



同濟大學

TONGJI UNIVERSITY

硕士学位论文

(专业学位)

# 基于多源数据的制冷机房综合故障诊断

姓 名：李泓名

学 号：1832751

所在院系：机械与能源工程学院

专业学位名称：动力工程

指导教师：许鹏

二〇二一年一月



同濟大學  
TONGJI UNIVERSITY

A dissertation submitted to

Tongji University in conformity with the requirements for  
the degree of Master Philosophy

## **Research on Fault Detection and Diagnosis of the Chiller Room Using Multi-sensor Data**

Candidate: Li Hongming

Student Number: 1832751

School/Department: School of Mechanical Engineering

Discipline: Engineering

Major: Power Engineering

Supervisor: Prof. Xu Peng

January, 2021

基于多源数据的制冷机房综合故障诊断

李泓名

同济大学

## 学位论文版权使用授权书

本人完全了解同济大学关于收集、保存、使用学位论文的规定，同意如下各项内容：按照学校要求提交学位论文的印刷本和电子版本；学校有权保存学位论文的印刷本和电子版，并采用影印、缩印、扫描、数字化或其它手段保存论文；学校有权提供目录检索以及提供本学位论文全文或者部分的阅览服务；学校有权按有关规定向国家有关部门或者机构送交论文的复印件和电子版；在不以赢利为目的的前提下，学校可以适当复制论文的部分或全部内容用于学术活动。

学位论文作者签名：

年 月 日

# 同济大学学位论文原创性声明

本人郑重声明：所提交的学位论文，是本人在导师指导下，进行研究工作所取得的成果。除文中已经注明引用的内容外，本学位论文的研究成果不包含任何他人创作的、已公开发表或者没有公开发表的作品的内容。对本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。本学位论文原创性声明的法律责任由本人承担。

学位论文作者签名：

年 月 日

## 摘要

建筑暖通空调系统的正常运行依赖于健全的运维管理机制和有效的设备故障诊断分析。对于公共建筑及大型住宅区而言，其制冷机房系统和关键设备故障诊断分析尤为重要。当前故障诊断研究主要基于机房 BA(Building Automation) 数据，从研究部署的角度上看，BA 数据的准确度和可用性往往受机房运维水平影响，单纯依赖 BA 数据容易造成算法诊断失误。

随着巡检机器人技术的不断发展和越来越多工程应用案例出现，使用巡检机器人在制冷机房进行自动巡检和数据采集具备可行性和优越性。其可以搭载多类传感器如振动、声音、热成像等，从而获取多类型的数据，有效辅助制冷机房日常运维和设备故障诊断工作，提高机房运维水平。

本文在巡检机器人辅助运维的应用基础上，基于 BA 数据、声音、振动、热成像等多源数据，搭建了从基于 BA 数据的水泵能效异常检测到基于多源数据融合的水泵机械电气等故障分类框架，实现了制冷机房综合故障诊断方法。

水泵声音异常检测算法中，首先进行声音去噪，基于制冷机房场景需求，对小波变换去噪方法进行优化，对含噪声音信号提取小波系数，使用神经网络模型代替传统阈值处理方法去除小波系数中的噪声成分，重构回声音信号后较好地剔除了水泵声音中的噪声。其次，针对机房内异常噪声数据匮乏的情况，训练自编码器模型，实现了小异常样本下的声音异常检测，有效区分了异常声音和正常声音。

水泵振动异常检测算法中，首先采用倒谱预白化的方式进行振动去噪，之后采用量化经验分析的方法，将经验中根据振动信号频谱特征进行异常识别的过程进行统计分析量化，实现了有效的水泵转轴或轴承磨损、基础松动、叶轮激振等异常检测。

多源数据融合故障诊断算法中，结合数据融合的三层结构，对水泵电功率、热成像、声音和振动数据采用结论层融合的形式，并基于历史数据提出多源数据结论可信度的计算方法，基于可信度和故障发生的独立非互斥性假设开发了多源数据融合故障诊断算法。

**关键词：**机器学习 巡检机器人 数据融合 故障诊断 制冷机房

## ABSTRACT

The state of HVAC system in building depends on its operation and maintenance level and the effectiveness of FDD (Fault Detection and Diagnostics). Moreover, it is important for public buildings and large-scale residential district to make fault diagnosis to mechanical equipment of their chiller plants that are important components of HVAC system. Today, methods of FDD is mostly based on data collected by BA (Building Automation Systems), which are easily affected by the operation and maintenance level of chiller plant. Usually, it means diagnosis error caused by data error.

With the development of inspection robot, it has been deployed in more and more engineering projects. It is feasible to use inspection robot to perform inspection tasks and equip with sensors of vibration and sound and thermal imaging equipment to collect data of mechanical equipment in chiller plant. It has lots of advantage over traditional operation and maintenance in efficiency and accuracy.

Based on the application of inspection robot in chiller plant, we have developed a method using multi-sensor data contains of vibration, sound and thermal image. It is a framework to connect the part of FDD on equipment's energy efficiency with the part of FDD on equipment's mechanical and electrical aspects.

In the second part (taking the pump as examples) of the framework, we use data of sound. Firstly, we develop a method to filter noise of the sound of pumps, which contains the voice of background. We adjust the denoising via wavelet transform method by replacing its threshold adjustment part with neural network model, then we get a good performance in test set. Secondly, we develop an autoencoder model to classify normal and abnormal sounds of pumps, to solve the problem of lack of abnormal data. Also, we get good results.

In the second part of the framework, the vibration data based method also used to anomaly detection. Firstly, the vibration data are edited through cepstrum editing procedure to denoising. Secondly, the feature spectrums of denoised vibration data are quantified to classify different fault states of pumps, which has good results in test set.

As the final step in the second part of the framework, the method of multi-sensor data based FDD is developed. Firstly, we use the pumps' data of power, thermal image, sound and vibration to carry out anomaly detection respectively and get results.

Secondly, we evaluate these results' credibility and the probability of occurring these events. Then the credibility and probability are multiplied as the final results.

**Key Words:** machine learning, Inspection robot, data fusion, FDD, chiller plant



## 目录

第 1 章 引言 .....	1
1.1 概述 .....	1
1.2 制冷机房故障诊断研究现状 .....	1
1.3 非侵入式制冷机房设备故障诊断研究现状 .....	3
1.4 制冷机房多源数据故障诊断研究现状 .....	5
1.5 研究基础及验证场所 .....	5
1.5.1 研究基础 .....	5
1.5.2 验证场所 .....	6
1.6 技术路线 .....	7
第 2 章 制冷机房综合故障诊断流程搭建 .....	10
2.1 基于 BA 数据的能效故障分析流程 .....	10
2.2 基于机器人采集数据的故障分析流程 .....	12
第 3 章 基于神经网络-小波变换的水泵音频信号去噪 .....	13
3.1 音频去噪算法介绍 .....	13
3.2 音频信号采样 .....	14
3.3 水泵音频信号时频域分析 .....	15
3.4 小波变换去噪原理 .....	18
3.4.1 小波变换基本原理 .....	18
3.4.2 小波变换对信号的分解与重构 .....	19
3.4.3 小波变换去噪过程 .....	20
3.5 神经网络-小波变换去噪算法原理 .....	23
3.5.1 小波变换去噪算法局限性 .....	23
3.5.2 小波变换去噪算法改造 .....	23
3.5.3 BP 神经网络介绍 .....	24
3.5.4 神经网络-小波变换去噪算法搭建 .....	27
3.6 水泵音频信号去噪验证及结果分析 .....	29
3.6.1 混音原理 .....	29
3.6.2 混音公式 .....	30
3.6.3 含噪声信号合成 .....	30

3.6.4	数据集构建	31
3.6.5	训练结果	31
第 4 章	基于自编码器的水泵音频信号异常检测	33
4.1	水泵音频信号样本分析	33
4.2	自编码器原理	34
4.3	水泵音频信号异常检测验证及结果分析	35
第 5 章	基于倒谱预白化的水泵振动信号去噪	38
5.1	水泵振动信号采样	38
5.1.1	水泵振动检测方法	38
5.1.2	水泵振动采样原理	39
5.2	水泵振动信号数据分析	40
5.2.1	误差及噪声来源分析	40
5.2.2	振动去噪要求	42
5.3	倒谱预白化原理	42
5.3.1	倒谱分析原理	42
5.3.2	倒谱预白化操作	43
5.4	振动信号去噪计算	44
第 6 章	基于量化经验分析的水泵振动信号异常检测	47
6.1	基于经验分析的水泵异常判断	47
6.2	量化经验分析算法的实现	47
6.2.1	算法基本原理和流程	47
6.2.2	量化过程	49
6.2.3	规则构建	53
6.3	水泵振动数据异常检测验证	54
第 7 章	多源数据融合算法	58
7.1	多源数据融合层次选择	58
7.2	多源数据分析	58
7.2.1	电功率数据	58
7.2.2	热成像数据	64
7.2.3	音频数据	65
7.2.4	振动数据	65
7.3	多源数据结论层与故障关联分析	65

