

中图分类号: TP399

论文编号: 10357WA21301046

安徽大學

硕士学位论文

减震器的数据扩充和跨传感器故障检测方法研究

作者姓名	朱慧娟
专业学位类别	电子信息
专业学位领域	人工智能
指导教师	赵鹏、赵云波

Research on Data Augmentation and Cross-Sensor Fault Detection Methods for Shock Absorbers

A Dissertation Submitted for the Degree of Master

Candidate: Zhu Huijuan

Supervisor: Associate Prof. Zhao Pen Prof. Zhao Yunbo

中图分类号: TP399

论文编号: 10357WA21301046

硕士学位论文

减震器的数据扩充和跨传感器故障检测方法研究

作者姓名	朱慧娟	申请学位级别	工学硕士
指导教师姓名	赵鹏、赵云波	职 称	副教授、教授
学科专业	电子信息	研究方向	故障检测
学习时间自	2021年 09月 07日	起至	2024年 07月 01日止
论文提交日期	2024年 05月 23日	论文答辩日期	2024年 05月 17日

独创性声明

本人声明所呈交的学位论文是本人在导师指导下进行的研究工作及取得的研究成果。据我所知，除了文中特别加以标注和致谢的地方外，论文中不包含其他人已经发表或撰写过的研究成果，也不包含为获得安徽大学或其他教育机构的学位或证书而使用过的材料。如有学术不端行为，一切后果由本人承担，与导师和安徽大学无关。

学位论文作者签名：朱慧娟

签字日期：2024年5月17日

学位论文版权使用授权书

本学位论文作者完全了解安徽大学有关保留、使用学位论文的规定，有权保留并向国家有关部门或机构送交论文的复印件和磁盘，允许论文被查阅和借阅。本人授权安徽大学可以将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、汇编学位论文。

(保密的学位论文在解密后适用本授权书)

学位论文作者签名：朱慧娟

导师签名：赵明 李波

签字日期：2024年5月17日

签字日期：2024年5月17日

摘要

减震器在表面贴装技术中扮演着至关重要的角色。它通过减少锡膏印刷机的震动来确保锡膏印刷质量，从而间接影响了后续整体流程的顺利进行。虽然在生产线上减震器的故障较少发生，但一旦发生故障，往往很难及时检测和排查出来，将导致整个工厂停工数小时进行检修，给生产带来严重的影响和经济损失。在这个背景下，对减震器进行故障检测成为确保设备在故障发生时能够及时预警的关键步骤。故障检测的重要性体现在以下几个方面：及时识别设备异常运行，使得问题可以尽早得到解决；加速维护和降低停机时间，以最小化生产中断的影响；同时，故障检测也有助于确保生产的安全性。因此，对减震器进行故障检测，可以提高生产线的稳定性和效率，减少停机时间和经济损失，从而对整体生产过程产生重要的影响。

目前，对减震器的故障检测研究存在一些局限性，这些局限性主要包括以下方面：首先，减震器数据的稀缺和不平衡导致故障检测模型的准确率不尽如人意，进而影响了模型在实际应用中的效果。其次，现有的模型未能充分考虑多传感器数据之间的显著差异特点，这些数据通常以堆叠的方式输入网络进行模型训练，这种方法不利于模型捕捉多传感器变量之间的共享特征，也难以减小变量数据特征之间的差距，因此对于提升模型性能存在一定的制约。

为了克服上述问题，本文着重研究了减震器故障检测问题，并在以下几个方面做出了主要贡献：

- 1、针对减震器数据集稀少和类别不平衡的问题，提出了注意力生成对抗网络，生成了高仿真的减震器数据集。该方法主要通过多生成器结构来生成数据，保证了跨传感器各数据特征组内的相关性，并利用注意力机制捕获数据的时序性并修正各特征间的相关性。该方法提出了分组对抗生成的设计，从而生成高度贴合真实样本的生成数据。针对工业场景下有效标注稀缺的问题，该方法可以有效建模数据分布，通过扩充生成大量真实的减震器故障数据，使减震器故障检测模型更好的学习故障数据的特征，从而提高模型的检测性能。

- 2、针对减震器多传感器的特点，提出了一种跨传感器多层级的生成式自监督学习网络用于故障检测。针对具有大量无标注数据的场景，我们设计了多层级自编码器结构来进行表征学习，通过在多个维度中建模传感器信号，以实现特征之间的相关信息挖

掘，从而有效提升特征的表达能力。同时，我们在下游缺陷预测任务中微调任务重引入了显著性模块，使警告特征信息突出，从而提高分类器的准确性。在减震器数据集上进行的实验结果表明，所提出的方法在性能方面显著优于其他先进方法。

本文重点关注了减震器数据集的数据不平衡特性以及多传感器数据的特性，分别提出了注意力生成式对抗网络和跨传感器多层级的自监督学习网络，为以上问题提供了有效的解决方案，提高了故障检测性能，对智能制造的故障检测推进做出了一定贡献。

关键词：数据不平衡；数据扩充；跨传感器特征提取；减震器故障检测

Abstract

Shock absorbers play a crucial role in surface mount technology. They ensure the quality of solder paste printing by reducing vibrations from the solder paste printer, indirectly affecting the smooth progress of subsequent processes. Although failures of shock absorbers are relatively infrequent on the production line, once a failure occurs, it is often difficult to detect and troubleshoot in a timely manner, resulting in the entire factory being shut down for several hours for maintenance, causing significant impact and economic losses to production. In this context, the detection of shock absorber failures becomes a key step in ensuring timely warning of equipment failures. The importance of fault detection is reflected in several aspects: timely identification of equipment abnormalities, enabling early problem resolution; accelerating maintenance and reducing downtime to minimize the impact of production interruptions; and ensuring production safety. Therefore, conducting fault detection on shock absorbers can improve the stability and efficiency of the production line, reduce downtime, and minimize economic losses, thus having a significant impact on the overall production process.

Currently, there are several limitations in the research on fault detection of shock absorbers. These limitations mainly include the following aspects: Firstly, the scarcity and imbalance of shock absorber data lead to relatively unsatisfactory accuracy of fault detection models, which in turn affects the effectiveness of these models in practical applications. Secondly, existing models have not fully taken into account the significant differences between multi-sensor data. These data are indiscriminately inputted into the network for model training, which is not conducive to capturing shared features among multi-sensor variables. It also makes it difficult to reduce the differences between the data features. As a result, there are certain constraints in improving the performance of the models. In conclusion, the current research on fault detection of shock absorbers has limitations in terms of data scarcity and imbalance, as well as the inadequate consideration of significant differences among multi-sensor data. Addressing these limitations will be crucial to enhance the accuracy and effectiveness of fault detection models in practical applications.

In order to overcome the aforementioned issues, this thesis focuses on the fault detection

of shock absorbers and makes the following main contributions:

1. Addressing the problems of scarce and imbalanced shock absorber datasets, an Attention Generative Adversarial Network is proposed to generate highly realistic shock absorber data. This method utilizes a multi-generator structure to generate data, ensuring the correlation within feature groups across sensors. It employs an attention mechanism to capture the temporal characteristics of the data and correct the correlations between different features. It innovatively introduces the design of group-wise adversarial generation, resulting in generated data that closely resembles real samples. By effectively modeling the data distribution, this method addresses the issue of scarce annotated data in industrial scenarios. It generates a large number of realistic fault data, enabling the fault detection model to better learn the characteristics of fault data and improve the detection performance.

2. A cross-sensor, multi-level generative self-supervised learning network is proposed for fault detection in multi-sensor shock absorbers. To address scenarios with a large amount of unlabeled data, a multi-level autoencoder structure is designed for representation learning. By modeling sensor signals across multiple dimensions, the network effectively captures the correlated information between features, thus enhancing feature representation capabilities. Additionally, in the downstream defect prediction task, the network is fine-tuned with the reintroduction of a saliency module to emphasize warning feature information and improve the accuracy of the classifier. Experimental results on the shock absorber dataset demonstrate that the proposed method significantly outperforms other state-of-the-art approaches in terms of performance.

The thesis focuses on the data imbalance characteristics of the shock absorber datasets and the characteristics of multi-sensor data. It proposes an Attention Generative Adversarial Network and a Cross-sensor Multi-level Self-supervised Learning Network to provide effective solutions to the above problems, improving the fault detection performance and contributing to the advancement of fault detection in intelligent manufacturing.

Key words: Data imbalance; Data augmentation; Cross-sensor feature extraction; Damper fault detection.

目 录

第一章 绪论	1
1.1 研究背景和意义	1
1.2 国内外研究现状	2
1.2.1 数据扩充研究现状	2
1.2.2 故障检测研究现状	5
1.3 研究内容	8
1.4 章节安排	9
第二章 相关基础知识	10
2.1 减震器及其数据集介绍	10
2.1.1 减震器介绍	10
2.1.2 减震器数据集介绍	10
2.2 数据预处理方法	11
2.2.1 缺失值处理	11
2.2.2 异常数据检测	12
2.2.3 数据标准化	12
2.3 深度学习	14
2.3.1 神经网络	14
2.3.2 自监督学习	20
2.4 跨模态学习算法	20
2.5 本章小结	21
第三章 基于时序 Attention-GANs 模型的数据扩充方法	22
3.1 特征相关性分析	24
3.2 Attention-GANs 时序数据扩充方法	25
3.3 实验与结果分析	28
3.3.1 实验环境和数据集	28
3.3.2 评估指标	28
3.3.3 实验设计	29

3.3.4 实验结果分析	30
3.3.5 消融实验	33
3.4 本章小结	34
第四章 基于跨传感器多层级的自监督故障检测方法	35
4.1 跨传感器多层级网络	35
4.1.1 预训练任务	36
4.1.2 下游任务	38
4.2 实验与分析	40
4.2.1 数据标准化	40
4.2.2 结果与分析	41
4.2.3 对比实验	41
4.2.4 消融研究	42
4.3 本章小结	43
总结与展望	45
参考文献	47
攻读硕士学位期间取得的学术成果	53
致 谢	54

图目录

图 2.1 xyz 轴数据标准化	11
图 2.2 异常样本示意图	13
图 2.3 简单的神经网络	16
图 2.4 GANs 模型结构	18
图 2.5 GANs 训练过程	18
图 3.1 样本数据 PCA 可视化	23
图 3.2 减震器数据集统计	23
图 3.3 Pearson 相关系数分析	25
图 3.4 Attention-GANs 方法结构	26
图 3.5 数据扩充实验流程	30
图 3.6 Attention-GANs 数据扩充结果	31
图 3.7 特征标准差结果	31
图 3.8 特征均值结果	31
图 3.9 Attention-GANs 数据扩充对比实验结果	33
图 4.1 整体网络框架	36
图 4.2 预训练网络框架	37
图 4.3 显著性模块的示意图	39
图 4.4 预训练后的 PCA 可视化	42
图 4.5 微调后的 PCA 可视化	42

List of Figures

Fig. 2.1	Data normalization along the x, y, and z axes	11
Fig. 2.2	Schematic diagram of anomalous samples	13
Fig. 2.3	Simple neural network	16
Fig. 2.4	GAN model architecture	18
Fig. 2.5	GAN training process	18
Fig. 3.1	PCA visualization of sample data	23
Fig. 3.2	Statistics of the shock absorber dataset	23
Fig. 3.3	Pearson correlation coefficient analysis	25
Fig. 3.4	Structure of the Attention-GANs method	26
Fig. 3.5	Data augmentation experiment process	30
Fig. 3.6	Results of the Attention-GANs data augmentation	31
Fig. 3.7	Results of feature standard deviation	31
Fig. 3.8	Results of feature mean	31
Fig. 3.9	Results of the comparative experiment on Attention-GANs data augmentation ...	33
Fig. 4.1	Overall network architecture	36
Fig. 4.2	Pre-trained network architecture	37
Fig. 4.3	Schematic Diagram of the Significance Module	39
Fig. 4.4	PCA visualization after pre-training	42
Fig. 4.5	PCA visualization after fine-tuning	42

表目录

表 3.1 减震器数据集	28
表 3.2 数据扩充对比实验结果	32
表 3.3 数据扩充消融实验结果	33
表 4.1 实验参数设置	40
表 4.2 SMT-SA 数据集不同样本数量故障检测实验结果	41
表 4.3 故障检测对比实验结果	42
表 4.4 跨传感器故障检测消融实验结果	43

List of Tables

Table 3.1 Shock absorber dataset	28
Table 3.2 Results of the comparative data augmentation experiment	32
Table 3.3 Results of the data augmentation ablation experiment	33
Table 4.1 Experimental parameter settings	40
Table 4.2 Fault detection experiment results on the SMT-SA dataset with different sample sizes	41
Table 4.3 Results of the fault detection comparative experiment	42
Table 4.4 Results of the cross-sensor fault detection ablation experiment	43

第一章 绪论

1.1 研究背景和意义

现代工业中生产场景复杂，生产场景下的设备发生故障或停机都会导致严重的经济损失。设备维护是确保工业制造系统安全、可靠性和可用性的重要环节之一。随着自动化技术的迅速发展和实际生产需求的增加，机械设备的集成和复杂性不断提高，以适应各种复杂和恶劣条件。新兴的预测性维护落实有助于改变传统意义上的预防性维护，并且在成本、交付、品质方面均会有所改善，譬如：延长保养周期（维护人力成本下降）、降低设备停机率、提升整体的产品品质。在工业生产中，减震器作为表面组装技术（Surface Mounted Technology, SMT）中锡膏印刷机的一个关键部件，作用是减少锡膏印刷机因中央平台上下往复运动所产生的震动。因此，减震器设备的运行状态会直接影响到锡膏印刷机将锡膏按照相应的规格涂抹到印刷电路板（Printed Circuit Board, PCB）上的印刷要求，印刷质量将决定后续各个环节能否正常进行。对减震器进行故障检测以及时识别设备异常运行状况方面发挥着至关重要的作用。故障检测出减震器异常状态能够及时有效地进行必要的机械维护以排除故障，加速非计划外的维护，降低设备的停机时间，并最小化性能降低，从而有效地预防严重的安全事故^[1]。减震器的动态运行数据由传感器进行记录保存，并通过监测传感器数据，可以检测到设备的运行状态和潜在故障，从而实现故障检测，进而对减震器进行维护降低锡膏印刷精度受震动所产生的不良影响而导致后续环节的正常进行。因此，实现对减震器的故障检测在整体生产过程起着积极意义和重要影响。通过对减震器进行故障检测以实现早期故障预警，以便及时察觉和预警减震器设备状态的早期微小异常，及时开展维护，这对于确保整体生产安全和质量至关重要^[2-4]。

传统的故障检测方法侧重于构建分析模型，使用系统或物理模型或者逻辑规则进行预测。但 SMT 工业生产环境下存在较多噪声，减震器传感器所采集到的数据因此也包含较多噪声，传统的故障检测方式在区分噪音和异常点时难度很大。并且 SMT 生产工艺复杂，减震器的设备复杂性较高很难使用传统方法对问题建模。通常这些方法还依赖于专家的工程经验，模型较为复杂且拓展性较差。近些年深度学习方法被广泛的应用于预测性维护领域并且得到迅速发展，因为深度学习方法只需要依赖于生产过程中的

设备运行状态数据就能实现优秀的故障检测性能，克服传统方法的局限性。因此，研究有效的深度学习故障检测方法已成为非常热门的研究课题，并且随着安装在工业系统中的传感器越来越多，深度学习的优势变得更加突出。基于深度学习的故障检测能够及时地检测出设备的异常运行状态，以便执行必要的机器维护以排除故障，加快计划外维护的进度并缩短设备停机时间，最大限度保证生产安全和降低产能下降。

1.2 国内外研究现状

根据本文中涉及到的数据扩充方法和缺陷检测方法技术，充分调研了海内外的研究进展。数据扩充方法包括传统的时序扩充方法和基于深度学习时序扩充方法，缺陷检测技术也同时包括了传统缺陷检测办法和基于深度学习的故障检测方法。

