

编号 \_\_\_\_\_



南京航空航天大学

# 本科毕业设计（论文）

题 目

基于无监督学习的低转速滚动轴承  
早期故障诊断方法研究

学生姓名	张经纬
学 号	071951108
学 院	通用航空与飞行学院
专 业	交通运输（民航维修工程）
班 级	0719901
指导教师	陈果教授

二〇二三年六月



# 南京航空航天大学

## 本科毕业设计（论文）诚信承诺书

本人郑重声明：所呈交的毕业设计（论文）是本人在导师的指导下独立进行研究所取得的成果。尽我所知，除了文中特别加以标注和致谢的内容外，本设计（论文）不包含任何其他个人或集体已经发表或撰写的成果作品。对本设计（论文）所涉及的研究工作做出贡献的其他个人和集体，均已在文中以明确方式标明。

作者签名：\_\_\_\_\_

日 期： 20\_\_年\_\_月\_\_日

# 南京航空航天大学

## 毕业设计（论文）使用授权书

本人完全了解南京航空航天大学有关收集、保留和使用本人所送交的毕业设计（论文）的规定，即：本科生在校攻读学位期间毕业设计（论文）工作的知识产权单位属南京航空航天大学。学校有权保留并向国家有关部门或机构送交毕业设计（论文）的复印件和电子版，允许论文被查阅和借阅，可以公布论文的全部或部分内容，可以采用影印、缩印或扫描等复制手段保存、汇编论文。保密的论文在解密后适用本声明。

论文涉密情况：

不保密

保密，保密期（起讫日期：\_\_\_\_\_）

作者签名：\_\_\_\_\_

导师签名：\_\_\_\_\_

日 期： 20\_\_年\_\_月\_\_日

日 期： 20\_\_年\_\_月\_\_日



## 摘 要

航空发动机滚动轴承故障频发，严重影响到飞行安全，对其进行故障诊断具有重要的理论意义和工程实用价值。低转速滚动轴承故障诊断技术可以在地面不开车情况下实现航空发动机主轴承故障早期诊断和日常定检，对于航空发动机滚动轴承故障的早期预警尤其重要。

首先介绍了国内外在低转速滚动轴承故障诊断领域的研究现状，以此提出了低转速滚动轴承的重要性和存在的早期故障诊断的相关问题。在此基础上提出本文研究工作。

然后，提出一种利用 DSVDD 实现用于滚动轴承低速诊断的无监督深度学习模型。该方法首先对相关数据进行预处理；然后使用深度支持向量描述方法提取滚动轴承振动信号的特征；最后建立 DCNN 深度学习模型，实现高精度的分类和识别。通过 DSVDD 异常检测方法，基于深度学习和支持向量机通过深度神经网络将输入数据映射到一个高维特征空间中，然后在该空间中使用支持向量描述方法来描述正常样本与异常样本的分布，最终完成了诊断模型的建立。

最后，利用带机匣的航空发动机转子试验器以及某型真实航空发动机的低速转动试验数据对本文方法进行了验证，表明了方法的正确有效性。采集实验数据资料使用实验数据资料检验所提方法的性能和应用性。

本文方法将为航空发动机滚动轴承故障诊断领域提供新的技术途径和方法。

**关键词：**滚动轴承，低转速，故障诊断，无监督学习，深度学习，支持向量数据描述

## ABSTRACT

The frequent occurrence of rolling bearing faults in aviation engines seriously affects flight safety. Therefore, fault diagnosis for them has important theoretical significance and practical engineering value. Low speed rolling bearing fault diagnosis technology can realize early diagnosis and routine inspection of aeroengine main bearing fault without driving on the ground, which is particularly important for early warning of aeroengine rolling bearing fault.

Firstly, the research status in the field of fault diagnosis of low speed rolling bearings at home and abroad was introduced, and the importance of low speed rolling bearings and the related issues of early fault diagnosis were proposed. On this basis, the research work of this article is proposed.

Then, an unsupervised deep learning model for low speed diagnosis of rolling bearings using DSVDD is proposed. This method first preprocesses the relevant data; Then, deep support vector description method is used to extract the features of rolling bearing vibration signals; Finally, establish a DCNN deep learning model to achieve high-precision classification and recognition. By using the DSVDD anomaly detection method, the input data is mapped into a high-dimensional feature space using deep learning and support vector machine through a deep neural network. Then, the support vector description method is used to describe the distribution of normal and abnormal samples in this space, ultimately completing the establishment of the diagnostic model.

Finally, the method proposed in this paper was validated using an aircraft engine rotor tester with a gearbox and low-speed rotational test data of a real aircraft engine, demonstrating its correctness and effectiveness. Collect experimental data and use experimental data to verify the performance and applicability of the proposed method.

This method will provide a new technical approach and method for the fault diagnosis of aircraft engine rolling bearings.

**KEY WORDS:**Rolling bearing, Low speed, Fault diagnosis, Unsupervised learning, Deep learning, Support vector data description

## 目录

第一章 绪论	4
1.1 研究目的与意义	4
1.1.1 研究目的	4
1.1.2 研究意义	4
1.2 国内外研究现状	5
1.2.1 高转速诊断现状	5
1.2.2 低转速诊断现状	5
1.3 问题的提出	7
1.4 本文的主要研究工作	10
第二章 用于滚动轴承低速诊断的无监督深度学习模型	11
2.1 引言	11
2.2 无监督学习方法概述	11
2.2.1 聚类分析	11
2.2.2 SVDD 方法	12
2.2.3 一类支持向量机	12
2.2.4 深度卷积神经网络 DCNN	12
2.3 深度支持向量描述 DSVDD	16
2.3.1 深度支持向量描述方法 DSVDD 原理	16
2.3.2 深度支持向量描述方法 DSVDD 模型架构	16
2.3.3 深度支持向量描述方法 DSVDD 训练与学习	17
2.3.4 基于公开数据集的模型验证	17
2.4 基于深度支持向量描述 DSVDD 的滚动轴承低速诊断	18
2.4.1 诊断流程	18
2.4.2 关键技术	19
2.5 本章小结	19
第三章 低速转动下的滚动轴承试验器试验验证	20
3.1 引言	20
3.2 带机匣的航空发动机转子试验器简介	20
3.2.1 试验器的结构特征及功能	20
3.3 带机匣的航空发动机转子试验器滚动轴承低速转动试验	20
3.4 实验验证结果	22
3.5 本章小结	26
第四章 低速转动下的某真实航空发动机主轴承故障诊断试验验证	28
4.1 引言	28
4.2 实验方案及内容	28
4.3 实验验证结果	28
4.4 本章小结	30
第五章 结论与展望	31
5.1 结论	31
5.2 展望	31
参考文献	32

## 第一章 绪论

### 1.1 研究目的与意义

#### 1.1.1 研究目的

目前，航空发动机主轴承故障频发，严重影响到飞行安全和运行可靠性，图 1.1 为某型航空发动机主轴承失效的典型照片。低转速滚动轴承故障诊断技术是一种重要的机械故障诊断方法，对于在地面不开车情况下航空发动机主轴承故障早期诊断和日常定检具有重要意义。该方法可以有效地监测轴承故障状态，提前发现故障迹象，避免故障扩大化和对设备的损坏。在日常定检中，低转速滚动轴承故障诊断可以对轴承进行全面的检测和评估，为设备的维护和保养提供准确的数据支持。

相比于地面试车诊断和空中机载监测，低转速滚动轴承故障诊断具有更为便捷和方便的特点。地面试车诊断需要将设备移至试车场进行测试，而低转速滚动轴承故障诊断可以在设备正常运行时进行，无需停机检修，节省了时间和成本。空中机载监测需要专门的监测设备和技术支持，而低转速滚动轴承故障诊断则可以通过常规设备和技术实现，具有更广泛的适用性和普及性。因此，该项研究具有广泛的应用前景和推广价值。



