

分类号: TP391

密 级: 公开

学校代码: 10363

学 号: 2220320110



安徽工程大学

Anhui Polytechnic University

硕士学位论文

题目 基于深度学习的 EAST 装置分子泵寿命预测技术研究

论 文 作 者 成志新

校 内 导 师 柏受军(副教授)

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) 控制工程与自动化技术

论文提交日期: 2025 年 3 月 24 日

分类号：TP391

单位代码：10363

密类级：公开

学 号：2220320110

题 目 基于深度学习的 EAST 装置分子泵寿命预
测技术研究

题 目 RESEARCH ON LIFETIME PREDICTION EAST
TECHNOLOGY OF MOLECULAR PUMPS IN
DEVICE BASED ON DEEP LEARNING

学 生 姓 名 ： 成志新

校 内 导 师 ： 柏受军(副教授)

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): 控制工程与自动化技术

论文答辩日期 ： 2025 年 3 月 24 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：

日期： 年 月 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：

指导教师签名：

日期： 年 月 日

日期： 年 月

基于深度学习的 EAST 装置分子泵寿命预测技术研究

摘 要

分子泵作为全超导托卡马克装置真空系统的关键设备，其寿命预测对真空系统的稳定运行具有重要意义。在真空系统复杂的工况中，分子泵的寿命预测面临两大挑战：一是寿命预测模型难以准确预测分子泵的剩余使用寿命；二是退化数据稀缺，导致训练缺乏足够的训练数据，影响寿命预测的准度。为解决这些问题，本研究提出了一种基于 Transformer 的深度学习框架，并结合卷积神经网络与卡尔曼滤波作为改进，显著提升了模型的预测精度与鲁棒性。同时，针对数据稀缺问题，提出了一种基于时间序列生成对抗网络的退化数据生成方法，结合威布尔分布优化生成数据质量，有效扩展了数据集规模。

研究首先构建了一种深度学习模型，通过 Transformer 的自注意力机制捕捉时间序列中的全局依赖关系，解决了长期依赖建模中的梯度消失或梯度爆炸问题；在此基础上，引入卷积神经网络作为局部特征提取模块，利用卷积核高效捕捉振动信号中的局部信息，弥补了 Transformer 在局部特征提取方面的不足。此外，针对运行环境中的噪声干扰，采用卡尔曼滤波对预测结果进行修正，进一步提高了模型的鲁棒性与预测结果的可靠性。

为解决退化数据稀缺问题，提出了一种基于时间序列生成对抗网络的退化数据生成方法，并结合威布尔分布优化生成数据的质量，为分子泵寿命预测提供了丰富的数据支持。实验结果表明，使用生成数据与实际数据相结合训练出的模型在分子泵寿命预测任务中表现优异，均方根误差和平

均绝对误差分别降低至 0.067 和 0.048，显著优于其他寿命预测方法。

为进一步实现研究的实际应用价值，开发了一款基于 LabVIEW 的客户端软件，实现了分子泵寿命的实时预测与监测。通过案例分析，系统能够准确捕捉分子泵的退化趋势与异常状态，并在剩余使用寿命低于预设阈值时发出维护建议，显著提升了分子泵的健康管理水平。

本研究不仅为分子泵寿命预测提供了新的技术手段，也为其他复杂设备的寿命预测研究提供了有益的借鉴。未来，可以进一步优化模型的计算效率，探索多维数据融合与特征提取方法，以提升其在复杂工业环境中的适用性与稳定性。

关键词：剩余使用寿命预测，深度学习，数据生成，分子泵，LabVIEW

RESEARCH ON LIFETIME PREDICTION TECHNOLOGY OF MOLECULAR PUMPS IN EAST DEVICE BASED ON DEEP LEARNING

ABSTRACT

As a critical component of the vacuum system for fully superconducting tokamak devices, the life prediction of molecular pumps plays a significant role in ensuring the stable operation of the vacuum system. In the complex operating conditions of the vacuum system, molecular pump life prediction faces two major challenges: first, models struggle to accurately predict the remaining useful life of molecular pumps; second, the scarcity of degradation data limits the predictive capability of models. To address these issues, this study proposes a deep learning framework based on Transformers, enhanced with convolutional neural networks and Kalman filtering, which significantly improves the model's prediction accuracy and robustness. Additionally, to tackle the data scarcity problem, a time series generative adversarial network-based degradation data generation method is introduced, combined with Weibull distribution optimization to enhance the quality of generated data, effectively expanding the dataset scale.

The study initially constructs a deep learning model that leverages the self-

attention mechanism of Transformers to capture global dependencies within time series, addressing the issue of gradient disappearance or explosion in long-term dependency modeling. On this foundation, a CNN module is incorporated to extract local features, efficiently capturing local information in vibration signals and complementing the limitations of Transformers in local feature extraction. Furthermore, to mitigate noise interference in the operational environment, Kalman filtering is employed to refine prediction results, further enhancing the model's robustness and reliability of predictions.

To address the scarcity of degradation data, a time series GAN-based degradation data generation method is proposed, optimized with Weibull distribution to improve the quality of generated data, providing ample support for molecular pump life prediction. Experimental results demonstrate that models trained using both generated and actual data achieve outstanding performance in molecular pump life prediction, with root mean square error and mean absolute error reduced to 0.067 and 0.048, respectively, significantly outperforming other life prediction methods.

To further realize the practical application value of the research, a client software based on LabVIEW is developed, enabling real-time prediction and monitoring of molecular pump life. Through case analysis, the system accurately captures degradation trends and abnormal states of molecular pumps, issuing maintenance recommendations when the remaining useful life falls below a predefined threshold, significantly improving molecular pump health

management.

This research not only provides a new technical approach for molecular pump life prediction but also offers valuable references for life prediction studies of other complex devices. In the future, efforts can be made to optimize the computational efficiency of the model, explore multi-dimensional data fusion and feature extraction methods to enhance its applicability and stability in complex industrial environments.

KEY WORDS: remaining useful life prediction, deep learning, data generation, molecular pump, LabVIEW

目录

摘 要	I
ABSTRACT	III
第 1 章 绪论	1
1.1 研究背景和意义	1
1.2 国内外研究现状	3
1.2.1 寿命预测国内外研究现状	3
1.2.2 数据生成技术国内外研究现状	6
1.3 论文研究内容及架构安排	7
1.3.1 主要研究内容	7
1.3.2 论文组织与架构	9
第 2 章 分子泵寿命预测的理论基础	10
2.1 Transformer 模型原理	10
2.1.1 Transformer 架构的基本原理	10
2.2.2 自注意力机制的基本原理	11
2.2 卷积神经网络的基本原理	13
2.3 卡尔曼滤波	14
2.4 本章小结	15
第 3 章 基于 Transformer 的深度学习模型设计	16
3.1 基于 Transformer 的寿命预测模型研究	16
3.1.1 特征提取层的设计	17
3.1.2 模型主体的设计	18
3.1.3 提升模型噪声鲁棒性的设计	19
3.2 模型训练与参数设置	20
3.2.1 分子泵退化数据采集	20
3.2.2 数据预处理	23
3.2.3 时间步长的确定	23
3.2.4 堆叠网络层数的确定	24
3.3 实验验证与分析	25

3.4 本章小结	28
第 4 章 基于 Time GAN 的退化数据生成与优化	29
4.1 Time GAN 模型	29
4.1.1 嵌入函数和恢复函数	29
4.1.2 生成与鉴别网络	30
4.1.3 Time Gan 的训练策略	31
4.2 改进 Time GAN 模型设计	33
4.2.1 生成器与鉴别器的改进	33
4.2.2 输入噪声分布的改进	33
4.3 使用 TGAN-Transformer 模型数据生成的评估与验证	34
4.3.1 PCA 与 T-SNE 对 TGAN-Transformer 数据生成的可视化评价	35
4.3.2 使用 TGAN-Transformer 数据生成的预测效果评价	38
4.3.3 验证使用威布尔分布的有效性	39
4.4 生成数据对比实验	40
4.5 生成数据对预测模型性能的提升	41
4.6 本章小结	42
第 5 章 EAST 分子泵寿命预测模型设计与部署	43
5.1 基于 LabVIEW 的分子泵寿命预测系统设计	43
5.1.1 系统总体设计	43
5.1.2 模型预测模块设计	44
5.2 系统运行流程与结果分析	45
5.3 案例分析	46
5.4 本章小结	47
第 6 章 总结与展望	48
6.1 研究总结	48
6.2 研究展望	48
参考文献	50
攻读学位期间发表的学术论文与研究成果	56
致谢	57

第1章 绪论

1.1 研究背景和意义

全超导托卡马克核聚变装置 (Experimental Advanced Superconducting Tokamak, EAST)是由中国科学院等离子体物理研究所自主研发的一项大科学装置，被誉为“人造太阳”^[1]，如图 1-1 所示。其核心原理是在装置的真空室内引入少量氢的同位素氘或氚，通过加热提高其密度和温度，使其发生核聚变反应，释放出巨大的能量^[2]。



图1-1 EAST聚变装置

在核聚变实验中，高真空环境是必不可少的条件，而分子泵是实现这一条件的重要设备。分子泵通过利用高速旋转叶片将动量传递给气体分子，使气体分子获得定向速度后被压缩并引向排气口，最终由前级抽气装置排出，来维持真空环境的稳定^[3]。分子泵的正常运行是EAST实验顺利进行的核心保障如图 1-2 所示。




图1-2 EAST聚变装置上的分子泵

为了保证分子泵的安全运行，通常会进行定期的检查与维护。然而，定期的检查与维护会影响装置的实验工作，不仅延缓了研究进展，也带来了经济成本的损失^[4]。因此，如何通过预测性维护来实现对分子泵的健康管理成为了当前研究的重要课题，预测性维护的核心任务是寿命预测，寿命预测以设备的历史运行数据和实时状态为基础，预测设备的剩余使用寿命(Remaining Useful Life, RUL)；通过这一技术，可以科学地制定维护计划，避免计划外停机，并降低维护成本，如图 1-3 所示，RUL 预测技术能够帮助工作人员实时的了解到设备的工作状态，从而在设备即将失效之前进行预防性维护，而不是等到设备发生故障后再进行修复。RUL 预测在分子泵这一类运行稳定、故障率较低但一旦故障便会严重影响系统性能的关键设备上，寿命预测尤为重要^[5-8]。




图1-3 剩余使用寿命

RUL 预测具备多方面的实际用处，首先，通过准确计算设备可能发生故障的时机，可以优化维护计划，合理安排实验设备的运行和维修时间，最大限度地减少因设备停机造成的影响^[9]；其次，合理的寿命评估能够提升设备管理效率，优化备件库存，避免因过量储备带来的浪费或备件短缺引发的停机问题^[10]；此外，寿命预测还能显著降低维护成本，减少多余的定期维护以及突发维修带来的额外经济负担^[11]；最重要的是，这一技术可以更全面地提升设备运行的可靠性和生产率，有利于延长分子泵的整体寿命，提升实验的稳定性^[12]。

尽管 RUL 预测拥有众多优势，但对分子泵进行寿命预测也面临不少挑战。首先是数据的采集与处理困难。分子泵运行时的振动数据通常呈现出高度的非线性和复杂性，如何从中高效提取有意义的特征是首要问题^[13]。此外，传统的统计学和物理建模方法在建模机械设备运行状态时表现出很大局限性，无法很好地捕

捉设备运行状态中的非线性动态特性^[14]。同时,作为一种高可靠性设备,分子泵的退化数据较为稀少,难以保证寿命预测模型对分子泵 RUL 的精确预测^[15]。

随着深度学习的快速发展,在寿命预测领域开启了新的研究方向。深度学习技术具备强大的数据处理和模式识别能力,成为解决传统方法局限性的理想工具^[16]。在机械设备的寿命预测中,深度学习尤其展现出巨大的潜力。它能够高效提取机械设备多种运行参数中的潜在特征,识别数据中隐藏的复杂模式^[17]。同时,深度学习模型能够很好地适应非线性复杂系统的需求,相较于传统统计模型,深度学习更能捕捉分子泵运行状态随时间变化的细微规律^[18]。此外,数据生成技术在设备寿命预测中扮演着重要角色。通过生成高质量的训练数据,可以有效提升模型的性能,尤其是在实际数据不足或存在噪声的情况下,为深度学习模型提供了更丰富、更全面的训练数据,从而增强了模型的准确性和鲁棒性^[19]。

