究基于分子泵故障诊断与预测技术研究任务中，虽然在故障诊断与预测精度有了一定的提升，并且在托克马克装置上取得了一定的实践，但是鉴于时间和个人研究能力等因素的限制，研究内容仍需进一步完善，后续工作重点准备将从以下方面开展：

1.本文在故障诊断实验中，虽然提出的基于改进 BP 的分子泵故障诊断算法，在准确率上有所提高，但模型训练时间相对工程应用需求会比较长，后期会更注重轻量化模型的训练，从准确性以及效率等多方面结合出发。同时由于实验条件有限，目前模拟的故障类型较少，且该方法能否在不同类型分子泵上取得较好的测试效果需要后期更多的实验进行验证，从而更好地说明本文算法的泛化性以及优越性。

2.本文在故障预测实验中，虽然提出的基于 DE-Bi-LSTM 的故障预测算法，在拟合精度上取得了较好的效果，但在实验过程中未完全考虑噪声的影响，后期需要引入更好的去噪方法对数据进行有效的清洗，同时在参数量较大的基础上进行模型训练，增加时间成本，后期需要从降低参数设置以及计算资源的消耗方向出发。并且考虑到受实验条件的限制，导致实验的单一性，后期将增加多个实验平台建设，采集更多不同状态下分子泵退化趋势信号，丰富故障预测内容。

3.本文在 EAST 分子泵故障监测诊断实验平台部署中，对于传感器选择有限，后期考虑加入多个传感器，从多方位采集分子泵运行状态信息；同时通过搭建不同故障模拟实验平台监测不同类型故障信号，实现更多分类模型的训练，并且后期尝试融合轻量化学习算法训练部署，不仅更深层次挖掘数据隐藏信息，同时满足工程应用实际需求，部署更高效准确的故障诊断系统，完善分子泵健康管理机制。

参考文献

- [1] 孟凡卫, 张小辉, 胡广海, 等. EAST-CTI 测试平台上六硼化镧等离子体源的研制[J]. 核聚变与等离子体物理, 2024, 44(1): 24-29.
- [2] 万宝年, 徐国盛. EAST 全超导托卡马克高约束稳态运行实验研究进展[J]. 中国科学:物理学 力学 天文学, 2019, 49(4): 47-59.
- [3] 岳动华, 张兴义, 周又和. 国际热核聚变实验堆用管内电缆导体力学行为研究进展[J]. 科学通报, 2018, 63(4): 396-414.
- [4] 李建刚. 托卡马克研究的现状及发展[J]. 物理, 2016, 45(2): 88-97.
- [5] Hu J S, Wang X M, Li J H, et al. Vacuum and wall conditioning system on EAST[J]. Fusion Engineering and Design, 2009, 84(12): 2167-2173.
- [6] 韩恒文, 韩伟, 程薇. 石化行业 CO₂ 排放核算与减排技术进展[J]. 石油化工, 2023, 52(12): 1754-1764.
- [7] 张春晖, 肖楠, 苏佩东, 等. 氢能、碳减排与可持续发展[J]. 能源与环保, 2023, 45(7): 1-9.
- [8] 武魏楠. 核聚变再现净能量增益[J]. 能源, 2023, (9): 64-66.
- [9] 魏金莹, 李山峰, 郭永朝, 等. 真空系统的设计[J]. 低温与特气, 2022, 40(1): 26-30.
- [10] 蔡易平, 文霞, 王栋, 等. 一种分子泵除气系统断电保护及高真空保持技术[J]. 真空电子技术, 2019, (5): 47-52.
- [11] Yuan X L, Jia K, Chen Y, et al. A support vector machine framework for fault detection in molecular pump[J]. Journal of Nuclear Science and Technology, 2023, 60(1): 72-82.
- [12] 陈长基, 梁树华, 吴达雷, 等. 一种可解释人工智能(XAI)在测量设备故障诊断和寿命预测中的应用[J]. 西南大学学报(自然科学版), 2024, 46(1): 167-177.
- [13] 薛建儒, 房建武, 吴俊, 等. 多机协同智能发展战略研究[J]. 中国工程科学, 2024, 26(1): 101-116.
- [14] 王敏, 邓艾东, 马天霆, 等. 基于双注意力机制的 MSCN-BiGRU 的滚动轴承故障诊断方法[J]. 振动与冲击, 2024, 43(6): 84-92+103.