图 1.1 某型航空发动机主轴承失效的典型照片

#### 1.1.2 研究意义

滚动轴承在机械设备中的应用非常广泛，其正常运行对于确保设备的可靠性和安全性至关重要。然而，由于工作条件的恶劣性和长期使用的磨损，滚动轴承容易出现故障和损坏，从而导致设备的停机、生产损失甚至事故发生。只有通过及时的诊断和维护，才能保障滚动轴承的正常运行和长期稳定性。



## 1.2 国内外研究现状

### 1.2.1 高转速诊断现状

(1) 国内高转速滚动轴承早期故障诊断的研究现状：

基于振动信号的故障诊断方法：通过分析高转速滚动轴承的振动信号，提取故障特征，以实现故障诊断，该方法具有实时性和高精度性，但需要对信号进行复杂的处理和分析。

基于声音信号的故障诊断方法：通过分析高转速滚动轴承的声音信号，提取故障特征，该方法具有实用性和高精度性，但需要对信号进行复杂的处理和分析。

(2) 国外高转速滚动轴承早期故障诊断的研究现状：

国外研究者在高转速滚动轴承早期故障诊断方面已经取得了一定的进展。主要研究方法包括基于振动信号分析、基于声音信号分析等多种方法。

在振动信号分析方面，国外研究者提出了多种特征提取与选择方法，如时域特征、频域特征、小波包特征和统计特征等，以提高滚动轴承故障诊断的准确性和效率。

在声音信号分析方面，国外研究者主要采用频谱分析、小波分析等方法，以提取故障特征。同时，也有研究者采用声音信号与振动信号相结合的方法，以提高故障诊断的准确性和可靠性。

### 1.2.2 低转速诊断现状

在国内，针对低转速滚动轴承早期故障诊断的研究已经取得了一定的进展。以下是国内研究现状的详细介绍：

何沿江等在自相关预处理算法的基础上，利用独立分量分析和支持向量机相结合的算法对轴承故障声发射信号进行分析，结果表明该方法可以准确地识别滚动轴承的故障模式<sup>[1]</sup>。张晓涛等通过利用快速谱峭度算法设计的滤波器，将齿轮箱声发射信号经奇异值分解后进行滤波处理，最后作能量算子解调分析，并通过仿真和实验数据验证了该方法的有效性<sup>[2]</sup>。

侯伟针对低速轴承振动信号监测中，由于采样频率较高而导致的数据量较大的问题，提出了峰值保持降采样的算法，通过对实验数据进行分析，成功实现了对低速轴承内、外圈故障的诊断，验证了该方法的有效性<sup>[4]</sup>。

国内的研究者们利用机器学习算法实现滚动轴承故障诊断的研究取得了显著进展<sup>[5]</sup>。支持向量机（Support Vector Machine, SVM）等传统机器学习方法被大量使用于特征分类和故障识别<sup>[6]</sup>。此外，还有一些研究采用集成学习方法，如 AdaBoost 和 XGBoost 等，用于

提高分类性能和模型的鲁棒性<sup>[7]</sup>。

国内研究者还关注滚动轴承故障预测和预警方面的研究，以提高滚动轴承的可靠性和安全性。在这方面，研究者们采用了多种方法，如基于物理模型的预测方法、基于统计学的预测方法等，以提高滚动轴承故障的预测准确性和及时性。

以下是国外在低转速滚动轴承早期故障诊断方面研究现状的详细介绍：

(1) 特征提取与选择方法：Choudhury 对轴承声发射信号进行研究<sup>[8]</sup>，提出了振铃计数和峰值时间分布图相结合的算法，实现了对变故障尺寸的轴承滚子和内圈的故障诊断<sup>[9]</sup>。还有一些方法包括统计特征、时域特征和频域特征等。下列是滚动轴承发生外圈、内圈、滚动体故障状态下对应的典型时域波形<sup>[10]</sup>：




图 1.2 发生外圈故障时的典型时域波形




图 1.3 发生内圈故障时的典型时域波形




图 1.4 发生滚动体损伤时的典型时域波形

(2) 深度学习方法的应用：基于机器学习的方法在近年来得到了广泛的关注和应用，其主要思想是通过训练模型，自动识别和分类滚动轴承的故障类型和位置。卷积神经网络（Convolutional Neural Network, CNN）被广泛应用于滚动轴承故障的特征获取和分类。卷积过程示意图如图 1.5。CNN 能够从原始的振动信号中学习到有关故障模式的高级特征，进而实现对滚动轴承的准确诊断。此外，还有一些研究基于深度学习模型改进的方法，如使用残差模块（Residual Block）来增强模型的性能和稳定性。




图 1.5 卷积过程示意图

(3) 综合方法：国外的研究工作注重跨领域合作和实际应用。研究者们与机械工程师、领域专家和工业界合作，共同开展滚动轴承故障诊断的研究。他们利用实际工况下的数据集进行实验和验证，评估算法的性能和适用性。此外，还有一些研究关注滚动轴承故障预测和健康（Recurrent Neural Network, RNN）的预测。这些模型能够利用历史故障数据和振动信号，进行故障趋势分析和预测，为设备维护和故障预防提供支持。

综上所述，国内外的研究者在低转速滚动轴承早期故障诊断领域开展了丰富的研究工作。传统机器学习方法和深度学习方法被广泛应用于故障诊断任务，通过提取有效的特征和利用高级模型实现了一定程度的成功<sup>[11]</sup>。

### 1.3 问题的提出

(1) 针对航空发动机主轴承故障诊断研究工作较少，这给实际应用带来了一定的挑战。目前，主要的诊断方法是基于振动信号的分析 and 处理，但是由于航空发动机的特殊性，其振动信号存在多种干扰因素，导致诊断结果不够准确和可靠。图 1.6 为典型的航空发动机主轴承结构图，需要通过低转速转动诊断出角接触球轴承结构图，需要通过低转速诊断出角接触球轴承的典型故障。




图 1.6 涡轮风扇发动机内部的部分轴承

(2) 在低转速的情况下，主轴承的故障特征频率存在难于检测的问题。这是因为低转速下主轴承的振动信号幅值较小，故障特征频率的信噪比较低，难以准确检测和提取。因此，需要采用更加敏感和准确的检测方法，以提高主轴承故障的诊断准确率和可靠性。

(3) 在进行手动摇转下转速难于保证均匀，使得主轴承故障特征更加难于提取。手动摇转是一种常见的低速旋转测试方法，但是由于人工操作的不稳定性，转速难以保证均匀，导致振动信号的频谱分布不均匀，主轴承故障特征的提取更加困难。因此，需要采用更加高效和准确的测试方法，以提高主轴承故障的诊断效率和准确性。

在传统的故障诊断方法中，通常需要基于专家经验和人工特征提取来判断滚动轴承的健康状态。然而，这种方法存在着依赖于专家经验的局限性和特征提取的主观性，无法全面准确地评估滚动轴承的早期故障状况。总体上，利用数据驱动的滚动轴承故障诊断方法可以分为三类。这三类方法分别是基于信号时域、频域、时频域分析等方法，机器学习方法以及二者结合的综合方法<sup>[12]</sup>，如图 1.7 所示：