---

7.3.1 单向关联分析 .....	66
7.3.3 可信度累积分析 .....	67
7.4 结论层的条件概率融合算法 .....	69
第 8 章 结论与展望 .....	71
8.1 结论 .....	71
8.2 展望 .....	72
致谢 .....	73
参考文献 .....	74
附录 A 部分代码节选 .....	78
个人简历与研究成果 .....	88

# 第 1 章 引言

## 1.1 概述

建筑暖通空调系统的正常运行依赖于健全的运维管理机制和有效的设备故障诊断分析。对于公共建筑及大型住宅区而言，其制冷机房系统和关键设备故障诊断分析尤为重要，暖通空调系统耗能约占该类型建筑总电耗的 10%~20%。而制冷机房作为暖通空调系统的核心，其运行过程中出现的异常物理变化，部件老化，不正确的安装、使用和维护均会对整个暖通空调系统的能耗和性能产生不利影响，导致能源浪费和室内环境质量的下降。当前暖通空调领域中制冷机房故障诊断方法均有着数据依赖性，其诊断结果的好坏受数据质量的影响。而且数据来源一般为机房 BA 数据和新增传感器采集的数据，考虑到工程成本，传感器采集的数据种类有限，且一般不存在数据冗余，这导致了故障诊断范围受限、鲁棒性不强的问题。

在巡检机器人技术和图像识别技术日益发展的今日，可利用机器人在制冷机房内自动巡逻，对于水泵等目标设备，采集其运行状态下可见光和红外图像、运行声音及振动数据，获取常规 BA 系统难以采集的数据。基于这类数据，可以从设备机械层面和热工层面进行异常检测，进一步的，结合这类异常检测结果和 BA 数据，可以进行数据验证，以数据融合等方式实现范围更广、鲁棒性更强的故障诊断。

## 1.2 制冷机房故障诊断研究现状

随着现代智能化控制技术的发展和充分应用，常见公共建筑的制冷机房 BA 系统配置比例得到极大提升，基于机房运行数据的故障诊断研究也得到快速发展，常见的方法有：

(1) 统计学分析，其中以主元分析法最为常见，一部份学者将主元分析法<sup>[1-7]</sup>应用于 BA 数据中对制冷机房进行故障诊断，避开对系统解析建模，直接使用正常运行阶段的测量数据建模。考虑到系统的非线性，张夏泉<sup>[8]</sup>在主元数选取时选用了主元贡献率法加以应用遗传算法的神经网络预测器，在 MATLAB 仿真实验中该方法变现了一定的诊断能力；禹法文<sup>[9]</sup>考虑传感器间的耦合，采用相关性分析，对检测率较低的几类故障进行解释，将平方预测误差（SPE）和 Hotelling' s T<sup>2</sup>

这两种方法的指标合成为新的故障检测指标，检测效率得到明显提升。X J Luo 等人<sup>[10]</sup>提出了两阶段模式识别传感器故障检测与诊断方法。在模式识别的第一阶段，通过传感器读取无故障和不同故障测试用例的数据集，生成各种特征模式。在模式识别的第二阶段，用一天的特征模式来诊断正偏、负偏、精度下降和一般漂移的传感器故障；而用三天的特征模式可以进一步识别正或负漂移故障。因此，本文提出的模式识别策略可以自动检测、诊断和修正不同类型的传感器故障。对一个具有代表性的冷水机组，发现正偏差、负偏差、精度下降、正漂移和负漂移的两阶段模式识别诊断成功率分别为 97.9%、100%、96.4%、95.4%和 98.1%。

(2) 其他机器学习方法，如支持向量机<sup>[10-15]</sup>，ShengFa Yuan 等人<sup>[16]</sup>提出了一种新的支持向量机多类分类算法。它是由多个按故障优先级组织的两类分类器组成的二叉树分类器，结构简单，重复训练量小，训练和识别速度快。通过在涡轮泵转子故障诊断中的应用，验证了该方法的有效性。Ke Yan 等人<sup>[17]</sup>提出结合外生变量自回归模型（ARX）和支持向量机（SVM）的混合方法。利用 ARX 模型构造高维参数空间，运用支持向量机对参数空间超平面进行细分，实现故障分类。实验结果表明，与传统的基于模型或数据驱动的方法进行对比，时间序列建模和机器学习相结合的方法在冷水机组故障诊断中具有更高的预测精度和更低的误诊断率。贝叶斯网络<sup>[18-19]</sup>，决策树<sup>[20]</sup>等也得到了广泛的应用。K. H. Ng 等人<sup>[21]</sup>结合管道系统中水的流量和温度之间的热物理关系，采用贝叶斯方法建立了中央冷水机组水流量和温度传感器偏差的检测和评估模型。该模型能够处理多个传感器同时发生的偏差，并与单纯基于热物理关系的传统方法进行了比较，贝叶斯方法在处理缺乏完整冷水机组运行工况的数据时更优。柴伟和池彬彬两人<sup>[22]</sup>收集入水和出水数据，训练径向基函数神经网络，构建出水变量预测模型，以参数线性集员辨识算法进行输出权值集合描述，给出出水变量的置信区间，一旦超出置信区间，即判断故障。

(3) 小波神经网络<sup>[23-26]</sup>，Zhu Y<sup>[27]</sup>等人提出了一种基于小波分形预处理神经网络的空调机组传感器故障诊断方法。利用小波分析提取出各层故障数据的分形特征，并对其进行频谱分析。通过这些步骤，将一个信号转化为一个由几个分形特征组成的特征向量中。然后，将特征向量引入到神经网络中，并对其进行训练，以诊断传感器故障。

(4) 聚类<sup>[28-31]</sup>等，以刘涵<sup>[32]</sup>为例，他使用自编码器对机组运行数据进行降维，摆脱对故障标签的依赖，研究无监督故障聚类，以 K-Medoids 聚类离散机组运行参数，根据聚类结果轮廓系数不断优化聚类数，并赋予各聚类区间实际物理意义，构建故障集。基于其理论开发的故障诊断系统已成功应用。

尽管目前制冷机房的故障诊断方法研究已经近乎完备,却未在实际楼宇中得到广泛的应用。从研究层面来看,现有的故障诊断方法大多还停留在理论和实验室层面,其灵敏度和准确率未得到实际楼宇的检验。从工程应用层面来看,现有的故障诊断方法往往不注重投资回报率、传感器性能、管理者操作水平等实际因素,造成了制冷机房故障诊断技术难以落地的局面。对于大多数部署故障诊断算法的制冷机房,其故障检测和诊断效果受数据来源的影响。一方面,为节约成本而部署基本的传感器,不存在数据冗余,难以检验数据的准确性;另一方面,部分设备故障诊断所需的数据常规传感器难以监测,例如水泵电机温度特征,即便设备自带数据监测功能,也由于设备商之间建立的专利壁垒导致无法完全开放给BA系统,例如冷水机组的面板数据,往往需要BA系统类型与其适配。由此可见,建筑机房的BA故障诊断算法离大规模部署应用还有一段距离。

### 1.3 非侵入式制冷机房设备故障诊断研究现状

随着巡检机器人技术和图像识别技术逐渐发展和完善,机器人逐渐开始投入电力设施巡检的工程应用中。因此,在制冷机房中利用巡检机器人自动采集设备图像信息,并提取设备运行数据和故障特征也具有较高的可行性。巡检机器人在制冷机房的应用将代替人工巡检、抄表等工作,节省大量用人成本,同时提高巡检安全质量水平。巡检机器人搭配众多传感器也可完成常规传感器难以完成的数据采集工作,例如借助红外摄像机采集管道的温度分布矩阵,采集设备与背景温差等。这体现了制冷机房巡检机器人巨大的经济效益。目前本人所在的许鹏教授课题组已在多个制冷机房进行巡检机器人试运并自动采集了多个设备图像信息,为进一步利用图像数据进行特征提取,与BA数据进行验证和融合,进行综合故障诊断提供现实依据。

#### (1) 设备音频故障诊断

潘永泰等人<sup>[33]</sup>对比多种分帧方法,对音频采用计算量小且能量泄露小的矩形窗进行分帧处理,通过阈值判定的方式选取了显著的时域特征包括均值、最值、差值等,最后基于这些显著特征进行正负样本数据处理,并达到了较好的故障诊断结果。

陈静等人<sup>[34]</sup>采用小波分解的方法对音频数据进行时频域特征提取,得到多层小波系数,将多层小波系数作为故障识别的特征,并以此训练误差反向传播神经网络分类模型,其在测试集上取得了较高的准确率。

刘登等人<sup>[35]</sup>对风机工作时的音频特性进行分析,发现故障状态与正常状态在音频能量上存在显著区别,便基于此基于ITD固有时间尺度分解的时频分析方法