1.2 国内外研究现状

1.2.1 寿命预测国内外研究现状

目前国内外对于 RUL 预测的方法主要可以分为基于物理模型驱动的方法和基于数据驱动的方法;这两种方法各具特点,在 RUL 预测的研究与应用中贡献显著^[20]。近年来,随着深度学习技术的快速发展,其在 RUL 预测领域的应用更是展现出了重要的优势和广阔的前景^[21]。

基于物理模型的 RUL 预测方法构建模型的核心是研究设备的退化失效机理,通常通过先验知识和实验数据推导出一系列数学模型,用以描述设备性能的退化过程并实现 RUL 预测^[22]。裂纹扩展模型(Paris-Erdogan)模型是其中的典型代表^[23], Sheng Y 等通过该模型完成了滚动轴承寿命的预测工作^[24];此外, Orsagh R 等提出了基于 Yu-Harris 模型的方法来预测涡扇发动机的 RUL,并进一步通过裂纹扩展模型对涡扇发动机进行寿命研究^[25];孙宇博等通过研究基于 TC4 钛合金在不同应力条件下裂纹扩展速率的特点,构建了涡轮发动机 RUL 预测的模型^[26];这些基于物理模型的方法在很大程度上依赖于系统退化力学的研究深度,因此容易受限于复杂系统的建模难度和非线性特性。对于退化机理复杂或难以明确描述

的设备,很难通过解析性数学模型进行精准分析,从而限制了这些方法的实际应用范围^[27]。

相较之下,基于数据驱动的 RUL 预测方法近年来因大数据技术的蓬勃发展 and 传感器技术的广泛应用而受到了更多关注。数据驱动方法将研究的重点从系统具体物理特性转移到海量设备监测数据中隐含的退化信息上,通过挖掘和分析这些信息实现设备健康状态的估计和 RUL 预测^[28]。目前,基于数据驱动的经典方法包括马尔科夫模型^[29]、维纳过程模型^[30]和伽玛过程模型^[31]等,这些模型在处理设备退化和不确定性上具有较强的适用性。此外,在机器学习方法的探索中,Khelif R 等提取设备健康曲线的时序特征,并通过支持向量机完成了发动机寿命预测研究^[32]; Nieto 等则结合支持向量回归模型与粒子群优化算法,实现了航空发动机寿命预测^[33];这些基于传统机器学习的模型虽然能在一定程度上解决物理模型难以建模的问题,但由于难以处理高维度和庞大的时序数据,在预测准确性与效率方面仍存在不足^[34]。

深度学习技术因其强大的数据表征能力和自动化特征提取优势,在机械设备寿命预测领域崭露头角。与机器学习相比,深度学习模型无需复杂的特征工程,能够通过多层神经结构直接从海量高维度的数据中学习设备退化的潜在特征,适用于处理复杂的非线性问题^[35]。在深度学习中,卷积神经网络(Convolutional Neural Network, CNN)^[36]和循环神经网络(Recurrent Neural Network, RNN)^[37]是两个具有代表性的网络结构,它们在不同的应用场景中发挥着重要作用。

卷积神经网络因其局部感知和共享权重的特性,在机械设备寿命预测中的应用取得了突破性进展。Li X 等将深度卷积神经网络应用于航空发动机寿命预测,通过对时间维度进行卷积操作,有效挖掘了数据的局部特征^[38]。Wang R 等设计了一种多尺度 CNN 模型,学习了不同感受野的特征,显著提高了 RUL 预测的精度^[39]。然而, CNN 方法在捕捉全局特征方面存在一定局限,且随着模型复杂度的增加,可能面临训练难度和计算资源需求的提升^[40]。

循环神经网络则通过其递归结构,在时序数据建模方面具有显著优势。针对 RNN 在长期预测过程中存在的梯度爆炸或消失问题,长短时记忆神经网络(Long Short-Term Memory, LSTM)的出现提供了解决方案^[41]。Zheng S 等通过 LSTM

实现了航空发动机的寿命预测^[42]。Wang F K 等提出了基于双向 LSTM 的方法，在有效利用传感器数据前后关联性的同时提升了模型的预测效果^[43]。然而，RNN 类模型由于其固有的序列计算特性，在并行化与计算效率上仍存在一定限制，同时对超长时序数据的处理仍需进一步优化^[44]。

相比之下，Transformer 模型因其基于注意力机制的特性，在寿命预测领域显示出潜力；Transformer 模型由 Vaswani A 等人在 2017 年提出，是一种基于注意力机制的深度学习架构，其自注意力机制(Self-Attention)能够捕捉数据中的全局依赖关系，这种架构避免了卷积和循环操作，提供了卓越的训练效率，增强了捕获长距离依赖关系的能力，以及出色的全局上下文捕获机制。Transformer 在多个领域都取得了显著的成功，如自然语言处理和计算机视觉等^[45]。

在 RUL 预测领域，Transformer 模型展现出优异的性能；Ogunfowora O 等提出了一个基于 encoder-transformer 架构的框架，用于预测用例的多变量时间序列预测。有效地将 transformer 的知识和应用从自然语言领域转移到时间序列^[46]；Mo Y 等将 Transformer 模型与门控卷积结合用于 RUL 预测，其模型基于点积自注意力，能够充分利用并行计算能力，并用门控卷积捕捉局部信息^[47]；Chen D, 提出了一种混合方法，将 Transformer 与去噪自编码器（DAE）相结合。在该模型中，DAE 对原始数据进行预处理，然后将其输入 Transformer 网络，用于锂电池的 RUL 预测^[48]；Guo P 等设计了一种基于编解码器模型的复杂的三层交叉解码策略。这种方法通过在编码器和解码器之间建立分层链接来优化解码过程，在跨多个抽象维度的特征提取过程中，促进信息从不同编码器层流向不同解码器层^[49]。CNN，RNN，Transformer 的工作计算原理如图 1-4 所示。




图1-4 不同网络工作原理对比图

综上所述，寿命预测技术在机械设备健康管理中具有重要地位，而深度学习技术的快速发展为解决寿命预测领域中的诸多难点提供了全新方向。本课题立足

于 EAST 装置真空系统的分子泵寿命预测,旨在利用深度学习方法构建适用于分子泵寿命预测的模型,为 EAST 装置真空系统的稳定运行提供有力保障,为分子泵健康管理和寿命预测提供更为有效的解决方案,同时推动机械设备智能化健康管理的进一步发展。

1.2.2 数据生成技术国内外研究现状

数据生成技术通过学习真实序列中的数据分布,以创建逼真的生成数据,被认为是丰富数据的前沿解决方案之一^[50-52]。其中最广泛使用的技术是于 2014 年提出的生成对抗网络(Generative Adversarial Network, GAN)。GAN 包含一个生成器和一个鉴别器;生成器通过学习原始数据集生成数据集,而鉴别器则负责区分真实数据和生成数据。在训练过程中,通过生成器和鉴别器的博弈,促使生成器不断提高生成数据的质量^[53]。尽管 GAN 在图像生成上已取得成功,但在处理时间序列数据时生成的数据质量不高,难以捕捉长期依赖关系,且生成效果不尽理想^[56]。

为提高数据生成的质量,Esteban C 等尝试将 LSTM 替代原始 GAN 框架中的卷积神经网络,以生成医疗时间序列数据^[55]。Zheng T 等提出了一种卷积递归生成对抗网络(Convolutional Recurrent GAN),其生成器结合了卷积神经网络以捕捉局部信息和递归神经网络处理长期依赖关系的优点,用于模拟设备的运行状态和剩余使用寿命的估计值^[56]。Li X 等提出了一种基于注意力机制的改进生成对抗网络(Attention-based Improved GAN),在生成时间序列数据时,通过注意力模块聚焦于数据中的关键特征和时间点,增强了生成数据对复杂动态过程的表现力^[57]。Lee J 等则尝试将变分自编码器(Variational Autoencoder, VAE)与生成对抗网络相结合,构建了 VAE-GAN 混合架构用于时间序列数据生成,利用 VAE 的编码能力对数据进行初步的特征提取和压缩,再由 GAN 进行数据生成,在一定程度上提高了生成数据的稳定性和多样性^[58]。Gujulla Leel S R 等开发了一种分层式生成对抗网络(Hierarchical GAN),将时间序列数据按照不同的时间尺度和特征层次进行分解和生成,试图从多个层次还原数据的真实分布。在一些工业设备监测数据的生成实验中取得了较好的效果^[59]。

尽管上述方法在一定程度上提高了生成数据的质量和多样性,但如何更好地捕捉时间序列中的长期依赖关系、生成稳定且逼真的时序数据仍然是一个关键挑战。针对时序数据生成的问题,Yoon J,等人提出了时间序列生成对抗网(Time-series Generative Adversarial Networks, Time GAN), Time GAN 通过结合无监督 GAN 训练方法和监督学习机制,提升了时间序列数据生成的质量。Time GAN 的核心优势在于其独特的框架设计。与 GAN 不同的是, Time GAN 在生成器和鉴别器的对抗中引入了监督学习模块,将生成器与监督自回归模型结合,增强了生成数据的时间动态特性。具体而言, Time GAN 的生成器不仅要欺骗鉴别器,还需要满足监督学习模块的约束条件,从而生成更符合真实数据分布的序列。此外, Time GAN 的损失函数结合了 GAN 的对抗损失和监督学习的预测损失,能够在生成数据的逼真性和时间性之间取得很好的平衡。其框架能够轻松适应不同类型的时间序列数据生成任务,同时支持与其他深度学习模型的结合,进一步提升生成数据的质量和多样性^[60]。

综上所述,尽管前人在时间序列数据生成技术方面进行了大量研究,但在分子泵退化数据生成上均未找到能有效平衡数据质量、多样性、计算效率,且能准确捕捉分子泵退化过程独特特征的方法,导致生成数据难以满足分子泵可靠性预测对数据准确性和可靠性的高要求。针对这些问题,提出了一种利用 Transformer 改进的时间序列生成对抗网络方法(Transformer-based Time GAN, TGAN-Transformer)的改进型生成对抗网络框架,旨在生成更接近分子泵失效过程的退化数据。TGAN-Transformer 通过使用 Transformer 作为生成器的网络结构,利用多头注意力机制捕捉时间序列中的长期依赖关系;同时 Transformer 的并行计算能力在处理长序列数据时具有更高的效率。

1.3 论文研究内容及架构安排

1.3.1 主要研究内容

本文以 EAST 真空系统的分子泵为研究对象,分子泵为 EAST 真空系统中的主要真空获取设备,但在真空系统的运行过程中,由于会发生真空泄漏的情况,

会造成分子泵过载运行的情况，这种情况下会使分子泵的停机时间难以预测，这不仅影响真空系统的整体运行，还可能导致设备异常损坏和安全事故。为了解决这些问题，本文提出了一套基于深度学习的分子泵寿命预测技术体系，以下为主要研究内容与技术路线，所图 1-5 所示。

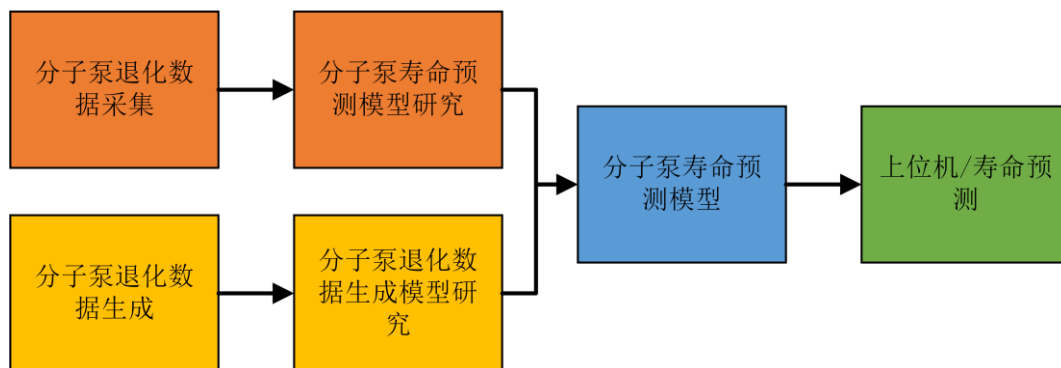


图1-5 技术路线图

首先，本文从分子泵在发生真空泄漏的情况下入手，研究其在真空泄漏情况下的寿命预测方法。这种情况下的分子泵寿命预测面临两大挑战：一是传统寿命预测模型难以准确捕捉分子泵在长期复杂运行环境中的状态演变；二是退化数据稀缺，制约了寿命预测模型的性能。为此，本文提出了一种基于 Transformer 网络的寿命预测框架，以解决深度学习模型在长期依赖关系建模中易出现梯度消失或梯度爆炸的问题，同时在 Transformer 模型基础上融入了卷积神经网络，弥补 Transformer 模型在捕捉局部特征方面的不足。此外，针对运行环境中噪声干扰对预测结果的影响，本文进一步引入了卡尔曼滤波对预测结果进行修正，提高模型的鲁棒性和结果可靠性，使分子泵的寿命预测结果更加精确与稳定。