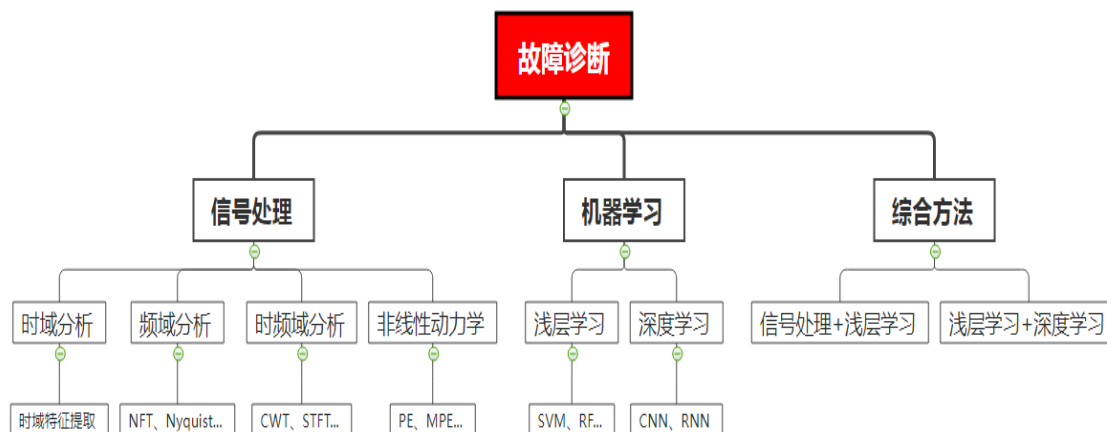


图 1.7 利用数据驱动故障诊断方法的分类

监督学习和无监督学习是机器学习中两种常见的学习方式。它们的区别在于学习过程中是否需要标记好的数据。

监督学习需要标记好的数据，即训练集中每个样本都有已知的标签或输出<sup>[13]</sup>。在监督学习中，算法通过学习输入和输出之间的关系来建立模型，然后利用该模型对新的输入进行预测。常见的监督学习算法包括分类、回归和神经网络等<sup>[14]</sup>。

相比之下，无监督学习不需要标记好的数据，即训练集中每个样本没有已知的标签或输出。在无监督学习中，算法通过学习数据之间的内在结构和模式来建立模型，然后利用该模型对新的数据进行分析和探索。常见的无监督学习算法包括聚类、降维和关联规则挖掘等<sup>[15]</sup>。

如图 1.8，在故障诊断中会提取信号的多个特征，图中横坐标与纵坐标分别表示样本特征的两个维度，图中使用两个维度进行示意。总的来说，无监督学习相比监督学习具有更广泛的应用领域、更好的数据探索和分析能力、更好的适应性和鲁棒性等优势。




图 1.8 监督学习与无监督学习区别

通过无监督学习的低转速滚动轴承早期故障诊断方法的研究，我们可以深入了解滚动轴承的故障机理和诊断方法，为相关领域的研究提供重要的参考和支持。首先，无监督学习方法能够从未标记的数据中学习和发现滚动轴承故障的潜在模式和规律，避免了依赖大量标记样本的限制。这为大规模滚动轴承故障诊断提供了可行的解决方案，减少了人力和时间成本。

其次，基于无监督学习的方法能够充分利用滚动轴承的运行数据，实现对多维特征的自动提取和学习，从而更全面、准确地评估滚动轴承的健康状态。这不仅有助于及早发现滚动轴承的早期故障迹象，还能提供有效的预警和预防措施，避免故障的扩大和设备的停机。

此外，基于无监督学习的方法具有较强的泛化能力，可以适应不同类型和规模的滚动

轴承系统。这为不同行业和领域的工程师和维护人员提供了通用的故障诊断工具，有助于提高设备的可靠性和运行效率。

#### 1.4 本文的主要研究工作

本文的主要研究工作包括以下几个方面：

(1) 提出了基于无监督学习的低转速滚动轴承早期故障诊断方法。利用深度学习来实现主轴承故障诊断，避免人工提取故障特征频率，克服转速波动带来的诊断困难问题通过无监督学习的方法，不需要事先标记的故障样本，可以从轴承振动信号中自动学习故障特征，实现对早期故障的准确诊断。

(2) 针对工程实际问题，在缺乏大量故障样本的情况下，仅仅利用正常样本进行机器学习获取故障分类边界，实现故障异常检测，因此，利用无监督深度学习方法来实故障的异常检测。

(3) 利用带机匣的航空发动机转子试验器进行试验验证。该实验可得到大量真实的轴承振动信号，具有较高的代表性和可信度。

(4) 利用实际航空发动机的低速转动下的机匣振动信号进行试验验证，能够有效验证本文提出的故障诊断方法的准确性。

## 第二章 用于滚动轴承低速诊断的无监督深度学习模型

### 2.1 引言

本章介绍了机器学习中的无监督学习方法，包括聚类分析、SVDD方法和一类支持向量机等与深度卷积神经网络 DCNN 的基本概念，提出了一种利用 DSVDD 实现用于滚动轴承低速诊断的无监督深度学习模型。

### 2.2 无监督学习方法概述

无监督学习是机器学习中的一个方式，其目的是从未标示的数据中发掘出潜在的模式和构型<sup>[16]</sup>。与监督学习不同，无监督学习不需要已知的标签或目标变量，而是通过对数据本身的分析来发现模式。简而言之，无监督学习方法可以帮助我们从未标记的数据中发现潜在的模式和结构，从而对数据进行更深入的分析 and 理解。

#### 2.2.1 聚类分析

聚类分析是一种无监督学习方法，其主要是通过对数据进行聚类，将相似的数据样本划分为同一类别，不相似的数据样本划分为不同类别。聚类分析的原理是将数据样本划分为不同的类别，使得同一类别内的数据样本相似度高，不同类别之间的相似度低<sup>[17]</sup>。聚类分析的主要思想是基于相似性原理，即相似的数据样本应该被划分为同一类别。聚类分析的应用范围较广，包括数据挖掘、模式识别、生物信息学等方向。




图 2.1 聚类分析示意图

### 2.2.2 SVDD 方法

SVDD 方法是基于支持向量机 (SVM) 的异常情况检测办法。它通过在正常样本空间中构建一个最小的超球体来描述正常样本的分布, 从而检测出离群点。能够自动地学习异常的特征和规律, 同时还具有更加灵活和可控的特点, 从而在异常检测方面具有较大的优势。




图 2.2 SVDD 方法示意图

### 2.2.3 一类支持向量机

一类支持向量机 (One-Class SVM) 是一种基于 SVM 的无监督学习方法。它的目标是将数据集中的所有样本都划分到同一个类别中, 即正例类别。一类支持向量机通常用于异常检测、数据预处理、数据压缩等领域。

### 2.2.4 深度卷积神经网络 DCNN

DCNN (Deep Convolutional Neural Network) 是一类深度学习模型, 它是 CNN (图 2.3) 的一种扩展, 主要用途用作音图识别、自然语言处理等工作<sup>[18]</sup>。DCNN 模型具有多个卷积层和池化层, 可以自动提取图像或文本中的特征, 从而实现高精度的分类和识别。






图 2.3 CNN 方法示意图

DCNN 模型是多个卷积层、池化层和全连接层共同组成的神经网络模型<sup>[19]</sup>。在卷积层中通过卷积操作对输入的图像或文本进行特征提取，池化层则用于减少特征图的维度，全连接层是用来将特点态射到归纳结果<sup>[20]</sup>。DCNN 模型可以通过反向传播算法进行训练，不断优化模型参数，从而实现高精度的分类和识别<sup>[21]</sup>，下面是对 DCNN 各组成部分的详细介绍：

(1) 卷积核：这是卷积神经网络中卷积层的重要组成部分，作用是对输入的图像数据完成卷积运算以提取特征。卷积运算是指卷积核使用的算法，故名卷积层<sup>[22]</sup>。卷积运算包括连续卷积与离散卷积，但由于卷积神经网络的输入图像像素是离散的数据点，因此所使用的运算为离散卷积运算。

$$y(n) = x(n) * h(n) = \sum_{i=0}^{N-1} x(i)h(n-i) \quad (2-1)$$

公式中  $y(n)$  为特征映射， $x(n)$  为输入图像， $h(n)$  为卷积核函数。

公式(2-1)表示的为一维卷积核，下式对二维卷积核进行介绍。假定  $K(m,n)$  是二维卷积核， $l(i,j)$  是输入图像，则卷积运算如式：

$$S(i,j) = (l * K)(i,j) = \sum_m \sum_n l(m,n)K(i-m,j-n) \quad (2-2)$$

因卷积运算存在可交换性，式(2-2)可写做：

$$S(i,j) = (l * K)(i,j) = \sum_m \sum_n l(i-m,j-n)K(m,n) \quad (2-3)$$

$m,n$  为卷积核长与宽的大小。卷积层中，考虑对卷积运算的特征结果完成一个偏置，则公式如下：

$$x_f^l = f \left( \sum_{i \in M_j} x_i^{l-1} * k_{i,j}^l + b_j^l \right) \quad (2-4)$$

