



# 南京航空航天大学本科毕业生设计

---

## 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

**汇报人：张经纬**

**专业： 交通运输（民航维修工程）**

**指导老师：陈果教授**

**南京航空航天大学智能诊断与专家系统研究室**



# 汇报内容

1

绪论

2

用于滚动轴承低速诊断的无监督深度学习模型

3

低速转动下的滚动轴承试验器试验验证

4

低速转动下的某型真实航空发动机主轴承故障诊断试验验证

5

总结与展望

## 研究目的与意义：

1) 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。


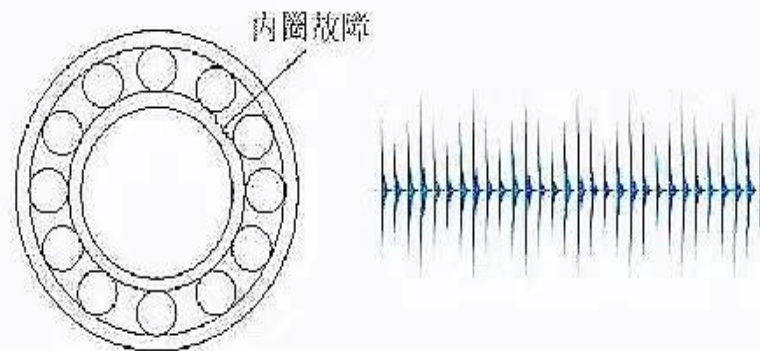

2) 相比于地面试车诊断和空中机载监测，低转速滚动轴承故障诊断相较于传统的诊断方法具有**更为便捷，适用性和普及性更强**。

3) 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**。  
因此，该项研究具有广泛的应用前景和推广价值。

# 国内外低转速诊断现状：

国内外在低转速滚动轴承早期故障诊断方面进行了广泛而深入的研究。以下是国内外研究现状的有关介绍：

1) 研究者们利用统计特征、时域特征和频域特征等进行早期故障诊断，以下是滚动轴承发生内圈、外圈、滚动体损伤的不同情况下对应的典型时域波形：



# 国内外低转速诊断现状：

2)基于机器学习的方法：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。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。

3)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。

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。

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。

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现在故障的异常检测。

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。



# 汇报内容

1

绪论

2

用于滚动轴承低速诊断的无监督深度学习模型

3

低速转动下的滚动轴承试验器试验验证

4

低速转动下的某型真实航空发动机主轴承故障诊断试验验证

5

总结与展望




## 无监督学习概述：

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。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。

## 无监督学习——聚类分析：

通过对数据进行聚类，利用相似性原理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。聚类分析的目的在于发现数据中的结构和模式，将数据进行分类和归纳，以便更好地理解和分析数据。