提取特征向量，采用 PCA 进行特征降维后通过支持向量机进行分类，该方法相较于传统 EMD 方法有着更高的准确率。

## (2) 设备振动故障诊断

赵国欣<sup>[36]</sup>将变频水泵分为正常、不平衡、不对中和基础松动四种状态，根据转子机械机理着手分析各状态的振动特征。用三层小波包分解信号，提取各状态样本的特征向量，对调速震动和故障震动加以区分。

Shijie Hao等人<sup>[37]</sup>提出了一种基于一维卷积长短时记忆 (LSTM) 网络的端到端故障诊断方法，该方法提取了多传感器振动信号的空间和时间特征，对其进行了联合诊断。同时采用下采样的方法降低了数据长度，从而降低 LSTM 层的计算复杂度。实验结果表明，该方法在轴承故障诊断方面比其他方法有更好的性能，同时也验证了该方法对不同负载和低信噪比的适应性。

一般来说，传统的振动故障诊断方法需要事先获得必要的特征和大量的标注数据，这需要大量的时间和人力。为了提高故障诊断能力，Shaowei Liu<sup>[38]</sup>等人提出了一种基于深度残差分析的自编码生成对抗网络数据扩充方法。首先，将编码器融合到生成对抗网络中，学习真实数据的深层特征，提高数据生成质量。其次，将深度残差分析方法与识别器相结合，通过对其施加梯度惩罚来避免发散。第三，通过模块匹配的操作强化模型的特征提取能力，避免过拟合。通过对两个滚动轴承数据集的诊断，验证了该方法的有效性。结果表明，该方法比典型的基于数据综合的故障诊断方法具有更好的有效性和鲁棒性。

在图像识别和计算机视觉不断发展的今天，图像识别越来越多的进入到异常情况检测和故障识别的领域中。同时，深度学习的发展也推动了图像识别领域向大规模处理和智能识别的方向迈进。一方面，现阶段图像分类和目标检测越来越多的指导包括农业和工业领域一些视觉上直观可以得到信息的研究任务的进行。基于可见光图像和红外图像的电机故障识别也已经在工程应用中提供了较好的指导作用。在制冷机房中，水泵、制冷机组、管道等作为机房的重要设备和组成部分，其异常状态的发生大多具有可视性和温度相关性，因此基于可见光图像和红外图像进行特征提取可为故障诊断提供可靠可用的数据输入。另一方面，通过图像采集可识别制冷机房中各类机械仪表盘等数据，其中大多与 BA 数据为异源关系，这增加了可用数据的冗余度，可提升故障诊断算法的鲁棒性，同时也提供了更多较难获取的互补数据，完善故障诊断内容。现有针对制冷机房设备图像识别的研究主要基于神经网络，如 CNN、RCNN 和形态学操作等图像处理方法，其对采集的图像有着较多的限制。而采用巡检机器人进行图像采集必然存在图像采集角度、清晰度、大小等限制，如何优化图像识别算法，使之适配机房巡检场景也有着重要的现实意义。

## 1.4 制冷机房多源数据故障诊断研究现状

多源数据融合可以在三个层次进行<sup>[39-40]</sup>：

(1) 数据层融合。以赵书涛<sup>[41]</sup>的工作为例，他们对声信号去除噪声，进行带通滤波，叠加低频振动信号，完成声振信号联合，这些数据样本作为一维卷积神经网络训练集，同时使用局部均值归一化和核函数去相关性改进模型结构，该卷积神经网络诊断准确率达到 97.75%；

(2) 特征层融合。以王占伟<sup>[42]</sup>的工作为例，考虑实际冷水机组存在传感器数量不足，故障类型不全等缺憾，发明特征选择方法，即选用现场普遍存在、加以补充获取成本低或对故障更敏感的特征，对多源特征进行增补、排序，然后运用融入距离拒绝的贝叶斯网络诊断其性能，该研究提高了对已知故障的诊断正确率和对新故障的识别正确率，尤其在小样本量情况下更优于传统方法；

(3) 决策层融合<sup>[43-50]</sup>，以黄志彦<sup>[51]</sup>等人为例，他们引入 Dempster-Shafer (D-S) 证据理论数据，使用信度函数表达各症状相应的各故障的发生概率，加以组合原则和判断原则，提高了故障模式的识别能力。

## 1.5 研究基础及验证场所

### 1.5.1 研究基础

传统制冷机房运维流程中，定期巡检工作占据运维人员大量的时间，需要运维人员根据值班安排和巡检要求定期对各个设备进行巡检。主要是运行数据记录、状态检查和异常反馈，该流程具有高重复性和连续性，且需要运维人员的运维基础和判断能力差距较小，以避免误操作和异常未及时反馈。

当前巡检机器人技术以达到了可工程应用水平，在变电站、数据机房等工业场景下均有应用，疫情期间也出现了室内自动消杀机器人的新产品。将巡检机器人应用于制冷机房的日常巡检具有可行性，可以有效解放运维人员大量巡检时间，从而降低建筑运维用人成本，并且巡检机器人具有重复稳定性，能实现全天候设备巡检；根据巡检需求搭载相应传感器，可以实现自动数据记录，数据分析以及异常上报，将数据记录与 BA 数据同步在一起，提高数据的可用性，为运维人员决策提供有效数据支持。

本文来源于巡检机器人在目标机房进行自动巡检部署、数据采集及故障诊断算法开发等工作。截止至本文撰写时，已实现巡检机器人在空调机房、多个制冷机房、锅炉房、办公空间等实地部署，实现自动巡检、自动充电功能。在本



文目标机房中，实现了水泵和冷机的热成像数据、可见光数据、音频数据；机械仪表盘图像数据；管道热成像、可见光数据的采集。其外观如下图所示。



图 1.1 机器人外形结构

### 1.5.2 验证场所

本文基于上海某高端住宅小区的制冷机房进行技术框架构建和算法验证。该制冷机房包括天棚热泵系统、新风热泵系统、新风冷水系统，小区的生活热水供应系统也位于该制冷机房，其系统关键设备拓扑如下表所示：

表 1.1 目标制冷机房关键设备拓扑

系统	设备	数量
天棚热泵系统	螺杆式地源热泵主机	2
	地源水循环泵	2
	天棚循环泵	2
新风热泵系统	螺杆式地源热泵主机	2
	地源水循环泵	2
	新风循环泵	2
新风冷水系统	螺杆式冷水机组	2
	新风冷冻水循环泵	2
	冷却水循环泵	3

该小区夏季采用天棚供冷+新风的形式进行室内热湿环境调节，通过室内天棚吊顶辐射供冷以及新风调节相对湿度，相比住宅建筑常见的中央空调系统，能实现更高的冷冻水供水温度设定，减少冷量损耗，并且避免了空调箱的大量使用，

还实现了热湿分离。通过地源热泵系统夏季辅助制冷和冬季供热，也节省了单位住宅面积空调能耗。

对于该制冷机房，本文主要工作聚焦于其关键设备。当前，制冷机房内冷水机组和地源热泵等主机一般由厂商预装了各类参数检测传感装置，具有一定程度的自我调节能力，附带故障报警和故障代码说明书等，方便运维人员操作和检修。但机房内的水泵往往不具备预装相关传感器和自动报警功能，其一般受 BA 系统控制，由 BA 系统调度并进行简单故障判断，因此，本文着重对目标机房的水泵设备进行研究，结合巡检机器人采集到的多种数据进行故障分析。

## 1.6 技术路线




图 1.2 技术路线

本文技术路线主要分为两大部分，第一部分为基于 BA 数据的能效诊断，从 BA 数据中计算能效指标：冷机的 COP（制冷量与耗电量比值）、冷却水泵冷却水输送系数 $WTF_{cw}$ （冷却水泵输送冷量与冷却水泵耗电量比值）以及冷冻水泵冷冻水输送系数 $WTF_{chw}$ （冷冻水泵输送冷量与冷冻水泵耗电量比值）。当检测到冷机 COP 下降后，基于 BA 数据进行初步判断，若同时出现 $WTF_{cw}$ 下降或 $WTF_{chw}$ 下降，

再依据 BA 数据进行水泵故障分析，其中，水泵机械部分的故障诊断依赖于第二部分工作。

第二部分为基于 BA 数据中电耗数据及机器人采集数据中振动数据、声音数据和热成像图像数据的故障诊断。分别对各类数据进行故障诊断算法开发，得到故障诊断结果，在结论处进行数据融合，最终得到二次诊断结果：轴承磨损、叶轮激振、基础松动等。

## 第2章 制冷机房综合故障诊断流程搭建

### 2.1 基于BA数据的能效故障分析流程

制冷机房的BA系统间存在一定差异性。在系统智能化程度上，一般新建建筑制冷机房的BA系统较老旧建筑的BA系统智能，大型公共建筑较小型、住宅型建筑智能；在系统可用性上，一般新建建筑较老旧建筑运行可靠，大型公共建筑较小型住宅型建筑运行可靠，对于一些试点新建筑或改造建筑其智能化程度和可用性也较高<sup>[52]</sup>。