1.2.1 数据扩充研究现状

本文针对减震器数据集不均衡的特点提出了数据扩充的方法。而数据不平衡问题在深度学习中是一个普遍存在的问题，表现为各个类别的样本数量差异较大。在分类任务中，通常来说，那些少数类别的样本更为有价值。数据集不平衡可能导致模型在学习特征时过度关注大类别样本的数据特征，由于小类别样本数量有限，其特征可能被忽略，导致训练出的模型在大类别样本上表现较好，而在小类别样本上表现较差。因此，在实际应用中，如何在不平衡的数据集中进行合理的分类成为一个重要的挑战。减震器的故障检测属于二分类任务，其数据类别可分为故障和正常两类。我国制造行业蓬勃发展，减震器技术逐渐趋于成熟，然而，由于减震器大多数时间都处于正常运行状态，仅在极少时间内发生故障并导致设备停机，这使得传感器采集到的减震器故障和正常运行数据极为不均衡。在减震器技术的应用中，面对不平衡的数据集，有效地进行减震器故障检测成为一项严峻挑战。解决这一问题的关键在于采取有效的策略来平衡不同类别的样本影响。数据扩充是一种常用的方法，通过对小类别样本进行变换和生成，提高其数量，以达到与大类别相当的水平。同时，采用权重调整训练样本的重要性，使得模型更加关注小类别样本，从而提升其在小类别上的性能。另外，集成学习方法、改进的损失函数设计以及采用迁移学习等技术也被广泛应用于解决不平衡数据问题。为了解决数据集不平衡的挑战，常常采用欠采样和过采样技术。欠采样通过删除多数类样本，以减少其数量；而过采样则通过合成少数类样本，以增加其数量，从而实现数据集各类别样

本数量的平衡。对于时序数据扩充方法，将通过传统时序扩充方法（如时域、频域）和深度学习方法的角度解释当前的时序数据扩充方法，以提供更清晰的总结。

A. 传统时序扩充方法

(1) 时域：对时间序列数据的数据增强中，时域变换是一种直接且有效的方法。其中，主要通过对原始输入时间序列进行操作来实现，例如时间窗口截取、窗口扭曲、翻转和噪声注入等。这些操作能够直接改变时间序列的特征，从而提升数据的多样性和丰富性。时序数据的处理方法通常是采用时间窗口截取或切片的方法^[5]，窗口截取（Window cropping）最早是由 Cui 等人^[6]在计算机视觉领域中提出了一种名为“图片裁剪”的方法。该方法是一种子采样技术，用于从原始时间序列中提取连续的切片，而切片的长度可以进行调节。在分类问题中，这些切片样本的标签与原始时间序列的标签相同。该方法的引入为数据扩充提供了一种有效的数据处理策略。窗口扭曲（Window warping）是一种常用的时序数据增强方法，其基本原理是在原始时间序列中选择一个随机的时间范围，然后对该范围内的数据进行下采样或上采样，同时保持其他时间范围不变。通过这种方式，窗口扭曲在保持时间序列的整体结构的同时，引入了一定的变化和扰动。由于窗口扭曲会改变原始时间序列的总长度，因此在深度学习模型中，通常与窗口截取方法结合使用，以确保输入数据的固定长度。通过组合窗口扭曲和窗口截取，可以增加数据的多样性，提高模型的鲁棒性和泛化能力。此方法还包括普通的全局下采样，通过整个原始时间序列的长度进行下采样。翻转是另一种生成新序列 x'_1, \dots, x'_N 的方法，通过改变原始时间序列 x_1, \dots, x_N 中的符号，即 $x'_t = -x_t$ 。对于异常检测和分类任务，假设在上下方向之间存在对称性，标签仍然保持不变。Fawaz 等人^[7]提出了一种集成动态时间规整和质心均值算法的方法，该方法通过利用动态时间规整（Dynamic Time Warping, DTW）从而生成新的时间序列，然后通过质心均值算法（Barycentric Averaging, DBA）算法的加权版本进行集成，该方法在时序分类任务中表现出良好的性能。最后，还有一种直接的方法通过噪声注入，既通过向时间序列中注入少量噪声或异常值，而不改变相应的标签，该方式能有效的扩展时序数据，并增强模型的稳定性。

(2) 频域：目前大多数现有的数据扩充方法侧重于时域，但也有少数研究从频域的角度探讨时间序列的数据扩充。Gao 等人^[8]该研究提出了一种数据扩充方法，用于时间序列异常检测，并应用于卷积神经网络中，通过对振幅谱和相位谱进行调整和扰动，可以引入不同的频域变化，从而增加时间序列数据的变异性具体而言，对于输入时间序

列 x_1, \dots, x_N ，通过傅里叶变换计算其频谱，对于振幅谱的扰动，该方法对于振幅谱的扰动，随机选择的片段的振幅值会被高斯噪声替代，而这个高斯噪声的均值和方差会考虑原始数据的统计特性。此外，对于相位谱的扰动，会随机选择片段的相位值，并在相位谱上添加零均值高斯噪声。这样的叠加操作能够引入随机性，进一步增加时间序列数据的变异性。振幅和相位的扰动数据扩充与前述时域扩充方法结合，取得显著效果。

时间频率分析也是一种广泛应用的时间序列分析技术，可作为神经网络中的合适输入特征。Steven Eyobu 等人^[9]在人体活动分类任务中，采用了短时傅里叶变换来生成传感器时间序列的时频特征，并通过深度 LSTM 神经网络对这些时频特征进行数据增强。研究中提出了两种增强技术。首先，一种是基于预定义标准的局部平均方法，通过计算特征的局部均值，并将生成的特征追加到特征集的尾部。其次，另一种增强技术是对特征向量进行洗牌操作，即随机调整特征向量的顺序。通过这两种增强技术，可以引入更多的变异性 and 多样性，增强特征的表达能力，以在数据中创建变化。在语音时间序列中，Park 等人^[10]利用梅尔频率进行数据增强，其中增强方案包括扭曲特征、遮挡频率通道块和遮挡时间步骤块。他们的方法可以极大地提高语音识别神经网络的性能。

时域数据扩充方法简单而直观，适用于强调时序关系的问题；频域方法能够捕捉振荡和周期性模式，但计算成本较高，不适用于所有时间序列；时频域方法结合时域和频域的优势，全面捕捉时间序列特征，适用于需要同时考虑时序和频率信息的任务。但是传统直接的时序数据扩充方法，对于一些稀少数据的任务，无法提供足够有效的数据，强行扩充可能会导致故障模型稳定性降低，时频域的方法

B. 时序深度学习扩充方法

近年来，深度学习模型在生成方面有了很大突破，能够生成逼真的高维数据对象，如图像和序列。为生成数据开发的生成模型（例如音频和文本）通常可以扩展到时序数据领域^[11-13]。生成对抗网络（Generative Adversarial Networks, GANs）是应用非常广泛的生成模型之一，通常通过生成样本达到扩充训练集的目的。目前，GANs 被广泛应用于在众多领域，但只有较少的研究将 GANs 用于时间序列数据增强当中。

Esteban 等人^[14]提出了递归生成对抗网络（RGAN）和递归条件生成对抗网络（RCGAN），用于生成逼真的多维实值时间序列数据。RGAN 采用 RNN 作为生成器和判别器，而 RCGAN 则使用两个受辅助信息条件限制的 RNN。这两种模型在时间序列数据增强方面展现出了出色的性能。Yoon 等人^[15]提出了一个可用于各个领域生成逼真时间

序列数据的生成式时间序列模型 (TimeGAN)，通过一个学到的嵌入空间并通过对抗训练和联合训练，同时使用监督和非监督损失，通过引入逐步监督损失学习数据的逐步条件分布，还引入了嵌入网络用于反映特征和潜在表示之间的可逆映射，从而减少对抗学习空间的高维度。

然而，减震器数据具有较高噪声水平、复杂的分析要求，并面临数据不平衡的问题。目前，针对这一设备时序数据的研究尚不充分，已有的方法也难以适应当前设备的实际状况。为了解决减震器数据不平衡的特性，本文充分利用深度学习领域的理论知识，深入研究减震器数据的规律，以有效扩充减震器数据集。

1.2.2 故障检测研究现状

基于减震器运行状态数据的故障检测技术主要通过构建相应的故障检测模型，分析传感器收集到的数据变化趋势而实现。故障检测被视为故障诊断的初步阶段。目前，故障检测的工作主要可划分为两大类：一是基于信号分析，另一是基于机器学习。基于信号分析的方法依赖于时域、频域和时频域的信号处理技术^[16]，通过对信号的波形、频谱等特性的深入研究来识别潜在故障迹象，为故障诊断提供了直观而详尽的信息。而基于机器学习的方法则通过对大量数据的学习和模式识别，能够自动发现和利用特征，适应不同工况下的故障模式，为滚动轴承的故障检测提供了一种更加智能和灵活的解决方案。接下来详细介绍一下两种类型的方法：

A. 传统故障检测方法

在设备故障检测领域，基于振动数据分析的传统方法被广泛应用^[17-22]。Wang 等人^[17]提出的方法主要用于非稳态工业过程中的故障检测，利用递归策略抑制非平稳趋势并揭示故障信息，通过采用递归更新模型和综合多个变量信息的方式，提高了模型对动态变化的适应能力和故障检测的准确性。然而，该方法复杂性较高，涉及到复杂的数学模型和算法，并对数据质量具有一定敏感性，需要在实际应用中有一限制。Zhang 等人^[18]利用蒙特卡洛模拟 (Monte Carlo simulation) 的方法，系统评估了传感器精度在数据驱动建筑故障检测与诊断模型性能中的影响。通过引入不同水平的传感器精度，研究者模拟了多次实验，量化地探讨了传感器精度变化对模型性能的影响。尽管实验具有一定的简化和局限性，但这种定量评估为理解传感器精度在实际应用中的作用提供了有益的信息。但同时由于简化的操作，导致该方法的使用有点一定限制。Hu 等人^[19]引入

自适应谱峭度计算，提高了对不同工况振动信号的适应性，并通过频域分析更好地捕捉了信号的特征，该文章强调了其方法的自适应性和适用的广泛性，但是在其他领域的情况并未给出详细说明。Huo 等人^[20]在机械故障诊断中利用了熵测量的方法，熵作为信息度量的基本原理，在振动、声音等多个领域展示了其应用价值，熵也被应用于特征提取，以优化构建故障监测模型。但是，熵对于信号中的噪声比较敏感，需要额外的处理措施以提高在嘈杂环境中的准确性。Wang 等人^[21]提出了一种双增强稀疏分解方法，通过稀疏分解技术高效地提取与故障相关的特征，同时引入自适应阈值处理和多层次信息增强的双增强策略，以提升信号分解结果的性能。该方法涉及复杂的数学模型和算法，需要特定的专业知识，并且在不同情况下的，参数调整是一大难题，并且在实际应用中，需权衡其高效的特征提取和复杂性。

传统方法在故障检测领域通常具有较强的可解释性，然而，这些方法也伴随着一系列明显的局限性，使得它们在处理复杂的实际工程问题时显得相对不足。

1、传统方法在很大程度上依赖于提取和选择的特征质量。在实际工程中，由于受到多种干扰和环境变化的影响，采集到的信号数据往往具有复杂性和不稳定性。这种复杂性表现为数据中存在大量噪声，因此需要进行降噪处理。然而，传统降噪方法往往在消除噪声的同时减弱了携带早期故障信息的信号，从而降低了故障检测的准确性和可靠性。

2、其次，传统方法中的数据特征提取和选择常常依赖于领域专家的工程经验。这种依赖性不仅增加了人力成本，而且限制了方法的通用性和可扩展性。由于专家经验的主观性和局限性，这些方法在面对新型故障或者不同类型的机器设备时可能表现出较差的适应性^[23, 24]。

因此，传统方法在处理大规模、多样化的故障数据时，往往无法充分挖掘数据中的潜在信息，导致诊断效果的局限。为解决这些问题，近年来深度学习等数据驱动方法逐渐受到关注。这些方法自动的从原始数据中学习特征表示，无需繁琐地手动提取数据特征，从而提高了对复杂数据的表征能力。相较于传统方法，数据驱动方法更具通用性和可适应性，使得故障检测系统能够更好地适应不同环境和故障模式，同时减少对领域专家经验的依赖。

B. 基于深度学习的故障检测方法

对比于传统方法，基于深度学习方法的故障检测不采用精确的物理或者数学模型，

而是通过大量数据训练模型提取数据特征再进行分类学习,从而实现监控设备的传感器变量,进一步推断设备状态。并且,基于数据驱动的深度学习模型不需要专家的工程经验,但能适应复杂设备的故障检测^[25-27]。因此,深度学习比传统方法在设备故障检测领域更受欢迎。至今,深度学习包括 Deep Belief Network (DBN), Stacked Auto-Encoder (SAE), Convolutional Neural Network (CNN), Long Short-Term Memory (LSTM)^[28-32] 等方法已被广泛地应用于设备状态检测和故障诊断,取得了优异的性能^[33-35]。Hao 等人^[22]在旋转机械大数据中的故障特征挖掘和智能诊断中探索了深度神经网络的潜在应用,深度神经网络通过学习复杂数据特征的能力,提高了故障检测的准确性。Zhao 等人^[36]提出了一种采用了深度残差网络结构和自适应参数的修正线性单元的故障检测方法。通过引入深度残差网络,该方法能够有效解决深层网络中的梯度消失问题,提高网络学习能力,并且 APReLU 激活函数通过自适应调整参数,增强网络的非线性建模能力,使得该方法在故障检测任务中具备较好的性能,能够自动化地识别复杂数据中的故障。Liang 等人^[37]提出了一种利用稀疏自编码器进行泵故障检测和隔离的无监督方案。采用无监督学习的方法,模型通过学习正常运行状态下的特征表示,实现了对泵系统异常的检测和隔离。稀疏自编码器的应用使得模型能够有效地捕捉数据中的关键特征,提高了泵故障检测的准确性。Zhang 等人^[38]介绍了一种端到端无监督学习的故障检测方法,通过无监督学习,模型能够从无标签数据中学习有用的特征表示用于故障检测任务。该方法简化了模型设计、能够适应时序信息并提高学习的能力,有助于提高整体性能。然而,该方法对超参数敏感,需要仔细调优以达到最佳性能;而且由于采用端到端学习和复杂模型,可能需要较大的计算资源,这在一些资源受限的环境中限制了方法的应用。此外,其他基于 DNN 或 AE 模型方法^[39, 40]在故障检测上也取得了良好的性能。然而,虽然上述方法在故障检测领域提供了很好的应用模型,但存在以下缺点:(1) 基于有监督的方法通常每一个类别的标签都需要人工标记,需要的人工成本是昂贵的。(2) 现有的深度学习方法摒弃了传统方法依赖于专家工程经验的特点,不考虑多传感器数据之间存在明显的区别特点,将多传感器数据无区别式送进网络进行模型训练,这种做法不利于模型捕获多传感器变量之间的共享特征、减小变量数据特征之间的差距,从而对提升模型性能有一定的限制。

此外,以深度神经网络(DNN)或自动编码器(AE)为基础的其他故障检测方法^[39, 40]在故障检测方面也取得了显著的成果。尽管上述方法在故障检测领域展现出了

良好的应用前景，却存在一些明显的缺陷：

1、基于有监督学习的方法通常要求每一类别的标签都进行人工标记，这涉及到昂贵的人工成本。

2、目前，时序异常监测中多变量之间的相关性已有广泛的研究，多传感器信号之间的相关性对时序异常检测的重要性已经得到广泛的验证^[41-43]。但在故障检测中，针对这个问题的现有工作大多还是采用堆叠信号的方式处理传感器数据^[22, 36-38]，堆叠的方式难以挖掘传感器信号之间的相关性，这种方法限制了模型性能的提升。

因此，为了克服这些限制，需要更深入地考虑多传感器数据之间的差异性，以及如何更有效地融合专家经验和深度学习方法，从而全面提升故障检测模型的性能。

1.3 研究内容

本文针对减震器目前国内外研究现状局限性进行解决，提出了面向减震器数据扩充和跨传感器的故障检测的研究方法：

1、针对减震器数据集稀缺和类别不平衡的难题，本文提出了一种注意力生成对抗网络（Attention Generative Adversarial Networks, Attention-GANs），用以应对这一挑战。通过该方法，在生成样本数据时全面考虑了传感器间数据特征的相关性和时序特性。Attention-GANs 采用了多生成器结构，确保了在生成数据时跨传感器各数据特征组内的相关性。此外，通过引入 Attention 机制，成功捕获了数据的时序性，从而更准确地修正了各特征间的相关性。实验证明，Attention-GANs 方法能够有效生成更真实的减震器故障数据，为模型更好地学习故障数据的特征分布提供了有效手段，进而提升了整体检测性能。