- [15]李峻辉, 黄伟. 基于 GRA-DeepAR 的燃气轮机燃烧室故障预警研究[J]. 上海电力大学学报, 2023, 39(1): 19-24+32.
- [16]武文志. 基于物联互联的设备管理应用平台研究[J]. 设备管理与维修, 2021, (16): 88-89.
- [17]田晶, 高晓岚, 陈仁桢, 等. 基于贝塔分布与滤波降噪算法的滚动轴承故障预警方法[J]. 仪器仪表学报, 2023, 44(12): 44-54.
- [18]赵丰, 易辉. 基于改进 LLE-LSTM 的化工过程故障诊断[J]. 中国仪器仪表, 2023, (12): 46-51.
- [19]Kafeel A, Aziz S, Awais M, et al. An expert system for rotating machine fault detection using vibration signal analysis[J]. Sensors, 2021, 21(22): 7587.
- [20]钟辉, 郭瑜, 高国泽. 参数自适应 SMHD 滚动轴承 IAS 信号特征提取方法[J]. 电子测量与仪器学报, 2023, 37(12): 10-17.
- [21]熊剑, 邓松, 时大方. 基于改进残差网络的滚动轴承故障诊断[J]. 轴承, 2020, (11): 50-55.
- [22]贾凯, 江明, 袁啸林, 等. 基于代价敏感型 LightGBM 的分子泵故障检测[J]. 电子测量与仪器学报, 2022, 36(10): 55-64.
- [23]慕晓冬, 魏轩, 曾昭菊. 基于注意力残差网络的航天器测控系统故障诊断[J]. 仪器仪表学报, 2022, 43(9): 81-87.
- [24]Qin A S, Mao H L, Hu Q, et al. Bearing fault diagnosis method based on ensemble composite multi-scale dispersion entropy and density peaks clustering[J]. IEEE Access, 2021, 9: 24373-24389.
- [25]Mahmoud M S, Huynh V K, Senanyaka J S L, et al. Robust multiple-fault diagnosis of PMSM drives under variant operations and noisy conditions[J]. IEEE Open Journal of the Industrial Electronics Society, 2023, 4: 762-772.
- [26]王骁贤, 陆思良, 何清波, 等. 变转速工况下基于多传感器信号深度特征融合的电机故障诊断研究[J]. 仪器仪表学报, 2022, 43(3): 59-67.
- [27]邬春明, 朱海潮, 马欣, 等. 两级混淆对抗域自适应网络轴承故障诊断[J]. 北京交通大学学报, 2022, 46(5): 159-166.
- [28]Pham M T, Kim J M, Kim C H. Rolling bearing fault diagnosis based on

- improved GAN and 2-D representation of acoustic emission signals[J]. IEEE Access, 2022, 10: 78056-78069.
- [29] Ghazali S N A M, Sujod M Z, Jadin M S. A multi-scale smart fault diagnosis model based on waveform length and autoregressive analysis for PV system maintenance strategies[J]. Chinese Journal of Electrical Engineering, 2023, 9(3): 99-110.
- [30] 林俊亭, 王帅, 刘恩东, 等. 基于模糊聚类 and CNN-BIGRU 的轨道电路故障预测[J]. 振动.测试与诊断, 2023, 43(3): 500-507+619-620.
- [31] Li Q, Lv K H, Qiu J, et al. Research on residual life prediction for electrical connectors based on intermittent failure and hidden semi-markov model[J]. Applied Sciences, 2018, 8(8): 1373.
- [32] Khelif R, Chebel-Morello B, Malinowski S, et al. Direct remaining useful life estimation based on support vector regression[J]. IEEE Transactions on Industrial Electronics, 2017, 64(3): 2276-2285.
- [33] Wang Y, Ding H, Sun X C. Residual life prediction of bearings based on SENet-TCN and transfer learning[J]. IEEE Access, 2022, 10: 123007-123019.
- [34] Wu X Q, Li J, Jin Y Q, et al. Modeling and analysis of tool wear prediction based on SVD and BiLSTM[J]. The International Journal of Advanced Manufacturing Technology, 2020, 106: 4391-4399.
- [35] Kizito R, Scruggs P, Li X P, et al. Long short-term memory networks for facility infrastructure failure and remaining useful life prediction[J]. IEEE Access, 2021, 9: 67585-67594.
- [36] Jafari S, Byun Y C. Optimizing battery RUL prediction of lithium-ion batteries based on harris hawk optimization approach using random forest and lightgbm[J]. IEEE Access, 2023, 11: 87034-87046.
- [37] Wang S, Yu Z L, Xu G C, et al. Research on tool remaining life prediction method based on CNN-LSTM-PSO[J]. IEEE Access, 2023, 11: 80448-80464.
- [38] Park K, Choi Y, Choi W J, et al. LSTM-based battery remaining useful life prediction with multi-channel charging profiles[J]. IEEE Access, 2020, 8: 20786-