高智能化程度和可用性往往意味着BA数据可采集数据类型更多，其可靠度也更高。反之，对于智能化程度一般或者可用性一般的制冷机房，其BA系统所能提供的数据较为局限。基于这点，本文选取了制冷机房内较容易获取的几类数据，如下表所示：

表 2.1 BA 数据结构

设备	数据类别	符号	单位
冷水机组	启停状态 (0-1)	$S_{chiller}$	$1$
	逐时功率	$P_{w,chiller}$	$kW$
	单位时间制冷量	$P_{q,chiller}$	$kW$
	冷却水供水温度	$T_{cw,o}$	$^{\circ}C$
	冷却水回水温度	$T_{cw,e}$	$^{\circ}C$
	冷冻水供水温度	$T_{chw,o}$	$^{\circ}C$
	冷冻水回水温度	$T_{chw,e}$	$^{\circ}C$
	高压	$p_h$	$MPa$
	低压	$p_l$	$MPa$
冷却水泵	启停状态 (0-1)	$S_{cw,pump}$	$1$
	逐时功率	$P_{cw,pump}$	$kW$
	流量	$Q_{cw,pump}$	$m^3/h$
冷冻水泵	启停状态 (0-1)	$S_{chw,pump}$	$1$
	逐时功率	$P_{chw,pump}$	$kW$
	流量	$Q_{chw,pump}$	$m^3/h$

性能指标计算表如下表所示<sup>[53]</sup>：

表 2.2 性能指标计算表

设备	性能指标	计算式
冷水机组	制冷能效比	$COP = \frac{P_{q,chiller}}{P_{w,chiller}}$
冷冻水泵	冷冻水输送系数	$WTF_{chw} = \frac{c_p(T_{chw,e} - T_{chw,o})Q_{chw,pump}}{P_{chw,pump}}$
冷却水泵	冷却水输送系数	$WTF_{cw} = \frac{c_p(T_{cw,e} - T_{cw,o})Q_{cw,pump}}{P_{cw,pump}}$




图 2.1 基于 BA 数据的能效故障分析

如图所示，当发现 COP 下降，判断是否高低压异常或者冷机电功率异常，其对应冷机故障；若不是，则判断冷冻水和冷却水供回水温度是否异常，若无显著特征则冷机仅仅是在低能效下运行；若出现异常并且其输送系数过低，则判断水泵电功率是否过低，其对应水泵是否仅是在低能效下运行，否则，进入水泵机械及电气诊断部分。

## 2.2 基于机器人采集数据的故障分析流程

机器人采集数据加上 BA 数据中的电功率数据，可以进行融合故障诊断，分别对电功率数据、声音数据、振动数据、热成像数据进行特征提取，并开发各自算法进行异常检测，最后在结论层进行数据融合，提升故障诊断结果的可信度和扩展故障诊断的内容。




图 2.2 基于机器人采集数据的能效故障分析

## 第3章 基于神经网络-小波变换的水泵音频信号去噪

### 3.1 音频去噪算法介绍

水泵等机电设备运行所产生的音频信号中蕴藏着众多信息，其中包含设备自身固有特征、运行状态特征等信息。在工程上，机电运维人员也通过“听声音”的方式基于经验判断水泵等设备运行是否异常。理论上，可采集水泵运行时的音频信号，通过信号处理等算法提取相关特征，并基于这些特征进行水泵运行状态异常检测。该方法可代替传统人工“听声音”的检测方式，一方面，其检测音频的频域范围大于人耳感知域，感知性能更强，另一方面，其具有人工检测不具有的重复检测稳定性和高效性。

Khuram Naveed<sup>[54]</sup>等人提出了一种基于数据驱动的变分模式分解（VMD）算法和Cramer-Von-Misses(CVM)统计量的信号去噪方法。与经典经验模态分解(EMD)相比，VMD 具有优越的数学和理论框架，对噪声和模态混合具有较强的鲁棒性。VMD 的这些理想特性体现在将大部分噪声分离为几个最终模式，而大部分信号内容分布在早期模式中。为了利用这种表示进行去噪，我们提出了估计噪声主要来自噪声模式的噪声分布，然后用它来检测和抑制剩余模式的噪声。该方法首先利用统计距离的 CVM 测度来选择主要的噪声模式。接下来，在剩余的模式上局部使用 CVM 统计量来测试模式与估计的噪声分布的拟合程度；拒绝产生更接近噪声分布的模式（设置为零）。大量实验证明了该方法在信号去噪方面的优越性，并强调了它在噪声分布未知的实际应用中的实用性。

对于故障样例较少的音频故障分类情况，常采用人工添加噪声的方法进行数据增强，但这容易造成数据特征分布的变化，从而使模型出现分类盲点，Hyun Kwon 等人<sup>[55]</sup>提出了一种声学诱饵方法来分析这类方法带来的弊端，其对分类模型进行逆向分析，获取能干扰模型分类效果但不影响实际样本类别的“对抗性”噪声，并且成功降低了分类模型的准确度，该方法对于模型训练中人工添加异常的做法进行了干扰性评估。

通过对目标制冷机房的调研，我们发现机房内往往同时有多台水泵、冷机等设备运作，这些设备时刻产生着背景噪声，这对我们通过音频信号进行水泵故障诊断的过程产生了一定的干扰，需要合理消除这些背景噪声。这些背景噪声均由旋转机械设备产生，其声音特性与目标水泵存在一定的相似性，且机房内的不同位置、不同时刻设备启停状态不同，背景噪声也存在着变化，因此需要开发一种针对该场景的有效水泵音频信号去噪算法。



### 3.2 音频信号采样

水泵数字音频信号采样的好坏很大程度上影响后续算法的效果。所采集的数字音频信号应能还原实际水泵运行声音。音频信号采样的过程本质上是通过音频采集设备，将实际声波波形转换成一串二进制数据来记录保存原始声音。这一过程中，音频采集设备的采样率（采样速率）越高、用于量化声波波形的采样位数越高，其对声波波形的记录效果也越好，并且，还可通过双声道采样的方式实现立体音的记录。在工程上，一般采用香农采样定理来确定声音采样率的合理范围。

香农采样定理，也叫奈奎斯特采样定理，其定义为：数字信号采样率需要大于等于模拟信号频谱中最高频率的2倍，才能够完好地从数字信号中恢复模拟信号<sup>[56]</sup>，即：

$$f_s \geq 2f_{max} \quad (3.1)$$

其中， $f_s$ 为合理的采样率， $f_{max}$ 为模拟信号频谱中最高频率。

我们在制冷机房现场分别选用 44100Hz、22050Hz、11025Hz 的采样率进行水泵声音试采样，通过对声音信号进行频谱分析确定了其最高频率范围。频谱分析是指利用如傅里叶变换等算法将时域下的信号在频域下表示出来，使得可以更直观得到其不同频率分量的信息如振幅、功率、强度和相位等。对于数字采样信号，快速傅里叶变换可以使计算机时域到频域信号变换的计算量大为减少。应用快速傅里叶变换（FFT）这一针对离散时域数据的快速算法，将声音的时域数据转换成频谱图，通过观察频谱图中有效信息所在的频率范围，可确定频谱中最高频率。

我们发现使用 22050Hz 采样率下能够较好满足香农采样定理要求，且不会由于采用率过高导致采样数据量过大，这可以减少后续信号分析处理过程的算力需求。本文机房现场数据采集过程中，基于 22050Hz 采样率，20s 一段音频的采样时间，分别在不同距离采样各个水不同运行工况下的声音，采集远离水泵各处的声音信号作为背景噪声，数据储存位数为 16 位。

由于机房现场采集音频数据工况点较为单一，且缺乏故障情况下的水泵音频信号数据。而更加完备的实际有利于故障诊断算法的开发和验证，因此我们在水泵实验台中也采集了一系列音频信号数据，构造水泵音频故障数据集，其音频数据结构如下：

表 3.1 实验台水泵声音数据集

音频个数	较弱背景噪声 V0	中等背景噪声 V1	强背景噪声 V2	较强背景噪声 V3
纯背景噪声	210	300	272	278
正常状态 F0	64	96	70	44

表 3.1 (续)

音频个数	较弱背景噪声 V0	中等背景噪声 V1	强背景噪声 V2	较强背景噪声 V3
管道阻塞 F1	80	82	76	84
水含泥沙 F2	66	62	66	44

该数据集背景噪声使用水泵、电机等旋转机械设备产生，分为4个级别，分别为较弱背景噪声（V0），中等背景噪声（V1），强背景噪声（V2），较强背景噪声（V3），用于模拟制冷机房现场背景噪声情况。采集点为随机选取的实验台周边各个位置点。

该数据集包含水泵正常、管道阻塞、水含泥沙共3种状态，均为人为产生，其中两类故障状态未对水泵造成不可逆损伤。在不同背景噪声条件下采集水泵不同状态下的音频信号数据，最终产生16类音频信号数据。