$x_j^l$ 表示第1层（卷积层）输出的第j个特征图，卷积层于输出前需要完成  $f(x)$  激活函数运算， $M_j$ 为输入特征图，\*是卷积数学符号， $k_{i,j}^l$ 是卷积核的权重矩阵。运算过程中，引入相应偏置b对应输出图，采集输入图像的深层特征并更多的存留特征，完成去噪，最终所得特征说服力更强，使得故障识别和分类的准确性提高。

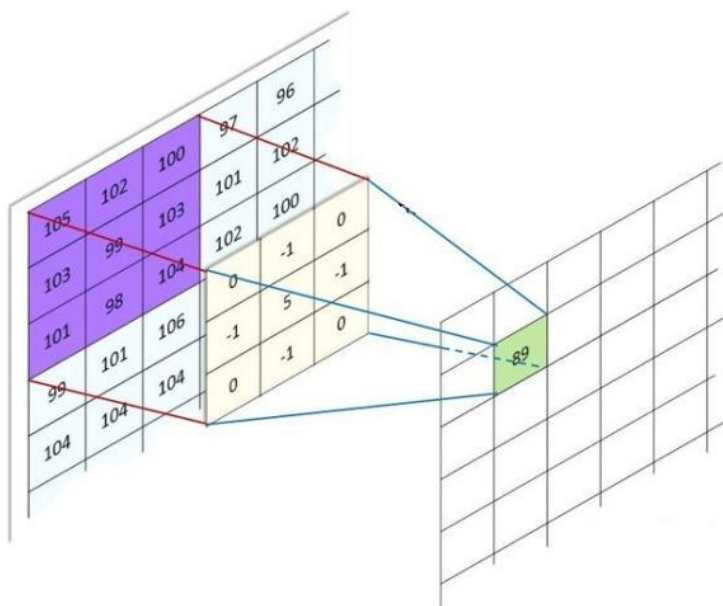


图 2.4 卷积示意图

(2) 池化层：池化层主要是对特征图进行降维，保证特征图拥有平移不变性。池化层能够减少 CNN 中特征图的参数数量，减少非重点数据，减轻计算量。一般情况下，不更新权重，仅对池化层进行研究下降。不重复的区域由于卷积层的池化作用，生成的图像在两个维度中可下降一倍。池化层的过滤器使用了一种更为方便的平均值或者最大值的运算。

公式如下：

$$x_j^l = f \left[ \beta_j^l \text{down}(x_i^{l-1}) + b_j^l \right] \quad (2-5)$$

$x_j^l$ 为池化层输出的j个特征图， $\text{down}(x)$ 为池化函数，对于每个输出图都会有给定的b和 $\beta_j^l$

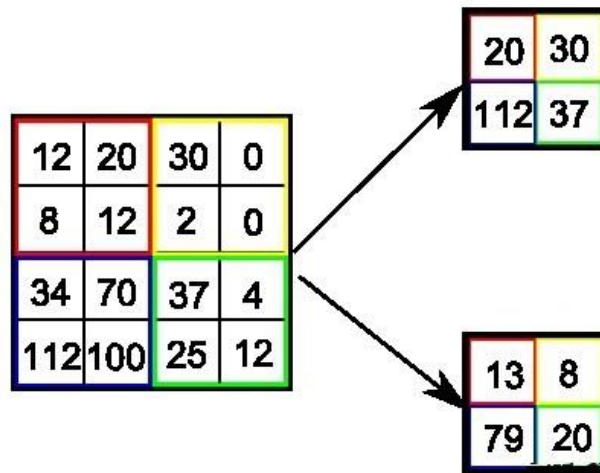


图 2.5 池化示意图

(3)全连接层: 输入数据经卷积层和池化层完成交替传播后, 运用全连接层完成分类。全连接层上, 输入是全部特征图所得的一维特征向量, 经过加权求和通过激活函数后有公式如下:

$$y^k = f(w^k x^{k-1} + b^k) \quad (2-6)$$

K 表示网格层的序号;  $y^k$  表示全连接层的输出;  $x^{k-1}$  表示一维特征向量;  $w^k$  表示权重系数;  $b^k$  表示权重系数。




图 2.6 全连接层示意图

DCNN 模型已经被大量使用在图像判别、语音判别、自然语言处置等方向。在图像判别方向, DCNN 模型可以实现高精度的物体识别、人脸识别、场景识别等任务。在语音判别方向, DCNN 模型可以实现高精度的语音识别和语音合成。在自然语言处置领域, DCNN 模型能够实现文本归纳、程式设计等方向。

## 2.3 深度支持向量描述 DSVDD

### 2.3.1 深度支持向量描述方法 DSVDD 原理

深度支持向量描述方法 (DSVDD) 是一种基于深度学习和支持向量机的异常检测方法。深度支持向量描述方法的原理是通过借助深度神经网络将输入数据映射到一个高维特征空间中, 找到一个也就是包含全部和大部分数据的最小超球, 然后在该空间中使用支持向量描述方法 (SVDD) 来描述正常样本的分布, 检出离群点。

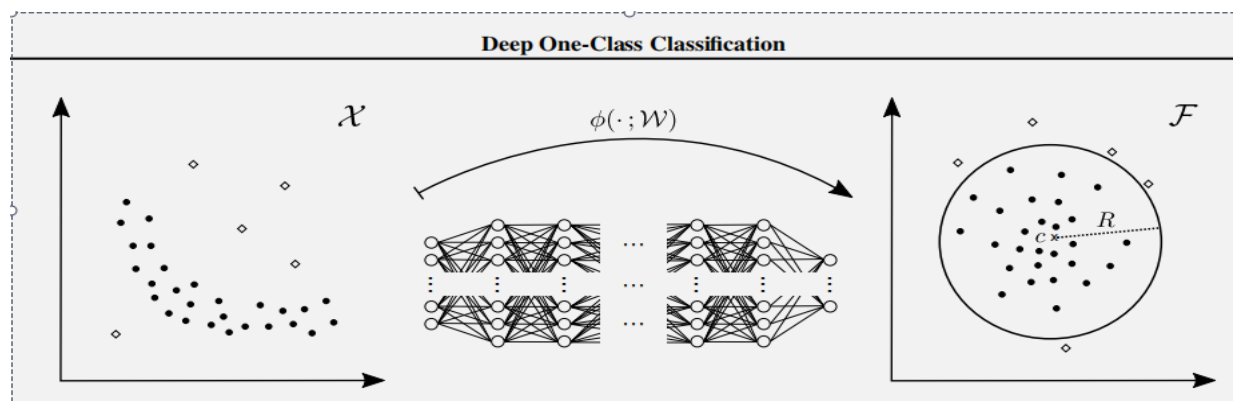


图 2.7 DSVDD 方法示意图

### 2.3.2 深度支持向量描述方法 DSVDD 模型架构

深度支持向量描述方法 (Deep Support Vector Data Description, DSVDD) 是一个基于深度学习的异常测试工具, 它利用支持向量数据描述的思想, 通过深度神经网络来学习特征表示和反常判别。

DSVDD 模型架构处理数据信号过程示意图如图 2.8; 各部分功能如下:

(1) 输入层: 输入数据经过预处理后送入网络中, 通常是将数据进行标准化或归一化处理。

(2) 特征提取层: 使用多个卷积层和池化层来采集输入数据的特征表示。这些层可以通过反向传播算法进行训练, 以最大化模型的性能。

(3) 全连接层: 将特征提取层的输出连接到一个或多个全连接层中, 以进一步提取特征并减少维度。

(4) 输出层: 最后一层是一个单独的节点, 用于输出异常得分。该节点的输出值越接近 1, 表示输入数据越可能是异常数据。

(5) 损失函数: DSVDD 使用的损失函数是基于 SVDD 的, 它通过最小化到中心点的距离来学习一个球形的边界。

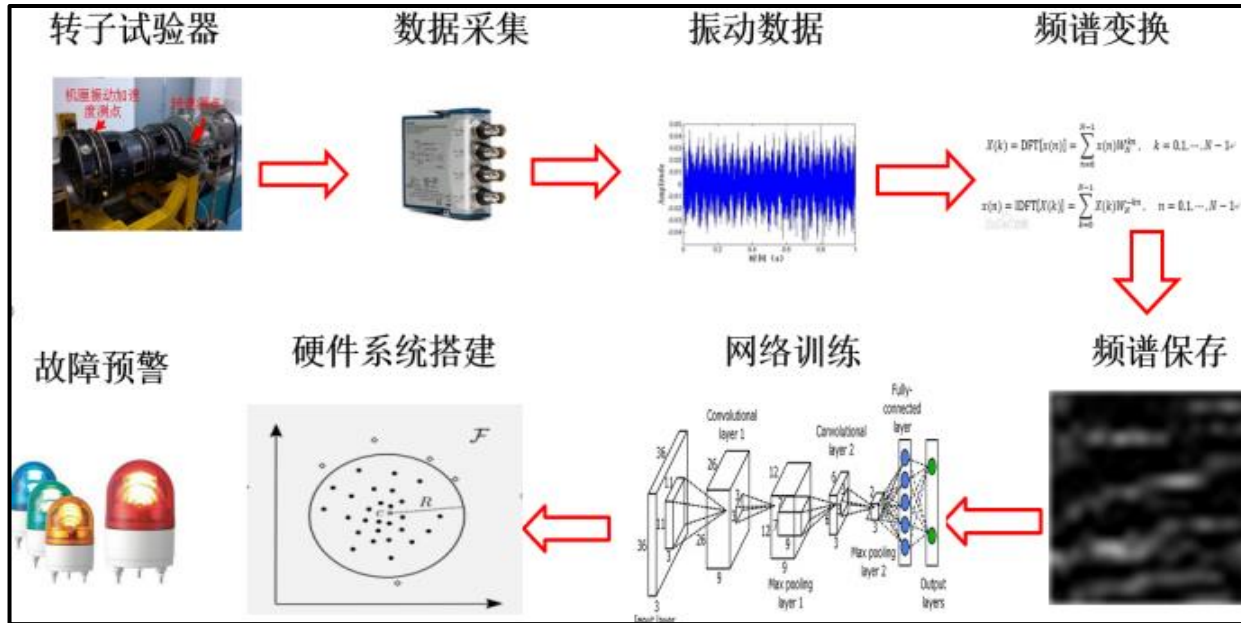


图 2.8 DSVDD 模型架构示意图

### 2.3.3 深度支持向量描述方法 DSVDD 训练与学习

DSVDD 的训练与学习分为以下几个步骤：

(1) 数据准备：首先需要准备训练数据和测试数据。训练数据应该包含正常数据和异常数据，测试数据只包含正常数据。

(2) 特征提取：使用深度神经网络对训练数据进行特征提取，将数据转换为高维特征空间中的向量。这些特征向量将用于训练 DSVDD 模型。

(3) 模型训练：使用训练数据训练 DSVDD 模型。训练过程中需要设置模型的超参数，如学习率等<sup>[23]</sup>。

(4) 模型评估：使用相关数据来判定模型功能。根据模型输出的异常得分，可以计算出模型的精度、召回率、F1 值等指标。

(5) 模型优化：基于模型判定结果，进行调整。可以尝试调整超参数、增加或减少网络层数等方法来提高性能。

需要注意的是，在训练 DSVDD 模型时，需要保证正常数据和异常数据的比例合适。如果正常数据占比过高，模型可能会出现偏差，无法正确识别异常数据；如果异常数据占比过高，模型可能会过于保守，将正常数据误判为异常数据。因此，在数据准备阶段需要仔细考虑数据的选择和处理。

### 2.3.4 基于公开数据集的模型验证

深度支持向量描述方法已经在多个公开数据集上进行了模型验证，以下是其中的一些

例子:

(1) KDDCup99 数据集: 这是一个常用的网络入侵检测数据集, 包含正常数据和多种攻击类型的非正常信息。在这个数据集上, DSVDD 方法与其他异常检测方法相比表现良好, 可以准确地检测出各种类型的攻击。

(2) MNIST 数据集: 这是一个手写数字识别数据集, 包括六万个训练样本以及十万个测试样本。在这个数据集上, DSVDD 方法可以准确地识别出异常数字, 如写得非常歪斜或非常模糊的数字。

(3) CIFAR-10 数据集: 这是一类包含十个种类的图像分类数据集, 每个类型包含六千个 32x32 像素的彩色图像。在这个数据集上, DSVDD 方法可以准确地检测出异常图像, 如包含不同类型物体的图像或非常模糊的图像。

(4) NSL-KDD 数据集: 这是一个网络入侵检测数据集, 包含正常数据和多种攻击类型的异常数据。在这个数据集上, DSVDD 方法可以准确地检测出各种类型的攻击, 包括 DoS、Probing、R2L 和 U2R。

DSVDD 方法在各种数据集上都表现出了很好的性能, 可以准确地检测出各种类型的异常数据。但是, 需要注意的是, DSVDD 方法的性能还受到许多因素的影响, 如数据预处理、网络结构、超参数等。因此, 在使用 DSVDD 方法时, 需要根据具体情况进行调整和优化。

## 2.4 基于深度支持向量描述 DSVDD 的滚动轴承低速诊断

### 2.4.1 诊断流程

(1) 数据采集: 使用振动传感器或加速度计等传感器提取滚动轴承的振动讯号。

(2) 特征提取: 对采集到的振动信号进行预处理, 提取出频域和时域的特征参数<sup>[24]</sup>。

(3) 数据标注: 对采集到的数据进行标注, 将正常运行状态和故障状态进行区分, 以便后续的模式训练和测试。

(4) 模型训练: 使用 DSVDD 算法对标注后的数据进行训练, 构建滚动轴承的异常检测模型。

(5) 模型测试: 使用未标注的数据对模型进行测试, 检测滚动轴承的运行状态, 判断是否存在异常。

(6) 异常诊断: 如果模型检测到滚动轴承存在异常, 根据异常的特征参数进行诊断, 判断异常的类型和严重程度。

(7) 维修建议: 根据异常诊断的结果, 提出维修建议, 指导工程师进行维修和保养操

作，以保证滚动轴承的正常

## 2.4.2 关键技术

(1) 预处理：预处理是指对原始数据进行处理，以提取有用的特征<sup>[25]</sup>。在滚动轴承低速诊断中，预处理通常包括信号去噪、特征提取和特征选择等步骤。信号去噪是为了去除噪声干扰，以保证后续特征提取的准确性；特征提取是为了从原始信号中提取出有用的特征，常用的特征包括时域特征、频域特征和小波特征等；特征选择则是为了采集到最具代表性的数据。

(2) 参数优化：参数优化是指利用改变模型的参数，以提高模型的性能。优化参数的方法包括网格搜索、遗传算法和粒子群优化等<sup>[26]</sup>。

(3) 训练与学习：训练与学习是指使用已经处理好的数据，通过 DSVDD 模型进行训练和学习，以建立模型。

(4) 测试与诊断：测试与诊断是指使用 DSVDD 模型对新的数据进行测试和诊断。在测试和诊断过程中，需要根据 DSVDD 模型的输出结果，对滚动轴承的运行状态进行判断和诊断。常用的诊断方法有时域、频域和能量谱分析等。

## 2.5 本章小结

本章介绍了机器学习中的无监督学习方法，包括聚类分析、SVDD 方法和一类支持向量机。同时，本章还介绍了深度卷积神经网络 DCNN 的基本概念、模型和应用，并介绍了深度支持向量描述方法 DSVDD 的原理以及基于数据集的模型验证与关键技术。无监督学习可以帮助我们从未标记的数据中发现潜在的模式和结构，而 DCNN 和 DSVDD 等深度学习方法则可以实现更高精度的分类和识别，为实际应用提供了更多的可能性。