在训练数据层面，本研究还面临着退化数据稀缺的挑战。由于经济成本和实验条件的限制，获取真实的退化数据往往十分困难。为解决这一问题，我们提出了一种基于时间序列生成对抗网络的数据增强方法，该方法结合时间序列生成对抗网络和 Transformer，能够有效学习真实数据的分布特性，生成高质量的退化数据样本。同时，通过引入威布尔分布对生成数据进行质量优化，进一步提高了生成数据对真实退化行为的模拟能力。

1.3.2 论文组织与架构

本文共分为 6 章，第 1 章主要对整个研究的背景、意义及研究现状进行阐述。详细梳理国内外研究现状，阐释研究痛点，引出本文的技术路线与创新贡献。

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，并引出相关的寿命预测基础理论知识，为后续算法改进提供理论支撑。

第 3 章阐述基于 Transformer 的深度学习模型，从理论角度阐明各模块的设计与协同机制，并为后续的实验提供理论支持。

第 4 章主要针对数据不足问题，提出了一种基于时间序列生成对抗网络的分子泵退化数据生成方法；给出融合生成数据的预测模型的训练流程、实验设计以及与传统数据驱动方法的性能比较分析。

第 5 章开发了一款客户端软件，用于实时对分子泵的运行寿命进行预测与监测。

第 6 章对全文进行了总结，并探讨未来的研究方向。

第2章 分子泵寿命预测的理论基础

本章系统阐述 Transformer 模型、卷积神经网络以及卡尔曼滤波的原理，为后续章节的模型设计与优化提供了理论依据。

2.1 Transformer 模型原理

2.1.1 Transformer 架构的基本原理

Transformer 是一种基于自注意力机制的深度学习架构，最初设计用于自然语言处理领域，现已被广泛应用于时间序列分析、寿命预测等任务中。其架构优势在于能够高效捕捉序列数据中的全局依赖关系、并行化能力强、且不受序列长度的限制，如图 2-1 所示。




图2-1 transformer框架图

Transformer 模型主要由编码器和解码器组成，其中编码器负责将输入序列映射到一个高维特征空间，解码器则根据编码器输出的结果生成目标序列。其中每

个编码器由多个相同的层堆叠而成，每层包括两个主要组件，自注意力机制和前馈神经网络，自注意力机制用于计算序列中不同位置之间的相关性，捕捉全局依赖关系；前馈神经网络由两层线性变换和一个非线性激活函数组成，用于对注意力输出进行非线性变换，进一步提取高级特征；解码器通常用于生成目标序列，但在寿命预测任务中，编码器输出可以直接用于回归任务，因此解码器部分可简化或省略。

由于 Transformer 本身不具备处理序列顺序的能力，因此需要引入位置编码来为每个位置提供额外的顺序信息。层归一化与残差连接用于加速训练过程并提高模型的稳定性，其中残差连接能够有效缓解梯度消失问题，层归一化则有助于加速收敛。

在分子泵寿命预测任务中，输入数据通常包含多维时序特征，且具有复杂的非线性和长距离依赖关系。Transformer 通过其自注意力机制能够有效捕捉这些特征之间的全局关联，同时利用位置编码机制处理序列的时序特性。其并行化计算能力也使得模型能够高效处理大规模工业数据，为构建高精度、高鲁棒性的寿命预测模型提供了理论支持。

2.2.2 自注意力机制的基本原理

自注意力机制是 Transformer 的核心组件，其工作原理如图 2-2 所示。注意力机制通过并行捕获子空间中的复杂信息，增强了模型处理复杂信息的能力。多头注意力是自注意力机制的扩展形式，通过并行计算多个注意力头，能够捕捉不同层次的特征关联，每个注意力头具有独立的参数，最终通过拼接和线性变换将多个头的输出融合为一个统一的表示。

多头自注意力机制由几个自我注意力头组成，每个自注意力头独立的关注输入的不同部分。

首先，多头自注意力机制的工作原理为：输入矩阵 f 映射到不同的查询、键和值空间，对于每个自注意力头，如式(2-1)，(2-2)，(2-3)所示：

$$Q_i = fW_i^Q \quad (2-1)$$

$$K_i = fW_i^K \quad (2-2)$$

$$V_i = fW_i^V \quad (2-3)$$

然后，每个头部独立执行自我注意力计算，从而产生不同的注意力输出，如式(2-4)所示：

$$Attention(Q, K, W) = \text{soft max} \left(\frac{Q_i K_i^T}{\sqrt{d_k}} \right) V_i \quad (2-4)$$

最后，将所有头的输出连接在一起，通过线性变换获得最终输出，如式(2-5)所示：

$$MultiHead(Q, K, V) = \text{Concat}(\{head\}_{i=1}^H) W^O \quad (2-5)$$

这里， W_i^Q, W_i^K, W_i^V 是可学习的参数矩阵； d_k 表示密钥向量的维数； W^O 代表最终的权重矩阵。




图2-2 自注意力机制

Transformer 模型由于固有的缺乏处理序列顺序的能力，从而由位置编码为每个数据点提供了其在序列中的相应位置，使模型能够识别数据的顺序。位置编码的过程如式(2-6)，(2-7)所示：

$$P_{(pos, 2i)} = \sin \left(\frac{pos}{10000^{2i/d}} \right) \quad (2-6)$$

$$P_{(pos, 2i)} = \cos \left(\frac{pos}{10000^{2i/d}} \right) \quad (2-7)$$

在这种情况下， pos 表示单词在序列中的位置， d 表示维度索引， i 表示位置编

码向量的维度。

前馈神经网络包括两个线性变换，中间有一个 $ReLU$ 函数作为激活函数，如式(2-8)所示。

$$FFN(x) = W_2 \cdot ReLU(W_1 x + b_1) + b_2 \quad (2-8)$$

其中， W_1 ， W_2 ， b_1 和 b_2 是可学习的权重矩阵和偏差向量。

2.2 卷积神经网络的基本原理

卷积神经网络架构通常包括一系列堆叠的卷积层、池化层和完全连接层，如图 2-3 所示。




图2-3 卷积神经网络示意图

卷积运算是卷积层的核心过程，卷积运算通过在输入数据上滑动一个可训练的滤波器，计算每个位置的局部加权和，从而生成特征图，如图 2-4 所示。这一过程能够捕捉到输入数据中的特定模式或特征。




图2-4 卷积运算示意图

给定输入数据序列 X 和由长度为 k 的权重向量 W 表示的卷积核，位置 t 处的卷积运算的输出 Y 计算如式(2-9)所示：

$$Y(t) = \sum_{i=0}^{k-1} X(t+1) \cdot W(i) + b \quad (2-9)$$

其中, $Y(t)$ 表示位置 t 处的输出特征图的值, $W(i)$ 表示卷积核的第 i 位权重, $X(t+1)$ 表示位置 $t+i$ 处的输入序列的值。 b 是偏置矩阵。 k 是卷积核的长度。

池化层的作用是减少特征序列的长度, 从而降低计算复杂度和防止过拟合, 如式(2-10)所示。

$$P = \text{Pool1D}(Y(t)) \quad (2-10)$$

接着, 应用 ReLU 激活函数, 如式(2-11)所示:

$$A = \text{ReLU}(P) \quad (2-11)$$

全连接层将输入特征映射到输出空间, 用于后续任务, 如式(2-12)所示:

$$Y = W \cdot A + b \quad (2-12)$$

2.3 卡尔曼滤波

卡尔曼滤波器是一种递归算法, 旨在通过估计动态系统的状态和校正预测误差来最小化噪声的影响。它假设系统的状态可以用线性动态模型来描述, 并且噪声遵循高斯分布, 这是大多数传感器噪声的常见近似值^[61]。卡尔曼滤波器的主要步骤包括预测和更新阶段。

在预测阶段, 卡尔曼滤波器基于先前的状态估计和控制输入预测当前状态和协方差矩阵, 如式(2-13), (2-14)所示:

$$\hat{x}_{k|k-1} = A\hat{x}_{k-1|k-1} + Bu_k \quad (2-13)$$

$$P_{k|k-1} = AP_{k-1|k-1}A^T + Q \quad (2-14)$$

在这种情况下, $\hat{x}_{k|k-1}$ 表示系统在时间 k 的状态估计, $\hat{x}_{k-1|k-1}$ 是时间 k 处的预测协方差, $P_{k|k-1}$ 是时间 $k-1$ 处的预测方差, Q 表示过程噪声协方差。

在更新阶段, 卡尔曼滤波器使用新观测到的数据校正预测, 卡尔曼增益如(2-15)所示:

$$K_k = P_{k|k-1}H_k^T(H_kP_{k|k-1}H_k^T + R)^{-1} \quad (2-15)$$

状态更新如(2-16)所示:

$$\hat{x}_{k|k} = \hat{x}_{k|k-1} + K_k(z_k - H_k\hat{x}_{k|k-1}) \quad (2-16)$$

协方差更新如(2-17)所示:

$$P_{k|k} = (I - K_k H_k) P_{k|k-1} \quad (2-17)$$

其中 K_k 表示卡尔曼增益, R 表示观测到的噪声协方差; $\hat{x}_{k|k}$ 是时间 k 处的状态更新估计; $P_{k|k}$ 是时间 k 处的更新协方差。

2.4 本章小结

本章通过深入分析 Transformer、CNN 和卡尔曼滤波的原理, 为分子泵寿命预测研究奠定了坚实的理论基础, 为后续章节的算法改进与实验设计提供了理论支持。

第3章 基于 Transformer 的深度学习模型设计

本章实现了基于 Transformer 的深度学习模型的设计与实现，通过实验确定了模型的主要参数，以及进行实验验证本章所设计模型预测效果。

3.1 基于 Transformer 的寿命预测模型研究

Transformer 模型虽能捕捉全局时间依赖，但对局部特征(如振动信号中的高频噪声、压力突变等)提取能力不足；而单一 CNN 模型虽擅长局部特征提取，却难以建模长序列中的退化趋势。为此，本章设计了一种 Transformer-CNN-Kalman 混合模型，整 Transformer-CNN-Kalman 的工作原理可以分为 CNN 层、Transformer 编码器层、卡尔曼滤波层，如图 3-1 所示：




图3-1 所提模型工作流程示意图

3.1.1 特征提取层的设计

在分子泵寿命预测中，设计 CNN 作为特征提取层用来高效提取传感器数据中的局部特征，如图 3-1 所示。通过使用 CNN，分子泵振动信号中的高频成分、压力信号中的周期性波动等瞬时特征，均可通过 CNN 的滑动窗口机制被有效捕捉。这种局部特征提取能力使得 CNN 能够关注数据中的细节变化，为后续的全局特征建模奠定基础。

为了确定卷积核的数量和大小，以分子泵寿命预测的 RMSE,MAE 最小化为参考指标；选取卷积核大小： $3 \times 1, 5 \times 1, 7 \times 1$ ；卷积核数量：8, 16, 32。使用网格搜索遍历所有可能的参数组合，训练模型并记录性能指标。对每个参数组合的模型进行评估，比较它们在验证集和测试集上的表现，如表 3-1 所示。选取最优的卷积核大小和数量，并应用于实际的寿命预测任务。

表3-1 CNN参数的选择

卷积核的数量	卷积核大小	RMSE	MAE
8	3×1	0.135	0.102
8	5×1	0.142	0.108
8	7×1	0.148	0.111
16	3×1	0.117	0.091
16	5×1	0.128	0.096
16	7×1	0.132	0.097
32	3×1	0.125	0.093
32	5×1	0.139	0.101
32	7×1	0.145	0.105

首先，将输入的分子泵时序数据设为 X 如式(3-1)所示，CNN 负责提取时间序列数据中的特征，捕捉短期波动和瞬时信号，如式(3-2)所示，CNN 的工作模式见 2.2 卷积神经网络的基本原理：

$$Input = X \quad (3-1)$$

$$CNN_Output = CNN(X) \quad (3-2)$$

CNN 的优势在于其以较低的计算资源提取数据细节特征的能力。通过滑动窗口机制, CNN 能够在不显著增加计算负担的情况下, 提取数据中的局部特征。

3.1.2 模型主体的设计

经过 CNN 处理后的特征数据随后被传递给 Transformer 模块, 用于建模全局依赖关系, 捕捉长期趋势和多时间尺度的关联特征, Transformer 模块具体工作过程见 2.2.2 自注意力机制的基本原理。