2、为解决现有故障检测模型在特征间学习能力较弱的问题，本文引入了一种专为多传感器故障检测设计的跨传感器多层级的生成式自监督学习网络。该网络在多个维度中建模传感器信号，并且添加了多层级的维度限制，实现了特征之间的相关信息挖掘，有力地捕获了多传感器数据之间的共享特征，并成功减小了通道数据特征之间的差距。通过在下游任务中进行微调，并引入显著性模块对少量标记数据进行优化，使警告特征信息更加突出，最终提高了分类器的准确性。实验证明，所提出的方法在性能上明显优于其他先进方法，为提高减震器故障检测的效果和应用推广提供了创新思路。

1.4 章节安排

本篇文章主要分为五个章节，各章内容如下：

第1章：绪论。首先介绍减震器故障检测技术研究的背景和意义。然后对国内外在数据扩充和故障检测方面的研究现状进行综述，并对本文的研究难点和主要内容进行概括总结。

第2章：相关基础知识。本章首先对减震器数据采集及解析流程进行了概述，然后介绍了减震器故障检测领域相关的理论知识，包括数据预处理技术、深度学习、跨模态学习、时序故障检测模型等。

第3章：基于 Attention-GANs 模型的时序数据扩充方法研究。本章提出了一种处理减震器不平衡数据集的新方法。首先，详细阐述了减震器数据集存在的不平衡问题，接着对减震器特征的重要性和相关性进行了深入分析。根据分析结果，构建了 Attention-GANs 模型，并通过与其他数据不平衡处理方法进行对比来验证 Attention-GANs 方法的有效性。

第4章：基于跨传感器多层级的生成式故障检测方法研究。本章提出了一种跨传感器多层级的生成式故障检测模型。首先，针对减震器数据集中存在的问题，利用第三章获得高质量的减震器数据集，并通过跨传感器和多层级方法构建了预训练模块，并在微调阶段设计了显著性模块。最后，通过消融实验和对比实验对所提出方法的有效性进行验证。

第5章：总结与展望：在本章中，对论文的关键技术要点、研究内容以及所做的贡献进行了综合总结，并对未来的研究工作进行了明确阐述。

第二章 相关基础知识

2.1 减震器及其数据集介绍

2.1.1 减震器介绍

液压减震器是利用液体的压缩和流动来减缓机械振动和冲击的装置。在多种场景中发挥着重要作用，主要是通过调节液体的流动和压力来实现减震效果。在实际应用中，液压减震器能够有效控制机械系统中的振动。当机械系统受到外部振动或激励时，液体在减震器内流动，通过阻尼效应减缓振动的传播。当系统遭受冲击或撞击时，液压减震器能够通过流动和压缩液体来吸收和分散冲击力，防止冲击传递到整个系统。并且在一些机械系统中，液压减震器可以用作负载支撑装置。它们可以在负载变化时通过液体的调节来保持系统的平衡和稳定性。液压减震器通过调整液体的流动速度和压力，可以用于实现对机械系统运动的精确控制，尤其在需要缓慢运动或精确位置控制的应用中。液压减震器在防止系统共振方面发挥了重要作用，通过调节阻尼效应，使外部激励的频率与系统的固有频率不匹配，从而有效避免振动幅度的急剧增加。液压减震器在工业生产过程中有助于控制物体精准落位，同时在汽车、飞机、船舶和其他交通工具中，液压减震器用于提高乘坐的舒适性，减少车辆或飞机在行驶过程中对乘客的颠簸感，有着广泛的用途。

设备故障检测和寿命预测等技术的广泛应用在智能制造领域为生产奠定了坚实的基础。生产系统能够实现实时的故障监测，提前预测设备寿命，从而有效降低生产中断风险，这为智能化管控提供了有力支持，使企业能够更加智能、高效地管理生产流程，提升生产效益和质量。同时，传感器技术和深度学习的快速发展为减震器数据的实时传输、高并发解析和海量存储提供了有力支持。通过记录大量的减震器运行数据，结合机器学习和深度学习算法进行分析，实现对减震器性能、潜在故障以及寿命的预测，这对SMT生产过程和智能化建设有重要影响。

2.1.2 减震器数据集介绍

SMT 减震器数据集（SMT-SA 数据集）是私有数据集。为了对数据进行清晰解释，如图2.1所示进行了可视化显示。该数据集来自一家公司在表面贴装技术（SMT）的生




图 2.1 xyz 轴数据标准化

Fig. 2.1 Data normalization along the x, y, and z axes

成过程中收集的减震器的传感器数据。液压减震器用于缓解焊膏印刷机的设备振动问题，作为焊膏印刷机的关键支持部件之一，直接影响 SMT 的稳定性。液压减震器通常很少出现故障，但一旦出现故障，维护成本可能很高。因此，对液压减震器设备状况的异常检测在 SMT 的正常运行中起着重要作用，它有助于及时修复故障，避免重大事故，并保持经济效益。SMT-SA 采用的是 BMA250E 三轴加速度计模块，分别收集 x、y 和 z 方向的振动数据 (S_x , S_y , S_z)。在该研究中，使用了 20 毫秒的采样周期和 50 赫兹的采样频率。

2.2 数据预处理方法

由于工业生产和传感器等特性，采集到的减震器数据在一定程度上可能包含脏数据。对脏数据进行处理有助于提高模型效果，因此对脏数据进行处理是十分必要的。通常，对脏数据的处理涉及数据预处理，在构建减震器故障检测模型之前需要对减震器数据集进行数据预处理。数据预处理方法按顺序处理过程主要包括缺失值处理、异常数据处理和数据标准化。

2.2.1 缺失值处理

数据缺失指的是在数据集的某列特征或某行记录中存在缺失值或空值的情况。在进行深度学习模型构建之前，对数据集进行预处理是必要的步骤。缺失值处理则是其中的一个关键步骤。以下是一些常用的缺失值处理方法：1. 删除缺失值：最简单的方法是直接删除其中包含缺失值的特征或样本，这可能会致使信息丢失，特别是当缺失值占比较大时。2. 中位数或均值填充：通过使用整个特征的中位数或均值来填充缺失部分。这种方法适用于特征的分布较为对称的情况。3. 前向填充或后向填充：使用缺失值前一个或后一个时间点的观测值来填充。特别适用于时间序列数据。4. 插值方法：插值方包

括线性插值、样条插值或多项式插值等，从已知的观测值中推断缺失值。5. 基于模型的填充：使用机器学习模型（如 K 近邻算法或回归模型）来预测缺失值。这样的方法可以更好地利用其他特征的信息。6. 使用特殊值填充：将缺失值用特殊值（如 0 或 -1）进行填充，以表示缺失的信息。

2.2.2 异常数据检测

异常数据处理旨在辨识和处置数据集中的异常样本或异常值。这些异常样本或异常值可能来源于测量误差、设备故障、录入错误等诸多因素，会对模型的训练和性能构成不良影响，如图2.2所示。在深度学习领域，异常样本或异常值可能导致模型训练过程的不稳定性，进而影响模型的泛化能力，甚至使模型对异常值过于敏感。异常数据处理方法：1. 删除异常值：最简单的方法是直接删除包含异常值的样本，或者删除整个特征中的异常值。这种方法适用于异常值数量较少的情况，而且删除不会造成信息丢失。2. 替换异常值：将异常值替换为特定的数值，例如使用数据特征的中位数、平均值或其他统计值进行替换。这有助于消除异常值对模型的不良影响。3. 标记异常值：将异常值标记为特殊的数值或通过添加额外的二进制标志变量来表示异常值的存在。这样，在模型训练过程中，可以采取不同的策略来处理这些标记的异常值。4. 统计方法检测异常值：统计方法通常包括箱线图、Z 分数等，来识别超过阈值的异常值。Z 分数可以帮助确定数据点与平均值的偏离程度，而箱线图可以显示数据分布的离散程度。5. 基于模型的方法：利用模型来检测异常值，例如使用聚类、回归或其他机器学习方法。模型可以学习正常数据的特点，从而识别与这些模式不符的数据点。

2.2.3 数据标准化

数据标准化是深度学习预处理中的一项重要步骤，其主要目的是确保使不同特征的数据具有相似的尺度，以帮忙模型能够更好地收敛并提高训练效果。标准化通常指的是将数据按照一定的方式进行缩放，使其具有零均值和单位方差。数据标准化可以加速模型收敛，在梯度下降等优化算法中，不同特征的尺度差异可能导致收敛速度较慢。通过将数据标准化到相似的尺度，可以使优化算法更快地收敛到最优解；还可以避免权重不平衡，未经标准化的特征可能导致模型对某些特征的权重过大或过小，使得模型更加依赖某些特征而忽略其他特征。通过数据标准化，可以避免这种权重不平衡，确保每个特征对模型的贡献相对均衡。数据标准化可以有效提高模型性能，有助于确保不同特征




图 2.2 异常样本示意图

Fig. 2.2 Schematic diagram of anomalous samples

对模型的影响更加均衡。增强模型对输入数据的泛化能力具有至关重要的意义，以确保其在未来的、未曾接触过的数据上能够展现出优秀的性能。这一目标的实现对于保障模型的可靠性和适应性至关重要。在有些在异常值处理中遗漏的未被处理的异常值，数据标准化可降低异常值对模型的影响，使数据更加鲁棒，减少异常值对模型的影响，如 Robust 标准化，可降低异常值对模型的影响，提高模型的鲁棒性、稳定性。在模型解释部分，数据标准化可以使模型权重更易于解释。当特征处于相似的尺度时，模型的权重更容易比较，有助于理解模型是如何基于输入特征做出预测的。数据标准化的常用方法有以下几种方式：

1. Z-score 标准化 (Standardization):

$$z = \frac{x - \mu}{\sigma} \quad (2.1)$$

其中 x 表示原始数据， μ 表示数据的均值， σ 表示数据的标准差。Z-score 标准化适用于大多数情况，尤其是数据近似正态分布时效果好。对于线性模型、支持向量机等对数据分布敏感的模型表现效果较好。

2. Min-Max 标准化:

$$x_{\text{norm}} = \frac{x - \min(X)}{\max(X) - \min(X)} \quad (2.2)$$

Min-Max 标准化方法通常适用于具备明确边界的数据情境，其能够将数据映射到 $[0, 1]$

的范围之内。该标准化方法在处理数据时，通过对最小值和最大值之间的线性映射，使得数据的取值范围被归一化到 $[0, 1]$ 的区间内。这种归一化操作有助于消除数据之间的尺度差异，使得不同特征的数值可以直接进行比较和分析。

3. Robust 标准化：

$$x_{\text{norm}} = \frac{x - Q1}{Q3 - Q1} \quad (2.3)$$

其中， x 表示原始数据， $Q1$ 表示数据的第一四分位数， $Q3$ 表示数据的第三四分位数。存在大量异常值时，该方法使用的是四分位数而不是均值和标准差，因此对异常值更具鲁棒性。这使得它在处理存在离群值的数据集时更为可靠，不受异常值的影响。Robust 标准化被更广泛应用于那些对于异常值敏感的模型，例如对异常值较为敏感的回归模型。

2.3 深度学习

深度学习是机器学习领域的一个分支，其通过模拟人类大脑的神经网络结构，实现对数据的理解、学习和模仿。它的核心思想是通过多层神经网络来学习和表示数据的复杂特征，从而能够进行识别和决策。深度学习模型通常包含多层神经网络，这些层次允许模型学习从简单到复杂的特征表示。深度学习模型通过反向传播算法来调整神经网络中的权重，以最小化预测输出与实际标签之间的误差。深度学习在多个领域取得了引人注目的突破，包括但不限于计算机视觉、语音识别和自然语言处理。这一方法已成功应用于诸如图像分类、物体检测、机器翻译等任务，并在这些领域中展现出超越传统方法的卓越性能。

2.3.1 神经网络

神经网络是一种受到人脑结构启发的机器学习模型，它被设计用于模拟和执行各种任务。神经网络通过学习输入数据的模式和特征，可以进行分类、回归、聚类等多种任务。神经网络的基本结构由神经元 (Neuron)、层 (Layer)、权重 (Weight) 和激活函数 (Activation Function) 组成。神经元的神经元通过权重来调整输入信号的重要性，权重决定了每个输入对神经元输出的贡献程度。激活函数则引入非线性变换，使得神经网络能够学习和表示复杂的非线性关系。常见的激活函数包括 Sigmoid、ReLU、Tanh 等。神经网络模仿人脑中的神经元，每个神经元接收输入、应用权重并执行激活函数，

以产生输出。在学习过程中，权重会被不断调整以优化模型。最后由激活函数决定神经元的输出。常见的激活函数包括 *Sigmoid*、*tanh*、ReLU (Rectified Linear Unit)、等。

1、Sigmoid 激活函数：

$$\text{Sigmoid}(x) = \frac{1}{1 + e^{-x}} \quad (2.4)$$

其中， e 表示自然对数的底数（欧拉数）， x 表示输入。*Sigmoid* 函数输出范围在 (0, 1) 之间，实现将任意实数映射到该范围。该函数在整个实数轴上可导且平滑，这样有助于在反向传播算法中计算梯度。*Sigmoid* 函数通常被用于二元分类问题，因为 *Sigmoid* 的输出可以被解释为事件发生的概率。例如，当输出大于 0.5 时，可以将样本分类为正类，否则分类为负类。在深度学习的神经网络中，使用 *Sigmoid* 函数可能会造成梯度消失，使反向传播时梯度过小，难以更新权重。

2、tanh 激活函数：

$$\text{tanh}(x) = \frac{e^{2x} - 1}{e^{2x} + 1} \quad (2.5)$$

其中， e 是自然对数的底数（欧拉数）， x 是输入。*tanh* 函数是另一种常用的激活函数，其的输出范围在 (-1, 1) 之间，实现将任意实数映射此范围内。相比于 *Sigmoid* 函数，*tanh* 函数具有更广的输出范围。并且 *tanh* 函数具有零中心化的性质，即其均值接近零。这有助于加速模型的训练，因为正负样本的信息可以在训练中更好地传播。*tanh* 函数曾经广泛应用于神经网络，尤其是循环神经网络 (RNN) 等架构中。然而，由于梯度消失问题等问题，ReLU 及其变种更为常见。

3、ReLU 激活函数：

$$\text{ReLU}(x) = \max(0, x) \quad (2.6)$$

对于输入 x ，如果 x 大于零，输出就是 x ；如果 x 小于或等于零，输出就是零。ReLU 函数在正数范围内保持线性增长，并将负数值截断为零，即负数输入时输出为零。这种简单的非线性变换使得 ReLU 函数具有许多优点。首先，ReLU 函数的计算非常高效，因为它只涉及简单的比较和截断操作。相比于传统的 *Sigmoid* 和 *tanh* 函数，ReLU 函数的计算速度更快，尤其在大规模深度神经网络中具有明显的优势。其次，ReLU 函数避免了梯度消失的问题。在正数区域，ReLU 函数的导数始终为 1，因此在反向传播过程中梯度不会衰减。这有助于有效地传播梯度并更新权重，使得网络更容易收敛和学习复




图 2.3 简单的神经网络
Fig. 2.3 Simple neural network

杂的特征。此外，ReLU 函数的零输出对于稀疏性和稀疏表示具有正面影响。由于 ReLU 函数将负数值截断为零，它可以促使神经元激活的稀疏性增加。这意味着在给定输入中，只有少数神经元会被激活，从而减少了参数的冗余性，提高了网络的泛化能力。然而，ReLU 函数也存在一些缺点。一是它在负数区域上完全不激活，这可能导致神经元的“死亡”，即负数输入时无法更新梯度和权重。为了解决这个问题，研究者们提出了一些变体，如 Leaky ReLU 和 Parametric ReLU，它们在负数区域引入一定的斜率，以保证梯度的流动。

简单介绍一下神经网络，如图2.3所示：

神经网络的结构通常可以表示为一系列层次，其中每一层包含多个神经元。对于一个有 L 层的神经网络可以用以下符号表示：

输入层： $X = [x_1, x_2, \dots, x_m]$ ，其中 m 是输入特征的数量。

隐藏层： $H^{(l)} = [h_1^{(l)}, h_2^{(l)}, \dots, h_{n_l}^{(l)}]$ ，其中 l 表示隐藏层索引， n_l 表示该层神经元数量。