## 第三章 低速转动下的滚动轴承试验器试验验证

### 3.1 引言


本章利用转子-滚动轴承-机匣试验器对航空发动机中存在的几种代表性故障进行试验器演示和与不同工作状态情况下的模拟。通过相关实验数据进行分析，完成了低速转动下的滚动轴承试验器的实验验证。

### 3.2 带机匣的航空发动机转子试验器简介

转子-滚动轴承-机匣试验器主体部分主要由安装台架、电机、基础平台及齿轮传动系统等有关部件组成。试验器实物图（图 a）与 3D 结构示意图（图 b）如下：



（a）试验器实物图



（b）试验器 3D 结构示意图

#### 3.2.1 试验器的结构特征及功能

试验器可以对发动机中可能出现的几种典型故障进行试验器演示和与不同工作状态情况下的模拟，主要包括如下几种类别：

（1）涡轮叶片与机匣封严间隙处的碰撞与摩擦，可能表现为点碰撞、局部碰撞、轻度或重度碰撞等不同形式；

（2）封严蓖齿间的碰撞与摩擦，影响涡轮机械正常运行的情况；

（3）轴承损坏导致涡轮机械的振动特性发生变化；

（4）前后支承不同心状况导致的机械失衡、振动加剧等问题；

（5）支承刚度的变化影响机械的正常运行的问题

### 3.3 带机匣的航空发动机转子试验器滚动轴承低速转动试验

（1）实验器材以及测点布置方案：为研究滚动轴承在不同尺寸故障下运行时的信号特点，在南京航空航天大学智能诊断与专家系统研究室于 2022 年 7 月至 2022 年 12 月，利



用带机匣的航空发动机转子模拟实验器和配套的振动信号采集系统（如图 3.1）进行了滚动轴承故障模拟试验及数据采集，完成了预制内外圈故障尺寸为 2.2mm 的试验。




图 3.1 带机匣的航空发动机转子模拟实验器

(2) 传感器型号及技术指标：采用 B&K 加速度传感器采集轴承振动信号的传感器为由丹麦 B&K 公司研制的 4508 型加速度传感器，其灵敏度为 9.782mV/g，该传感器如图 3.2 所示。

(3) 数据采集器指标：试验所用采集卡为扬州晶明科技有限公司生产的 JM5937USB(8CH)数据采集器。该设备为一个高效能数据采集分析的动态信号测试分析系统，利用 USB2.0 端口与计算机完成交互功能，实现电压/IEPE 信号的整理和数据的提取。系统可实现八台设备共同运作，设备间通过级联实现同步工作。通道内部均设置单独 24bit ADC，确保每通道在 128 千赫兹的采样率下同时采集。该系统如图 3.3 所示。



图 3.2 4508 加速度传感器实物图



图 3.3 JM5937 动态信号测试分析系统

在本次试验中，以 32k 两种采样频率获取了各个试验轴承在不同转速下的数据，其中 MOD1\_CH1 为转速通道，MOD1\_CH2 为机匣垂直和 MOD1\_CH3 为机匣水平，MOD1\_CH4 为轴承座的振动测点。

(4) 振动信号采集系统：试验所用振动信号采集系统为航空发动机滚动轴承失效监控与寿命评估系统 BLES(Aero-Engine Rolling Bearing Fault Monitoring and Life Evaluation

System)。该系统的功能包括滚动轴承数据采集与转换、状态监控与评估、故障诊断、寿命预测、机器学习、失效仿真等<sup>[27]</sup>。其界面如图 3.4 所示。

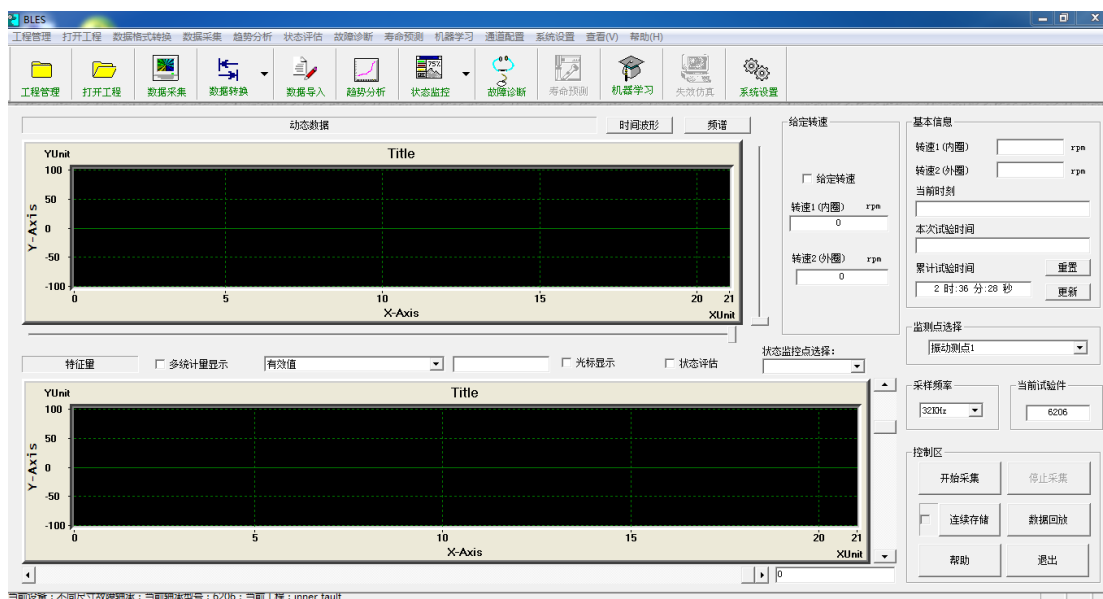


图 3.4 BLES 主界面示意图

### 3.4 实验验证结果

本文试验中采用 GPU 为 NVIDIA GTX1660 6G; i5-9600K 处理器; 运行系统为 Windows10; 8G 内存; 编程语言为 python3.7; 深度学习模型的框架均为 Pytorch1.11; 批处理样本量为 64; 迭代轮数为 200; 采用 Adam 优化算法, 学习率为 0.001, 为证明在低转速状态下机匣测点信号故障特征的微弱性和较难使用信号分析方法获取该微弱特征。因此使用恒定转速下轴承座测点和机匣测点的振动信号完成数据比较。由于转速低的原因, 在实验过程中使用了 5 秒的信号完成有关分析。本次实验数据结果分两次采集, 实验结果列表如表 3-1 所示:

表 3-1 滚动轴承故障数据列表

日期	采样率	故障模式	损伤尺寸	转速	采样时间	数据点数	样本数
2022.7 -2022.12	25.6kHz	内圈故障	2.2mm	120rpm	10s	256000	每种情况下约 20个
		外圈故障	2.2mm				

保持架的故障特征频率计算公式:

$$f_c = \frac{f_r}{2} \left( 1 - \frac{d}{D} \cos \alpha \right) \quad (3.1)$$

滚动体的故障特征频率计算公式:

$$f_b = \frac{D}{2d} \left[ 1 - \left( \frac{d}{D} \right)^2 \cos^2 \alpha \right] f_r \quad (3.2)$$

外圈的故障特征频率计算公式：

$$f_{out} = z(f_r - f_c) = \frac{z}{2} \left[ 1 - \frac{d}{D} \cos \alpha \right] f_r \quad (3.3)$$

内圈的故障特征频率计算公式：

$$f_{in} = z(f_r + f_c) = \frac{z}{2} \left[ 1 + \frac{d}{D} \cos \alpha \right] f_r \quad (3.4)$$

其中表示滚动体直径；表示轴承的节径； $\alpha$ 表示接触角的大小； $z$ 表示滚动体个数

可以得到对于内圈故障，其故障特征频率为 10.86Hz，两测点位置的频谱中无法发现明显的谱线可以对应。外圈故障情况下，其所对应的故障特征频率为 7.14Hz，两测点位置的频谱中同样无法发现明显的故障特征频率。通过以上分析可知，在低转速下，若直接采用传统的信号分析方法，很难通过寻找特征频率的方法实现轴承的故障检测。