## 无监督学习——一类支持向量机与SVDD方法：

一类支持向量机是一种基于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。

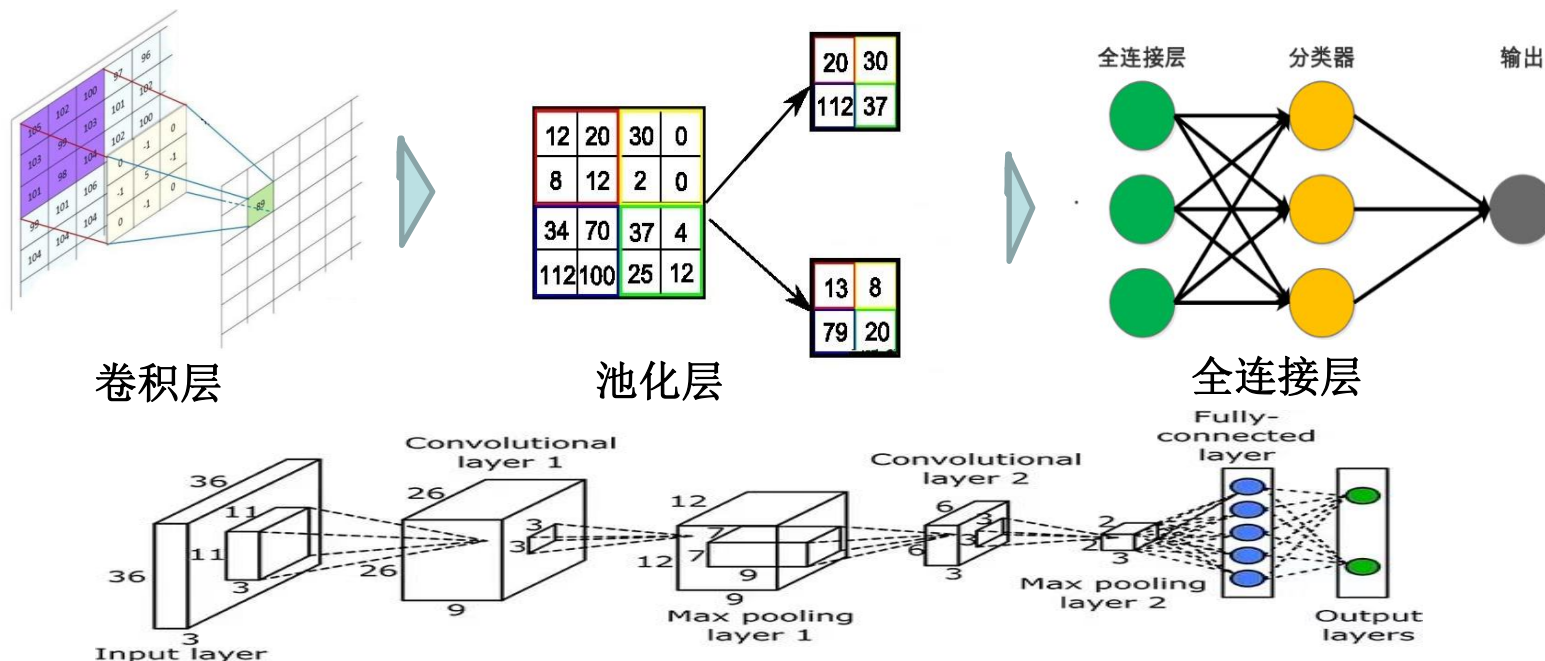
**SVDD**方法是基于支持向量机（SVM）的异常情况检测办法。它通过在正常样本空间中构建一个最小的超球体来描述正常样本的分布，从而检测出离群点。