### 3.3 水泵音频信号时频域分析

对所采集的实验台水泵音频信号数据，分别取纯背景噪声（V2）、纯水泵声音（F0）、相同背景噪声下水泵声音（F0-V2）3类数据进行频谱分析，如下图所示：




图 3.1 某组音频信号时域波形（噪声背景下水泵声音/纯水泵声音/纯背景噪声）

对于图 3.1 音频信号波形图，直观来看，噪声背景下水泵声音（混噪）、纯水泵声音（纯音）和纯背景噪声（纯噪）三者波形图未有明显的区分。通过特征工程，提取这三类音频信号波形图的相关特征，并进行聚类分析，来分析时域上三者是否存在显著差异性，从而评估在时域上进行噪声去噪的可行性。

首先将数据集划分为混噪、纯音、纯噪三类数据，如表 3.2 所示，表中每一行代表水泵在相同运行状态，相同背景噪声水平下的数据。

表 3.2 数据集分类聚类表

条件	背景噪声下的水泵声音（混噪）	纯水泵声音（纯音）	背景噪声（纯噪）
1	F1-V1	F1-V0	V1
2	F1-V2	F1-V0	V2
3	F1-V3	F1-V0	V3
4	F2-V1	F2-V0	V1
5	F2-V2	F2-V0	V2
6	F2-V3	F2-V0	V3
7	F3-V1	F3-V0	V1
8	F3-V2	F3-V0	V2
9	F3-V3	F3-V0	V3

其次，分别对每一行数据进行特征提取，计算相关特征，包括：均值、方差、标准差、均方根、偏度、峭度、波形因子、峰值因子、脉冲因子、裕度因子<sup>[57]</sup>。

最后，对每一行特征数据进行聚类分析，本文采用 k-means 聚类法，设定聚类类别为 3，得到如图 3.2 结果（条件 1）。图中椭圆框为聚类边界，三种颜色点对应表中三类数据，可以发现出现较多的误聚类点（被聚到其他类别中的数据点），混噪、纯音、纯噪三种类别的数据存在相互混合，说明该行三类数据的时域特征差异未存在具有规律性的分布。




图 3.2 条件 1 下三类数据特征聚类结果

计算每一行中误聚类点占该行数据点总数的比例，可以衡量各个条件误聚类

情况,如表 3.3 所示,条件 1-9 的聚类效果均较差(平均误聚类比例达 38.5%),可以得出在时域空间内,三类数据未存在显著差异,在时域上进行噪声去噪的可行性较低。

表 3.3 时域空间各条件下误聚类比例

条件	误聚类点比例
1	39.2%
2	34.7%
3	27.4%
4	34.0%
5	34.4%
6	25.5%
7	50.0%
8	49.9%
9	51.2%

在频域空间内,通过快速傅里叶变化将时域信号转换成频谱图。同样地,对频域上的数据进行聚类分析,得到如表 3.4 结果,聚类效果均与实际分类较为相近(平均误聚类比例仅 13.9%)可见在频域空间内进行水泵声音与背景噪声的分离具有更高可行性。

表 3.4 频域空间各条件下误聚类比例

条件	误聚类点比例
1	7.6%
2	16.4%
3	18.5%
4	18.7%
5	13.4%
6	15.1%
7	11.7%
8	11.6%
9	11.8%

取某组水泵音频信号频谱图,如图 3.3 所示(横坐标为频率,纵坐标为幅值)。可以直观地看到,纯水泵声音在低频区存在较大分量,中高频区存在较明显的分量,而纯背景噪声只在低频区存在较大分量。在背景噪声下的水泵声音频谱图则融合了前两者的特征。在中高频段,可以在频域上进行信号处理来有效从含噪声水泵声音中去除背景噪声,但在低频段两者存在分量叠加。前述的音频去噪算法一般适用于有效音频信息与噪声信息存在明显频谱分离的情况,因此在本场景频谱

低频段效果较差。




图 3.3 某组音频信号频谱图（噪声背景下水泵声音/纯净水泵声音/纯背景噪声）

## 3.4 小波变换去噪原理

### 3.4.1 小波变换基本原理

传统通过傅里叶变换进行信号频谱分析的过程中，对于高频段和低频段的频率分辨率和时间分辨率均是一样的，对于如低频段富集有效信号的场景，无法做到高频段时间细分，低频段频率细分。小波变换<sup>[58]</sup>是指利用具有特殊波形的小波函数（基底），通过平移缩放等对原始时域信号进行逐步运算，实现对原始信号的多尺度细分。可根据信号处理需求对信号的不同频率段进行不同尺度运算，解决傅里叶变换所难以解决的问题。

连续小波变换首先需要确定小波母函数。若存在一个函数 $\Psi(t)$ 满足平方可积的要求，即 $\Psi(t) \in L^2(\mathbb{R})$ ，该函数的傅里叶变换结果 $\Psi(w)$ 满足：

$$C_{\Psi} = \int_{\mathbb{R}} \frac{|\Psi(w)|}{|w|} dw < \infty \quad (3.2)$$

满足该条件的变换便是小波基函数。对上述 $L^2(\mathbb{R})$ 空间中的任意一个函数 $f(t)$ ，在确定的小波基函数下分解，如下所示：

$$WT_f(\alpha, \tau) = \left( f(t), \Psi_{\alpha, \tau}(t) \right) = \frac{1}{\sqrt{\alpha}} \int_{\mathbb{R}} f(t) \Psi^n \left( \frac{t - \tau}{\alpha} \right) dt \quad (3.3)$$

也可得该函数对于的小波逆变换为：

$$f(t) = \frac{1}{C_{\Psi}} \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} \int_{\mathbb{R}} \frac{1}{|\alpha|^2} W_f(\alpha, b) \Psi \left( \frac{t - b}{\alpha} \right) d\alpha db \quad (3.4)$$

在工程使用过程中，实际数据基本为离散数据，计算机运算时也具有离散运算特性，因此需要对连续小波变换进行改造，使之适用于离散运算。小波变换离散过程主要是 $\alpha$ ， $\tau$ 的离散化，小波变换对应的离散化表达式为：

$$WT_f(\alpha_0^j, k\tau_0) = \int f(t) \Psi_{\alpha_0^j, k\tau_0}^{n_f}(t) dt \quad (3.5)$$

$$j = 0, 1, 2, 3, \dots, k \in \mathbb{Z}$$

也可得该函数对于的小波逆变换为:

$$f(t) = c \sum_{-\infty}^{\infty} \sum_{-\infty}^{\infty} c_{j,k} \Psi_{j,k}(t) \quad (3.6)$$

通过上述计算方法, 可对一个离散信号数据进行小波变换, 得到其时频域信息, 小波变换的另一个特点在于可以对信号数据进行多尺度的分析, 其原理为选取一个正交函数系, 在该函数系构造一系列可渐近分解的正交补函数作为正交小波基, 不同分辨率的小波基可以描述不同频率和时间分辨率下的信号时频特征, 由此实现了小波变换的尺度变化。

### 3.4.2 小波变换对信号的分解与重构

对于一段离散信号 $f(t)$ , 对其进行多层次下的波变换, 得到不同尺度的特征组, 并且可以通过小波逆变换基于该特征组进行重构, 还原原始信号。在这个过程中, 小波分解可以视为对信号的一种滤波, 其运算过程为利用小波基函数组(分别起到低通滤波与高通滤波作用)在信号数据上滑动计算内积, 得到低通滤波结果和高通滤波结果, 前者为低频信息代表近似分量, 后者代表高频信息代表细节分量, 保留高通滤波结果, 对低通滤波结果进行下一次的小波基函数组滤波, 直到到达指定分解层次。




图 3.4 小波分解与重构

如图 3.4 所示, 最终 $f(t)$ 可分解为 $[cA3, cD3, cD2, cD1]$ 特征组, 由于小波分解的可逆性和特征组包含完整结果, 可以通过小波逆变换重构原始信号。

取本文声音数据集中某一个音频信号数据为例, 其分解后的特征组图, 如图 3.5 所示:




图 3.5 小波分解与重构

特征组的每一个特征均为一个时间序列数据，对这些特征值进行线性操作，等效于对原始信号进行定性非线性操作。在语音、图像去噪的过程中恰恰面临着时域空间噪声与信号高度混合的情况，通过小波分解，可以将这一非线性去噪过程转变为线性运算。

### 3.4.3 小波变换去噪过程

小波变换去噪<sup>[59]</sup>的基本条件为，一段信号数据中，其有效信号部分和噪声部分在频域上存在分离，例如含噪语音信号的有效信号主要位于高频段，而噪声部分一般位于低频段。对该含噪语音信号进行小波分解后，可发现噪声与语音信号在各个尺度上表现特性不同，由此实现去噪。