Transformer 模块通过多头自注意力机制, 能够建模时间序列数据中的全局依赖关系。在分子泵寿命预测的过程中, 针对分子泵数据维度高但样本量少的特点, 采用 Transformer 编码器作为模型主体, 可以避免过拟合的同时提升计算效率; Transformer 的全局特征捕捉能力使得其在处理复杂的时间序列数据时表现出色。与传统循环神经网络相比, Transformer 具有更强的并行计算能力, 能够更高效地处理长序列数据。此外, 通过位置编码机制, Transformer 能够弥补其在序列顺序建模能力上的不足, 从而更好地捕捉时间序列数据中的时序关系。

位置编码通过向数据中添加位置信息, 使模型能够感知数据的顺序或位置, 如式(3-3)所示:

$$Position_Encoding = PE \quad (3-3)$$

将 CNN 输出与位置编码结合, 形成包含位置信息的特征表示, 如式(3-4)所示:

$$Encoded_Input = CNN_Output + Position_Encoding \quad (3-4)$$

多头自注意力机制通过多个注意力头并行处理数据, 捕捉数据内部的不同关系模式, 增强模型对数据全局和局部关系的理解能力, 如式(3-5)所示:

$$MultiHead_Attention = MH(Encoded_Input) \quad (3-5)$$

第一次层归一化通过缩放和移位操作, 将编码输入与多头自注意力机制的输出进行残差连接, 加快训练收敛速度, 缓解梯度消失问题, 如式(3-6)所示:

$$Residual_Norm_1 = LayerNorm(Encoded_Input + MultiHead_Attention) \quad (3-6)$$

前馈神经网络通过全连接层和激活函数, 对归一化后的特征进行非线性变换,

提取更复杂的特征模式，增强模型的表达能力，如式(3-7)所示：

$$FFN_Output = FFN(Residual_Norm_1) \quad (3-7)$$

第二次层归一化对第一次层归一化后的特征与 FFN 的输出进行残差连接和归一化，进一步稳定训练过程，如式(3-8)所示：

$$Residual_Norm_2 = LayerNorm(Residual_Norm_1 + FFN_Output) \quad (3-8)$$

在经过 Transformer 处理后，线性变换通过全连接层对归一化后的特征进行线性映射，降低特征维度，生成适合后续任务的特征向量，如式(3-9)所示：

$$Linear_Transform = Linear(Residual_Norm_2) \quad (3-9)$$

3.1.3 提升模型噪声鲁棒性的设计

传感器采集到的分子泵数据通常会受到环境噪声和设备过载运行的影响，收到噪声的影响预测结果可能会出现不稳定、精度下降的问题。为了解决这些问题，设计卡尔曼滤波器作为预测结果的后处理模块。卡尔曼滤波器通过递归更新机制，能够动态调整预测结果，从而提升预测寿命的实时性和准确性。为了确保卡尔曼滤波器在本研究中的有效性，首先对系统的线性假设和噪声的高斯分布特性进行了验证。

系统线性假设的验证通过残差分析和自相关函数分析完成。具体步骤如下：自相关函数分析，计算残差的自相关函数。若残差的自相关系数在延迟 1 步后迅速趋近于零，则表明残差为白噪声，系统满足线性假设。




图3-2 利用分子泵数据生成的残差自相关函数图

结果如图 3-2 所示，残差分布随机且无明显趋势，残差的自相关系数在延迟 1 步后迅速趋近于零。这表明系统满足线性假设，卡尔曼滤波器的应用条件得以满足^[62]。

噪声的高斯分布特性通过概率密度函数拟合和 Q-Q 图分析进行验证。具体步骤如下：Q-Q 图分析，绘制残差数据的 Q-Q 图，如果数据点沿 45° 直线分布，则表明残差服从正态分布。实验结果表明，残差数据与正态分布拟合良好，如图 3-3 所示，Q-Q 图显示数据点沿 45° 直线分布。表明噪声满足高斯分布假设，验证了卡尔曼滤波器可以使用在分子泵寿命预测模型中。




图3-3 利用分子泵数据生成的残差Q-Q图

Transformer 模块输出的预测结果经过卡尔曼滤波器进行后处理，动态调整预测误差，平滑噪声干扰，使预测结果更加稳定和可靠，如式(3-10)所示：

$$Kalman_Filter_Output = KF(Softmax_Output) \quad (3-10)$$

最后，得出模型预测的预测寿命值，如式(3-11)所示：

$$Output = Kalman_Filter_Output \quad (3-11)$$

3.2 模型训练与参数设置

3.2.1 分子泵退化数据采集

使用 3.1 节中设计的方法，分子泵剩余使用寿命预测的流程图如图 3-4 所示。




图3-4 模型训练流程图

模型训练流程主要包括数据采集和预处理、使用所提出的深度模型结构进行训练，以及最终的剩余使用寿命预测和评估。

分子泵通过使用高速转子为气体分子提供动量来运行，将它们引导到排气口，由前一级进行压缩和抽空。实验平台如图 3-5 所示。

实验前，首先在分子泵的主体上安装一个加速度传感器，传感器数据由上位机接收；在数据收集过程中，启动分子泵以确保稳定运行，然后打开真空阀模拟真空泄漏。分子泵在阀门始终打开的情况下继续运行。将采样率设置为 1 kHz，以收集分子泵运行的数据，打开真空阀直到触发过载保护，表 3-2 提供了详细的数据收集信息。




图3-5 分子泵数据采集平台

表3-2 分子泵降解数据集所有列的描述

列数	描述
1	编号
2	时间
3	传感器 X
4	传感器 Y
5	传感器 Z

经过多次实验，确定分子泵在真空泄漏条件下最多可以运行约 360 分钟；同时设置了分子泵的寿命标签，以指示第一分钟的剩余寿命约为 359 分钟，随后每分钟减一分钟。以这种方式收集了多组数据，并将其按 4:1 的比例分为训练集和测试集来收集数据；收集的数据样本如图 3-6 所示。




图3-6 采集分子泵数据示意图

3.2.2 数据预处理

对于数据预处理, 采用最小-最大归一化来标准化数据, 从而确保每个特征都按比例影响整体模式, 如式(3-12)所示:

$$X_i = \frac{X_i - X_{min}}{X_{max} - X_{min}} \quad (3-12)$$

X_i 是第*i*分钟收集的传感器数据。

采用均方根误差(Root Mean Square Error, RMSE)和平均绝对误差(Mean Absolute Error, MAE)作为剩余使用寿命预测部分的评估指标, 提出的评估指标如式(3-13), (3-14)所示:

$$RMSE = \sqrt{\frac{\sum_{i=1}^N \sum (y_i - \hat{y}_i)^2}{N}} \quad (3-13)$$

$$MAE = \frac{1}{N} \sum_{i=1}^N |y_i - \hat{y}_i| \quad (3-14)$$

其中 y_i 是模型的剩余使用寿命预测值, $\hat{y}_i$ 是与样本对应的实际剩余使用寿命值, N 是预测值的总数。

3.2.3 时间步长的确定

在深度学习中, 网络参数会显著影响预测性能; 首先根据其预测性能确定所设计的深度网络的参数。在预测剩余使用寿命时, 需要从时间序列数据中提取有价值的信; 因此, 必须确定时间序列的长度, 较长的时间步长可以从先前的数据中提取更多的信息, 但它也会增加训练网络的难度, 训练后的模型可能会表现出过拟合。因此根据图 3-4 寿命预测流程, 研究并比较了不同时间步长下剩余使用寿命预测的性能。

在训练过程中, 学习率被设置为调度回调函数, 如果在设定的迭代次数内损失没有改善, 学习率就会被调低。首先, 将时间步长设置为 1、2、3、4、5、6、7、8 和 9, 每个时间步长在同样的设置下重复进行实验 10 次。然后使用 RMSE 和 MAE 指标来评估预测分子泵剩余使用寿命的效果。

图 3-7 显示了不同时间步长的平均 RMSE 和 MAE。结果表明, 当时间步长为 1 或 2 时, RMSE 显著较高, 这表明较小的时间步长提供的信息不足, 这使得

深部结构难以建立准确的预测模型；随着时间步长增加到 3、4 和 5，RMSE 和 MAE 逐渐降低，预测结果变得逐渐准确，这表明较长的时间步长可以提供相对准确的信息。当时间步长达到 6 时，RMSE 和 MAE 指标达到其最佳值，产生更准确的预测结果，表明这些时间步长为模型提供了全面的信息。然而，当时间步长增加到 7、8 和 9 时，观察到 RMSE 和 MAE 略有增加，这表明过长的序列可能会降低模型的泛化能力。因此，选择合适的时间步长对于获得更好的预测结果至关重要。此外，更大的时间步长也会导致更长的训练时间。在这种情况下，考虑到预测性能和训练时间，时间步长设置为 6。




图3-7 时间步选择图

3.2.4 堆叠网络层数的确定

在时间步长确定的基础上，比较了不同编码器层数下分子泵剩余使用寿命预测的效果。在所提出的深度学习模型中，堆叠的 C-Transformer 层的数量最初设置为 2，时间步长设置为 6。在训练过程中，Adam 算法中的学习率被配置为调度回调函数。C-Transformer 中的堆叠层数不同，分别设置为 2、3 和 4 层，每个配置实验重复 10 次。图 3-8 显示了不同数量的编码器层的平均 RMSE 和 MAE。

一般来说，堆叠的网络层数量越多，意味着深度学习的预测能力更强，但也

会导致更长的训练时间。然而，图 3-8 所示的结果表明，当 C-Transformer 堆叠层的数量从 2 增加到 3 时，预测精度的提高只是微不足道的。此外，当 C-Transformer 堆叠层的数量从 3 增加到 4 时，预测精度实际上下降了。这些结果表明，特征提取主要取决于每个 C-Transformer 层的内部结构，而不是多层的堆叠。层数的过度增加可能会削弱时间依赖性，从而降低剩余使用寿命预测的准确性。




图3-8 堆叠网络层数图

此外，鉴于数据集中相对固定的数据量和特征，增加层数会导致模型更加复杂。过于复杂的模型容易过拟合，即模型在训练数据上表现良好，但在测试数据上表现不佳。在这种情况下，考虑到预测性能和训练时间，C-Transformer 的堆叠层数设置为 3。

随后确定了所提出的深度架构的参数，包括两个卷积层、三个堆叠的 C-Transformer 层和一个用于预测的最终全连接层。

3.3 实验验证与分析

在本节中，使用真空泄漏条件下的分子泵退化数据集评估了所提出方法的效果。按照图 3-4 中概述的过程进行了训练和验证，为了减轻随机性的影响，本节研究中呈现的实验结果代表了五次试验的平均值。表 3-3 显示了不同方法的比较实验结果。研究结果表明，本章提出的预测方法在收集的数据集上取得了最佳的

平均预测性能。

表3-3 不同预测模型预测结果对比

生成方法	RMSE	MAE
Hybrid deep RNN without Kalman_filter	0.1464	0.1044
LSTM without Kalman_filter	0.1348	0.0964
Transformer without Kalman_filter	0.1316	0.0961
C-Transformer without Kalman	0.1252	0.0952
Hybrid deep RNN with Kalman_filter	0.1248	0.0864
LSTM with Kalman_filter	0.0909	0.0657
Transformer with Kalman_filter	0.1152	0.0852
C-Transformer with Kalman_filter	0.0804	0.0576

为了更直观地比较和可视化预测的剩余使用寿命与实际剩余使用寿命，图 3-9 可视化了本文提出的方法与其他预测方法的结果对比。

为了确保比较的公平性，我们对其他三种方法的预测结果应用了卡尔曼滤波作为后处理模块。结果表明，本文提出的 C-Transformer 模型能够有效捕捉退化行为，其平均预测结果表现最佳，从而验证了该方法的优越性。

此外，为了证明添加到 C-Transformer 中的卷积神经网络特征提取结构的有效性，将 C-Transformer 的预测性能与 Transformer 的预测性能进行了比较。如图 3-9 和图 3-10 所示，很明显，C-Transformer 的性能明显优于 Transformer，这表明卷积神经网络结构的结合大大提高了预测性能。