能够自动地学习异常的特征和规律，具有灵活和可控的特点，从而在异常检测方面具有较大的优势。



**卷积层**：它的作用是对输入的图像数据完成卷积运算以提取特征。通过卷积运算进行数据处理。

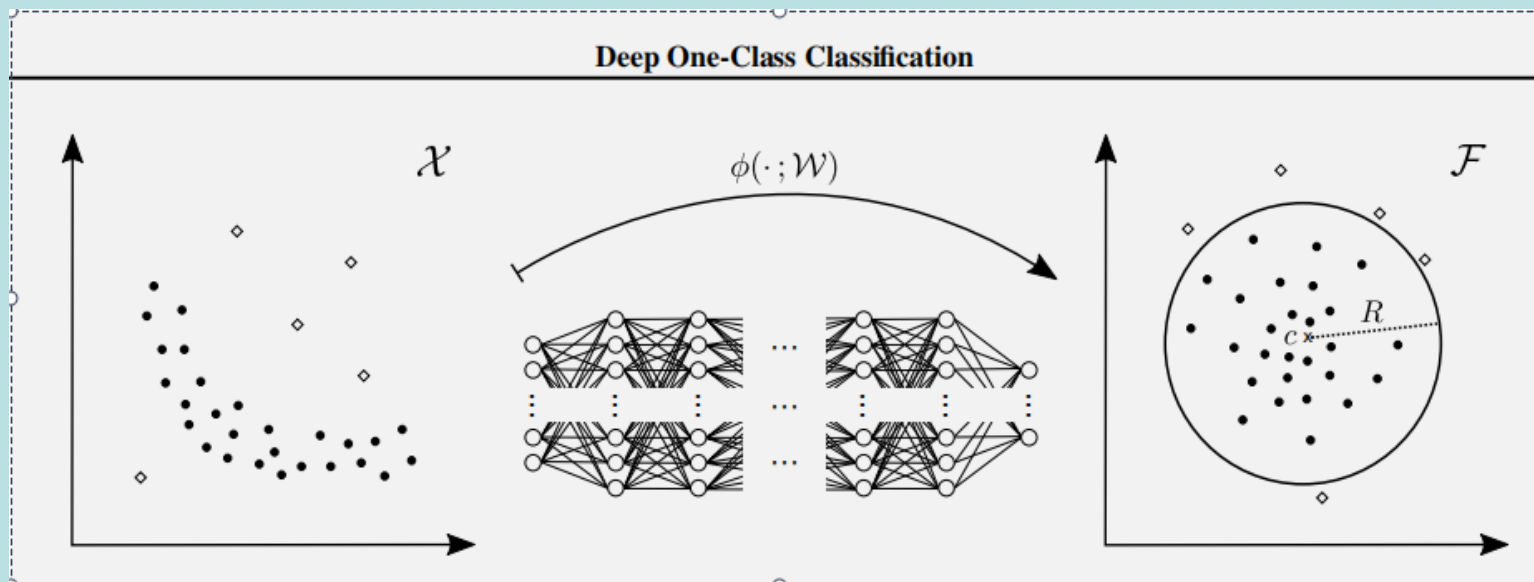
**池化层**：池化层主要是对特征图进行降维，保证特征图拥有平移不变性。池化层能够减少特征图的参数数量，减少非重点数据，减轻计算量。