输出层： $O = [o_1, o_2, \dots, o_k]$ ，其中 k 是输出的数量。

可以使用权重矩阵 W 和偏置向量 b 来描述神经网络的变换过程。假设第 l 层到第 $l+1$ 层的变换表示为：

$$Z^{(l+1)} = W^{(l+1)} \cdot H^{(l)} + b^{(l+1)} \quad (2.7)$$

其中， $Z^{(l+1)}$ 表示第 $l+1$ 层的输入， $W^{(l+1)}$ 表示权重矩阵， $b^{(l+1)}$ 表示偏置向量。

对于激活函数，可以使用 $\sigma(\cdot)$ 表示，例如，对于隐藏层的激活：

$$H^{(l+1)} = \sigma(Z^{(l+1)}) \quad (2.8)$$

如果使用的是 *Sigmoid* 激活函数，神经网络的整体结构可以由下列公式描述：

$$\begin{aligned} H^{(1)} &= \sigma(W^{(1)} \cdot X + b^{(1)}) \\ H^{(2)} &= \sigma(W^{(2)} \cdot H^{(1)} + b^{(2)}) \\ &\vdots \\ O &= \sigma(W^{(L)} \cdot H^{(L-1)} + b^{(L)}) \end{aligned} \quad (2.9)$$

这个公式描述了从输入层到输出层的前向传播过程。整个神经网络通过调整偏置向量和权重矩阵学习到从输入到输出的映射关系。在应用中，通常利用反向传播算法优化权重和偏置达到最小化预测误差。这涉及到损失函数的定义以及梯度下降等优化技术。

随着深度学习的迅猛发展，各个领域涌现了多种类型的网络结构，为模式识别、图像处理、自然语言处理等任务带来了显著的进展。其中一些重要的网络结构包括 CNN、VGG、GANs 等。

A. 生成对抗网络

生成对抗网络（Generative Adversarial Networks, GANs）是一种强大的深度学习模型，旨在通过训练生成器（Generator）和判别器（Discriminator）这两个相互竞争的神经网络，学习数据的潜在分布并生成逼真的新样本，如图2.4所示。它由 Ian Goodfellow 等人^[44]于2014年提出，并展示了在图像生成、文本生成、语音合成等任务中的出色性能。生成器网络的目标是学习生成与真实数据相似的样本，而判别器网络的目标是区分生成器生成的样本和真实样本。通过反复的迭代训练，生成器逐渐提高生成样本的质量，而判别器也逐渐变得更加准确。这种相互博弈、相互对抗的训练方式使得 GANs 能够逼近真实数据的分布，从而生成具有高度逼真性的样本。GANs 的核心思想在于最小化生成样本与真实样本之间的分布差异，以使生成器能够逼近真实数据的分布。这种基于对抗性训练的方法使得 GANs 在多个领域展现出出色的性能，如图像生成、文本生成和语音合成等任务。GANs 的优势在于其能够生成与真实数据分布非常相似的高质量样本。此外，GANs 还能够学习到数据的潜在表示，这对于数据压缩、特征提取和数据增强等任务非常有益。

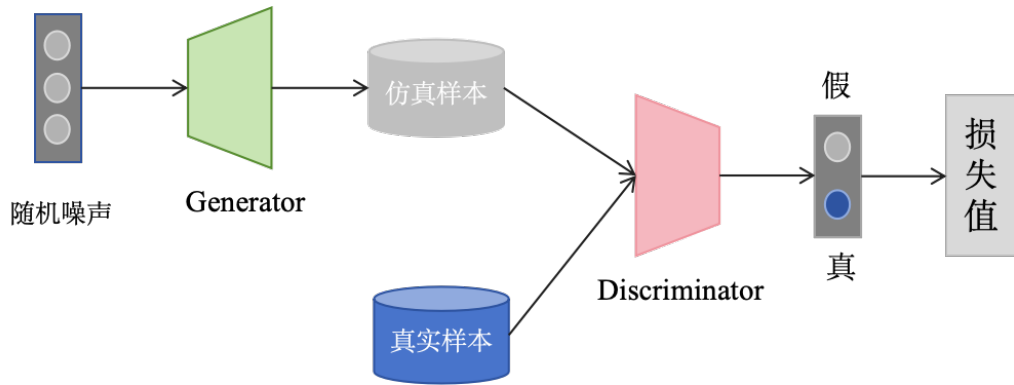


图 2.4 GANs 模型结构
Fig. 2.4 GAN model architecture

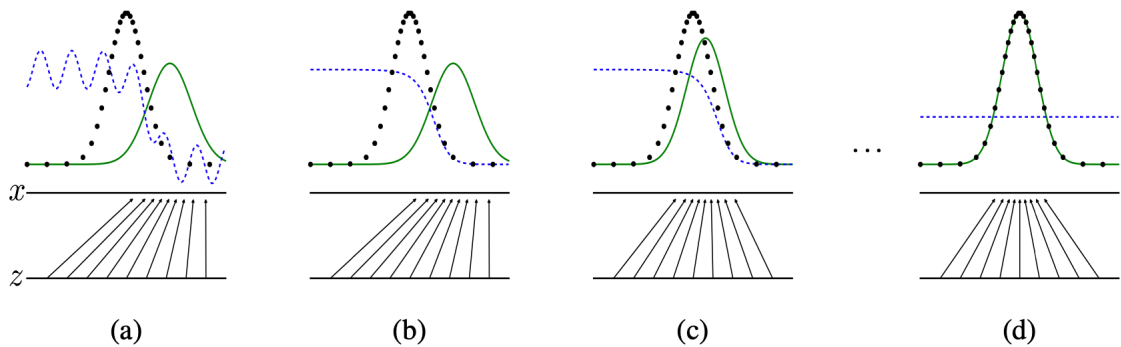


图 2.5 GANs 训练过程
Fig. 2.5 GAN training process

在生成对抗网络（GANs）中，通过交替训练判别器（Discriminator）和生成器（Generator）来提升它们的性能。训练过程可以用以下方式描述（如图2.5所示）：初始阶段，判别器和生成器的性能都很差。生成器生成的样本分布与真实样本分布存在明显差异，判别器对真实样本和生成样本的判别结果波动不定（图2.5(a)）。接下来，通过固定生成器的参数，训练判别器。随着训练的进行，判别器逐渐提高对真实样本的判别能力，使其输出接近 1，同时对生成样本的判别能力使其输出接近 0（图2.5(b)）。然后，固定判别器的参数，训练生成器。判别器的改进，生成器生成的样本分布逐渐接近真实样本分布。然而，判别器可能会对部分生成样本判断错误（图2.5(c)）。最后，通过判别器和生成器的对抗训练，生成器生成的样本数据的分布与真实样本数据的分布完全重合，导致判别器无法准确判定样本的来源（图2.5(d)）。这种对抗训练使生成器逐步提高生成逼真样本的能力，判别器逐渐提高对真实样本和生成样本的判别能力，从而产生与真实数据分布相似的高质量样本。

B. 注意力机制

注意力机制（Attention）是一种在机器学习和深度学习中广泛应用的重要技术。它

通过动态地分配权重，使模型能够聚焦于输入序列中与当前任务相关的部分。注意力机制不仅仅是一种计算方法，更是一种对人类视觉和认知机制的启发，通过模拟人类的关注和集中注意力的行为，提高了模型在处理序列数据时的表现。

在序列任务中，注意力机制通过计算查询向量与输入序列中每个位置的相似度得分，将得分进行归一化，从而可以得到各个位置的注意力权重参数。这一过程可以用公式来表达，其中一个常见的形式是缩放点积注意力公式。假设输入序列 X 包含 N 个位置，每个位置的特征可以表示为 $X = [x_1, x_2, \dots, x_n]$ ，查询向量特征表示为 Q 。最后，注意力得分（Attention Scores）可以通过公式2.10计算：

$$S = \frac{Q \cdot K^T}{\sqrt{d}} \quad (2.10)$$

其中， K 表示输入序列 X 的特征为经过线性变换获得的键（Key）向量， d 表示特征维度。再对注意力分数进行特征归一化，从而注意力权重（Attention Weights）：

$$A = \text{softmax}(S) \quad (2.11)$$

softmax 函数会将注意力分数归一化成概率分布，确保每个注意力权重最后的总和为 1。最后，通过将注意力权重与输入序列 X 中的特征表示相加，可以得到加权求和后的表示：

$$O = A \cdot X \quad (2.12)$$

其中， O 表示注意力加权后的表示，它是根据注意力权重对输入序列的加权求和得到的。

注意力机制在故障检测中的应用具有重要意义。故障检测涉及从大量的系统数据中识别和定位故障。通过引入注意力机制，可以使模型更加关注与故障有关的时间步，提高故障检测的准确性和鲁棒性。例如，在故障检测任务中，可以将待检测的系统数据表示为时间序列，然后使用注意力机制来动态地计算每个时间步的注意力权重，以区分对故障检测更重要的时间步。将时间步的特征表示和注意力权重进行加权求和，得到加权后的数据特征表示，供后续的故障检测算法或模型使用。这种应用方式使模型能够自适应地对不同时间步的数据进行加权处理，从而提高故障检测的效果。

总之，注意力机制是一种在序列任务中用于动态关注和加权输入序列中不同位置信息的重要技术。其原理通过计算注意力权重，将重要的信息加权汇聚起来，提高模型的性能和表现。在故障检测中，注意力机制可应用于提取与故障相关的信息，帮助定位故障和识别故障，能够提升故障检测的模型的性能。

2.3.2 自监督学习

有效的监督学习需要大量标记数据，然而获取这些数据的成本很高^[45,46]。此外，监督学习经常受到伪相关性、泛化错误和对抗性攻击的困扰。针对这些问题，许多研究人员已经探索了替代解决方案。自监督学习（SSL）是无监督学习重要分支之一，通过设计预设任务从而在大量未标记的数据挖掘有效信息，然后通过获得的监督信息对网络进行训练。随着 SSL 的预训练，学习权重被传递到下游阶段完成微调任务。SSL 可以克服由于稀疏样本引起的过拟合问题，提高泛化能力并增强模型稳定性。与此同时，自监督学习在各个研究领域都取得了成功，相应的预训练任务设计用于解决特定问题，如人脸识别、目标检测、语音文本生成和故障检测^[47-51]。

2.4 跨模态学习算法

由于跨传感器概念源于图像和文本领域的跨模态概念，因此有必要将跨模态概念引入作为引入跨传感器概念的基础。多/跨模态学习的基本思想是找到一个多模态共享空间，其中多层神经网络学习多模态表示。传统方法构建多个子网络来学习每个模态的特征，然后与各种条件结合以将特征约束到结果编码器层上。目前为止，跨模态生成学习在图像、文章和音频领域已经得到了更广泛的应用。在 Srivastava 等人^[52,53] 提出深度玻尔兹曼机和深度信念网络被用来解释多模态数据融合或学习的好处和有效性。近年来，随着大数据发展速度的加快，各种数据都被记录下来，跨模态学习已经得到了广泛研究，并且在与其他传统深度学习模型相比取得了更好的效果。Zhang 等人^[54] 中提出了一种从文本-图像生成学习的跨模态生成方法（XMC-GAN），通过捕捉对应于跨模态和内模态的多个损失，从而实现精准的通过图形的描述文本到图像的生成。Zhao 等人^[55] 中，从 RGB 图像到深度图的生成学习被利用来使模型捕捉丰富的语境信息并减小两种模态之间的差距，从而为下游任务提供有效的初始化，实现了显著物体检测，并取得了一些显著的结果。Wang 等人^[56] 中，提出了一种通过有效融合 2D 相机图像和 3D 激光

雷达点来进行跨模态三维物体检测的算法 (PointAugmenting), 与单一模型相比取得了显著的改进。在以上跨模态概念的基础上, 并考虑在工业领域从多个传感器收集数据的特点, 本文目标是将跨模态方面整合到多传感器领域。这导致了跨传感器概念的引入, 旨在缩小传感器之间提取的数据特征差异。这种整合预计将有助于在微调阶段进行故障检测。

2.5 本章小结

在第二章中, 主要介绍了减震器和相关的数据集, 并对数据预处理、异常数据检测、深度学习中的神经网络、自监督学习以及跨模态学习进行了总结。在减震器和数据集介绍中着重介绍了减震器的概念及其在工程和科学领域的应用, 引入了与减震器相关的数据集, 这些数据集可能包含传感器测量、时间序列等信息, 用于分析和预测减震器的性能。讨论了数据预处理的重要性, 以确保数据质量和模型性能。具体讨论了缺失值处理方法, 例如删除缺失值、插值法和使用机器学习模型填充缺失值等。并且强调了异常数据检测在工程和科学研究中的重要性, 探讨了常见的异常数据检测方法, 包括基于统计学的方法和基于深度学习方法等方法。解释深度学习中的神经网络, 并提供了深度学习中神经网络的基本概念, 强调了神经网络中的层次结构、激活函数和权重的作用。介绍了自监督学习的概念, 其中模型从数据中学习表示而无需显式的标签。讨论了跨模态学习的概念, 即利用不同模态 (如图像、文本、传感器数据) 的信息进行联合学习, 跨模态学习在减震器领域的潜在应用, 以提高模型性能和泛化能力。总体而言, 第二章提供了一个广泛的视角, 从数据获取、预处理到深度学习和先进的学习范式, 为理解和应用减震器数据打下了基础。这对于解决实际问题 and 提高减震器故障检测的性能以及推动相关研究都有重要的意义。

第三章 基于时序 Attention-GANs 模型的数据扩充方法

随着智能制造的迅速发展，生产设备的可靠性不断提升，减震器数据集的收集了大量正常状态的样本和少量异常状态的样本，导致减震器故障和正常运行时段的持续时间比例逐渐扩大，进而引发采集到的减震器样本数据集呈现类别不均衡的特征，但这种现象符合正常工业生产。对减震器数据集进行 PCA 可视化（如图3.1所示）和数量统计（如图3.2所示）展示，减震数据集的异常数据只占 15.9%。设备从运行开始到发生故障结束运行，绝大部分时间处于正常状态，从设备异常到停机只占少数时间，因此健康数据量和异常数据量呈现出了极端的失衡。数据不平衡可能会导致以下问题：（1）、异常数据量过少，无法提供有效的数据特征。（2）、机器模型进行分类训练时，过度依赖健康数据，可能导致分类模型失效。（3）、当模型真实应用于现实场景时，模型的鲁棒性和准确性得不到保证。因此，在进行减震器故障检测建模之前，必须对数据不平衡情况进行处理。

针对减震器数据集的不平衡问题和数据时序性的特点，本章提出了一种基于 Attention-GANs 的方法。该方法综合考虑了减震器数据的时序性和特征相关性，通过利用注意力机制，让模型关注故障类别的样本，提升其在数据扩充中故稀少样本的生成效果。以下是本章的主要工作内容：

- 1、使用 Pearson 相关系数深入分析数据集特征，根据结果分组减震器特征。这样的分析不仅提高数据集可解释性，还为后续处理和模型构建奠定深度基础，有助于更精准的分析与决策。

- 2、基于分组结果，将减震器数据集划分为多个特征子集，并借助 Attention-GANs 模型进行构建。该模型的核心流程包括两个关键阶段：首先，针对各个分组特征数据子集分别进行 GANs 训练，以学习组内特征之间的紧密相关性，并生成相应分组的特征数据集；其次，将上述各 GANs 生成的数据拼接为输入，利用第二阶段的 GANs 并注入 Attention 机制修正不同分组之间特征的较弱相关性，从而生成高度仿真的少数类样本数据。该设计目的是为了利用注意力机制和生成对抗网络进行协同作用，从而有效地提升对数据集特定特征的建模能力。

- 3、在研究中，进一步将 Attention-GANs 方法与当前存在的失衡处理方法进行了




图 3.1 样本数据 PCA 可视化
Fig. 3.1 PCA visualization of sample data

二分类数据的不均衡分布




图 3.2 减震器数据集统计
Fig. 3.2 Statistics of the shock absorber dataset

比较。模型的基础骨架选用了 CNN（卷积神经网络）作为减震器故障检测模型，从而全面验证了 Attention-GANs 方法的有效性和可靠性。

通过一系列实验展现了 Attention-GANs 在处理不平衡数据集方面的独特优势，同时也证实了其在多种模型框架下的适用性，为该方法在实际工程应用中的可行性提供了坚实的理论支持。