下面将各类情况根据实验所采集数据得到频谱图如图 3.5-图 3.10 所示。




图 3.5 正常状态下根据所测数据得到的频谱图




图 3.6 外圈故障状态下根据所测数据得到的频谱图




图 3.7 内圈故障状态下根据所测数据得到的频谱图




图 3.8 采取手摇方式正常状态下根据所测数据得到的频谱图




图 3.9 采取手摇方式外圈故障状态下根据所测数据得到的频谱图




图 3.10 采取手摇方式内圈故障状态下根据所测数据得到的频谱图

在低速转动下，滚动轴承故障特征频率的不可检测性是由以下因素造成的：

(1) 低转速下的故障特征频率较低，难以被传感器检测到。滚动轴承的故障特征频率通常与其转速成正比，低速下故障特征频率较低，可能会掩盖在噪声信号中，难以被传感器检测到。

(2) 低转速下，滚动轴承的振动幅度较小。滚动轴承的振动信号通常较小，低转速下更容易被环境噪声掩盖，从而难以检测到故障特征频率。

(3) 低转速下，信号采样率可能不足。在低转速下，信号变化缓慢，需要更高的采样率才能准确地捕捉到信号的变化。如果采样率不足，则可能会导致故障特征频率的不可检测性。

(4) 低转速下，信号可能受到信号处理器的限制。信号处理器的带宽可能会受到限制，从而无法捕捉到低频信号，导致故障特征频率的不可检测性。

由于低速转动下的滚动轴承故障特征频率的不可检测性，需要采用更高灵敏度的传感器、更高的采样率和更先进的信号处理技术来提高信号的检测能力和准确性。

在实验中我们可以发现不同转速和不同日期下的故障识别率可能会受到多种因素的影响，包括但不限于以下几个方面：

(1) 数据采集质量：数据采集质量是影响故障识别率的重要因素。如果数据采集质量不好，例如采样率不足、信噪比低、采集时间不足等，就会影响故障识别的准确性和可靠性。

(2) 故障类型和程度：不同类型和程度的故障对故障识别率的影响也是不同的。一些故障可能在低转速下比在高转速下更容易被检测到，而另一些故障则可能在高转速下更容易被检测到。同样，不同日期下的故障类型和程度也会影响故障识别率。

(3) 检测方法和算法：不同的故障检测方法和算法对故障识别率的影响也是不同的。一些算法可能对特定类型的故障更敏感，而另一些算法则可能对不同类型的故障都能够有

效地识别。

(4) 数据量和质量：故障识别的准确性和可靠性还受数据量和质量的影响。大量高质量的数据可以提高故障识别的准确性和可靠性，而小量低质量的数据可能会导致故障识别的误差和不确定性。

分析不同转速和不同日期下的故障识别率时需要考虑以上因素，并选择合适的数据采集方法、故障检测算法和数据分析技术，以提高故障识别的准确性和可靠性。同时，还需要对不同转速和不同日期下的数据进行分析 and 比较，以找出其差异和规律，从而为工程实践提供支持。

利用本文提出的 DSVDD 方法对整体样本进行分析，得到深度一类分析结果如下图 3.11 所示。从图中可以看出，根据在正常样本、外圈故障、内圈故障不同情况下的所采集的数据结果可知：当纵坐标区间位于  $-0.259$  与  $-0.0627$  之间时为正常样本，当纵坐标区间高于  $-0.0627$  时产生内圈故障与外圈故障。试验结果充分表明了正常轴承和异常轴承的区别，验证了本文方法能够用于对滚动轴承在低速转动下的异常检测，能够有效地实现滚动轴承低速转动下的早期故障预警。




图 3.11 不同故障状态下深度一类分析结果

### 3.5 本章小结

本章介绍了转子-滚动轴承-机匣试验器的结构特征及功能。并利用该试验器对航空发动机中存在的几种代表性故障进行试验器演示和与不同工作状态情况下的模拟。本章还介

绍了本次试验的测试方案、实验器材、测点布置方案、传感器型号及技术指标、数据采集器指标、振动信号采集系统等相关内容。完成了不同状态、不同损伤位置下的实验数据采集和故障频率特征分析。最后，本文提出的 DSVDD 对试验数据进行了分析，充分表明了正常轴承和异常轴承的区别，验证了本文方法能够用于对滚动轴承在低速转动下的异常检测，能够有效地实现滚动轴承低速转动下的早期故障预警。

## 第四章 低速转动下的某真实航空发动机主轴承故障诊断试验验证

### 4.1 引言

为解决航空发动机低转速滚动轴承故障检测中存在的问题，验证相关方法的可行性，本章利用低速转动下的某型真实航空发动机主轴承进行数据采集，利用深度一类的分析方法完成了故障诊断的实验验证。

### 4.2 实验方案及内容

为了达成本文章所谈方法在实际情况下的航空发动机低转速滚动轴承故障检测工作中的可行性，在三台相同型号的航空发动机上进行了实验。其中，一台安装了完好的主轴承，另一台的三支点主轴承存在外圈剥落故障，还有一台主轴承存在内圈、外圈、滚动体的复合故障。在这三台发动机上分别获取了 120rpm 和 160rpm 两种转速下正常和故障两种状态的样本数据。通过这些实验数据，我们可以对本文提出的方法进行验证，并评估其在实际航空发动机低转速滚动轴承故障检测中的有效性。

### 4.3 实验验证结果

在本次实验中，采用了 16000Hz 的采样频率，以保证数据的准确性和可靠性。在数据处理过程中，我们按照 8:2 的比例将正常样本划分为训练集和测试集，并使用训练集进行模型的训练。在模型训练完成后，我们将所有的样本用于模型的测试，以验证模型的有效性和泛化能力。

在转速为 120rpm 的情况下，采用样本总量为 808 的样本，其中正常样本数为 160，故障样本数为 648 的样本进行模型测试。在转速为 160rpm 的情况下采用样本总数为 926，其中正常样本数为 160，故障样本数为 766 的样本进行模型测试。相关数据如表 4-1 所示：

表 4-1 某型航空发动机低转速试验样本信息

转速	样本数量		
	正常	故障	样本总量
120rpm	160	648	808
160rpm	160	766	926

在转速确定为 120rpm 的情况下，对总量为 808 的样本进行采集，将模型测试所得到



的实验结果进行研究可得到：大部分正常类样本的纵坐标区间位于 0 到 1.546 之间，而故障类样本纵坐标区间则高于 1.546 且大部分故障类样本纵坐标区间位于 1.60 至 1.78 之间。对 808 份样本研究可得深度一类分析结果如图 4.1 所示：




图 4.1 对 808 份样本进行深度一类分析结果

在转速确定为 160rpm 的情况下，对第二份总量为 926 的样本进行采集，将模型测试所得到的实验结果进行研究可得到：正常类样本的大部分纵坐标区间位于 0 到 1.615 之间，而故障类样本大部分纵坐标区间则在 1.615 与 1.9 之间。对 926 份样本研究可得深度一类分析结果如图 4.2 所示：




图 4.2 对 808 份样本进行深度一类分析结果

从图 4.1 和图 4.2 可以看出，本文提出的深度支持向量数据描述 DSVDD 方法对于实际航空发动机低速转动下的滚动轴承故障诊断也非常有效，能够充分表明正常轴承和异常轴

承的区别。

#### 4.4 本章小结

为了进一步验证本文方法对于真实航空发动机主轴承故障诊断的有效性，本章在三台相同型号的航空发动机上进行了实验，分别获取了不同故障状态下的样本数据。通过实验数据的处理和模型的训练，验证了该方法在实际航空发动机低转速滚动轴承故障检测中的有效性，结果表明本文方法为实际航空发动机低转速滚动轴承故障检测提供了一种新的有效技术途径和方法。