**全连接层**：输入数据经卷积层和池化层完成交替传播后，全连接层完成分类。

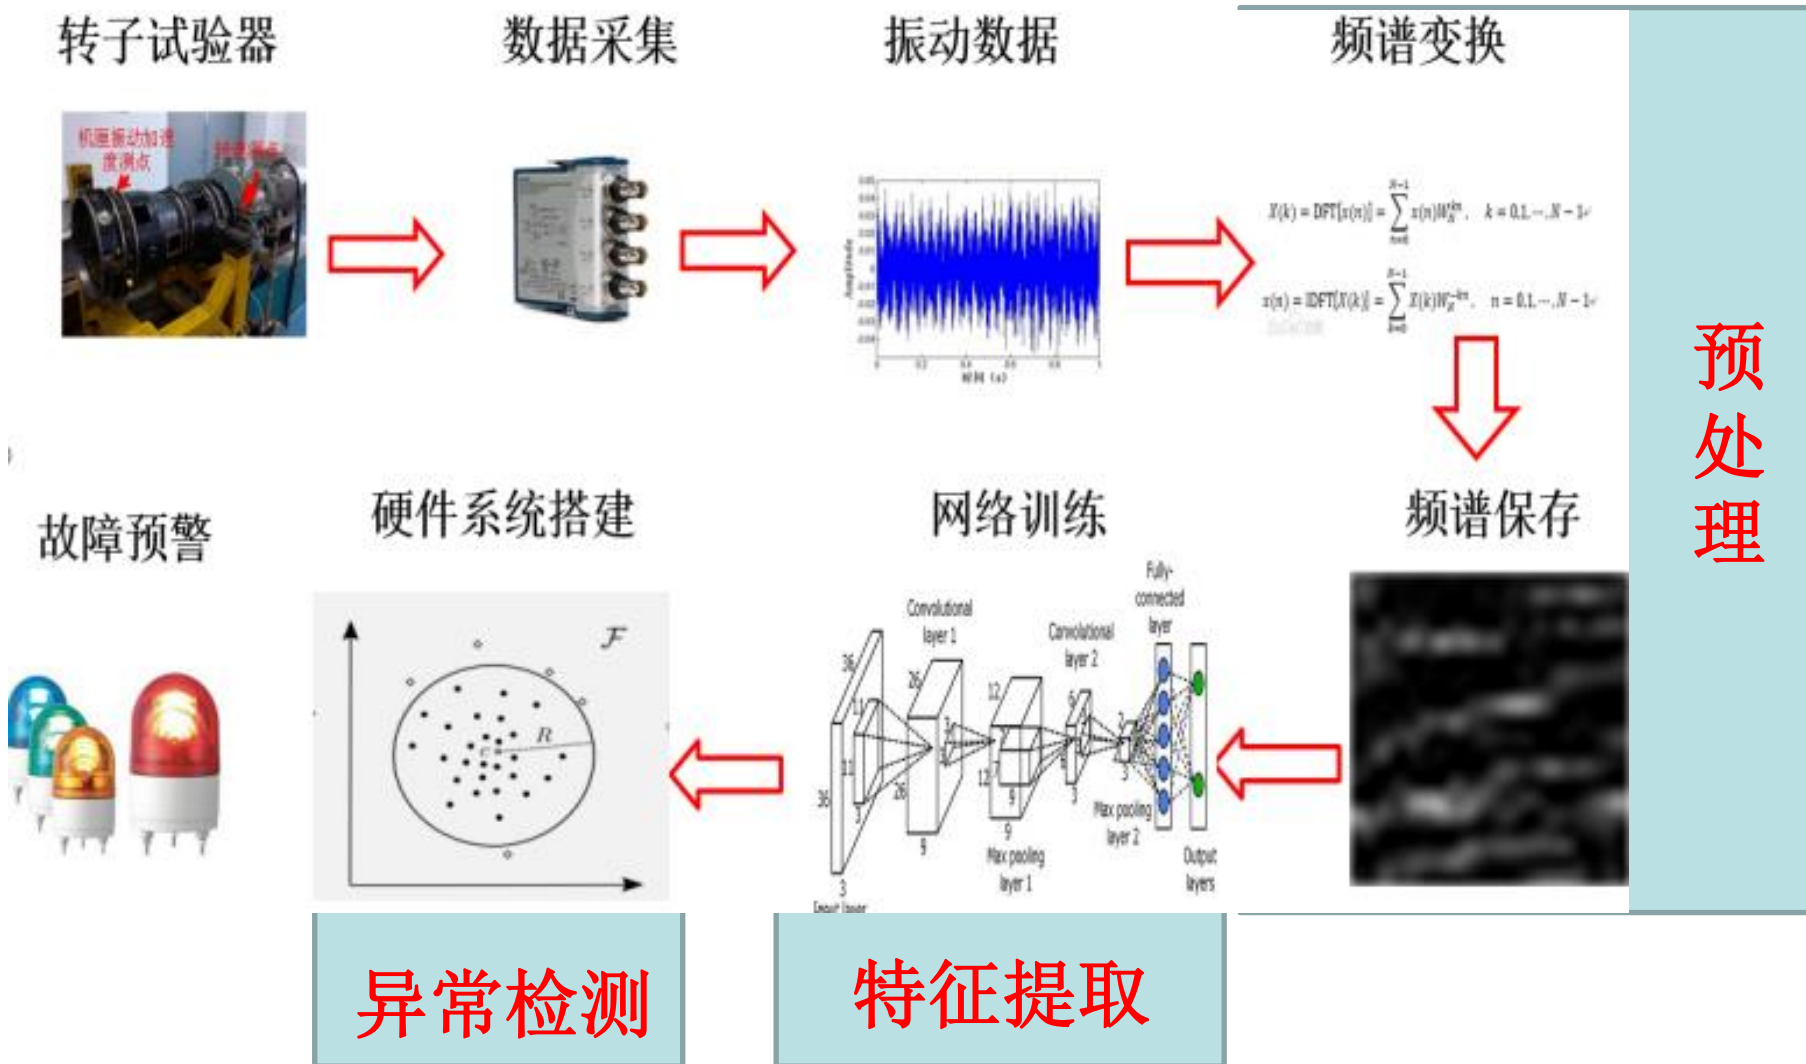


# DSVDD原理:

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。



# DSVDD模型架构:





# 汇报内容

1

绪论

2

用于滚动轴承低速诊断的无监督深度学习模型

3

低速转动下的滚动轴承试验器试验验证

4

低速转动下的某型真实航空发动机主轴承故障诊断试验验证


5

总结与展望



## 试验器简介与功能介绍:

本次实验利用转子-滚动轴承-机匣试验器进行故障演示与模拟



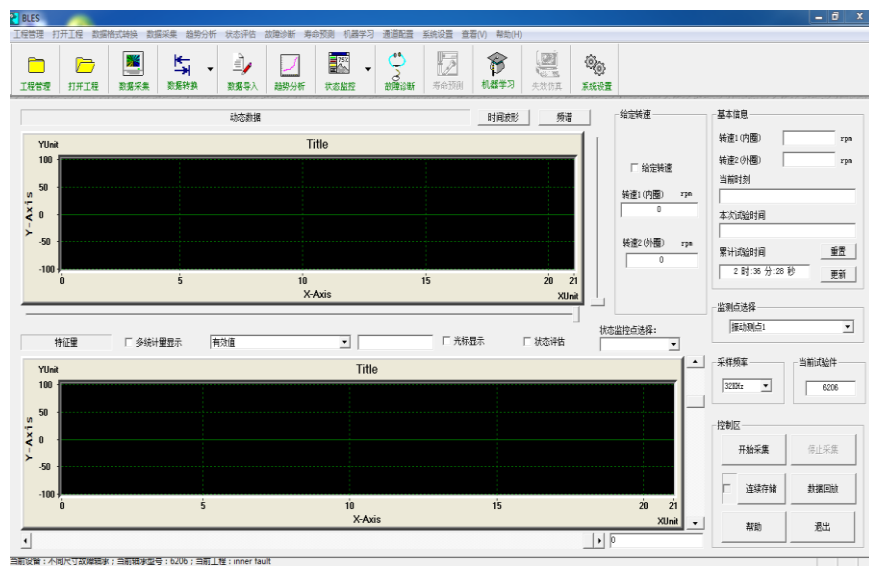
试验器可以对发动机中可能出现的几种典型故障进行试验器演示和与不同工作状态情况下的模拟，如以下几种类别：

- (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) 轴承损坏导致涡轮机械的振动特性发生变化；
- (3) 前后支承不同心状况导致的机械失衡、振动加剧等问题；
- (4) 支承刚度的变化影响机械的正常运行的问题。

## 带机匣的航空发动机转子模拟实验器



## B&K加速度传感器



## 航空发动机滚动轴承失效监控与寿命评估系统BLES

## 数据采集器



## 实验相关数据采集:

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。

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				



滚动轴承数据列表

## 实验相关数据分析：

对于内圈故障，其故障特征频率为10.86Hz，不管于轴承座测点处还是在机匣测点位置，可以发现频谱中无法发现明显的谱线可以对应。外圈故障的情况下，其所对应的故障特征频率为7.14Hz，在轴承座测点位置和机匣测点位置处，在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，低转速下，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。