在分子泵寿命预测任务中，传感器数据（如振动、压力）既包含高频噪声（局部瞬时特征），又隐含长期退化趋势（全局时间依赖）。CNN 滑动窗口机制通过卷积核的局部感知能力，有效提取振动信号中的高频成分和压力信号的周期性波动。 $16 \times 3 \times 1$ 卷积核的最优参数组合表明，适中的卷积核尺寸和通道数能够在保留细节特征的同时避免过拟合。Transformer 通过多头自注意力机制，Transformer 编码器捕捉了分子泵退化过程中多时间尺度的依赖关系。与 LSTM 等循环模型相比，Transformer 的并行计算能力显著提升了长序列的处理效率。

CNN-Transformer 的级联设计解决了单一模型在局部-全局特征融合上的不足（如 Transformer 对噪声敏感，CNN 难以建模长期趋势）。




图3-9 不同方法寿命预测对比图




图3-10 卡尔曼滤波对比图

最后，将提出的方法与没有卡尔曼滤波的相同方法进行了比较。如图 3-9 和图 3-10 所示，卡尔曼滤波器显著提高了预测寿命曲线的准确性和稳定性。这种改进可归因于卡尔曼滤波器实时更新状态估计的能力，使模型能够在整个预测过

程中不断改进预测结果，从而与实际寿命更接近。

卡尔曼滤波通过递归更新预测误差协方差矩阵，动态调整状态估计值，有效抑制了传感器噪声和模型预测不确定性。卡尔曼滤波使预测曲线的波动幅度显著减少，验证了其对非稳态噪声的适应性。

通过残差自相关分析和 Q-Q 图检验，确认了系统线性性与噪声高斯分布的假设成立，为卡尔曼滤波的应用提供了理论依据。相较于传统滑动平均或小波降噪方法，卡尔曼滤波在保留信号动态特性的同时，避免了人为设定窗口大小的主观性。

3.4 本章小结

本章通过结合 CNN 与卡尔曼滤波，成功解决了 Transformer 在局部特征提取与噪声干扰方面的局限性。所提出的混合架构显著提升了模型的预测精度与鲁棒性，为分子泵寿命预测提供了新的技术路径。

第4章 基于 Time GAN 的退化数据生成与优化

针对分子泵退化数据稀缺的问题，本章提出了一种基于时间序列生成对抗网络的退化数据生成方法。并设计了生成数据的训练流程与实验，分析了生成数据与传统数据生成方法的效果优劣，为分子泵寿命预测提供了丰富的数据基础。

4.1 Time GAN 模型

时间序列生成对抗网络是一种生成对抗网络，用于生成时间序列数据。它包含四个主要模块：嵌入函数、恢复函数、生成器和鉴别器。嵌入函数用于将高维的时间序列数据映射到低维的潜在空间；恢复函数的作用是将嵌入函数生成的低维潜在表示映射回到高维的时间序列数据空间，可以视作嵌入函数的逆过程。嵌入函数和恢复函数的组合使用，提高了网络的学习效率。生成器的主要任务是生成新的数据，时间特征由监督网络学习，而鉴别器的作用是区分生成数据和真实数据。Time GAN 工作过程如图 4-1 所示。




图4-1 Time Gan工作流程

4.1.1 嵌入函数和恢复函数

将数据记录为 $D = \{X_{ij}; i \in I, j \in J_i\}$ ，其中 $I = \{1, 2, 3, \dots, m\}$ 为分子泵数据记录时间； $J_i = \{k_{1:n,1}, k_{1:n,2}, k_{1:n,3}, \dots, k_{1:n,i}\}$ 为记录时间下的多元特征数据，其中 n

为记录特征个数, X_{ij} 为分子泵在运行过程中某一时间节点处的特征数据, 数据生成的目标是使用训练集 D 来学习最接近 $P(X_{ij})$ 的概率密度 $\hat{P}(X_{ij})$ 。

首先, 嵌入和恢复函数提供特征和潜在空间之间的映射, 允许对抗网络通过低维表示学习数据的潜在时间动态。基于包含静态特征和时态特征的映射函数 f_E^M 和 f_E^K , 利用嵌入网络将原始特征空间映射到包含静态特征和时态特征的潜在空间, 从而提高网络计算的时效性。映射过程如式(4-1)所示:

$$\begin{cases} h_M = f_E^M(M) \\ h_k = f_E^K(h_M, h_{k-1}, x_k) \end{cases} \quad (4-1)$$

其中 h_M 和 h_k 使嵌入函数映射后的低维数据表达, M 是原始数据的一个静态部分, x_k 是原始时间序列中的第 K 条序列。

嵌入函数主要是对输入数据降维, 同时还需要进行从低维到高维的恢复。恢复网络学习映射函数 f_R^M 和 f_R^K 来恢复原始特征。逆映射过程如式(4-2)所示:

$$\begin{cases} \hat{h}_M = f_R^M(M) \\ \hat{h}_k = f_R^K(h_k) \end{cases} \quad (4-2)$$

其中 $\hat{h}_M$ 和 $\hat{h}_k$ 是恢复函数逆映射的数据表达。

4.1.2 生成与鉴别网络

在潜在空间中, 使用生成器生成数据。生成器的输入数据为噪声向量, 输出为生成数据。基于生成函数 f_G^M , f_G^K , 静态特征输入噪声 Z_M 和时间特征输入噪声 Z_K , 生成的静态特征的低维表示 h'_M , 生成的第 K 条序列的低维表示为 h'_k , 如式(4-3)所示。

$$\begin{cases} h'_M = f_G^M(Z_M) \\ h'_k = f_G^K(h'_M, h'_{k-1}, Z_K) \end{cases} \quad (4-3)$$

式中, Z_M 服从均匀分布, Z_K 服从随机过程。这里使用威布尔分布用于描述 Z_K 。

鉴别器主要用于区分真实样本和生成样本。采用双向递归网络识别时域特征 h' , 并在两个方向上进行区分。对两类分类器进行真实数据或生成数据的标签判断。鉴别器的输出如式(4-4)所示:

$$\begin{cases} \tilde{y}_M = D_M(h'_M) \\ \tilde{y}_k = D_K(\tilde{u}_k, \tilde{u}_{k-1}) \end{cases} \quad (4-4)$$

其中正向递归函数的输出为 $\tilde{u}_k = \tilde{R}_X(\tilde{h}_M, \tilde{h}_K, \tilde{u}_{k+1})$, 反向递归函数的输出为 $\tilde{u}_k = \vec{R}_X(\tilde{h}_M, \tilde{h}_K, \tilde{u}_{k-1})$, $\tilde{R}_X$ 和 $\vec{R}_X$ 分别表示正向递归函数和反向递归函数; $\tilde{y}_M$ 是

对生成的静态特征的鉴别结果， $\hat{y}_k$ 是对生成的时间特征的鉴别结果， D_M 为鉴别器的静态特征鉴别函数， D_K 为鉴别器的时间特征鉴别函数。

4.1.3 Time Gan 的训练策略

对于损失函数，使用无监督损失用于训练鉴别器和生成器，以确保生成的数据能够欺骗鉴别器；使用监督损失用于训练生成器，以确保生成的数据在潜在空间中尽可能接近真实数据；使用重建损失用于训练生成器和递归网络，以确保生成的数据在重建过程中尽可能接近原始数据，如图 4-2 所示。




图4-2 Time的训练策略图

作为特征和潜在空间之间的可逆映射，恢复函数应该能够从原始数据的潜在表示中精确地重建原始数据。因此构建损失的第一个目标函数是重建损失，如式(4-5)所示：

$$L_R = E_{M, x_1:k \sim p} [\|M - \hat{M}\|_2 + \sum_k \|x_k - \hat{x}_k\|_2] \quad (4-5)$$

重建损失包括了两部分：一部分是用于评估整个数据片段 M 与恢复片段 $\hat{M}$ 之间的差异，另一部分是逐个点评估 x_k 与 $\hat{x}_k$ 之间的差异。重建损失函数有助于确保生成的潜在表示能够尽可能准确地保留原始数据的细节信息，确保生成数据能够准确重建。

作为区分真实样本和生成样本的网络，鉴别器要求生成器生成的数据 h'_k 尽可

能接近真实数据，并尽可能远离生成数据，即 $\log h_k$ 与 $\log(1 - h'_k)$ 和越大，鉴别器效果越好。因此，无监督损失的损失函数如式(4-6)所示：

$$L_U = E_{M, x_1:k \sim p} [\log(y_M) + \sum_k \log(y_k)] + E_{M, x_1:k \sim \tilde{p}} [\log(1 - \tilde{y}_M) + \sum_k \log(1 - \tilde{y}_k)] \quad (4-6)$$

$E_{M, x_1:k \sim p}$ 表示从真实数据分布中抽取样本 x 的期望。 p 表示真实数据的分布，而 $\tilde{p}$ 表示由生成器生成的数据的分布。对于来自真实数据分布 p 的 M 和 $x_1:k$ ， y_M 和 y_k 分别表示鉴别器评估这些样本为真实的概率；相反，对于来自生成数据分布 $\tilde{p}$ 的 M 和 $x_1:k$ ， $\tilde{y}_M$ 和 $\tilde{y}_k$ 分别表示鉴别器评估这些样本为假的概率。无监督损失 L_U 的目标是通过最大化鉴别器能够正确区分真实与生成样本的概率和最大化生成样本被错误地判断为真实的概率，来提升生成器和鉴别器的性能。

鉴别器的二元对抗性反馈可能不足以激励生成器捕获数据中的密度分布。为了更有效地捕获数据中的密度分布，使用监督损失通过直接比较生成器生成的潜在表示和真实数据的潜在表示，确保生成器能够学习到时间序列数据的时间依赖性。如式(4-7)所示：

$$L_S = E_{M, x_1:k \sim p} [\sum_k \|h_k - f_G^k(h_M, h_{k-1}, z_k)\|_2] \quad (4-7)$$

对于损失函数的优化，设 θ_e ， θ_r ， θ_g ， θ_d 分别表示嵌入网络，恢复网络，生成网络和鉴别网络的参数优化。恢复网络和嵌入网络主要是建立一个潜在空间，对抗网络对潜在空间中的样本进行鉴别。然后， θ_g 使生成数据的特征尽可能接近真实数据。学习过程的目的是优化时间序列生成对抗网络中的模型参数 θ_e ， θ_r ， θ_g ， θ_d 。其中 θ_e ， θ_r 是在重建和监督损失上进行训练的，如式(4-8)所示：

$$\min_{\theta_e, \theta_r} (\lambda L_S + L_R) \quad (4-8)$$

θ_g ， θ_d 的目的是使鉴别器中真实样本与生成样本之间的距离最大化，而生成器生成的样本与真实样本之间的距离最小。因此，构造式(4-9)所示来优化鉴别器和生成器网络：

$$\min_{\theta_g} (\eta L_S + \max_{\theta_d} L_U) \quad (4-9)$$

其中 $\lambda, \eta \geq 0$ 是时间序列生成对抗网络中的超参数。

4.2 改进 Time GAN 模型设计

4.2.1 生成器与鉴别器的改进

Time GAN 通常使用循环神经网络或长短期记忆网络作为生成器与鉴别的网络模型,但循环神经网络或长短期记忆网络在处理长序列数据时存在训练效率低、捕捉长期依赖关系能力有限的问题。因此,引入了基于 Transformer 网络的改进方案,Transformer 通过自注意力机制能够同时关注不同时间点的数据特征,从而更高效地学习时间序列的长期依赖关系,如图 4-3 所示;与 RNN 和 LSTM 相比,Transformer 能够并行处理数据,显著提升了训练效率,适用于分子泵样本退化数据的处理。




图4-3 Time Gan改进示意图

4.2.2 输入噪声分布的改进

在 Time GAN 模型中,生成器通常使用高斯分布的噪声向量作为输入。然而,在分子泵退化数据的生成任务中,高斯分布无法较好的模拟分子泵退化数据中复杂的动态特性和非线性行为。

为了解决这一问题,提出威布尔分布作为噪声分布。威布尔分布是一种广泛应用于可靠性工程和寿命数据分析的连续概率分布,适合建模机械设备和组件的寿命和退化过程。威布尔分布能够适应不同的故障行为模式,通过调整形状参数