20798.

- [39] 罗毅, 武博翔. 基于深度学习 LSTM-DBN 的水轮机振动故障预测方法[J]. 振动.测试与诊断, 2022, 42(6): 1233-1238+1251.
- [40] 王文波, 彭伟, 顾寄南, 等. 基于深度学习与增量更新的滚动轴承故障预测方法研究[J]. 江苏科技大学学报(自然科学版), 2022, 36(5): 54-59.
- [41] 申彦斌, 张小丽, 夏勇, 等. Bi-LSTM 神经网络用于轴承剩余使用寿命预测研究[J]. 振动工程学报, 2021, 34(2): 411-420.
- [42] 丁显, 徐进, 黎曦琳, 等. 融合维纳过程和粒子滤波的风力发电机轴承剩余寿命预测[J]. 太阳能学报, 2022, 43(12): 248-255.
- [43] 苑清扬, 薛珂, 张博, 等. Gappy POD 算法重构储能电池组核心温度及与 BP 神经网络预测能力对比[J]. 工程科学学报, 2024, 46(1): 166-177.
- [44] 辛明泽, 孙兴伟, 张维锋, 等. 螺杆转子盘铣刀铣削表面粗糙度预测[J]. 电子测量与仪器学报, 2023, 37(12): 204-212.
- [45] Li Q, Yu J Y, Mu B C, et al. BP neural network prediction of the mechanical properties of porous NiTi shape memory alloy prepared by thermal explosion reaction[J]. Materials Science and Engineering: A, 2006, 419(1): 214-217.
- [46] Wang W, Zhu Q S, Wang Z B, et al. Research on indoor positioning algorithm based on SAGA-BP neural network[J]. IEEE Sensors Journal, 2022, 22(4): 3736-3744.
- [47] Zhang C C, Yu S, Li G J, et al. The recognition method of MQAM signals based on BP neural network and bird swarm algorithm[J]. IEEE Access, 2021, 9: 36078-36086.
- [48] 曹洁, 张玉林, 王进花, 等. 基于 VMD 和 SVPSO-BP 的滚动轴承故障诊断[J]. 太阳能学报, 2022, 43(9): 294-301.
- [49] Tian J S, Shi J. A high-accuracy and fast retrieval method of atmospheric parameters based on genetic-BP[J]. IEEE Access, 2022, 10: 19458-19468.
- [50] 董珍一, 林莉, 孙旭, 等. 基于 BP 神经网络的超声表面波定量表征金属表层裂纹深度研究[J]. 仪器仪表学报, 2019, 40(8): 31-38.
- [51] 张越, 张峰, 张峰瑞, 等. 一种基于 BP 神经网络的轮胎磨损程度检测算法[J].