## 第五章 结论与展望

### 5.1 结论

#### （1）提出了用于滚动轴承低速诊断的深度支持向量描述方法

首先对相关数据的预处理，然后使用深度支持向量描述方法提取滚动轴承振动信号的特征，最后建立 DCNN 深度学习模型，从而实现高精度的分类和识别，通过 DSVDD 异常检测方法，基于深度学习和支持向量机通过深度神经网络将输入数据映射到一个高维特征空间中，在该空间中使用支持向量描述方法来描述正常样本与异常样本的分布，最终完成故障诊断和预警。

#### （2）基于带机匣的转子试验器进行了方法验证

使用转子-滚动轴承-机匣试验器进行了低转速和手动摇转下的振动数据采集和分析，通过以上分析可知，低速转动下滚动轴承故障特征频率的不可检测性以及不同转速和不同日期下的故障识别率可能会受到多种因素的影响。在低转速下，若直接采用传统的信号分析方法，很难通过寻找特征频率的方法实现轴承的故障检测，利用本文方法能够非常明显地区分正常和故障数据，从而实现故障异常检测和告警，验证了本文方法的正确有效性。

#### （3）基于某型实际航空发动机进行了方法验证

利用某型真实航空发动机分别获取了在低速转动下、不同转正成故障模型下的样本数据，验证了本文提出的深度支持向量描述方法 DSVDD 在实际航空发动机低转速滚动轴承故障检测中的可行性。表明本文方法能够为实际航空发动机低速转动下的故障预警提供新的思路和方法。

### 5.2 展望

滚动轴承低速诊断的深度支持向量描述方法的诊断模型需要进一步应用于工程实践中，针对实际的航空发动机在外场低速转动下所采集的试验数据，对不同型号、不同使用工况下的发动机主轴承故障早期诊断进行试验验证和模型修正。最终形成有用的主轴承故障诊断模型和方法。

## 参 考 文 献

- [1]何沿江, 齐明侠, 罗红梅. 基于 ICA 和 SVM 的滚动轴承声发射故障诊断技术[J]. 振动与冲击, 2008(03): 150-153+186-187
- [2]张晓涛, 唐力伟, 王平, 等. 基于 SVD 与 Fast Kurtogram 算法的滚动轴承声发射故障诊断[J]. 振动与冲击, 2014, 33(10): 101-105
- [3]廖传军. 基于声发射技术的滚动轴承故障诊断时频分析方法研究[D]. 湘潭: 湖南科技大学, 2008
- [4]侯伟. 滚动轴承故障特征增强与检测方法研究[D]. 北京: 北京化工学,2015
- [5]吴美娇. 基于深度支持向量机的异常检测方法及其应用[D]. 云南财经大学,2022.DOI:10.27455/d.cnki.gycmc.2022.000299.
- [6]王晓慧,王延江,邓晓刚等.基于加权深度支持向量数据描述的工业过程故障检测[J].化工学报,2021,72(11):5707-5716.
- [7]金江涛,许子非,李春等.基于深度学习与支持向量机的滚动轴承故障诊断研究[J].热能动力工程,2022,37(06):176-184.DOI:10.16146/j.cnki.rndlgc.2022.06.024.
- [8] Choudhury A., Tandon N.. Application of Acoustic Emission Technique for The Detection of Defects in Rolling Element Bearings[J]. Tribology International,2000, 33(1): 39-45
- [9] Žvokelj M., Zupan S., Prebil I.. EEMD-Based Multiscale ICA Method for Slewing Bearing Fault Detection and Diagnosis[J]. Journal of Sound and Vibration, 2016, 370: 394-423
- [10]刁宁昆.滚动轴承故障检测的无监督学习方法研究.2022.石家庄铁道大学,MA thesis
- [11]芦奕霏. 基于深度学习的轴承故障诊断方法研究[D].南京邮电大学,2022.DOI:10.27251/d.cnki.gnjdc.2022.001101.
- [12]赵孝礼. 基于图嵌入自编码的滚动轴承故障诊断方法研究[D].东南大学,2021.DOI:10.27014/d.cnki.gdnau.2021.000057.
- [13]宋统帅. 基于图的半监督学习方法与应用研究[D].南京邮电大学,2021.DOI:10.27251/d.cnki.gnjdc.2021.000924.
- [14]刘源. 基于卷积神经网络的复杂场景下目标跟踪研究[D].南京理工大学,2021.DOI:10.27241/d.cnki.gnjgu.2021.000030.
- [15]荀晓芳. 基于数据挖掘的问题用地快速发现技术研究[D].东南大学,2017.
- [16]秦悦,丁世飞.半监督聚类综述[J].计算机科学,2019,46(09):15-21.

- [17]梅俊辉. 物流票据信息提取与分析的研究[D].北京交通大学,2019.
- [18]景啸.基于深度学习的航拍图像目标识别[J].数码世界,2019,No.163(05):50.
- [19]许强,李伟,Pierre Loumbi.深度卷积神经网络在 SAR 自动目标识别领域的应用综述[J].电讯技术,2018,58(01):106-112.
- [20]黄智,王俊杰,石国良.基于时频分析和 CNN 的雷达辐射源识别算法[J].舰船电子工程,2020,40(01):24-28.
- [21]吴宽. 基于图像编码和深度学习的滚动轴承智能故障诊断方法[D].江西理工大学,2022.DOI:10.27176/d.cnki.gnfyc.2022.000511.
- [22]胡立宏. 基于语义的不规则化场景感知与重建[D].湖北工业大学,2021.DOI:10.27131/d.cnki.ghugc.2021.000400.
- [23]梁昊明. 基于 CNN 的市场摊区监控目标检测识别方法研究[D].哈尔滨工程大学,2020.DOI:10.27060/d.cnki.ghbcu.2020.001115.
- [24]夏敏. 基于主成分分析和多分类器融合的滚动轴承故障分类研究[D]. 中国科学技术大学, 2012
- [25]王磊. 基于混合神经网络的中文短文本分类方法研究[D].浙江理工大学,2019.
- [26]徐晓明. SVM 参数寻优及其在分类中的应用[D].大连海事大学,2014.
- [27]王洪伟. 航空发动机滚动轴承故障诊断与预测关键技术研究[D].南京航空航天大学,2015.

## 致 谢

行文至此，哽咽顿语；微风拂来，落笔匆忙。

愚生不才，寥寥几言，言不尽理论宽度，理不明书海深度。幸得陈果老师教导，康玉祥师兄帮扶，文章落笔，道道为师，步步为兄，方知文章要义。钟山之荫，悉心指导，如沐春风，终使文章至此。

盛夏未滿，硕果笑枝。金秋将至，后会有期。

匆匆再见，浅浅几言，相约锦绣。若路遥马急，有人不见，相匿于江湖，毅步跃山，轻舟踏江。然江河川流不息，恰同学少年，风华正茂，斑驳笑颜，欢声笑语，定久驻心间。五湖四海至，漫天星光去，他乡望夜，星伴前路。踏歌前行，尽是山川美景！

天目秋冬，翠屏春夏。蓦然回首，花海依旧。

烟雨随风，谁人不来，又谁人不走。灯火阑珊处，尽是回忆。团结简朴，唯实创新；航空报国，责任在心，谆谆教导，指引前行。然笛声已绕，行囊在肩，长亭古道，浊酒尽欢，今宵别梦。问前路何处？寻赤红足迹，于无声处，八桂大地，尽展芳华！

落笔情至，情自成诗。不知何处雨，此间已觉凉。

一日看尽怡园路，四载金陵数风华；春风杨柳别离途，毕竟车船留不住。拙笔陋文，浅抒别情，潦草数语，难表情谊绵长。山水一程，三生有幸，此情此景，倾述衷肠，畅抒心愿！

愿母校:欣欣向荣，桃李天下；

愿众师:阖家欢乐，万事胜意；

愿双亲:吉祥如意，福寿安康；

愿诸君:此生辽阔，前程似锦！

南京；南航；经纬，换个身份，再见！