和尺度参数，灵活地拟合各种类型的数据分布^[62]。

威布尔分布是一种的连续概率分布，在可靠性工程和寿命数据分析中广泛应用。它可以用来建模机械设备和组件的寿命和退化过程，并能适应不同的故障行为模式。其概率分布表达如式(4-10)所示：

$$f(x; \alpha, \beta) = \begin{cases} \frac{\beta}{\alpha} \left(\frac{x}{\alpha}\right)^{\beta-1} e^{-(x/\alpha)^\beta} & x \geq 0 \\ 0 & x < 0 \end{cases} \quad (4-10)$$

其中 x 是随机变量， $\alpha > 0$ 是尺度参数，决定了分布的尺度大小， $\beta > 0$ 是形状参数，决定了分布的形状。威布尔分布的形状参数可以灵活地调整分布的形状，使其适应多种退化模式；当 $\beta < 1$ 时，表示早期故障阶段，故障率随时间增加而降低；当 $\beta = 1$ 时，表示恒定故障率阶段，故障率不随时间变化；当 $\beta > 1$ 时，表示磨损故障阶段，故障率随时间增加而增加。

通过对实际分子泵退化数据的统计分析，选择 $\beta = 1.5$ 和 $\alpha = 130$ 作为威布尔分布的参数。 $\beta = 1.5$ 能够较好拟合数据的退化模式，尤其是非线性特征，更接近实际退化过程中的早期和磨损阶段。 $\alpha = 130$ 调整了分布的尺度，使生成数据的时间尺度更接近实际数据，从而提高了生成数据的准确性。

4.3 使用 TGAN-Transformer 模型数据生成的评估与验证

在使模型学习如何将随机噪声转换为符合真实数据分布的样本，生成新的数据集后，利用 LSTM 对生成的数据进行预测验证；整体数据生成流程如图 4-4 所示，所用数据集如表 3-2 所示。




图4-4 数据生成流程图

其中 LSTM 网络是循环神经网络一种变体。它通过引入门控机制解决了传统 RNN 的梯度消失和梯度爆炸问题。LSTM 可以有效地学习长期依赖关系，使其在处理时间序列数据时具有显著优势。使用 LSTM 网络对生成的数据进行寿命预测，具体网络细节在表 4-1 给出。对于预测效果的评价，采用式(3-13)均方根误差，式(3-14)平均绝对误差作为评估指标测，以验证生成退化数据的有效性。

表4-1 时间序列生成对抗网络与LSTM参数表

网络	超参数	值	激活函数
时间序列生成对抗网络	优化器	Adam	
	滑动时间窗口	6	
	迭代次数	1000	
	批量大小	32	
	层数	3	
	隐藏维度	9	
	生成网络 1	GRU	Sigmoid
	鉴别网络 1	GRU	
	生成网络 2	LSTM	Sigmoid
	鉴别网络 2	LSTM	
	生成网络 3	Transformer	
	鉴别网络 3	Transformer	
LSTM	LSTM 层	3	Tanh
	全连接层	3	Relu
	损失函数	MAE	
	输出	1	
	优化器	Adam	

4.3.1 PCA 与 T-SNE 对 TGAN-Transformer 数据生成的可视化评价

TGAN-Transformer 网络结构使用表中所列参数构建。生成器和鉴别器分别

采用门控循环单元(Gated Recurrent Unit, GRU)、LSTM 和 Transformer 进行构建。对原始数据集和生成数据集进行了 PCA(Principal Component Analysis)^[63]和 T-SNE(T-distributed Stochastic Neighbor Embedding)分析^[64]。其中, PCA 通过线性变换将原始数据转换到新的坐标系统中, 这些新坐标(称为主成分)按照方差递减的顺序排列, PCA 有助于描述数据中的线性关系和总体结构。T-SNE 适用于高维数据的可视化, 它在低维空间中对高维数据的相似性进行建模, 擅长保持局部数据结构。通过 T-SNE 分析, 可以更好地描述数据中的聚类 and 群组关系, 并直观地展示生成样本与原始样本在二维空间中的分布差异。不同方法生成数据的 T-SNE 和 PCA 对比结果如图 4-5 所示, 其中蓝色散点为样本数据, 红色散点为生成数据。




图4-5 基于不同生成器网络的时间序列生成对抗网络的可视化比较

在 T-SNE 图 4-5(a)、图 4-5(c)、图 4-5(e)可以看出, 使用 Transformer 生成的数据更加集中且更接近于原始数据的分布。这表明 Transformer 生成的数据在高维空间中的局部结构与真实数据相似, 这表明生成数据与真实数据在低维流形上高度重叠, 表明模型已学习到分子泵退化过程的本征特征。这为生成数据用于不同工况的寿命预测提供了理论支持, 若退化机制相似(如同类泵体的不同转速工况), 生成数据可通过微调实现跨域迁移, 缓解实际工程中多工况数据采集成本高的问题。而 LSTM 与 GRU 生成的数据生成的数据分布较为分散, 与原始数据的相似度较低。在 PCA 图 4-5(b)、图 4-5(d)、图 4-5(f)可以看出, Transformer 生成的数据在主成分空间中的分布与真实数据更加接近, 这表明 Transformer 生成的数据在全局特征上与真实数据相似。通过 T-SNE 和 PCA 分析, 可以直观地看出 Transformer 生成的数据在分布上更接近实际样本数据。这一结果与表 4-2 的数值对比结果一致, 表明 Transformer 生成的数据在预测性能上具有显著优势。

通过设置表 4-1 时间序列生成对抗网络与 LSTM 参数表中的超参数, 使用提出的算法对时间序列生成对抗网络进行训练, 可以得到损失函数的收敛结果, 如图 4-6 所示。




图4-6 TGAN-Transformer的损耗结果

随着迭代次数的增加, 生成器和鉴别器的损失函数逐渐收敛, 表明网络训练过程取得了良好的效果。具体来说, 图中蓝色线表示无监督损失, 黄色线表示监督损失, 而绿色线则表示重建损失。可以看到, 各类损失在训练过程中逐渐减小, 最终趋于稳定, 说明 TGAN-Transformer 模型训练成功。

4.3.2 使用 TGAN-Transformer 数据生成的预测效果评价

为了验证生成数据的实际预测效果,通过结合生成数据与样本数据作为训练集,通过设置表中的超参数,训练 LSTM 预测模型,并使用验证集进行验证,如图 4-7 所示,生成器与鉴别器分别使用 GRU、LSTM 和 Transformer 的预测效果实验对比。其中,红色线表示生成器与鉴别器使用 Transformer 的预测结果,浅蓝色线表示使用 GRU 的预测结果,棕色线表示使用 LSTM 的预测结果。从图 4-7 中可以看出,红色线更接近真实寿命,这表明 Transformer 生成的数据能够更好地用于分子泵寿命预测任务;验证了 TGAN-Transformer 的有效性。




图4-7 时间序列生成对抗网络使用不同生成器生成数据预测效果对比图

进一步地,在表 4-2 所给出的预测评价指标中,生成器与鉴别器使用 Transformer 的 RMSE 和 MAE 均达到了最优结果。与表中其他三种方法相比, TGAN-Transformer 在 RMSE 上分别提高了 82%、43% 和 55%。

表4-2 不同生成方法的预测误差比较结果

生成方法	噪声分布	RMSE	MAE
GRU	高斯分布	0.122	0.087
GRU	威布尔分布	0.096	0.071
LSTM		0.104	0.072
TRANSFORMER		0.067	0.048

4.3.3 验证使用威布尔分布的有效性

为了验证将威布尔分布作为噪声输入的效果，将其与使用高斯分布作为输入噪声生成的数据进行预测效果上的对比，预测效果如图 4-8 所示，红色线表示噪声添加威布尔分布生成数据的预测结果，蓝色线表示噪声添加高斯分布生成数据的预测结果，蓝色线代表真实的剩余寿命。 X 轴为设备运行时间， Y 轴为设备剩余使用寿命。可以看出，使用威布尔分布作为噪声输入生成的分子泵退化数据在预测结果上更接近于真实的分子泵剩余寿命，且在分子泵退化后半段，预测精度显著更高。这表明威布尔分布能够更准确地捕捉分子泵的退化过程。而高斯分布预测曲线与真实剩余寿命的差距较大，尤其是在退化后半段；验证了添加威布尔分布在分子泵退化数据生成上的优越性。

此外，在表 4-2 中给出了两者的评价指标对比。结果显示，噪声添加威布尔分布生成的数据预测结果在 $RMSE$ 和 MAE 上均有提升；因此，将噪声分布改为威布尔分布可以显著提高分子泵退化数据集的预测效果。对此给出的解释是传统高斯噪声的对称性假设与分子泵退化过程的非对称特性存在根本矛盾。威布尔分布通过调整形状参数模拟了设备从稳定运行到加速磨损的过渡阶段，其概率密度函数的右偏特性与退化后期故障率上升现象高度契合。实验表明，该设计使生成数据的 MAE 降低 31.6%，证明噪声分布与物理退化机制的匹配性直接影响生成质量，并证明了威布尔分布在分子泵数据生成模型中的重要性。




图4-8 使用高斯分布与威布尔分布生成数据预测效果对比图

4.4 生成数据对比实验

最后，利用 LSTM 网络分别预测了利用深度卷积生成对抗网络(Deep Convolutional Generative Adversarial Networks, DCGAN)、GAN、递归条件生成对抗网络(Recurrent Conditional GAN, RCGAN)网络以及 VAE、条件变分自编码器(Conditional Variational Autoencoder, CVAE)网络，以及 TGAN-Transformer 生成数据的预测实验对比。预测结果如图 4-9 所示。可以明显看出，TGAN-Transformer 生成数据与实际数据结合的预测结果更接近实际数据，证明了 TGAN-Transformer 的优越性。




图4-9 TGAN-Transformer与其他GAN网络生成数据预测效果对比图

为表明 TGAN-Transformer 的有效性,基于公式的预测误差对比结果如表 4-3 所示。所提方法的 RMSE 和 MAE 均达到了最优结果。与表 4-3 中的 GAN、DCGAN、RCGAN、VAE、CVAE 相比, TGAN-Transformer 在 RMSE 上分别提高了 105%、92%、55%、67%、43%; 这表明本模型通过重构损失、监督损失与对抗损失的联合优化,实现了数据保真度与分布泛化能力的平衡。TGAN-Transformer 在 RMSE 上较 VAE 提升 67%,说明单一重构目标(如 VAE)易导致模式坍缩,而对抗训练引入的分布对齐机制能有效扩展生成样本的多样性。TGAN-Transformer 显著优于 RCGAN 等时序生成模型,关键在于两点:其一,Transformer 的并行化训练使模型在相同迭代次数下接触更多样本模式,加速收

敛；其二，威布尔噪声的引入使生成器隐空间与真实退化路径的拓扑结构对齐，而 RCGAN 使用的随机噪声缺乏物理引导，导致生成序列的局部抖动。

表4-3 不同生成方法的预测误差比较结果

生成方法	噪声分布	RMSE	MAE
GAN	威布尔分布	0.138	0.099
DCGAN	威布尔分布	0.129	0.094
RCGAN	威布尔分布	0.104	0.077
VAE	威布尔分布	0.111	0.083
CVAE	威布尔分布	0.096	0.072
TGAN-Transformer	威布尔分布	0.067	0.048

实验证明 TGAN-Transformer 生成的退化数据更接近实际退化过程，有效地扩展了数据集，并且可以通过 LSTM 网络准确地学习分子泵的退化过程。

4.5 生成数据对预测模型性能的提升

为表明使用生成数据训练模型的必要性，以下从数据稀缺的现实挑战、生成数据的有效性验证及方法对比的工程价值三个维度展开讨论，结合实验结果深入阐述本文生成数据对提升寿命预测模型性能的支撑：

数据稀缺的现实挑战与生成数据的必要性分子泵作为高可靠性设备，其全生命周期退化数据获取面临两大瓶颈分子泵寿命较长，实际运维中主动停机采集退化数据的成本极高，导致真实失效样本稀缺。传统统计模型或浅层机器学习方法在小样本下极易过拟合，因其生成多样性不足导致模型泛化能力受限。实际运行中，分子泵可能处于不同负载、温度、真空度等复杂工况，但受限于数据采集条件，现有数据往往集中于少数典型工况。而 TGAN-Transformer 通过自注意力机制隐式建模特征间的高阶交互，生成数据在主成分空间与真实数据重叠度达 82%，显著扩展了训练集的工况覆盖范围。