3.1 特征相关性分析

减震器数据的特征之间往往存在一定程度的相互关系。在进行数据生成时，如果仅仅采用简单的插值方法合成新数据，存在破坏特征间相关性的风险。这可能导致生成的数据不符合减震器特征的内在规律，从而在模型训练过程中引入偏差，降低模型的性能。为了避免这种情况，有必要在减震器数据生成过程中进行特征间的相关性分析。在本章中，选择采用 Pearson 相关系数作为分析工具，以深入了解减震器数据特征之间的关系。Pearson 相关系数能够量化线性相关性的强度和方向，提供了一个可靠的手段，用以评估特征之间的相互影响。通过细致的分析能够获取关键特征之间的相关性模式，这为后续的数据生成过程提供了有益的指导。本章的核心目标之一是确保生成的减震器数据不仅具有合适的特征分布，还能够保持原有数据集中特征间的相关性。通过利用 Pearson 相关系数进行特征相关性分析，旨在为数据生成过程提供有力支持，确保生成的数据能够更好地反映实际减震器数据的特性，提高模型的泛化能力和训练效果。

Pearson 相关系数通常用于统计两个连续变量之间的线性相关性，并提供了一个易于理解的度量。Pearson 相关系数的公式如下：

$$r = \frac{\sum_{i=1}^n (X_i - \bar{X})(Y_i - \bar{Y})}{\sqrt{\sum_{i=1}^n (X_i - \bar{X})^2 \sum_{i=1}^n (Y_i - \bar{Y})^2}} \quad (3.1)$$

n 表示样本数量， X_i 和 Y_i 分别表示第 i 个样本点两个变量的取值， \bar{X} 和 \bar{Y} 分别表示两个变量的样本均值。同时，Pearson 相关系数取值范围在 $[-1, 1]$ ，用于表示变量之间线性关系的强度和方向。当 $r = 1$ 代表完全正相关， $r = -1$ 代表完全负相关， $r = 0$ 代表没有线性关系。

对减震器的三个特征 $PRINT_D_X$ 、 $PRINT_D_Y$ 和 $PRINT_D_Z$ 分别映射简化为 x 、 y 和 z 。选取了减震器数据集的一个周期数据（如图2.1所示）进行 Pearson 相关

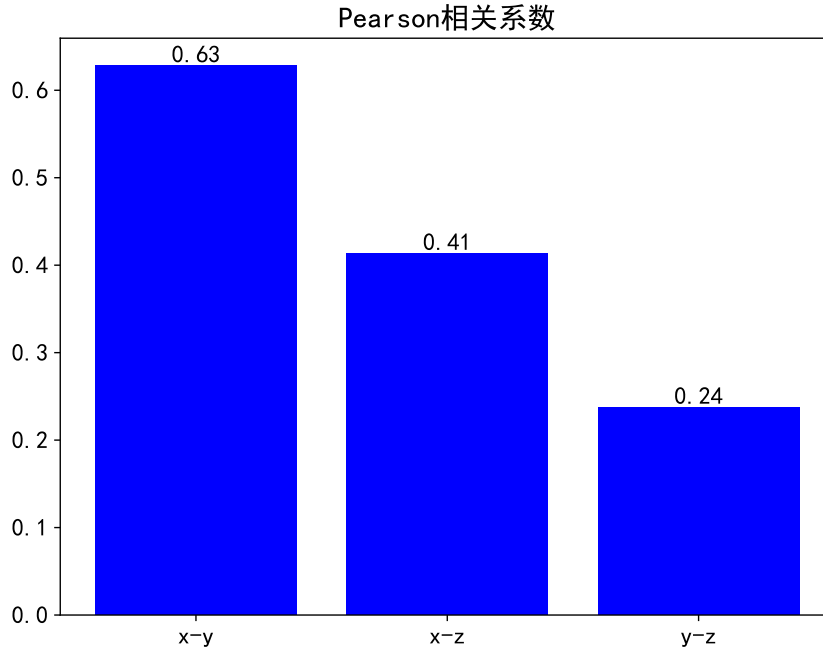


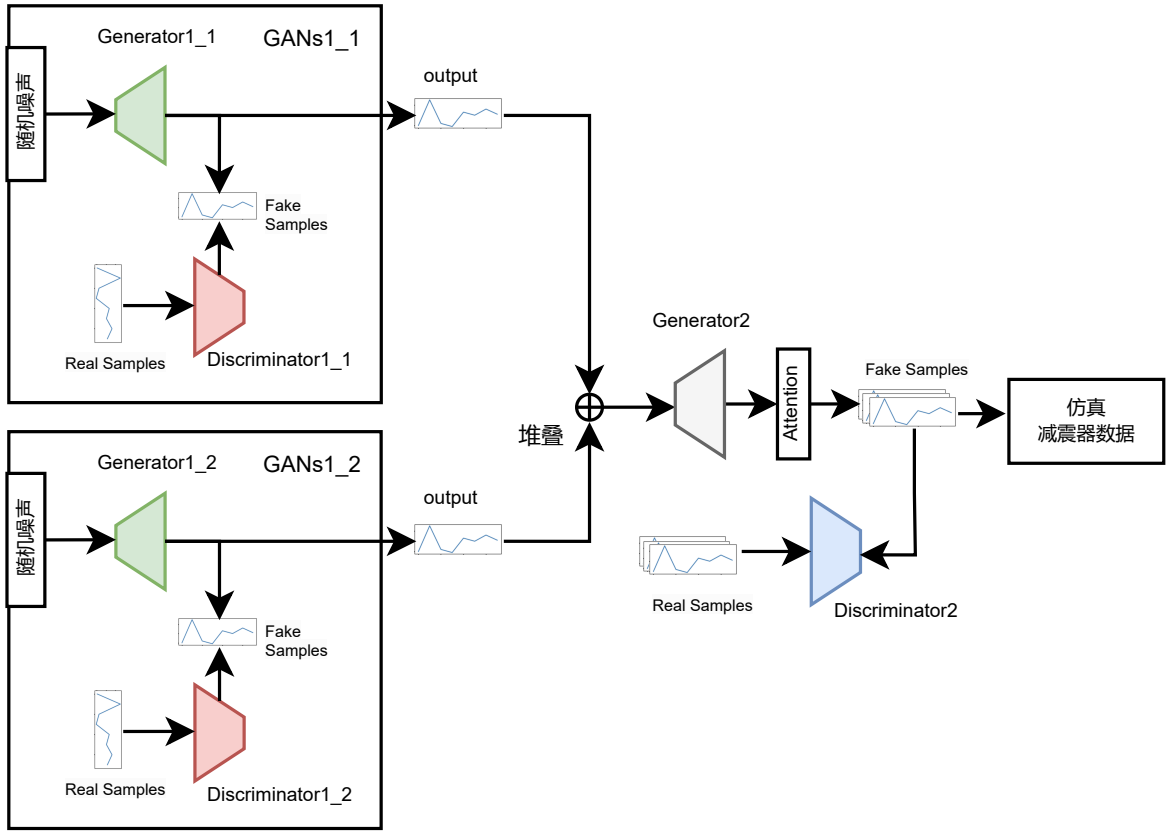
图 3.3 Pearson 相关系数分析
Fig. 3.3 Pearson correlation coefficient analysis

系数进行特征相关性分析，其结果如图3.3所示。最后选取了 Pearson 系数相关性最大的 x-y 数据作为一组数据 S_{xy} ，z 数据另作为一组数据 S_z 。

3.2 Attention-GANs 时序数据扩充方法

生成式对抗网络是目前广泛应用的一种深度学习算法，其组成主要包括生成器 (Generator) 和判别器 (Discriminator) 两个网络。在训练时，生成器不断生成高仿真的数据样本，而此时判别器也不断变得更善于区分真实样本和生成样本。训练不断迭代，直至生成器生成的数据样本不被判别器发现为止。本章通过利用 GANs 来生成少数类样本的高仿真训练数据，以达到解决减震器数据存在数据稀少和不平衡的问题。

鉴于减震器数据的特征间存在强相关性和弱相关性，仅采用单层 GANs 无法同时捕捉到这些强弱相关性。为解决这一问题，本章借鉴递进式思想，采用分阶段的方式生成数据。考虑到减震器数据的时序性，为保持生成数据间的时序关系，必须挖掘数据中的时序特性。在网络模型的选择上，CNN、RNN、LSTM 等是常见的选择。相对于 CNN 和 LSTM，RNN 结构相对简单。鉴于少数类样本数据量较少，使用结构简单的 RNN 有助于避免模型欠拟合。因此，各阶段 GANs 的 Generator 和 Discriminator 选择了基于 RNN 神经网络的搭建。最终，本章提出了 Attention-GANs 模型，用于生成减震器少数类样本数据。如图3.4所示为 Attention-GANs 模型的体系结构图。



step1: 分组训练GANs1用于学习组内特征的强相关性

step2: GANs2用于修正组间特征的弱相关性

图 3.4 Attention-GANs 方法结构
Fig. 3.4 Structure of the Attention-GANs method

图3.4是 Attention-GANs 模型的结构示意图，主要包括两个步骤：

步骤 1：通过对特征相关性进行 Pearson 相关系数的分析后，将数据集进行细致的分组，形成两个关键子集，即 S_{xy} 和 S_z 。具体而言， S_{xy} 被指定为供 $GANs1_1$ 训练之用，而 S_z 被用于培训 $GANs1_2$ 。在训练过程中，为 $GANs1_1$ 引入 $Generator1_1$ ，其输入为随机噪声。相应地， $Discriminator1_1$ 则接受 S_{xy} 以及 $Generator1_1$ 所产生的仿真数据作为输入。通过交替的最大化最小化策略（详见公式3.2），对 $Generator1_1$ 和 $Discriminator1_1$ 进行系统的训练。值得注意的是， $GANs1_2$ 同样经历了相似的训练过程，以确保整体模型的均衡性。这一步骤的目的在于通过合理的数据分组和对抗训练，使生成器能够逐步学习捕捉输入数据中的关联性，并提升生成的数据的多样性和真实性。

$$Loss = \min_G \max_D \mathbb{E}_{xy \sim S_{data}(xy)} [\log D(xy)] + \mathbb{E}_{n \sim S_n(n)} [\log(1 - D(G(n)))] \quad (3.2)$$

其中, $S_{\text{data}}(xy)$ 是真实数据的分布, $S_n(n)$ 是噪声的分布。

步骤 2: 经过训练的 $Generator1_1$ 和 $Generator1_2$ 分别生成 S_{xy} 和 S_z 数据。这两个数据子集通过拼接形成一个统一的数据集, 将其称为基本数据。这个基本数据的设计考虑到了组内特征的强相关性, 同时限制了组间特征的相关性, 以确保生成的数据具有更为合理的结构。在步骤 2 中, 引入了 GANs2 模型, 并对其进行训练。与之前的步骤不同的是, $Generator2$ 不再依赖随机噪声作为输入, 而是直接采用拼接后的基本数据。通过这样的设计, 使得模型更加关注基本数据的内在关联性, 有助于提高生成数据的质量。生成特征数据 F 后, 进一步引入 Attention 模块 (详见公式 3.3)。Attention 机制被引入的目的在于通过动态调整特征的权重, 使得模型能够更灵活地捕捉数据特征之间的关联性。这一迭代优化过程旨在不断提升模型的学习能力, 使其更为精准地反映原始数据的复杂关系。

$$\begin{aligned}\alpha_s &= \tanh(W_s F + b_s) \\ a_s &= \text{softmax}(W_i \alpha_s + b_i)\end{aligned}\tag{3.3}$$

其中 W_s 和 W_i 是可训练的权重参数, b_s 和 b_i 是可训练的偏差参数。

步骤 3: 在 Attention-GANs 模型的步骤 3 中, $Discriminator2$ 利用 Attention 处理后的仿真数据作为输入, 通过交替最大化最小化的公式进行训练, 同时训练 $Generator2$ 。这一步骤的目标在于调整生成数据的组间特征, 以增强数据的真实性。具体而言, $Generator2$ 的任务是通过修正组间特征的弱相关性, 进一步提升生成数据的质量。通过对抗训练, $Discriminator2$ 不仅评估生成数据的真实性, 还促使 $Generator2$ 学习更有效的特征表示, 使得生成的仿真数据样本更贴近真实数据。在完成 GANs2 模型训练后, 将移除 $Discriminator2$, 只保留 $Generator2$ 。将步骤 1 和步骤 2 的 $Generator$ 整合, 形成 Attention-GANs 生成时序扩充数据模型。在 Attention-GANs 模型中, $Generator1_1$ 和 $Generator1_2$ 利用随机噪声生成具有组内特征强相关性的分组数据。这些生成的分组数据被拼接形成基本样本数据。然后, $Generator2$ 对基本样本数据进行精炼, 通过 Attention 机制调整特征权重, 从而获得更符合减震器数据特征的高仿真少数类样本数据。

3.3 实验与结果分析

3.3.1 实验环境和数据集

本实验在 Ubuntu20.04 和 Pytorch 3.8 上进行模型训练和实验,硬件环境为 RTX3060Ti GPU。减震器数据集来自合肥市某制造企业的表面贴装技术生产线上的减震器历史运行数据,数据集重要包括三个特征 $PRINT_D_X$ 、 $PRINT_D_Y$ 和 $PRINT_D_Z$ 。数据集包括 1157014 个正样本, 26680 个负样本。最后,取 80% 正负样本作为训练集的数据,剩下的正负样本作为测试集数据,具体情况如表3.1所示。

表 3.1 减震器数据集
Table 3.1 Shock absorber dataset

名称	特征数量	正样本数量	负样本数量
训练集	3	925611	21344
测试集	3	231403	5336

3.3.2 评估指标

由于 SMT-SA 数据集是有标记的数据,因此使用了几个最常使用的定量评估指标:准确率 (Accuracy score ACC)、精确率 (Precision Score)、F1-score。这些定量评估指标的值越高,越接近 100%,表示模型分类的准确性越高。以下是引入的定量评估指标。

- 真正例 (True Positive, TP): 真正例表示从实际正例样本实例中正确预测的正样本值。
- 假正例 (False Positive, FP): 假正例表示从正样本中错误预测的值。
- 真负例 (True Negative, TN): 真负例表示从实际负例样本中正确预测的负样本值。
- 假负例 (False Negative, FN): 假负例表示从负样本中错误预测的值。

准确率 (Accuracy Score) 被定义为真正例和真负例占有所有正负值的比率,准确率的计算公式如下:

$$AccuracyScore = \frac{(TP + TN)}{(TP + FN + TN + FP)} \quad (3.4)$$

精确率 (Precision Score) 表示模型正确预测所有正样本的能力,精确率的计算公式如下:

$$PrecisionScore = \frac{TP}{(FP + TP)} \quad (3.5)$$

在介绍 F1-score 之前，需要介绍召回率 (Recall Score)：它表示模型从实际正样本中正确预测正样本的能力，计算公式如下：

$$RecallScore = \frac{TP}{(FN + TP)} \quad (3.6)$$

F1-score 是机器学习模型性能的度量标准，它对精确率和召回率给予相同的权重，以衡量模型准确性的性能，并且可以作为准确率的替代，因为它不需要知道总样本数，计算公式如下：

$$F1\text{-score} = 2 \times \frac{PrecisionScore * recall}{PrecisionScore + recall} \quad (3.7)$$

3.3.3 实验设计

为了验证 Attention-GANs 算法在数据扩充方面的有效性，进行了一系列综合的统计学分析，将由该算法生成的数据与真实数据集进行对比。最后选择了平均值和标准差这两个关键的统计特征，以全面评估 Attention-GANs 算法生成数据的质量。在实验中，利用生成的数据和真实数据集，采用严格的统计学方法对 Attention-GANs 算法的生成数据进行评估。通过比较平均值和标准差，可以深入了解生成数据与真实数据之间的相似性和差异性，为算法的性能提供直观而可信的评估指标。

此外，不仅仅局限于内部评估，还将所提出的 Attention-GANs 算法与先进的数据扩充算法进行了在减震器数据集上的实际应用对比实验。在这个实验中，选择了 RNN 网络框架的故障检测模型作为评估基准，以更全面地验证 Attention-GANs 算法在提升模型性能方面的作用。整个实验流程详细展示在图3.5中，涵盖了数据扩充、故障检测模型的训练和评估等关键步骤。通过这一综合性的实验设计，旨在全面评估 Attention-GANs 算法在数据扩充和故障检测任务中的实际效果，为进一步的研究和应用提供深刻的理解和可靠的依据。

在模型训练阶段，首先通过 Attention-GANs 对减震器的训练集进行处理，以使正样本和负样本的数量趋于平衡。接着，将生成的样本输入到减震器的故障检测模型中进行训练。在每个训练周期中，根据模型输出计算损失值，并通过反向传播不断更新模型的权重参数。经过 73 个训练周期，模型达到了最佳效果，最终以模型文件的形式输出，