在原理上，满足小波变换去噪条件的信号一般可用如下模型表示：

$$F(t) = s(t) + e(t) \quad (3.7)$$

其中 $s(t)$ 表示有效信号， $e(t)$ 表示噪声信号。对 $e(t)$ 进行合理假设，假设 $e(t)$ 为白噪声（均值0，方差 $\sigma^2$ ）。取小波函数 $\varphi(t)$ ，则该白噪声的小波变换为：

$$W_e(a, t) = \int_{-\infty}^{+\infty} e(u) \varphi_a(t - u) du \quad (3.8)$$

根据假设：

$$E\{e(u)e(v)\} = \sigma^2 \delta(u - v)$$

$$\begin{aligned} |W_e(a, t)|^2 &= \int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} e(u)\varphi_a(t-u)e(v)\varphi_a(t-v)dudv \\ &= \int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} e(u)e(v)\varphi_a(t-u)\varphi_a(t-v)dudv \end{aligned} \quad (3.9)$$

可以得到:

$$\begin{aligned} E\{|W_e(a, t)|^2\} &= \int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} E\{e(u)e(v)\}\varphi_a(t-u)\varphi_a(t-v)dudv \\ &= \sigma^2 \int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} \delta(u-v)\varphi_a(t-u)\varphi_a(t-v)dudv \\ &= \sigma^2 \int_{-\infty}^{+\infty} |\varphi_a(t-u)|^2 du \\ &= \sigma^2 \|\varphi\|^2 / a \end{aligned} \quad (3.10)$$

上述推导可证明信号经小波变换后, 其平均功率与表征尺度的  $a$  呈负相关。尺度  $a$  一般取 $[0,1]$ , 在该范围内, 设 $f(x)$ 在 $[a,b]$ 范围内有一致利普希茨指数 $\alpha$ 的充要条件是存在一个常量 $k>0$ , 使函数在 $[a,b]$ 范围内的小波变换满足:

$$\begin{aligned} |W_{2^j}, f(x)| &\leq k(2^j)^\alpha \\ &= \log_2 |W_{2^j}, f(x)| \leq \log_2 k + \alpha j \end{aligned} \quad (3.11)$$

可以知道, 当 $f(x)$ 的利普希茨指数 $\alpha$ 大于0时, 函数小波变换模极大值与尺度呈正相关, 当 $f(x)$ 的利普希茨指数 $\alpha$ 小于0时, 函数小波变换模极大值与尺度呈负相关。实际生活中的噪声一般利普希茨指数 $\alpha$ 小于0, 与有效信号噪声相反, 因此可以对小波变换后各尺度上的结果进行噪声去除。

对小波变换各尺度结果进行数值调整常采用小波变换阈值去噪法。该方法是找到一个合理的阈值, 可以保留大于该阈值的小波系数, 对小于该阈值的小波系数进行一定处理, 最终从处理后的小波系数中还原有效信号。该方法流程如下:




图 3.6 小波变换去噪流程图

阈值的选取极大影响了去噪的效果, 小波变换阈值去噪法又可分为硬阈值去噪和软阈值去噪法, 其处理函数如下。

(1) 硬阈值:



$$\sigma_{\lambda}^H(w) = \begin{cases} w, |w| \geq \lambda \\ 0, |w| < \lambda \end{cases} \quad (3.12)$$

(2) 软阈值:

$$\sigma_{\lambda}^H(w) = \begin{cases} [sgn(w)(|w| - \lambda)], |w| \geq \lambda \\ 0, |w| < \lambda \end{cases} \quad (3.13)$$

式中,  $w$  为小波系数,  $\lambda$  为阈值。硬阈值处理下, 由于函数并非连续, 处理后容易导致小波系数在  $\lambda$  值附近出现交错 0 值, 引入新的误差。软阈值处理下, 虽然连续函数处理后信号会相对平滑, 但也会丢失一些特征。

在阈值的选取上也存在不同的方法, 如

(1) 通用阈值规则:

$$\lambda = \sigma\sqrt{2\ln N} \quad (3.14)$$

式中,  $N$  为小波系数总数,  $\sigma$  为噪声的标准差。

(2) 最小极大方差阈值:

$$\lambda = \begin{cases} \sigma(0.3936 + 0.1829)\left(\frac{\ln N}{\ln 2}\right), N \geq 32 \\ 0, N < 32 \end{cases} \quad (3.15)$$

$$\sigma = \frac{\text{middle}(W_{1,K})}{0.6745}, 0 \leq k \leq 2^{j-1} - 1$$

式中,  $N$  为某个尺度上小波系数总数,  $W_{1,K}$  为尺度为 1 的小波系数,  $\sigma$  为噪声的标准差。

(3) 无偏似然估计阈值:

$$r(t) = \frac{n - 2t + \sum_{i=1}^t y(i) + (n-t)y(i)}{n} \quad (3.16)$$

$$\lambda = \sqrt{\min(r(t))}$$

式中,  $y(t)$  为信号  $|x(t)|^2$  的升序序列。

(4) 启发式阈值规则:

$$\text{eta} = \frac{\|x\|^2 - n}{n}$$

$$\text{crit} = \frac{[\log(n)/\log 2]^{1.5}}{\sqrt{n}} \quad (3.17)$$

$$\lambda = \begin{cases} \lambda_1, \text{eta} < \text{crit} \\ \min(\lambda_1, \lambda_2), \text{eta} \geq \text{crit} \end{cases}$$

式中， $n$  为信号  $x(t)$  数据点数， $\lambda_1$  为通用规则阈值， $\lambda_2$  为无偏似然估计阈值

上述几种阈值处理函数和阈值确定规则适用于噪声与信号的小波系数存在明显区分的情况，但对于噪声与信号小波系数存在部分区分的情况效果一般，容易对有效信号的小波系数造成一定误操作，造成新的干扰。

### 3.5 神经网络-小波变换去噪算法原理

#### 3.5.1 小波变换去噪算法局限性

当前场景下，一方面制冷机房内声场环境较为固定，其声音去噪需求相对常见通用语音去噪需求而言，对通用性的要求下降，但对精密性的要求提高了，另一方面，其噪声成分也相对确定，加上我们可以采集到大量纯净水泵声音、纯背景噪声、混噪声音数据，因此，基于数据驱动的去噪方法存在可行性。

前述的小波变换去噪算法由于适用条件限制，无法很好在本文水泵声音去噪场景下使用，但其可对信号多尺度分解的优点，相较传统傅里叶变换，更方便对信号系数进行微调，从而达到我们所需要的结果。当前常见的阈值处理过程较为单一，要么采用固化的阈值，要么基于假定噪声特征条件下，从统计的角度调整阈值，对信号数据有着较高的要求，实际工程情况中，较少存在信号噪声特征显著分离的情况。

#### 3.5.2 小波变换去噪算法改造

前述小波变换去噪算法的阈值去噪过程可以看作是寻找一系列矩阵  $\{M_0, M_1, \dots, M_n\}$ ，一一对各个尺度的小波系数进行矩阵变换，使之变换为趋近不包含噪声信号的小波系数，如下所示：

$$w_{se,i} \cdot M_i \rightarrow w_{s,i} \quad (3.18)$$

式中， $w_{se,i}$  为某个尺度的包含噪声的信号小波变换系数， $w_{s,i}$  为不包含噪声信号的小波系数， $w_{se,i}$  经矩阵  $M_i$  变换后，趋近于  $w_{s,i}$ 。

由于我们能采集到纯背景噪声数据以及纯净水泵声音数据，因此可以推导出变换矩阵，在大量数据支持下，可以得到在该场景下适用性较高的  $\{M_0, M_1, \dots, M_n\}$ 。

神经网络可以很好适应该需求，可以构造  $\{w_{se,0}, w_{se,1}, \dots, w_{se,n}\}$  为输入，以  $\{w_{s,0}, w_{s,1}, \dots, w_{s,n}\}$  为输出的神经网络  $M$ ，实现

$$\{w_{se,0}, w_{se,1}, \dots, w_{se,n}\} \cdot M \rightarrow \{w_{s,0}, w_{s,1}, \dots, w_{s,n}\} \quad (3.19)$$

由此，前述小波变换去噪算法可以改造为：




图 3.7 神经网络-小波变换去噪算法流程图

### 3.5.3 BP 神经网络介绍

BP (Back-propagation, 反向传播) 神经网络<sup>[60-63]</sup>, 采用了误差反向传播的思想, 属于多层前馈网络, 是一众神经网络中使用最广泛发展最迅速的神经网络。BP 神经网络一般为三层结构: 输入层、隐藏层、输出层, 如下所示:




图 3.8 BP 神经网络结构

图中隐藏层实际上可能有许多层级, 图中只是简略表示, 其中的每一个单元作为一个神经元, 首先接收前面多个输入, 对输入 $\{x_0, x_1, \dots, x_k\}$ 进行函数映射, 将输出值放入激活函数后处理后, 传递至后一层所有或部分神经元中(某些情况下采用部分连接来避免过拟合)。其中  $w$  为该神经元初始权重,  $b$  为偏置值。激活函数起到的作用是控制神经元的输出在合理范围内。




图 3.9 神经元前向传播过程

由于 BP 神经网络层数有时可以达到较大规模，其正向传播过程是一个数值累积过程，若未控制神经元的输出范围，则可能导致数值爆炸或数值趋于零，因此需要使用激活函数进行限制，常用激活函数有 Sigmoid、TanH、ReLU 等。