下面将各类情况由实验所采集数据制得频谱图示意如下：



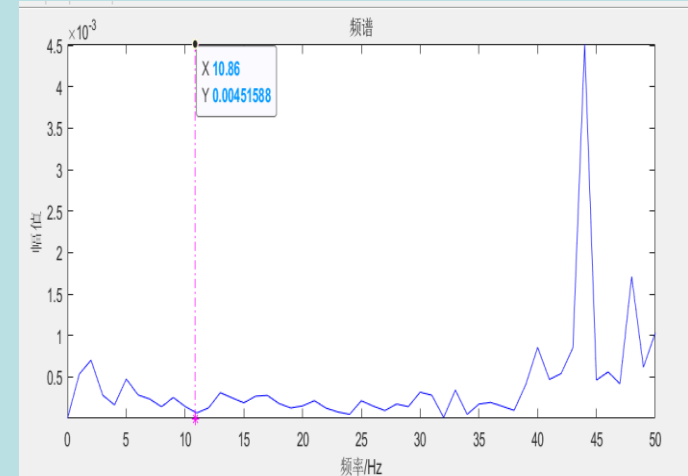

不能  
找到  
特征  
频率

正常状态下根据所测数据得到的频谱图

# 实验相关数据分析：



外圈故障状态下根据所测数据得到的频谱图





内圈故障状态下根据所测数据得到的频谱图

不能找到特征频率

## 实验相关数据分析：



采用手动摇转的方式分别对正常状态、外圈故障、内圈故障不同状态下的数据进行采集，所得频谱图如下列所示：



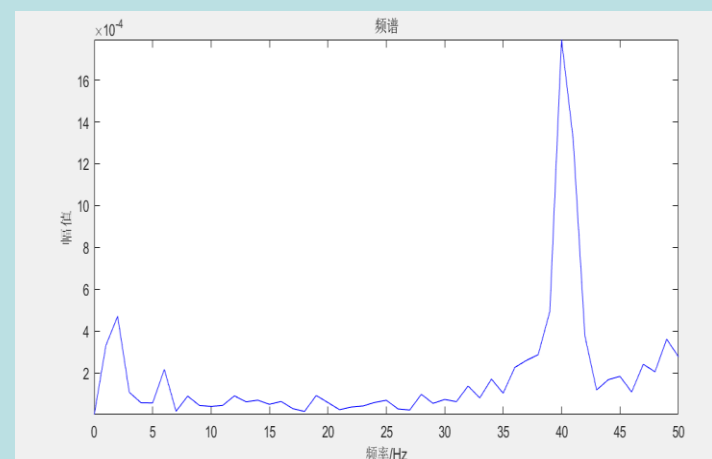

不能  
找到  
特征  
频率

采取手摇方式正常状态下根据所测数据得到的频谱图

# 实验相关数据分析：



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



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

不能  
找到  
特征  
频率




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。



## 实验相关数据分析：

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进行整体样本研究，可得深度一类分析结果如下图所示。可以发现当纵坐标区间位于-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。







# 汇报内容

1

绪论

2

用于滚动轴承低速诊断的无监督深度学习模型

3

低速转动下的滚动轴承试验器试验验证

4

低速转动下的某型真实航空发动机主轴轴承故障诊断试验验证

5

总结与展望

## 实验验证结果：

我们利用三台相同型号的航空发动机进行试验，第一台主轴承无故障，第二台的主轴承存在外圈剥落故障，第三台主轴承存在内圈、外圈、滚动体的复合故障。


采用16000Hz的采样频率，对总量分别为808与926的两组样本以8:2的比例将正常样本划分为训练集和测试集，使用训练集进行模型的训练。模型训练完成后，我们将所有的样本用于模型的测试分别获取120rpm和160rpm两种转速下正常和故障两种状态的样本数据。

实验相关数据如下表所示：

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


## 实验验证结果：

转速为120rpm的情况下，我们采用异常深度一类分类方法对总量为808的样本进行故障检测，结果如图所示，可以发现当纵坐标区间位于0与1.546之间时为正常样本，当纵坐标区间高于1.546且大部分位于1.60至1.78之间时为故障样本。由此证明异常深度一类分析方式的有效性。



## 实验验证结果：

转速为160rpm的情况下，我们采用异常深度一类分类方法对总量为926的样本进行故障检测，结果如图所示，可以发现当纵坐标区间位于0与1.615之间时为正常样本，绝大部分故障样本的纵坐标区间位于1.615至1.9之间。再次证明了本研究所采用异常深度一类分析的方式的有效性与其可行性。





# 汇报内容

1

绪论

2

用于滚动轴承低速诊断的无监督深度学习模型

3

低速转动下的滚动轴承试验器试验验证

4

低速转动下的某型真实航空发动机主轴承故障诊断试验验证

5

总结与展望

## 总结：

- 提出了用于滚动轴承低速诊断的深度支持向量描述方法，建立了诊断模型。
- 基于带机匣的转子试验器进行了方法验证。
- 基于某型实际航空发动机进行了方法验证。

## 展望：

- **故障预测与诊断：**将诊断模型应用于实际工程中，能够完成对滚动轴承的故障类别和位置的精准研究。将该方法应用于航空发动机、高速列车等领域，实现对滚动轴承故障的预测与诊断。
- **智能维护：**通过将深度支持向量描述方法的诊断模型与智能维护系统相结合，可以实现对滚动轴承的自动化监测和维护。在实际工程中，可以将该方法应用于滚动轴承的在线监测和自动化维护，提高设备的运行效率和可靠性。

展示结束!

感谢各位老师批评指正

T H A N K S