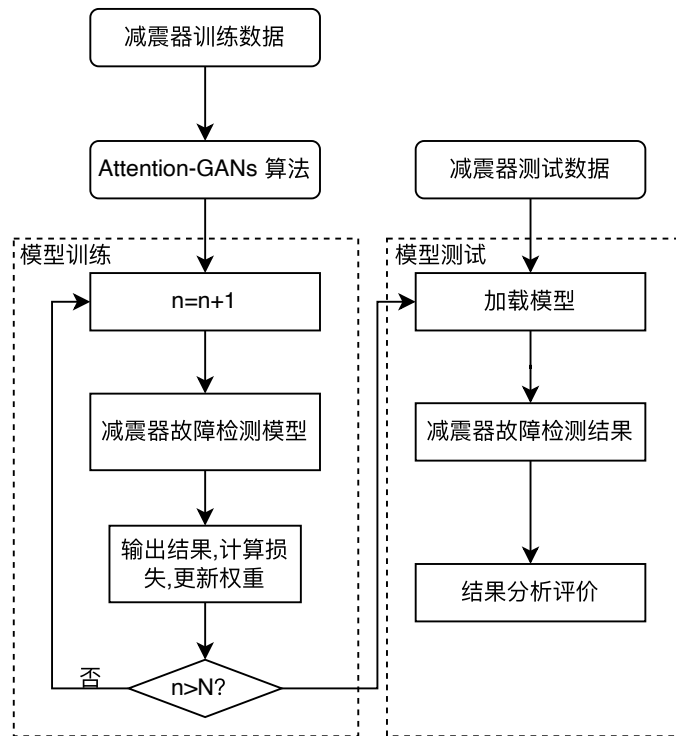


图 3.5 数据扩充实验流程

Fig. 3.5 Data augmentation experiment process

以供后续任务使用。

在模型测试阶段，进行了一系列步骤来全面评估训练好的减震器故障检测模型的性能。首先，加载之前存储的模型文件，将已训练好的减震器故障检测模型导入到测试环境中。这确保了能够在测试阶段使用与训练一致的模型，保持了模型的一致性和可复现性。接着，利用导入的模型对减震器的测试集进行故障检测。通过输入测试数据，模型将输出相应的故障检测结果，包括对每个样本的分类或概率分数。最后，采用评价指标对不平衡处理方法的有效性进行评判。这些评价指标可能包括准确度、精确度、召回率、F1 分数等，用以综合考量模型在处理不平衡样本分布时的表现。通过这一测试阶段的设计，能够验证模型在实际应用中的效果，评估不平衡处理方法的有效性，从而更全面地了解模型对减震器的故障检测效果。

3.3.4 实验结果分析

(1) 生成样本结果与分析：如图3.6所示，呈现了 Attention-GANs 数据扩充的结果。图3.6选择了减震器数据的一个完整周期进行展示，生成的数据总体上与原始数据相贴合，尽管在少数情况下存在轻微偏差。进一步，在图3.7和图3.8中，展示了生成样本和真实样本的特征变量的均值和标准差的对比情况。具体而言，图3.7展示了各特征变量

的标准差对比情况，而图3.8展示了各特征变量的均值对比情况。从这两图中可以明显看出，生成的少数类样本数据中各特征的均值和标准差与真实的少数类样本数据中的相应特征的均值和标准差非常接近。这表明通过 Attention-GANs 方法生成的样本与真实样本之间存在高度相似性。使用 Attention-GANs 方法，模型能够同时学习特征之间的强弱相关性以及时序特性，从而生成高度逼真的样本数据。这一结果进一步验证了 Attention-GANs 在样本生成方面的优越性，为数据扩充提供了可靠的解决方案。




图 3.6 Attention-GANs 数据扩充结果

Fig. 3.6 Results of the Attention-GANs data augmentation

图 3.6的蓝色线表示原始数据 x 、 y 、 z ，黄色线表示数据扩充后的高仿真数据 x' 、 y' 、 z' ，从图中可以看出高仿真数据和原始数据具有较高的相似性。

(2) 对比实验结果与分析：在对比实验中，本实验中将 Attention-GANs 方法与




图 3.7 特征标准差结果

Fig. 3.7 Results of feature standard deviation




图 3.8 特征均值结果

Fig. 3.8 Results of feature mean

ADA^[57]、MDAC^[58]、WGAN-GP^[59] 和 LWSM^[60] 以及未经不平衡处理的数据集进行对比实验。

- Lu 等人^[57] 提出对抗性数据增强 (Adversarial Data Augmentation, ADA) 的方法, 对抗性数据增强是通过引入对抗性扰动来增强训练数据。
- Jiang 等人^[58] 提出了一种多生成器 (Multigenerator structure of Data Augmentation classifier, MDAC) 的方法, 结合数据筛选和净化策略以及多生成器结构, 解决数据不平衡对故障检测性能的负面影响。
- Gao 等人^[59] 提出了使用基于 Wasserstein 生成对抗网络和梯度惩罚 (Wasserstein generative adversarial network with gradient penalty, WGAN-GP) 的数据增强方法, 通过生成数据样本来补充工业过程中的低数据或不平衡数据分布。
- Guo 等人^[60] 该论文提出了一种基于局部权重共享多生成器的生成对抗网络方法 (Local Weights-Shared Multi-Generator, LWSM)。

表 3.2 数据扩充对比实验结果

数据不平衡处理方法	F1Score	ACC	PrecisionScore
ADA	88.493%	87.024%	79.363%
MDAC	91.071%	90.238%	83.614%
WGAN-GP	93.452%	93.274%	87.715%
LWSM	93.801%	93.435%	88.333%
未处理	84.033%	81.145%	72.462%
Attention-GANs	95.425%	95.428%	91.247%

在实验中, 为了消除随机因素对各减震器故障检测模型的影响, 对每个算法进行了 15 次实验, 并计算了它们的 F1-score、ACC 和 Precision Score 的平均值。具体的实验结果如表3.2和图3.9所示。与其他数据不平衡处理算法相比, 本章提出的 Attention-GANs 方法在减震器故障检测模型上表现出色, 达到了评价指标的最优值, 优于其他方法。实验证明, Attention-GANs 方法在解决减震器数据不平衡问题方面表现出了显著的有效性。该方法在生成新的少数类样本时, 充分考虑了数据特征的相关性和时序特性, 使得生成的数据更为真实。本章提出的 Attention-GANs 数据扩充方法使模型能够更充分地学习故障类特征的分布, 从而在提升整体性能方面取得了显著的成功。

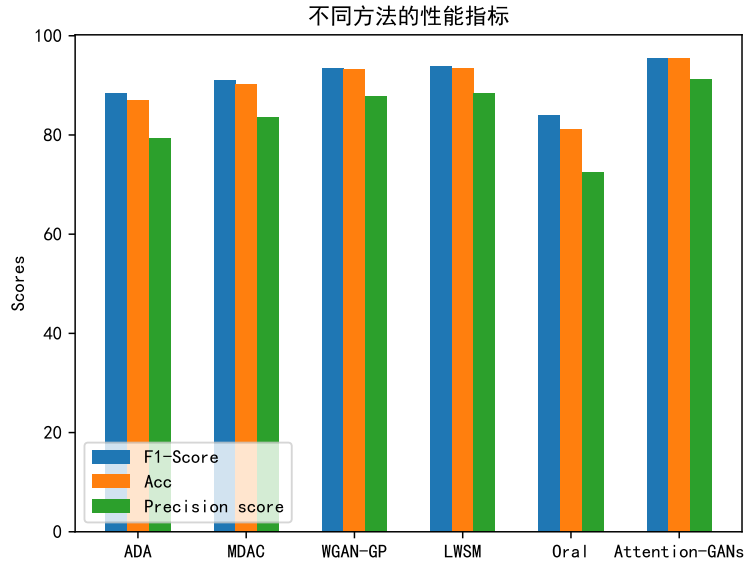


图 3.9 Attention-GANs 数据扩充对比实验结果

Fig. 3.9 Results of the comparative experiment on Attention-GANs data augmentation

3.3.5 消融实验

在这部分中，为了验证模型不同模块的有效性，设计了三个网络，分别是原始的 GANs、双流 GANs 网络、Attention-GANs 网络。

- GANs: 由于本论文中模型的骨干网络基于 GANs 网络，因此单独的 GAN 网络用于原始 GANs 在数据扩充上的效果。
- 双流 GANs 网络: 在本章模型的基础，去掉了 Attention 模块，只采用双流 GANs 网络设计。

表 3.3 数据扩充消融实验结果

Table 3.3 Results of the data augmentation ablation experiment

网络	均值 *100			标准差		
	x	y	z	x	y	z
原始数据	0.34686	0.27067	0.98843	1.10490	1.09620	1.09901
GANs	0.34223	0.24734	0.95323	1.14458	1.13652	1.13943
	0.00463	0.02333	0.03520	0.03968	0.04032	0.04042
双流 GANs 网络	0.34530	0.26288	1.01103	1.12930	1.10073	1.10367
	0.00156	0.00779	0.02260	0.02440	0.00453	0.00466
Attention-GANs	0.34538	0.27669	1.00143	1.10948	1.10069	1.10352
	0.00148	0.00602	0.01300	0.00458	0.00449	0.00451

表 3.3是消融实验的结果，首行表示原始数据的均值和标准差。因为均值数据较小，所以在原数据的情况下乘于 100 方便展示数据差值。每个模型结果的第一行表示模型数据扩充的结果，第二行表示当前数据减去原始数据的差值绝对值。从表 3.3可得，

Attention-GANs 网络数据扩充的结果最接近原始数据，其次是双流的 GANs 网络，原始的 GANs 网络与原始数据差距较前两个模型大。总结，Attention-GANs 的模型中双流结构和 Attention 的结构对原始模型都有较大的提升。

3.4 本章小结

本章针对减震器数据集的不平衡问题，提出了一种新颖的基于 Attention-GANs 的数据扩充方法。在生成样本数据的过程中，充分考虑了减震器传感器数据之间的复杂相关性和时序性。该方法的主要贡献包括以下几点：首先，采用了双生成式模型的策略，通过此方法生成的减震器样本数据能够有效地提取传感器数据之间的特征信息。其次，通过引入 Attention 机制，能够捕获传感器数据的时序特性，从而更加精细地生成样本数据。最终，对 Attention-GANs 生成的样本数据与真实样本进行了深入的数据分析，充分验证了两者之间的高度相似性。同时，还与其他不平衡处理算法进行了详尽的对比实验，结果表明 Attention-GANs 方法在解决不平衡问题上的优秀性能，其生成的样本数据更加贴近真实。

第四章 基于跨传感器多层级的自监督故障检测方法

减震器维护不仅仅关乎经济层面的损失，更涉及到生产系统的整体可持续性和效率。随着工业制造系统的规模和复杂性的增加，减震器故障可能导致生产线的中断，进而影响到整个供应链的正常运作。在工业监控中，减震器通常包含多个传感器数据，为模型提供了丰富的基础准备。如何有效的从多传感器数据中挖掘出更多有价值的信息来提高减震器故障检测的整体性能，提升工业生产设备的智能检测，是目前被广泛研究的问题。当现有的方法大都采用堆叠信号的方式处理传感器数据，堆叠的方式难以挖掘传感器信号之间的相关性，这种方法使得模型效果不理想。

针对以上问题，在本章里，提出了一种两阶段的提出了一种跨传感器多层级的生成式故障检测模型用于故障检测。主要工作内容如下：

1. 在预训练阶段，通过跨传感器多层级的网络，实现了跨传感器数据之间的交互。跨传感器多层级的方法在时间维度内协调了特征的融合，从粗粒度过渡到细粒度的表示。在整个预训练阶段，利用配对的多传感器数据，通过跨传感器重构训练在多维上提取特征。这个复杂的过程不仅有助于跨传感器特征融合，还有效地缩小了现有特征差距。

2. 在微调阶段，为了获得更具有区分性的表示，引入了一个显著性模块。通过加法和减法操作，该模块注入了人类先验知识，放大了两种模态之间的差异。在共享空间中逐渐扩大正常和异常数据特征之间的距离，导致了紧凑的类内表示，有效地增强了边缘特征的分类。

3. 在工业场景中的私有数据集 SMT 减震器数据集（SMT-SA 数据集）上进行了对比实验和消融实验，该方法的各项评价指标均表现最优，证明了该方法在提升故障检测性能上的有效性。

4.1 跨传感器多层级网络

在这一部分，将详细介绍用于故障检测的两阶段方法的详细框架，方法的总体结构训练如图 4.1所示。首先，全面描述了模型框架，包括一个预训练阶段和一个微调阶段。在预训练阶段采用了一个多维生成自监督学习的先验任务，以利用未标记数据的知识。

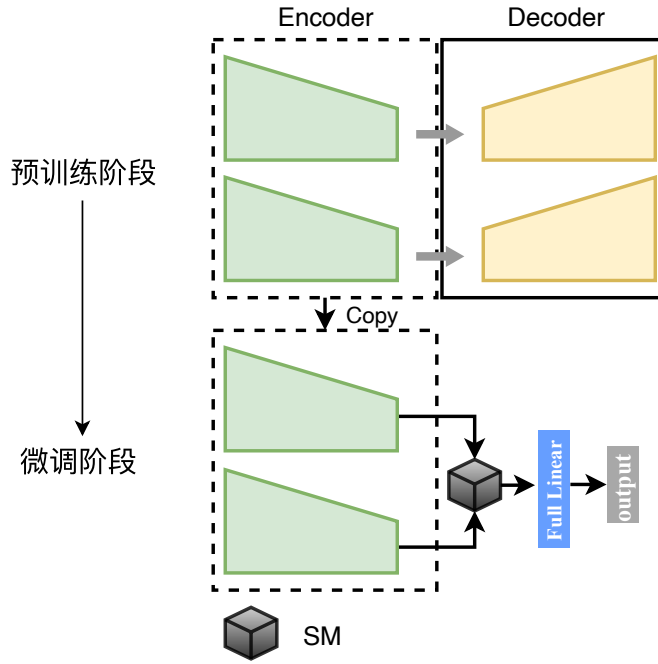


图 4.1 整体网络框架

Fig. 4.1 Overall network architecture

它涉及到数据特征的跨传感器相互生成和通过多维约束优化提取的数据特征。其次，在微调阶段，利用预训练阶段训练完成的编码器模块，并同时设计了显著性模块来进一步处理上游预训练阶段获得的数据特征。显著性模块通过聚合和分离从上游阶段学到的数据特征来操作，并在实证中对减小类内特征之间的距离和增加类间特征之间的距离具有有效性。

4.1.1 预训练任务

有效的预训练任务使特征提取器能够学习对下游任务有用的特征。在本章中，针对时间顺序中的故障检测问题，提出了一个定制的预训练任务，利用了一个跨传感器多层次自编码器模型。跨传感器方法使自编码器能够从每个模态学习信息并减小模态之间的差距，而多层次方法则在时间维度上促进了从粗粒度到细粒度的特征融合。

如图 4.2 所示，预训练框架采用了一个包含五个编码器块、四个输出层（ S^i 其中 $i \in \{1, 2, \dots, 4\}$ ）和四个解码器块（ D^i 其中 $i \in \{1, 2, \dots, 4\}$ ）的双流架构。为了清晰起见，图中省略了另一个模型之间的连接线和特征维度。两个模型的主要网络结构是相同的，但它们的区别在于模型的输入维度，其对应于另一个模型的输出维度。

为了进一步说明，以 SMT-SA 数据集为例，传感器数据在输入模型之前被分成两部分， S_{xy} 和 S_z 。 S_{xy} 的特征维度为二，而 S_z 的特征维度为一。将 S_{xy} 输入模型结构的上




图 4.2 预训练网络框架
Fig. 4.2 Pre-trained network architecture

半部分，在对应到解码器输出层时保持与 S_z 相同的特征维度，都为 1。 S_z 数据保持上述操作不变。解码器网络对编码器网络实施辅助功能，使编码器网络能够实现有效的跨传感器数据生成。因此，在微调网络时，不再需要解码器网络，只需根据特征使用编码器网络提取的数据。