反向误差传播的实现是通过反推梯度实现的，从输出层开始，根据累积激活函数及神经元映射函数梯度，一步步倒推回第一层神经元，如下图所示。




图 3.10 神经元反向传播过程

得到一次反向传播的梯度后，根据设定的学习率（更新步长），可对各个神经元的权重进行更新，由此完成训练的一步，通过不断重复正向传播、计算梯度、更新权重的过程，可以不断调整模型参数。

有了模型参数调整方法后，还需要评价指标和寻优方法，来评价模型效果和调整模型训练方向。一般采用损失函数来对模型效果进行评价，根据模型结构和功能不同，所构造的损失函数也不同，常用的几种损失函数为：

(1) softmax 交叉熵损失函数 (softmax cross entropy loss)

$$E(t, y) = - \sum_j t_j \log y_j \quad (3.20)$$

$$y_j = \text{softmax}(z_j) = \frac{e^{z_j}}{\sum_j e^{z_j}}$$

式中,  $t$  为目标标签,  $y$  为输出,  $y_j$  为损失函数。该损失函数一般适用于分类问题。

(2) 交叉熵损失函数 (Categorical Crossentropy)

$$H(y, t) = - \sum_i t_i \log y_i \quad (3.21)$$

该函数也常用于分类问题, 且类别间存在相互排斥。

(3) 均方误差损失函数 (Mean Square Loss)

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - t_i)^2 \quad (3.22)$$

该函数通过计算输出结果和标签值的均方误差来衡量模型效果, 是回归问题中最常用的损失函数之一。

根据损失函数所计算出的输出与标签的误差值, 选取合适的优化算法, 可以使模型误差收敛到可接受范围。梯度下降法是当前神经网络领域最流行的优化算法之一, 常见梯度下降法如下。

(1) 批量梯度下降法 (BGD, Batch Gradient Descent)

$$\theta = \theta - \eta \cdot \nabla_{\theta} J(\theta) \quad (3.23)$$

式中,  $\theta$  表示网络权值,  $\eta$  表示学习率, 代表一次更新的步长长度,  $\nabla_{\theta} J(\theta)$  代表权值的梯度。该算法一次对所有数据集进行梯度计算和更新, 虽然梯度下降较为稳定, 但不适用大量数据集的情况, 因此相对较少使用。

(2) 随机梯度下降 (SGD, Stochastic Gradient Descent)

$$\theta = \theta - \eta \cdot \nabla_{\theta} J(\theta; x^{(i)}; y^{(i)}) \quad (3.24)$$

式中,  $x^{(i)}$ ,  $y^{(i)}$  分别代表某一个输入和输出, 不同于 BGD 一次计算数据集所有数据, 该算法一次计算只对数据集中的一对数据进行梯度更新, 在一个循环过程完成后才完成数据集所有数据计算。对于大样本数据集来说可以减少冗余计算, 但相比 BGD 而言还是存在一定的噪声, 即 SGD 不是每一次计算都往梯度下降最优方向走, 存在一定随机性。

(3) 自适应矩估计 (Adam, Adaptive Moment Estimation)

该算法数据自适应优化算法范畴, 该范畴内存在着许多优秀的算法, 但 Adam 是其中在神经网络中较为常用的一种方法。该方法需要先初始化两个衰减指数:

$$m_t = \beta_1 m_{t-1} + (1 - \beta_1) g_t \tag{3.25}$$

$$v_t = \beta_2 v_{t-1} + (1 - \beta_2) g_t^2$$

其中 $m_t$ 为  $t$  轮次梯度的指数衰减平均值， $\beta_1$ 为求和权值， $g_t$ 为对角矩阵其元素  $g_i$  为  $t$  轮次梯度  $i$  的平方和， $v_t$ 为  $t$  轮次梯度平方的指数衰减平均值。并且，衰减指数可通过偏差校正来避免初始化为 0 的问题:

$$\hat{m}_t = \frac{m_t}{1 - \beta_1^t} \tag{3.26}$$

$$\hat{v}_t = \frac{v_t}{1 - \beta_2^t}$$

该算法梯度更新规则为:

$$\theta_{t+1} = \theta_t - \frac{\eta}{\sqrt{\hat{v}_t + \epsilon}} \hat{m}_t \tag{3.27}$$

该算法可以自适应调整学习率，并且相比其他算法能更快找到正确优化方向，可以达到非常快的收敛速度，在训练时可以达到较好的结果，但模型使用时，容易出现性能相较 SGD 较差的问题，因此需要根据数据量、使用场景进行选择。

### 3.5.4 神经网络-小波变换去噪算法搭建

由于该算法包含了神经网络部分，因此算法搭建流程也是一个训练的流程，训练流程如下:




图 3.11 神经网络-小波变换去噪算法训练流程 step1

训练过程分为两个阶段，阶段一如图 3.9 所示，取含噪信号数据与对应的纯净信号数据进行小波变换分解，得到含噪小波系数  $X$  和纯净小波系数  $L$ ，由此构建  $X$  为输入， $L$  为标签的  $(X, L)$  数据集。

根据数据集长度，定义了由两个全连接层组成的网络结构，全连接层是指其内的相邻层神经元采用全连接的形式，图中分别为  $1782 \times 512$  的全连接层 1 和  $512 \times 256$  的全连接层 2。激活函数选择 ReLU 函数。由于该神经网络用于回归，因此采用 MSE（均方误差）损失函数，计算模型输出  $Y$  与纯净小波系数  $L$  的误差。

通过该阶段一的训练后，可以得到一个损失函数值相对较小的模型，能够较好的把含噪小波系数  $X$  映射到纯净小波系数  $L$ 。但该阶段只关注于小波系数的处理，损失函数 MSE 对输入的各个特征权重为相同权重，即，该阶段是将小波系数中各个数值视为相同权重，来训练模型的。

实际上，小波系数中包含着不同尺度下声音信号的时频特征，有效信号处于特定频段而非全频段这一特性也导致了某些尺度下的小波系数的改变会显著影响有效信号，而其他尺度下的小波系数改变影响相对较小。

这一权重差异与信号中有效部分与噪声部分的分布有关，理论上，可以为模型输入的小波系数人为设定一个合理的权重分布，使训练后的模型输出的映射后的小波系数能较好重构到纯净信号，但这一过程无异于直接人为调整小波系数，甚至不如基于阈值法小波变换去噪。

因此，本文在阶段一结束后，对模型进行一定调整，并且引入了新的损失函数，该损失函数包含了信号数据本身的误差。阶段二流程如下图所示。




图 3.12 神经网络-小波变换去噪算法训练流程 step2

在阶段一的基础上，增加了新的计算损失函数的分支，对模型输出  $Y$  进行小波变换信号重构，得到重构信号  $C$ ，计算其与纯净信号  $B$  的 MSE 损失函数 2，将损失函数 1 与损失函数 2 加权求和，得到一个复合损失函数。该损失函数引入了信号本身的误差，通过损失函数 2 这一部分来调整模型后续优化方向，相当于在模型内部完成了输入特征权重赋值的操作。

完成模型训练后，对于一个新的含噪信号，通过预处理、小波变换分解成含噪小波系数后，可放入该模型，得到模型输出，并对输出值进行小波变换重构，最终得到去噪信号。

### 3.6 水泵音频信号去噪验证及结果分析

#### 3.6.1 混音原理

神经网络-小波变换去噪算法包含小波变换部分，而小波变换后的系数保留了信号的时间信息。由于不同时刻下采集的同一个位置信号数据会存在一定差别（包含随机噪声和信号本身变化），小波系数也会存在一定差异，这种微小差异在该算法神经网络部分的 MSE 损失函数中会被累加放大，导致模型训练时出现损失函数波动和无法收敛等问题，因此，理论上需要含噪信号和纯净信号为同一时



刻采集得到，这样模型能专注于去噪能力的提升。

但实际上，我们无法同时采集到某个位置的纯净信号数据和含噪信号数据，因此可以采集同一位置的噪声信号和纯净信号，通过一定的信噪比（衡量信号中有效信号的强弱）人工合成含噪信号，构造同一时刻同位置下的含噪信号和纯净信号数据集。这种人工合成信号的方式原理上具有合理性，且许多基于数据驱动的去噪算法如 RNNoise 也是如此操作。

声音信号混音原理<sup>[64-65]</sup>包含三个基本假定：

1. 声音是一种连续平滑的压力波，转换量化成声音信号后，仍然是一种连续平滑的信号波；
2. 量化的声音信号的频率对应声音的频率，其振幅对应声音的音量；
3. 量化的声音信号叠加等价于声波的叠加。