- 电气自动化, 2023, 45(1): 109-112.
- [52] 罗巍, 卢博, 陈菲, 等. 基于 PSO-SVM 及时序环节的数控刀架故障诊断方法[J]. 吉林大学学报(工学版), 2022, 52(2): 392-399.
- [53] 陶志勇, 于子佳, 林森. PSO_SVM 算法在太阳能电池板裂缝缺陷检测研究[J]. 电子测量与仪器学报, 2021, 35(1): 18-25.
- [54] 王文杰, 韩振华, 黄从兵, 等. 基于 PSO 的水利蜗壳泵叶轮和导叶匹配设计[J]. 中南大学学报(自然科学版), 2022, 53(11): 4282-4291.
- [55] Zaini F A, Sulaima M F, Razak I A W A, et al. A review on the applications of PSO-based algorithm in demand side management: challenges and opportunities[J]. IEEE Access, 2023, 11: 53373-53400.
- [56] 何存富, 王志, 刘秀成, 等. 基于 GA-PSO 混合算法的钢杆磁特性参数识别方法[J]. 仪器仪表学报, 2017, 38(4): 838-843.
- [57] 杨赫然, 孙兴伟, 戚朋, 等. 基于改进 BP 神经网络的螺杆转子铣削表面粗糙度预测[J]. 电子测量与仪器学报, 2022, 36(10): 189-196.
- [58] Zhang Z, Zhang W T, Yang K, et al. Remaining useful life prediction of lithium-ion batteries based on attention mechanism and bidirectional long short-term memory network[J]. Measurement, 2022, 204: 112093.
- [59] Tang G, Sheng J Q, Wang D M, et al. Continuous estimation of human upper limb joint angles by using PSO-LSTM model[J]. IEEE Access, 2021, 9: 17986-17997.
- [60] Liu H, Mi X W, Li Y F. Wind speed forecasting method based on deep learning strategy using empirical wavelet transform, long short term memory neural network and elman neural network[J]. Energy Conversion and Management, 2018, 156: 498-514.
- [61] Xu G X, Meng Y T, Qiu X Y, et al. Sentiment analysis of comment texts based on BiLSTM[J]. IEEE Access, 2019, 7: 51522-51532.
- [62] Tian G, Wang Q B, Zhao Y, et al. Smart contract classification with a Bi-LSTM based approach[J]. IEEE Access, 2020, 8: 43806-43816.
- [63] Crisóstomo de Castro H, Abílio de Carvalho Júnior O, Ferreira de Carvalho O L,

- et al. Rice crop detection using LSTM, Bi-LSTM, and machine learning models from sentinel-1 time series[J]. Remote Sensing, 2020, 12(16): 2655.
- [64]高玉才, 付忠广, 王诗云, 等. 基于 Bi-LSTM 和自注意力机制的旋转机械故障诊断方法研究[J]. 中国工程机械学报, 2022, 20(3): 273-278.
- [65]温惠英, 张东冉, 陆思园. GA-LSTM 模型在高速公路交通流预测中的应用[J]. 哈尔滨工业大学学报, 2019, 51(9): 81-87+95.
- [66]万若青, 张纯, 江汇强, 等. 基于深度自编码器的振动信号盲去噪方法[J]. 振动与冲击, 2023, 42(12): 118-125.
- [67]赵柄锡, 冀大伟, 袁奇, 等. 采用时域与时频域联合特征空间的转子系统碰磨故障诊断[J]. 西安交通大学学报, 2020, 54(1): 75-84.
- [68]聂少军, 汪运鹏, 王春, 等. 激波风洞测力信号的频域数据深度学习建模分析方法[J]. 振动与冲击, 2023, 42(13): 296-302+315.
- [69]RAMASSO E. Investigating computational geometry for failure prognostics in presence of imprecise health indicator: result and comparisons on C-MAPSS datasets[J]. Phmsociety Org, 2014, 5: 1-18.

攻读学位期间发表的学位论文及参加的科研项目

发表的学术论文

[1] Yang Zhou, Ming Jiang, Xiaolin Yuan, et al. Fault Prediction of Molecular Pump Based on DE-Bi-LSTM. Fusion Science and Technology, 2023: 1-11.

[2] 周阳, 袁啸林, 江明, 等. 基于改进 BP 的分子泵故障诊断研究[J]. 真空科学与技术学报, 2024, 44(03): 220-228.