A. 编码器

考虑到对多分辨率的建模需求，在预训练阶段的骨干网络使用 VGG-16。为了使 VGG16 适应重构需求，进行了一些修改。首先，原始的 VGG-16 网络中的所有 Conv2d 层都被重写为 Conv1d，以匹配传感器收集到的数据特征的维度。其次，用侧输出层（在下一节中解释）替换了 VGG-16 的最后一个池化层。此外，由于 VGG-16 没有残差结构，从而会有训练不稳定的风险，减少了网络层数，使用了简化版的参数量更低的 VGG-16。最后，对 VGG16 网络进行了层次切割，遵循 FPN 方法^[61]。经过 VGG16 网络层次切割后的特征维度如图 4.2 中的绿色模块所示。同时测试了 ResNet50 作为网络骨干，但是发现其残差结构设计在跨传感器重构的优化过程当中会增加收敛难度，因此最后选择不使用残差结构，并将简化版的 VGG-16 作为骨干网络。

B. 解码器

在预训练网络的解码器中，其主要目的是基于解码器块的输出层重构原始传感器

数据。每一个层级当中，将对应维度的编码器提取的数据特征与前一层级的解码器输出的数据元素相加，并将相加特征送入可学习的解码器块当中重构原始数据（因需要前一层级的编码器输出，解码器块只有四个层级）。解码器通过多层级的约束实现多粒度的空间信息建模。考虑到数据在传感器维度数据具有不同的结构特点，自编码器网络采用了两个分支，并在每个分支中采用了跨传感器重构策略。具体来说，分支 1 采取 $(S_X, S_Y) \rightarrow S_Z$ 的策略，而分支 2 采取 $S_Z \rightarrow (S_X, S_Y)$ 。因此在解码器网络的重构目标是，

$$L_{L1}^i = L_1(D^i(F_{xy}^i + F_{xy}^{i+1}), S_{xy}) + L_1(D^i(F_z^i + F_z^{i+1}), S_z) \quad (4.1)$$

$$L_{side} = \sum_{n=1}^N (L_{L1}^{(n)}) \quad (4.2)$$

其中， L_1 代表在故障检测领域被广泛使用的平均绝对误差， n 表示第 N 层的输出层。 L_{side} 是总的优化目标。

4.1.2 下游任务

在微调阶段，省略了预训练阶段的解码器结构。编码器的参数直接传递到微调网络并保持冻结。只有显著性模块（SM）和全连接层需要训练，如图 4.1 微调阶段所示。显著性模块在减小相似数据特征之间的距离和增加不同类别数据特征之间的差距方面起着关键作用。

由于预训练引入的平滑效应，正常和异常数据之间的过渡变得更加渐进，使得分类器更难准确区分轻微故障。因此，微调阶段的显著性模块旨在识别故障数据，分离异常部分，更有效地聚类正常数据，并减少误分类。在显著性模块之后，数据经过全连接层进行分类。

A. 显著性模块

显著性模块增强特征差异，实现了更好地聚合类内特征和增加类间特征之间的差距。这反过来增强了类特征的一致性，从而实现更准确的故障检测。所提出的显著性模块的内部结构如图 4.3 所示。设 F_{xy} 和 F_z 分别表示由预训练网络提取的两个特征，对应不同的模态（水平和垂直）。 F_{xy} 和 F_z 都经过 ReLU 函数的激活。最初，对 F_{xy} 和 F_z 进行逐元素求和操作，以获得两个模态之间的显著信号。通过使用标签进行监督来确保模

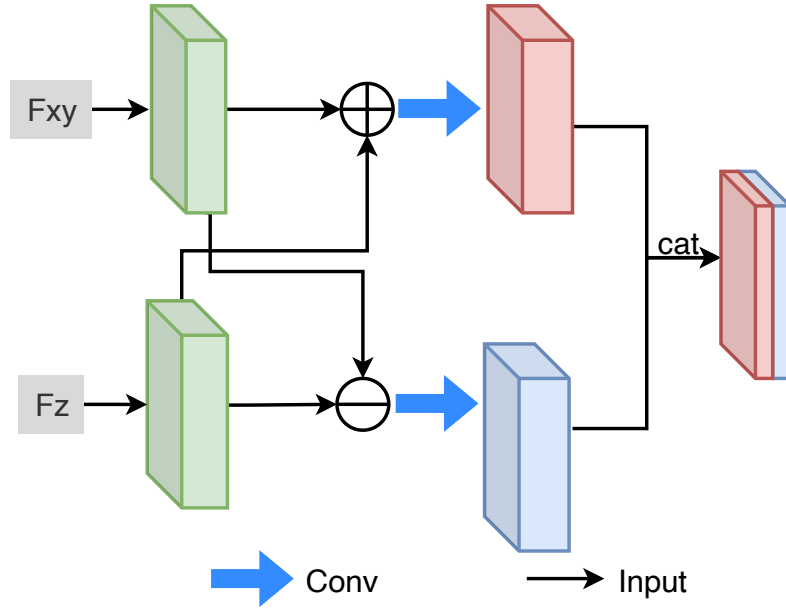


图 4.3 显著性模块的示意图

Fig. 4.3 Schematic Diagram of the Significance Module

型捕捉显著信号的能力，表示为：

$$F_C = Conv(F_{xy} \oplus F_z) \quad (4.3)$$

\oplus 表示逐元素相加， $Conv(\cdot)$ 表示卷积。随后，应用聚合操作增强 F_{xy} 和 F_z 中的主导特征，产生初始融合特征：

$$F_D = Conv(|F_{xy} \ominus F_z|) \quad (4.4)$$

\ominus 表示逐元素相减， $|\cdot|$ 计算绝对值。 F_D 描述了跨传感器的特征差异。最终的融合由 F_C 和 F_D 拼接生成：

$$F_{CD} = Conv(cat(F_C, F_D)) \quad (4.5)$$

F_{CD} 包含跨模态的更丰富的互补信息。显著性模块融入了先验知识，考虑到正常传感器信号在不同传感器间表现出平滑的振动，而异常传感器信号的初始出现则表现为小振动。这种先验知识指导了显著性模块内的操作，有助于识别指示故障的微妙模式。通过一系列的加法和减法操作，放大了两种模态之间的差异，逐渐扩大了共同空间中正常和异常数据特征之间的距离，实现了紧凑的类内表示。

4.2 实验与分析

为验证提出的两阶段方法的有效性、准确性和稳定性，在公共和私有数据集上分别进行了实验。首先，算法在私有数据集 SMT-SA 上进行故障检测，该数据集提供了设备故障停机前的标记正常数据和异常数据，用于测试所提出的方法是否能够准确区分正常和异常数据。该实验基于 PyTorch 3.8 实现，在 Ubuntu 20.04 的 RTX3060Ti GPU 上进行了 75 个 epoch 的预训练和 30 个 epoch 的微调。预训练和微调所使用的参数见表 4.1 所示：

表 4.1 实验参数设置
Table 4.1 Experimental parameter settings

参数	预训练阶段	微调阶段
数据标准化方法	MinMaxScaler	MinMaxScaler
Batch_Size b	128	256
Optimizer	SGD	SGD
Momentum parameter m	0.9	0.9
Learning rate lr	0.001	0.005
Weight decay	0.001	1e-3
Max epochs	75	30

4.2.1 数据标准化

首先，对 SMT-SA 数据集进行数据标准化 (Standardization, 又称 Z-score normalization)，通过将具有不同尺度分布的原始数据缩放为统一的大小，使得每一层的输出在一定范围内固定，这有利于卷积网络进行特征提取，并起到平滑梯度的作用。

数据标准化的过程：首先对数据 x 按均值 μ 中心化后，再按标准差 σ 缩放，数据就会服从为均值为 0，方差为 1 的正态分布 (即标准正态分布)，公式如下：

$$x^* = \frac{x - \mu}{\sigma} \quad (4.6)$$

然后，将 SMT-SA 数据集划分为窗口大小为 256 的滑动窗口，每个实例是一对数据 $xy_i \in \mathbf{XY}^{2 \times 256}$ ， $z_i \in \mathbf{Z}^{256}$ ， xy 数据由减震器的两个传感器数据组成，形成两个长度为 256 的信号通道，而 z 数据是减震器垂直方向的传感器数据，形成一个长度为 256 的信号通道。在预训练阶段，使用了所有的训练数据，这些数据是无标签的。

4.2.2 结果与分析

根据实验设置，首先通过将未标记的数据输入到预训练网络中对 D_{train} 进行训练，然后冻结预训练的编码器网络，并使用 D_f 进行微调训练。由于数据不足，在 D_{train} 和 D_f 上进行了数据增强，以避免过拟合。两阶段训练过程如图4.2和图4.1所示。为了符合工业条件下的数据不平衡情况，对在微调阶段使用的带标签数据进行了数据不平衡实验，结果如表4.2所示。考虑到在工业场景中正样本的数量远远大于负样本的数量，初始正样本数量和负样本数量分别设置为 800 个正样本和 25 个负样本，带标签的负样本数量逐渐减少。在这种情况下，模型仍然保持稳定的性能，符合模型的设计思想。最后，通过实验数据的最后一行，显示模型在很少的带标签数据下仍然能够获得令人满意的结果。

表 4.2 SMT-SA 数据集不同样本数量故障检测实验结果

Table 4.2 Fault detection experiment results on the SMT-SA dataset with different sample sizes

Data imbalance ratio	Data sample	ACC	F1Score	PrecisionScore
40/1	800/25	99.803%	99.833%	99.602%
80/1	800/10	99.724%	99.701%	99.404%
133/1	800/6	99.632%	99.602%	99.206%
400/1	800/2	99.523%	99.502%	99.010%
-	400/2	99.234%	99.206%	98.425%
-	200/2	98.912%	98.909%	97.847%
-	100/2	98.576%	98.522%	97.087%
-	100/10	99.803%	99.833%	99.602%

此外，将预训练前后的特征进行了可视化比较，如图4.4和图4.5所示。红色点和紫色点分别表示正常数据和异常数据。从图中可以看出，预训练后的特征已经准确地分组为类别。在引入显著性模块后，特征的情况如预期般，更多的类内特征聚类和更大范围的类间特征。尽管在预训练后数据已经取得了良好的分类结果，但在此基础上引入显著性模块以增强模型在极端条件下的稳定性。

4.2.3 对比实验

在这一部分，将提出的方法与深度学习最新的技术进行传感器故障检测效果比较。

- Ding 等人^[62] 提出了一种通过对比学习的自监督预训练方法（SSPCL）。
- Zhu 等人^[63] 提出了一种通过时频表示和多尺度卷积神经网络（MSCNN）进行深




图 4.4 预训练后的 PCA 可视化
Fig. 4.4 PCA visualization after pre-training




图 4.5 微调后的 PCA 可视化
Fig. 4.5 PCA visualization after fine-tuning

度特征学习的方法。

为了保证实验的公平性，在自监督模型的微调部分均匀使用了 100 个正样本和 100 个负样本。由于极端样本情况不适用于其他模型，因此无法展示其他模型的性能。

比较的实验结果列在表 4.3 中，本章所提出的模型具有比其他模型更高的准确率，并且接近 100% 的准确率。在工业案例中，误判率应尽量低，最好能够实现 99% 以上的准确率，这是工业实施的要求，所提出的方法展现了优秀的性能。

表 4.3 故障检测对比实验结果

Table 4.3 Results of the fault detection comparative experiment

Method	ACC	F1Score	PrecisionScore
SSPCL	98.835%	98.805%	98.413%
MSCNN	99.234%	99.206%	98.425%
Our Method	99.803%	99.833%	99.602%

4.2.4 消融研究

在这一部分，设计了四个不同的网络，探讨每个模块对整体网络的贡献程度。

- Model1: 由于本论文中模型的骨干网络基于 VGG16_Bn 网络，因此设计了一个自监督模型，使用 VGG16_Bn 网络进行特征提取的预训练，并在微调部分添加了两个全连接层。（在后续没有显著性模块的变体网络设计中，统一使用全连接层代替显著性模块）。
- Model2: 为了验证多层次，消除了交叉传感器模块和显著性模块，即双流网络不

表 4.4 跨传感器故障检测消融实验结果

Table 4.4 Results of the cross-sensor fault detection ablation experiment

Model	VGG16	MD	CM	SM	ACC	F1-score	PrecisionScore
Model 1	✓				90.816%	91.575%	90.821%
Model 2	✓	✓			93.423%	93.809%	88.339%
Model 3	✓		✓		98.233%	98.232%	96.525%
Model 4	✓	✓	✓		99.675%	99.018%	98.039%
Model 5	✓		✓	✓	99.687%	99.602%	99.206%
Our Model	✓	✓	✓	✓	99.803%	99.833%	99.602%

MD=multi-dimension, CM=cross-sensor, SM=saliency module.

再相互生成。

- **Model3**: 为了验证交叉传感器, 消除了多层级模块和显著性模块, 即在解码器网络中, 不再对每个维度进行监督学习, 只在最后一个维度维持监督学习。
- **Model4**: 为了验证多层级和交叉传感器, 消除了显著性模块。
- **Model5**: 为了验证显著性模块, 消除了多层级模块。由于显著性模块是基于交叉传感器设计的, 因此保留了交叉传感器模块。

为确保消融实验的公平性, 仍然使用 D_{train} 作为预训练数据集, 并保持参数不变。在微调部分使用的数据集中, 统一使用 100 个正样本, 其中 50 个样本。表4.4显示了所提出的方法与其他变体之间的性能比较。**Model2** 与原始网络 VGG_Bn 的 **Model1** 进行了比较, 其中多层级模块的自监督特征起到了使生成的特征接近实际值的作用。**Model3** 与 **Model1** 进行了比较, 基于交叉传感器的 **Model4** 集成了 **Model2** 和 **Model3**, 表达了两个模块的融合对模型性能更有益。当前, 模型具有强大的预训练模型用于特征提取, 然后引入显著性模块以实现最佳性能。

4.3 本章小结

在这项工作中, 提出了一种新颖的自监督故障检测算法, 不需要大量标记数据来完成模型训练。该方法基于一个自监督算法, 其预训练任务设计为交叉传感器多层级, 在微调任务中包含显著性模块。交叉传感器和多层级的预训练任务通过彼此生成数据特征和多层级约束来提取不同传感器的数据特征, 从而减小了类内之间的差距, 并为下游微调任务获取了最有益的信息。显著性模块的微调任务捕获了分类器的故障特征, 提高

了分类器的准确性。最后，进行了大量实验证明，所提出的模型优于其他模型，并具有稳定性、高准确性和低误报率。

总结与展望

工作总结

随着智能制造的迅速发展，工业生产智能化已成为不可避免的趋势，对生成设备的状态监控要求也日益提高。在 SMT 中，减震器作为一项关键技术，不仅能够有效缓解锡膏印刷机的震动，而且直接影响着印刷质量，对整体生产过程具有重要影响。本文以减震器为研究对象，旨在解决减震器故障检测中存在的 data imbalance 问题和特征间学习能力弱的问题，为提升减震器故障检测的准确度。主要的研究贡献如下：

(1)、针对减震器数据集稀缺和类别不平衡的问题，本文提出了一种创新性的方法 Attention-GANs 用于。通过该方法，在生成样本数据时全面考虑了传感器间数据特征的相关性和时序特性。Attention-GANs 采用多生成器结构生成数据，确保了跨传感器各数据特征组内的相关性，并通过 Attention 机制捕获数据的时序性，从而更准确地修正各特征间的相关性。实验证明，Attention-GANs 方法能够有效生成更真实的减震器故障数据，为模型更好地学习故障数据的特征分布提供了有效手段，进而提升了整体检测性能。

(2)、针对现有故障检测模型在特征间学习能力较弱的问题，本文引入了一种用于多传感器故障检测的跨传感器生成式自监督学习网络。该网络在多个维度中建模传感器信号，实现了特征之间的相关信息挖掘，有力地捕获了多传感器数据之间的共享特征，并成功减小了通道数据特征之间的差距。通过在下游任务中微调，并引入显著性模块，对少量标记数据进行优化，使警告特征信息更加突出，最终提高了分类器的准确性。实验证明，所提出的方法在性能上明显优于其他先进方法，为提高减震器故障检测的效果和应用推广提供了创新思路。

这些研究成果不仅在理论上拓宽了减震器故障检测的研究领域，同时在实践中为提升减震器故障检测的准确性提供了实际可行的解决方案。对于智能制造系统的发展和生产效率的提升具有积极的意义。