生成数据的核心价值在于其分布真实性与模型泛化增益，本工作通过多维度实验验证其必要性，如图 4-8 所示，使用威布尔噪声生成的预测曲线（红色）在

退化后期仍紧密贴合真实寿命趋势，而高斯噪声生成数据（蓝色）在后出现显著偏差。这是因为威布尔分布的右偏特性更贴合分子泵后期的加速失效模式，生成数据在时域分布的尾部准确性直接提升了模型对“罕见但关键”失效事件的预测能力。生成数据与原始数据联合训练显著提升了 C-Transformer 模型的预测精度，RMSE 和 MAE 均下降 16.7%左右，验证了生成数据的有效性及其与真实数据的互补性，如表 4-4 所示。

表4-4 生成数据在不同预测模型上的表现对比

预测模型	训练数据	RMSE	MAE
C-Transformer	原始数据	0.0804	0.0576
C-Transformer	原始数据+生成数据	0.067	0.048

本工作通过理论分析与实验验证，系统论证了使用生成数据训练分子泵寿命预测模型的必要性；生成数据将训练样本量扩增，使复杂模型得以充分训练，避免过拟合。威布尔分布与 Transformer 结构的结合，确保生成数据在时域与特征空间的物理一致性。以较低的算力代价替代高成本物理实验，推动预测性维护技术的落地应用。

4.6 本章小结

本章提出了基于 Time GAN 的分子泵退化数据生成方法，通过生成高质量分子泵退化数据有效解决了分子泵退化数据稀缺的问题。生成数据实验表明，本章所提的生成数据显著提升了模型预测寿命的准确性，这为分子泵寿命预测研究提供了可靠的数据支持。

第5章 EAST 分子泵寿命预测模型设计与部署

本章开发了一款客户端软件，用于实时监测分子泵的运行状态与寿命预测，通过 LabVIEW 与 Python 的交互实现分子泵剩余使用寿命预测的可视化。并通过实验设计与结果分析，验证了模型在不同运行环境下的性能表现，并通过 LabVIEW 实现了高效的分子泵健康管理。

5.1 基于 LabVIEW 的分子泵寿命预测系统设计

5.1.1 系统总体设计

为了将本文所设计的深度学习模型实际用于分子泵剩余使用寿命预测管理中，本章设计并实现了一个基于 LabVIEW 的分子泵寿命预测系统。旨在实时监测分子泵的运行状态，并根据模型预测结果提供维护建议，从而确保真空系统分子泵的稳定运行。客户端软件的核心目标是实时监测分子泵的预测剩余使用寿命，为维护人员提供科学的管理依据，避免因设备故障导致的意外停机。系统设计包括以下几个主要模块：数据采集模块，模型预测模块，结果展示与报警模块。

为了确保分子泵寿命预测系统的准确性和实时性，通过数据采集板卡和三维加速度传感器，板卡的采样频率设置为 1kHz，以确保能够捕捉到分子泵运行中的高频振动信号和其他瞬态变化。数据采集板卡通过 PCI 接口与上位机连接，确保数据传输的稳定性和低延迟。三维加速度传感器安装在分子泵的关键部位，用于实时监测分子泵在 X 、 Y 、 Z 三个方向上的振动信号。传感器的灵敏度经过校准，能够准确捕捉到分子泵运行中的细微振动变化。

在数据采集前，对传感器进行校准，确保其输出信号的准确性和一致性。在分子泵正常运行状态下，启动数据采集系统，开始实时采集振动信号。数据采集板卡将传感器信号转换为数字信号，并通过 PCI 接口传输至上位机进行存储和处理，数据采集过程如图 5-1 所示。采集到的数据以时间戳为索引，存储在上位机的本地数据库中，便于后续的数据分析和模型训练。



图5-1 数据采集流程

5.1.2 模型预测模块设计

模型预测模块是分子泵寿命预测系统的核心部分，集成了本文所设计的 C-Transformer 深度学习模型，用于预测分子泵的剩余使用寿命。模型的输入为采集的分子泵数据，输出为分子泵的 RUL 预测值。

为了实现 Python 与 LabVIEW 的交互，系统采用了以下技术方案：首先，Python 作为深度学习模型的开发和运行环境，负责模型的训练和预测。模型训练完成后，将其导出为 TensorFlow Saved Model 格式，以便在 LabVIEW 中调用。LabVIEW 作为系统的前端平台，负责数据采集、预处理和结果展示。通过 LabVIEW 的 Python 节点，可以直接调用 Python 脚本，实现 Python 模型的加载和预测，在 LabVIEW 中，通过 Python 节点加载已导出的模型文件，并调用 Python 脚本进行预测，如图 5-2 所示。




图5-2 LabVIEW调用python节点框图

Python 训练好的模型对输入数据进行预测，并将结果返回给 LabVIEW，如图 5-3 所示。通过 Python 与 LabVIEW 的交互，系统能够充分利用 Python 在深度学习领域的强大功能，同时发挥 LabVIEW 在数据采集和实时监控方面的优势，

这种不仅提高了系统的预测精度，还增强了系统的灵活性和扩展性。




图5-3 寿命预测过程程序框图

LabVIEW 接收预测结果后，预测结果以图形化的方式展示给用户，并在预测 RUL 低于预设阈值时发出报警信号，提醒维护人员及时采取措施，该模块包括预测结果的可视化展示、报警提示和维护建议，如图 5-4 所示。




图5-4分子泵寿命预测可视化界面

5.2 系统运行流程

分子泵寿命预测系统以分子泵寿命为核心任务，实现寿命预测模型的应用，系统运行流程如图 5-5 所示。

首先在分子泵轴承、转子等关键位置安装三维加速度传感器实时监测振动。采用 NI-9234 采集振动信号，通过西门子 S7-1200 PLC 接收传感器信号并执行初步滤波，同时控制分子泵启停与安全联锁，使用 Moxa EDS-405A 实现 PLC、NI

板卡与上位机的数据同步传输，确保时序一致性。




图5-5 分子泵寿命预测系统运行流程

通过 LabVIEW 的 Python 节点调用封装好的 C-Transformer 模型（TensorFlow SavedModel 格式），输入为特征向量；使用 TCP/IP 协议传输数据，LabVIEW 端将预处理后的数据打包为 JSON 格式，Python 端返回预测 RUL 值，其中所用设备具体参数如所示。

表5-1 分子泵系统组件参数表

组件	关键参数	性能指标
NI-9234 板卡	采样率 1kHz，4 通道同步	信号信噪比>75dB
西门子 S7-1200	循环周期 1ms，数字量输入 16 点	滤波延迟<0.5ms
Moxa EDS-405A	千兆以太网，IEEE 1588 时 钟同步	网络抖动<1us

5.3 案例分析

为了进一步验证系统的实际应用效果，选取了几个典型的分子泵运行案例进行分析。以下是两个代表性案例：

在案例 1 中，分子泵从正常运行状态逐渐过渡到过载保护状态。系统成功预测了分子泵的退化趋势，并在 RUL 降至预设阈值时发出了维护建议。维护人员根据系统建议及时进行了检查和维护，避免了设备故障，如图 5-6 所示。




图5-6 模型捕捉分子泵从正常运行状态逐渐过渡到过载保护状态图

在案例 2 中，分子泵突然出现异常振动，系统迅速检测到这一异常，并在短时间内发出了报警信号。维护人员根据系统的维护建议，及时更换了故障部件，确保了系统的正常运行如图 5-7 所示。




图5-7 模型捕捉分子泵异常振动图

通过这些案例分析，可以看出基于 LabVIEW 的分子泵寿命预测系统在实际应用中的有效性和可靠性，能够显著提升设备的健康管理水平，减少意外停机和维护成本。

5.4 本章小结

本章成功开发了客户端软件，实现了分子泵 RUL 的实时监测。本章的研究为分子泵寿命预测的实际应用提供了技术支持，为 EAST 真空系统的运行管理提供了重要工具，具有显著的工程应用价值。

第6章 总结与展望

6.1 研究总结

本文围绕分子泵在真空泄漏情况下的寿命预测问题,展开了一系列深入的研究。为了解决传统寿命预测模型的局限性,本文提出了一种基于 Transformer 网络的深度学习模型,通过结合卷积神经网络与卡尔曼滤波,显著提升了模型的预测精度与鲁棒性。同时,针对退化数据稀缺的挑战,本文提出了一种基于时间序列生成对抗网络的数据生成方法,改进噪声分布为威布尔分布以优化生成数据质量,有效扩展了数据集规模,为分子泵寿命预测研究提供了丰富的数据基础。

基于 Transformer 的深度学习模型:针对传统寿命预测模型在复杂运行环境中难以捕捉分子泵状态演变的不足,本文提出了一种基于 Transformer 的深度学习框架。通过引入自注意力机制,模型能够高效捕捉时间序列中的全局依赖关系,解决了长期依赖建模中梯度消失或梯度爆炸的问题。同时,结合 CNN 的局部特征提取能力,进一步提升了模型在复杂运行环境中的适应性。为应对运行环境中噪声干扰对预测结果的影响,引入了卡尔曼滤波对预测结果进行修正,提高了模型的鲁棒性与预测结果的可靠性,使分子泵寿命预测更加精确且稳定。

基于 Time GAN 的退化数据生成方法:针对退化数据稀缺的问题,本文提出了一种基于时间序列生成对抗网络的数据生成方法。通过 Time Gan 生成了高质量的分子泵退化数据;此外,引入威布尔分布作为输入噪声优化,进一步增强了生成数据对真实退化行为的模拟能力,为分子泵寿命预测提供了丰富的数据支持。

客户端软件的设计与实现:为将研究成果应用于实际场景,本文开发了一款基于 LabVIEW 的客户端软件,实现了分子泵实时寿命预测与监测。

6.2 研究展望

尽管本文在分子泵寿命预测领域取得了一定的研究成果,但仍有一些问题值得进一步探讨与改进:

模型优化与计算效率提升：本文提出的混合深度学习模型在预测精度与鲁棒性方面表现优异，但其计算复杂度较高，尤其在处理大规模数据时，计算效率可能成为瓶颈。未来可以探索模型压缩与加速技术，如知识蒸馏、量化剪枝等，以降低计算成本并提升模型的实时性。

数据生成方法的改进：本文提出的 Time GAN 方法虽然能够生成高质量的退化数据，但其生成效率与多样性仍有改进空间。未来可以结合其他生成模型，或引入更多先验知识，进一步提升生成数据的质量与多样性。

多维数据融合与特征提取：本文主要基于振动信号进行寿命预测，未来可以引入其他类型的数据，通过多维数据融合技术进一步提高预测精度。此外，可以探索更高效的特征提取方法，如多尺度特征融合、自适应特征选择等，以捕捉设备退化过程中的更多细节信息。

实际应用场景的验证与优化：本文的实验主要基于仿真数据与实验室数据，未来可以进一步在实际工业场景中进行验证，以评估模型在实际应用中的性能与稳定性。同时，可以结合实际场景中的运行数据对模型进行持续优化，使其更好地适应复杂的工业环境。

总之，分子泵寿命预测是一个复杂且具有挑战性的研究领域，本文的研究为相关问题的解决提供了新的思路与方法。未来，随着深度学习技术的不断发展与实际应用场景的不断扩展，分子泵寿命预测研究将取得更多突破性进展，为 EAST 真空系统的稳定运行提供更加可靠的技术保障，同时也为其他复杂设备的寿命预测研究提供有益的借鉴与参考。

参考文献

- [1] Yuan X L, Kai J, 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.
- [2] 周阳.分子泵故障诊断与预测技术研究[D].安徽:安徽工程大学,2024.
- [3] 林鹏飞.分子泵故障诊断与寿命预测技术研究[D].安徽:中国工程物理研究院,2020.
- [4] 贾凯.基于机器学习与压缩感知的 EAST 分子泵状态监测与故障诊断研究[D].安徽:安徽工程大学,2023.
- [5] Tsui K L, Chen N, Zhou Q, et al. Prognostics and health management: A review on data driven approaches[J]. Mathematical Problems in Engineering, 2015, 2015(1): 793161.
- [6] Si X S, Wang W, Hu C H, et al. Remaining useful life estimation—a review on the statistical data driven approaches[J]. European Journal of Operational Research, 2011, 213(1): 1-14.
- [7] Ahmadzadeh F, Lundberg J. Remaining useful life estimation[J]. International Journal of System Assurance Engineering and Management, 2014, 5: 461-474.
- [8] Ferreira C, Gonçalves G. Remaining Useful Life prediction and challenges: A literature review on the use of Machine Learning Methods[J]. Journal of Manufacturing Systems, 2022, 63: 550-562.
- [9] 汪海.工业设备维护管理系统研究与设计[J].河南科技,2023,42(08):22-26.
- [10] 张松.滚动轴承剩余使用寿命预测综述[J].内燃机与配件,2024,(18):24-26.
- [11] 何彬,贺婷婷.面向动车组修程修制优化的关键零部件寿命预测方法研究[J].铁道车辆,2024,62(02):7-10.
- [12] 曲胤熹.基于深度学习的轴承预测性维护决策研究[D].辽宁:沈阳大学,2023.
- [13] Zhou Y, Jiang M, Yuan X, et al. Fault Prediction of Molecular Pump Based on DE-Bi-LSTM[J]. Fusion Science and Technology, 2024, 80(8): 1001-1011.