实审的发明专利

袁啸林, 左桂忠, 周阳, 江明. 一种基于机器学习的聚变装置分子泵故障诊断与预测方法. CN202211476107.4.

参加学术会议

参加安徽省第七届“海迈杯”真空科技青年创新大赛暨学术会议，并在大会上发言分享研究成果，桐城，2023.

致谢

光阴似箭，日月如梭。在我落笔这封致谢信时，我的毕业论文也即将完成，硕士三年研究生涯也即将落幕。有幸这三年期间在江明导师的课题组度过，感受到一个大家庭的关爱，感受到同门间的互帮互助，使得自己的眼界得到拓展，个人解决问题的能力得到提升。三年间的点点滴滴，可以谱写成一幅美丽的画卷，有我研一勤奋刻苦钻研理论的样子，有我研二独立外出实习求知的样子，有我研三拼命投简历疯狂找工作的样子，万般思绪涌上心头，是兴奋、是迷茫、是激动、是焦虑，但更多的是对身边同门老师的感激。

首先，我要诚挚地感谢导师江明教授。在考研成绩出来的第一时间，我联系到江老师，很荣幸获得江老师的赞扬，后期通过自己的努力顺利地加入课题组。江老师为人正直，学富五车，担任多个学术界身份，但依旧非常低调，与同学之间和蔼相处，经常关心课题组成员的生活以及学习状态，事无巨细，像我们的一个大家长一样。在研二期间，江老师将我送到中国科学院合肥物质科学研究院等离子体所实习，对于我来说在中科院进行联合培养是个人快速成长的一次宝贵机会，这将使我能够将学校理论知识与工业实际生产应用更好地结合起来，对于我在硕士阶段的学习和成长具有重要意义，这一经历也为我后期撰写学术论文提供了更好的帮助。尽管在实习期间，与母校相隔甚远，江老师也经常通过腾讯会议、电话等通讯方式对我进行关心与指导，让我在外实习也不会感到孤独，您不仅仅是我学术上的良师，更是我人生道路上的益友。借此，再次向您表示真诚的感激之情，谢谢您，我的江老师！

其次，我要感谢中科院合肥物质研究院等离子体所指导老师袁啸林老师。刚进所里做这个课题时，对于我是迷茫的，不知方向从何下手，是袁啸林老师给我制定了教学计划，每周跟他进行一次课题交流当面汇报，虽然当时压力很大，但很快让我熟悉了课题，慢慢在边学边做的过程中，有了自己的想法，写出了硕士期间第一篇论文，同时在袁老师的鼓励与指导下，尝试写成英文，很幸运文章最后被顺利接受发表。这对于一个从科研小白的我到独立完成课题发表论文的我来说，是一个质的飞跃，在这里特别感谢袁老师的照顾！当然，更感谢袁老师不仅在课题上对我的帮助，空余时间也会带我做项目，锻炼我的工

程应用能力，这对我来说是学校里学不到的，是一笔宝贵的财富，再次谢谢袁啸林老师！

然后我还要感谢柏受军老师，平时对我们的关心照顾，感谢万国扬以及李云飞老师对我们组会期间课题的指点，让我的综合素养得到提升。感谢江老师课题组的徐印赞、卢志远、吴云飞、刘富春、贾凯、高宝林、殷宗坤、赵朝朝、葛凌枫师兄，感谢陶秀文、刘鹏、黄志远、张健、陈金城同门平时的关心与照顾，感谢等离子体所六室左桂忠、陈跃、侯吉磊、庄会东、徐伟、刘少清、元京升、管艳红、张德皓、周德泽、南凯博、王超、张煜轩、汪哲、周之泰、赵胜波的鼓励与支持。此外，感恩一路以来无条件养育我的家人，从小学到如今的硕士毕业，中间遇到的种种选择你们都是无条件尊重我，遇到的种种困难都是无条件陪伴我克服。最后感谢我的对象，你的理解、鼓励和关爱让我在学业上更加坚定努力，让我感受到无限的力量和温暖。再次特别谢谢你们！永远爱你们！

最后，感谢身边遇到的所有人，因为你们的出现，让我平淡曲折的生活，变得幸福而精彩！

尚德敏学 唯实惟新