未来工作展望

本文已按计划完成了算法研究任务，然而在研究过程中，仍存在一些局限性，这些问题需要进一步深入研究，具体包括以下几个方面：(1)、在处理数据不平衡的问题时，训练时采用了多个生成式对抗网络的设计，增加了计算的复杂性和训练时间，在后续研究中希望能够优化网络设计，同时提高生成数据还原度。(2)、针对数据特征分组问题，因为减震器数据集特征较少，只采用 Pearson 相关系数就能够很好的进行分类。但如果将模型泛化到其他领域或是其他数据集时，应探究更丰富的特征相关性方法，对数据特征进行更完善的归类。(3)、第四章对减震器数据集进行故障检测模型进行建模，对其他同类数据集的验证较少。未来工作可以对其他数据集进行进一步模型效果验证和其他先进方法比较。

参考文献

- [1] Jiang H, Li C, Li H. An improved eemd with multiwavelet packet for rotating machinery multi-fault diagnosis[J]. *Mechanical Systems and Signal Processing*, 2013, 36(2): 225–239.
- [2] Shao H, Xia M, Wan J, et al. Modified stacked autoencoder using adaptive morlet wavelet for intelligent fault diagnosis of rotating machinery[J]. *IEEE/ASME Transactions on Mechatronics*, 2021, 27(1): 24–33.
- [3] Li X, Yang Y, Shao H, et al. Symplectic weighted sparse support matrix machine for gear fault diagnosis[J]. *Measurement*, 2021, 168: 108392.
- [4] Zhao M, Zhong S, Fu X, et al. Deep residual shrinkage networks for fault diagnosis[J]. *IEEE Transactions on Industrial Informatics*, 2019, 16(7): 4681–4690.
- [5] Le Guennec A, Malinowski S, Tavenard R. Data augmentation for time series classification using convolutional neural networks[C]//ECML/PKDD workshop on advanced analytics and learning on temporal data. 2016.
- [6] Cui Z, Chen W, Chen Y. Multi-scale convolutional neural networks for time series classification[J]. *arXiv preprint arXiv:1603.06995*, 2016.
- [7] Fawaz H I, Forestier G, Weber J, et al. Data augmentation using synthetic data for time series classification with deep residual networks[J]. *arXiv preprint arXiv:1808.02455*, 2018.
- [8] Gao J, Song X, Wen Q, et al. Robusttad: Robust time series anomaly detection via decomposition and convolutional neural networks[J]. *arXiv preprint arXiv:2002.09545*, 2020.
- [9] Steven Eyobu O, Han D S. Feature representation and data augmentation for human activity classification based on wearable imu sensor data using a deep lstm neural network [J]. *Sensors*, 2018, 18(9): 2892.
- [10] Park D S, Chan W, Zhang Y, et al. Specaugment: A simple data augmentation method for automatic speech recognition[J]. *arXiv preprint arXiv:1904.08779*, 2019.
- [11] Semoglou A A, Spiliotis E, Assimakopoulos V. Data augmentation for univariate time

- series forecasting with neural networks[J]. *Pattern Recognition*, 2023, 134: 109132.
- [12] Luo D, Cheng W, Wang Y, et al. Time series contrastive learning with information-aware augmentations[C]//*Proceedings of the AAAI Conference on Artificial Intelligence: volume 37*. 2023: 4534–4542.
- [13] Pérez J, Arroba P, Moya J M. Data augmentation through multivariate scenario forecasting in data centers using generative adversarial networks[J]. *Applied Intelligence*, 2023, 53 (2): 1469–1486.
- [14] Esteban C, Hyland S L, Rätsch G. Real-valued (medical) time series generation with recurrent conditional gans[J]. *arXiv preprint arXiv:1706.02633*, 2017.
- [15] Yoon J, Jarrett D, Van der Schaar M. Time-series generative adversarial networks[J]. *Advances in neural information processing systems*, 2019, 32.
- [16] Neupane D, Seok J. Bearing fault detection and diagnosis using case western reserve university dataset with deep learning approaches: A review[J]. *IEEE Access*, 2020, 8: 93155–93178.
- [17] Wang M, Zhou D, Chen M. Recursive hybrid variable monitoring for fault detection in nonstationary industrial processes[J]. *IEEE Transactions on Industrial Informatics*, 2022.
- [18] Zhang L, Leach M. Evaluate the impact of sensor accuracy on model performance in data-driven building fault detection and diagnostics using monte carlo simulation[C]//*Building Simulation: volume 15*. : Springer, 2022: 769–778.
- [19] Hu Y, Bao W, Tu X, et al. An adaptive spectral kurtosis method and its application to fault detection of rolling element bearings[J]. *IEEE Transactions on Instrumentation and Measurement*, 2020, 69(3): 739–750.
- [20] Huo Z, Martínez-García M, Zhang Y, et al. Entropy measures in machine fault diagnosis: Insights and applications[J]. *IEEE Transactions on Instrumentation and Measurement*, 2020, 69(6): 2607–2620.
- [21] Wang L, Cai G, Wang J, et al. Dual-enhanced sparse decomposition for wind turbine gearbox fault diagnosis[J]. *IEEE Transactions on Instrumentation and Measurement*, 2018, 68(2): 450–461.
- [22] Hao Y, Song L, Ren B, et al. Step-by-step compound faults diagnosis method for equip-

- ment based on majorization-minimization and constraint sca[J]. *IEEE/ASME Transactions on Mechatronics*, 2019, 24(6): 2477–2487.
- [23] Jia F, Lei Y, Lin J, et al. Deep neural networks: A promising tool for fault characteristic mining and intelligent diagnosis of rotating machinery with massive data[J]. *Mechanical systems and signal processing*, 2016, 72: 303–315.
- [24] Shao S, McAleer S, Yan R, et al. Highly accurate machine fault diagnosis using deep transfer learning[J]. *IEEE Transactions on Industrial Informatics*, 2018, 15(4): 2446–2455.
- [25] Sakthivel N, Sugumaran V, Babudevasenapati S. Vibration based fault diagnosis of monoblock centrifugal pump using decision tree[J]. *Expert Systems with Applications*, 2010, 37(6): 4040–4049.
- [26] Rajakarunakaran S, Venkumar P, Devaraj D, et al. Artificial neural network approach for fault detection in rotary system[J]. *Applied Soft Computing*, 2008, 8(1): 740–748.
- [27] Eom Y H, Yoo J W, Hong S B, et al. Refrigerant charge fault detection method of air source heat pump system using convolutional neural network for energy saving[J]. *Energy*, 2019, 187: 115877.
- [28] Xia M, Li T, Shu T, et al. A two-stage approach for the remaining useful life prediction of bearings using deep neural networks[J]. *IEEE Transactions on Industrial Informatics*, 2018, 15(6): 3703–3711.
- [29] Chen S, Meng Y, Tang H, et al. Robust deep learning-based diagnosis of mixed faults in rotating machinery[J]. *IEEE/ASME Transactions on Mechatronics*, 2020, 25(5): 2167–2176.
- [30] Wang J, Fu P, Zhang L, et al. Multilevel information fusion for induction motor fault diagnosis[J]. *IEEE/ASME Transactions on Mechatronics*, 2019, 24(5): 2139–2150.
- [31] Pang X, Xue X, Jiang W, et al. An investigation into fault diagnosis of planetary gearboxes using a bispectrum convolutional neural network[J]. *IEEE/ASME Transactions on Mechatronics*, 2020, 26(4): 2027–2037.
- [32] Zhao X, Jia M, Ding P, et al. Intelligent fault diagnosis of multichannel motor–rotor system based on multimanifold deep extreme learning machine[J]. *IEEE/ASME Transactions on Mechatronics*, 2020, 25(5): 2177–2187.

- [33] AlThobiani F, Ball A, others. An approach to fault diagnosis of reciprocating compressor valves using teager–kaiser energy operator and deep belief networks[J]. *Expert Systems with Applications*, 2014, 41(9): 4113–4122.
- [34] Shao H, Jiang H, Wang F, et al. An enhancement deep feature fusion method for rotating machinery fault diagnosis[J]. *Knowledge-Based Systems*, 2017, 119: 200–220.
- [35] Janssens O, Slavkovikj V, Vervisch B, et al. Convolutional neural network based fault detection for rotating machinery[J]. *Journal of Sound and Vibration*, 2016, 377: 331–345.
- [36] Zhao M, Zhong S, Fu X, et al. Deep residual networks with adaptively parametric rectifier linear units for fault diagnosis[J]. *IEEE Transactions on Industrial Electronics*, 2020, 68(3): 2587–2597.
- [37] Liang X, Duan F, Bennett I, et al. A sparse autoencoder-based unsupervised scheme for pump fault detection and isolation[J]. *Applied Sciences*, 2020, 10(19): 6789.
- [38] Zhang L, Lin J, Shao H, et al. End-to-end unsupervised fault detection using a flow-based model[J]. *Reliability Engineering & System Safety*, 2021, 215: 107805.
- [39] Lu W, Li Y, Cheng Y, et al. Early fault detection approach with deep architectures[J]. *IEEE Transactions on instrumentation and measurement*, 2018, 67(7): 1679–1689.
- [40] Luo B, Wang H, Liu H, et al. Early fault detection of machine tools based on deep learning and dynamic identification[J]. *IEEE Transactions on Industrial Electronics*, 2018, 66(1): 509–518.
- [41] Chen Z, Chen D, Zhang X, et al. Learning graph structures with transformer for multivariate time-series anomaly detection in iot[J]. *IEEE Internet of Things Journal*, 2022, 9(12): 9179–9189.
- [42] Li G, Jung J J. Deep learning for anomaly detection in multivariate time series: Approaches, applications, and challenges[J]. *Information Fusion*, 2023, 91: 93–102.
- [43] Belay M A, Blakseth S S, Rasheed A, et al. Unsupervised anomaly detection for iot-based multivariate time series: Existing solutions, performance analysis and future directions[J]. *Sensors*, 2023, 23(5): 2844.
- [44] Goodfellow I, Pouget-Abadie J, Mirza M, et al. Generative adversarial nets[J]. *Advances in neural information processing systems*, 2014, 27.

- [45] Wang Y, Albrecht C M, Braham N A A, et al. Self-supervised learning in remote sensing: A review[J]. IEEE Geoscience and Remote Sensing Magazine, 2022, 10(4): 213–247.
- [46] Li C, Chen Y, Shang Y. A review of industrial big data for decision making in intelligent manufacturing[J]. Engineering Science and Technology, an International Journal, 2022, 29: 101021.
- [47] Pathak D, Krahenbuhl P, Donahue J, et al. Context encoders: Feature learning by inpainting[C]//Proceedings of the IEEE conference on computer vision and pattern recognition. 2016: 2536–2544.
- [48] Caron M, Bojanowski P, Joulin A, et al. Deep clustering for unsupervised learning of visual features[C]//Proceedings of the European conference on computer vision (ECCV). 2018: 132–149.
- [49] Misra I, Zitnick C L, Hebert M. Shuffle and learn: unsupervised learning using temporal order verification[C]//Computer Vision–ECCV 2016: 14th European Conference, Amsterdam, The Netherlands, October 11–14, 2016, Proceedings, Part I 14. : Springer, 2016: 527–544.
- [50] Korbar B, Tran D, Torresani L. Cooperative learning of audio and video models from self-supervised synchronization[J]. Advances in Neural Information Processing Systems, 2018, 31.
- [51] Misra I, Maaten L v d. Self-supervised learning of pretext-invariant representations[C]//Proceedings of the IEEE/CVF conference on computer vision and pattern recognition. 2020: 6707–6717.
- [52] Srivastava N, Salakhutdinov R. Learning representations for multimodal data with deep belief nets[C]//International conference on machine learning workshop: volume 79. 2012: 978–1.
- [53] Srivastava N, Salakhutdinov R R. Multimodal learning with deep boltzmann machines[J]. Advances in neural information processing systems, 2012, 25.
- [54] Zhang H, Koh J Y, Baldrige J, et al. Cross-modal contrastive learning for text-to-image generation[C]//Proceedings of the IEEE/CVF conference on computer vision and pattern recognition. 2021: 833–842.

- [55] Zhao X, Pang Y, Zhang L, et al. Self-supervised pretraining for rgb-d salient object detection[C]//Proceedings of the AAAI conference on artificial intelligence: volume 36. 2022: 3463–3471.
- [56] Wang C, Ma C, Zhu M, et al. Pointaugmenting: Cross-modal augmentation for 3d object detection[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. 2021: 11794–11803.
- [57] Lu S, Ma R, Sirojan T, et al. Lightweight transfer nets and adversarial data augmentation for photovoltaic series arc fault detection with limited fault data[J]. *International Journal of Electrical Power & Energy Systems*, 2021, 130: 107035.
- [58] Jiang X, Ge Z. Data augmentation classifier for imbalanced fault classification[J]. *IEEE Transactions on Automation Science and Engineering*, 2020, 18(3): 1206–1217.
- [59] Gao X, Deng F, Yue X. Data augmentation in fault diagnosis based on the wasserstein generative adversarial network with gradient penalty[J]. *Neurocomputing*, 2020, 396: 487–494.
- [60] Guo Q, Li Y, Liu Y, et al. Data augmentation for intelligent mechanical fault diagnosis based on local shared multiple-generator gan[J]. *IEEE Sensors Journal*, 2022, 22(10): 9598–9609.
- [61] Lin T Y, Dollár P, Girshick R, et al. Feature pyramid networks for object detection[C]//Proceedings of the IEEE conference on computer vision and pattern recognition. 2017: 2117–2125.
- [62] Ding Y, Zhuang J, Ding P, et al. Self-supervised pretraining via contrast learning for intelligent incipient fault detection of bearings[J]. *Reliability Engineering & System Safety*, 2022, 218: 108126.
- [63] Zhu J, Chen N, Peng W. Estimation of bearing remaining useful life based on multiscale convolutional neural network[J]. *IEEE Transactions on Industrial Electronics*, 2018, 66(4): 3208–3216.

攻读硕士学位期间取得的学术成果

- [1] 会议论文: Zhu H, Kang Y, Zhao Y, et al. Anomaly detection for surface of laptop computer based on PatchCore GAN algorithm[C]//2022 41st Chinese Control Conference (CCC). IEEE, 2022: 5854-5858.
- [2] 发明专利: 赵云波, 朱慧娟, 闫晓辉, 康宇. 基于跨模态生成式学习的液压减震器设备异常检测方法 [P]. 安徽省: CN115859175A,2023-03-28.

致 谢

毕业论文落笔到最后章，深感这三年路之快。回望这三年，从最开始研一的迷茫，研二的拼搏，研三为了毕业论文和找工作的忙忙碌碌，我由衷地对许多人致以最诚挚的感谢。

首先，我最想向我的实践导师赵云波老师和闫晓辉老师表达我最诚挚的敬意。在研究生阶段，赵老师宽厚的性格和平时的耐心指导，让我受益匪浅，对我的性格和未来规划都有着深远的影响。在毕业之际，赵老师为我的论文提供了宝贵的指导与建议，让我在学术和人生道路上都取得了长足的进步。感谢闫老师在我研究生生涯初期指点迷津，明确研究方向，让我往后有了明确的目标为之奋斗。此外，我也要感谢博士师兄刘斌琨和好友王志才，在我研究生阶段的时候，我不断地劳烦他们，从他们那学到大量的知识和技巧，为我的研究工作提供了许多有益的启示。

其次，感谢我的校内导师赵鹏老师。赵鹏老师严谨治学精神在我学术道路上起到了至关重要的作用。虽然我在校内只待了半年，但是每次参加赵鹏老师的组会，我都受益匪浅，学习到了很多，赵鹏老师的研究思维对我在今年两年半的科研工作中产生深远的影响。由衷的表示对赵鹏老师的感谢。

同时，我也要感谢安徽大学和合肥综合性国家科学中心人工智能研究院为我们提供了优良的学术环境和生活环境。在这里，接触到了很多优秀的老师和同学，也参加了很多前沿的讲座，开拓了我的视野，丰富了我的研究生生活。实验室的老师和同学们个个才思敏捷，互帮互助，始终保持团结互助的良好氛围。在实验操作、数据分析，乃至日常交流中，总是毫无保留地伸出援手，让我顺利度过一个又一个难关。

最后，我要感谢我的家人，他们是我坚强的后盾。在我追逐学术梦想的过程中，家人一直默默地支持和关心着我，是他们的理解和支持让我更加坚定地走在研究的道路上。

在此，我还要感谢所有关心、支持和帮助过我的老师、同学、朋友。正是有了你们的支持，我才能够顺利完成这篇论文。感谢每一位在我学术生涯中出现的人，是你们的陪伴和帮助，让我的求学之路不再孤独。愿我们在今后的道路上继续共同努力，共同成长。