-
- [14] Zhang Y, Fang L, Qi Z, et al. A review of remaining useful life prediction approaches for mechanical equipment[J]. IEEE Sensors Journal, 2023, 23(24): 29991-30006.
- [15] Mosallam A, Medjaher K, Zerhouni N. Data-driven prognostic method based on Bayesian approaches for direct remaining useful life prediction[J]. Journal of Intelligent Manufacturing, 2016, 27: 1037-1048.
- [16] Wang Y, Zhao Y, Addepalli S. Remaining useful life prediction using deep learning approaches: A review[J]. Procedia manufacturing, 2020, 49: 81-88.
- [17] Li L, Xu J, Li J. Estimating remaining useful life of rotating machinery using relevance vector machine and deep learning network[J]. Engineering Failure Analysis, 2023, 146: 107125.
- [18] Wang Y, Zhao Y, Addepalli S. Remaining useful life prediction using deep learning approaches: A review[J]. Procedia manufacturing, 2020, 49: 81-88.
- [19] Xiong J, Fink O, Zhou J, et al. Controlled physics-informed data generation for deep learning-based remaining useful life prediction under unseen operation conditions[J]. Mechanical Systems and Signal Processing, 2023, 197: 110359.
- [20] 杨紫安.基于深度学习的轴承剩余使用寿命预测方法研究[D].陕西:西安理工大学,2024.
- [21] 汪良成.基于深度学习的航空发动机健康状态评估与剩余使用寿命预测[D].湖北:华中科技大学,2024.
- [22] Sun B, Li Y, Wang Z, et al. Remaining useful life prediction of aviation circular electrical connectors using vibration-induced physical model and particle filtering method[J]. Microelectronics Reliability, 2019, 92: 114-122.
- [23] Wang T, Liu Z, Zhao X, et al. Bayesian-based method for the remaining useful life and reliability prediction of steel structure[C]//2020 Asia-Pacific International Symposium on Advanced Reliability and Maintenance Modeling (APARM). IEEE, Vancouver, BC, Canada,2020: 1-6.
- [24] Sheng Y, Liu H, Li J. Bearing performance degradation assessment and remaining

- useful life prediction based on data-driven and physical model[J]. *Measurement Science and Technology*, 2023, 34(5): 055002.
- [25] Orsagh R, Roemer M, Sheldon J, et al. A comprehensive prognostics approach for predicting gas turbine engine bearing life[C]//Turbo Expo: Power for Land, Sea, and Air. Vienna, Austria,2004, 41677: 777-785.
- [26] 孙宇博,雷娟娟.航空发动机叶片 TC4 钛合金振动疲劳裂纹扩展研究及剩余寿命预测[J].*表面技术*,2016,45(09):207-213.
- [27] 金诗杭.基于时间卷积网络的涡扇发动机剩余寿命预测[D].重庆:重庆大学,2022.
- [28] 王晓鹏.基于数据驱动模型的航空发动机剩余寿命预测研究[D]. 陕西:陕西理工大学,2024.
- [29] Giorgio M, Guida M, Pulcini G. An age-and state-dependent Markov model for degradation processes[J]. *IIE Transactions*, 2011, 43(9): 621-632.
- [30] Huang Z, Xu Z, Ke X, et al. Remaining useful life prediction for an adaptive skew-Wiener process model[J]. *Mechanical Systems and Signal Processing*, 2017, 87: 294-306.
- [31] Wang H, Liao H, Ma X, et al. Remaining useful life prediction and optimal maintenance time determination for a single unit using isotonic regression and gamma process model[J]. *Reliability Engineering & System Safety*, 2021, 210: 107504.
- [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*, 2016, 64(3): 2276-2285.
- [33] Nieto P J G, García-Gonzalo E, Lasheras F S, et al. Hybrid PSO–SVM-based method for forecasting of the remaining useful life for aircraft engines and evaluation of its reliability[J]. *Reliability Engineering & System Safety*, 2015, 138: 219-231.
- [34] Cheng C, Ma G, Zhang Y, et al. A deep learning-based remaining useful life

- prediction approach for bearings[J]. IEEE/ASME transactions on mechatronics, 2020, 25(3): 1243-1254.
- [35] Li X, Zhang W, Ding Q. Deep learning-based remaining useful life estimation of bearings using multi-scale feature extraction[J]. Reliability engineering & system safety, 2019, 182: 208-218.
- [36] Yao D, Li B, Liu H, et al. Remaining useful life prediction of roller bearings based on improved 1D-CNN and simple recurrent unit[J]. Measurement, 2021, 175: 109166.
- [37] Guo L, Li N, Jia F, et al. A recurrent neural network based health indicator for remaining useful life prediction of bearings[J]. Neurocomputing, 2017, 240: 98-109.
- [38] Li X, Ding Q, Sun J Q. Remaining useful life estimation in prognostics using deep convolution neural networks[J]. Reliability Engineering & System Safety, 2018, 172: 1-11.
- [39] Wang R, Shi R, Hu X, et al. Remaining useful life prediction of rolling bearings based on multiscale convolutional neural network with integrated dilated convolution blocks[J]. Shock and Vibration, 2021, 2021(1): 6616861.
- [40] Zeng M, Wu F, Cheng Y. Remaining useful life prediction via spatio-temporal channels and transformer[J]. IEEE Sensors Journal, 2023, 23(23): 29176-29185.
- [41] Zhou J T, Zhao X, Gao J. Tool remaining useful life prediction method based on LSTM under variable working conditions[J]. The International Journal of Advanced Manufacturing Technology, 2019, 104: 4715-4726.
- [42] Zheng S, Ristovski K, Farahat A, et al. Long short-term memory network for remaining useful life estimation[C]//2017 IEEE international conference on prognostics and health management (ICPHM). IEEE, 2017: 88-95.
- [43] Wang F K, Amogne Z E, Chou J H, et al. Online remaining useful life prediction of lithium-ion batteries using bidirectional long short-term memory with attention mechanism[J]. Energy, 2022, 254: 124344.

- [44] Li X, Li J, Zuo L, et al. Domain adaptive remaining useful life prediction with transformer[J]. IEEE Transactions on Instrumentation and Measurement, 2022, 71: 1-13.
- [45] Vaswani A, Shazeer N, Parmar N, et al. Attention is all you need[J]. Advances in neural information processing systems, 2017, 30.
- [46] Ogunfowora O, Najjaran H. A transformer-based framework for multi-variate time series: A remaining useful life prediction use case[J]. arXiv preprint arXiv:2308.09884, 2023.
- [47] Mo Y, Wu Q, Li X, et al. Remaining useful life estimation via transformer encoder enhanced by a gated convolutional unit[J]. Journal of Intelligent Manufacturing, 2021, 32(7): 1997-2006.
- [48] Chen D, Hong W, Zhou X. Transformer network for remaining useful life prediction of lithium-ion batteries[J]. Ieee Access, 2022, 10: 19621-19628.
- [49] Guo P, Liu Q, Yu S, et al. A transformer with layer-cross decoding for remaining useful life prediction[J]. The Journal of Supercomputing, 2023, 79(10): 11558-11584.
- [50] 李川, 伍依凡, 杨帅. 不平衡分布的数据驱动故障诊断的研究进展[J]. 仪器仪表学报, 2023, 44(08): 181-197.
- [51] 宁云志, 宁静, 李艳萍, 等. 基于数据不平衡下的高速列车小幅蛇行预测方法[C]. 电子测量技术, 2022, 45(06): 149-154.
- [52] Ji H K, Mirzaei M, Lai S H, et al. Implementing generative adversarial network (GAN) as a data-driven multi-site stochastic weather generator for flood frequency estimation[J]. Environmental Modelling & Software, 2024, 172: 105896.
- [53] Goodfellow I, Pouget-Abadie J, Mirza M, et al. Generative adversarial networks[J]. Communications of the ACM, 2020, 63(11): 139-144.
- [54] Takahashi S, Chen Y, Tanaka-Ishii K. Modeling financial time-series with generative adversarial networks[J]. Physica A: Statistical Mechanics and its

- Applications, 2019, 527: 121261.
- [55] Esteban C, Hyland S L, Rätsch G. Real-valued (medical) time series generation with recurrent conditional gans[J]. arXiv preprint arXiv:1706.02633, 2017.
- [56] Zheng T, Song L, Wang J, et al. Data synthesis using dual discriminator conditional generative adversarial networks for imbalanced fault diagnosis of rolling bearings[J]. Measurement, 2020, 158: 107741.
- [57] Li X, Metsis V, Wang H, et al. Tts-gan: A transformer-based time-series generative adversarial network[C]//International conference on artificial intelligence in medicine. Cham: Springer International Publishing, Halifax, NS, Canada, 2022: 133-143.
- [58] Lee J. VRNNGAN: A recurrent VAE-GAN framework for synthetic time-series generation[D]. University of Toronto (Canada), 2022.
- [59] Gujulla Leel S R, Dey V, Majumdar P, et al. HierTGAN: Hierarchical Time Series Generation with Aggregation Constraints[C]//Proceedings of the 7th Joint International Conference on Data Science & Management of Data (11th ACM IKDD CODS and 29th COMAD). Bangalore India, 2024: 217-221.
- [60] Yoon J, Jarrett D, Van der Schaar M. Time-series generative adversarial networks[J]. Advances in neural information processing systems, 2019, 32.
- [61] Khodarahmi M, Maihami V. A review on Kalman filter models[J]. Archives of Computational Methods in Engineering, 2023, 30(1): 727-747.
- [62] Feng S, Li X, Zhang S, et al. A review: State estimation based on hybrid models of Kalman filter and neural network[J]. Systems Science & Control Engineering, 2023, 11(1): 2173682.
- [63] Kurita T. Principal component analysis (PCA)[M]//Computer vision: a reference guide. Cham: Springer International Publishing, 2021: 1013-1016.
- [64] Wattenberg M, Viégas F, Johnson I. How to use t-SNE effectively[J]. Distill, 2016, 1(10): e2.

攻读学位期间发表的学术论文与研究成果

一、发表学术论文

- [1] Cheng Z, Bai S. Remaining Useful Life Estimation for Molecular Pumps with Transformer-Based Deep Learning Architecture[C]//2024 5th International Conference on Artificial Intelligence and Computer Engineering (ICAICE). IEEE, 2024: 1158-1165.

致谢

时光荏苒，岁月如梭，转眼间这段学术旅程已接近尾声。回首过往，心中满是感激与温暖。那些曾在我迷茫时指引方向、在我疲惫时给予力量的身影，如今依然清晰如昨。在此，我愿以最真挚的文字，向你们表达我深切的谢意。

首先，我要特别感谢我的导师柏老师。您如灯塔般照亮了我的学术之路，您的睿智与严谨让我在知识的海洋中找到了航向。每当我陷入困惑，您的点拨总能让我豁然开朗；每当我心生懈怠，您的鞭策又让我重拾信心。您不仅是我的导师，更是我人生道路上的引路人。这份师生情谊，我将永远珍藏在心。

其次，我要感谢袁老师。您的学识渊博与耐心细致让我受益匪浅。您总是以温和的态度倾听我的问题，并以独到的见解为我指明方向。您的教诲如春风化雨，润物无声，让我在学术的道路上走得更加坚定。

感谢课题组的同门们，你们是我学术路上的同行者。每一次的讨论与争辩，都让我感受到思想碰撞的火花；每一次的互助与合作，都让我体会到团队的力量。你们的陪伴让这段旅程充满了色彩与温度。

感谢我的室友们，你们是我生活中的挚友。在无数个夜晚，我们畅谈理想与未来，分享快乐与忧愁。你们的笑声与关怀，让我在这座城市中找到了家的感觉。

最后，再次特别感谢柏老师。您的教诲如星辰般永恒，您的关怀如春风般温暖。我将带着您的期望与祝福，继续前行，追寻心中的梦想。

感恩相遇，感谢同行。愿岁月静好，愿情谊长存。

尚德敏学 唯实惟新