### 3.6.2 混音公式

开阔空间中某个点  $j$  的声波  $b_j(t)$  等于周围  $k$  个声源声波  $b_{j,i}$  在该处的线性叠加，即：

$$b_j(t) = \sum_{i=0}^k b_{j,i} \quad (3.28)$$

封闭空间中某个点  $j$  的声波  $b_j(t)$  除了周围  $k$  个声源声波  $b_{j,i}$  在该处的线性叠加，还需考虑混响问题，即各个声源的声波在空间边界上衰减反射在点  $j$  形成声波延时叠加的情况。

$$b_j(t) = \sum_{i=0}^k (b_{j,i} \cdot h_{j,i}) \quad (3.29)$$

式中， $h_{j,i}$  为某个声源在该位置的脉冲响应（Impulse Response），其描述了某一声源在某个空间位置中的传输延时、混响衰减等信息，本质上是一张横轴为时间，纵轴为分贝的半对数时域图，在该点  $j$  对各声源声音信号和对应脉冲响应进行卷积求和计算，可以得到包含混响的声音  $b_j(t)$ 。

本文所研究场景下，制冷机房空间较为开阔，可以认为声音在机房内的回响效应较弱，因此水泵声音检测点处的噪声和水泵声音的叠加可简化为线性叠加。

### 3.6.3 含噪声音信号合成

$$SNR = 10 \cdot \log_{10} \frac{\sum_t s^2(t)}{\sum_t n^2(t)} \quad (3.30)$$

式中， $SNR$ 为信噪比， $\Sigma_t s^2(t)$ 和 $\Sigma_t n^2(t)$ 分别为有效信号的能量和噪声能量。在含噪声信号合成的过程中，采用不同的信噪比，可以调整信号在噪声能量水平，从而得到不同含噪水平的声音信号，扩充数据集的分布范围。合成的信号计算公式如下：

$$\alpha = \frac{\Sigma s^2(t)}{\Sigma n^2(t) \cdot 10^{SNR/10}} \quad (3.31)$$

$$b(t) = s(t) + \alpha \cdot n(t)$$

式中 $\alpha$ 为通过  $SNR$  公式反推的噪声缩放因子， $b(t)$ 为合成后的声音信号。由于声音信号储存位数的限制（本文采用 16 位储存），通过该式合成的声音信号容易产生数值溢出，即数值超过 $[-127, 127]$ 范围，因此需要进行振幅调节：

$$b(t) = \frac{s(t) + \alpha \cdot n(t)}{1 + \alpha} \quad (3.32)$$

$$s_1(t) = \frac{s(t)}{1 + \alpha}$$

上式可以使合成的含噪声信号数值不超过 $[-127, 127]$ ，但对应的纯净声音信号也需进行振幅调节。

### 3.6.4 数据集构建

本文所采集的实验台纯净水泵声音共 210 段，背景噪声共 850 段，由于算力限制，选择其中 100 段纯净水泵声音和 50 段背景噪声，分别按照信噪比 20、15、10、5db 进行混合，可以生成数量为 20000 的数据集。

分别进行小波变换分解后，可以得到长度为 1782 的小波系数，即形成  $1782 \times 20000$  输入矩阵， $1782 \times 20000$  的标签。

### 3.6.5 训练结果

将数据按照 7:3 划分训练集和测试集，将训练集输入模型进行训练，选取损失函数为 MSE，经过多次调参，最终选择优化方法为 SGD，学习率为 0.01，训练结果如下，可以看到损失函数数值随训练轮次增加快速下降到较低水平(0.0032)。

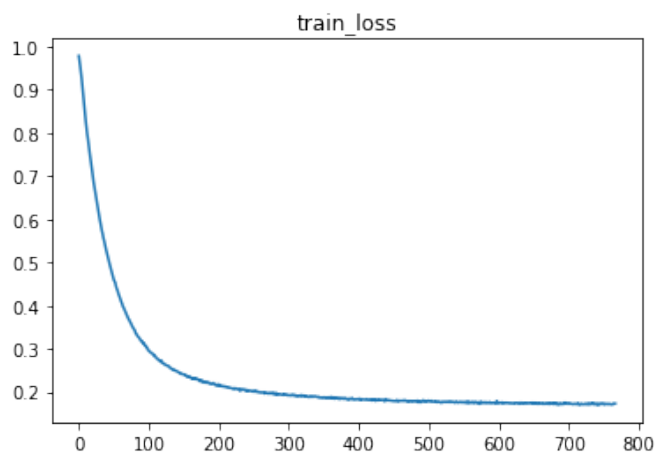


图 3.13 阶段一损失函数收敛过程

在测试集上进行测试，平均误差（Average MSE）达到 0.0043，接近训练时的平均误差。可见模型性能达到较好水平。

## 第4章 基于自编码器的水泵音频信号异常检测

### 4.1 水泵音频信号样本分析

在制冷机房现场进行水泵音频信号样本采集过程中，较难获得异常状态下的水泵音频信号，基本为正面样本。从实验台采集的数据包含多类水泵异常数据，可以基于该实验台数据训练故障分类模型，但这样的模型分类结果只是针对实验台数据，无法迁移到实际工程环境中使用或训练，一方面因为模型学习到的各类故障类别特征来自于特定水泵在特定情况下的故障状态，另一方面因为现场无法提供训练所需数据。

考虑到现场条件下运维人员基于水泵声音的水泵状态判断主要进行的是异常判断，即只判断水泵是否异常，进一步的异常检测需要依赖专业的仪器和维修人员进行拆解检测。出于水泵声音对异常检测的实际作用和算法迁移训练可行性考虑，可以将其视为异常检测问题而非多故障分类问题。

在上述异常检测方法中，自编码器<sup>[66]</sup>可以很好应对小负面样本甚至是零负面样本的异常检测问题。其常见的实现形式是神经网络，原理是对于一系列满足一定分布的数据，构造一个对称网络能够有效提取这一系列数据的分布特征，并用这些特征重构回其本身，即构造一个适用于该系列数据的自映射函数，对于不符合该分布的数据，该网络无法很好完成自映射，从而判断其为异常数据。




图 4.1 自编码器异常检测示意图

自编码器的训练过程由于均采用正面样本，且模型训练较快，可以较方便地迁移到工程现场中使用，符合本文场景需求。

## 4.2 自编码器原理

自编码器 (Autoencoder) <sup>[67]</sup> 是一种无监督的特征提取算法，分为编码器和解码器两部分，能够从样本中自动学习提取特征和重构数据的算法，且该过程是有损的，其过程是通过神经网络实现的。

随着自编码器在深度学习中重要性的逐渐提升，现已经演变出多种类别的自编码器，包括浅层自编码器、栈式编码器、变分自编码器等，适用于特征提取、图像增强等领域。

浅层自编码器较常用于异常检测，其网络结构如下图所示：




图 4.2 自编码器模型图

该网络结构为编码器、特征层、解码器三层对称结构，且这些网络均为前馈式神经网络，其特征层维度小于输入  $x$  和输入  $x'$ 。采用这样的结构训练该模型完成自映射，能够自动找到输入数据分布的显著特征。其原理如下：

$$\begin{aligned}\phi: X &\rightarrow F, \\ \psi: F &\rightarrow X,\end{aligned}\tag{4.1}$$

$$\phi, \psi = \operatorname{argmin}_{\phi, \psi} \|X - (\phi \circ \psi)X\|^2$$

式中  $\phi$  代表编码函数，将输入数据  $X$  映射到特征  $F$ ， $\psi$  代表解码函数，将特征  $F$  解码到  $X$ ，训练过程即拟合一个恒等函数，该恒等函数实现  $\|X - (\phi \circ \psi)X\|^2 = 0$ 。在实数域内（常见研究域），

$$\begin{aligned}z &= f(Ax + c), \\ x' &= g(Bz + d),\end{aligned}\tag{4.2}$$

$$L(x, x') = \|x - x'\|^2 = \|x - g(Bf(Ax + c) + d)\|^2$$

式中,  $f$  为编码器的激活函数,  $A$  为网络权重,  $c$  为偏置; 同理  $g$  为解码器的激活函数,  $B$  为网络权重,  $d$  为偏置。对于维度为  $m$  的输入数据, 构建厚度为  $n$  的编码层和解码层, 可以得到编码层  $A_{m \times n}$  维度为  $m \times n$ , 解码层  $B_{n \times m}$  维度为  $n \times m$ , 特征层的维度为  $n \times 1$  (采用单层特征的话)。可以证明, 当  $m > n$  时, 自编码器能够很好学习到数据分布的显著特征。

if  $n = m$ :

$$\text{令 } A_{m \times n} = B_{n \times m} = I_n, c=d=0, f=g=\text{id}, \text{ 使得 } L(x, x') \equiv 0$$

if  $n > m$ :

$$\text{存在无数 } B_{n \times m}, A_{m \times n}, \text{ 使得 } B_{n \times m} A_{m \times n} = I_n, L(x, x') \equiv 0$$

(4.3)

if  $n < m$ :

假设存在  $B_{n \times m} A_{m \times n} = I_n$ , 则

$$n = \text{rank}(I_n) = \text{rank}(BA) \leq \min\{\text{rank}(A), \text{rank}(B)\} \leq \min\{m, m\} =$$

$m$

产生矛盾, 故不存在  $B_{n \times m}, A_{m \times n}$  使得  $B_{n \times m} A_{m \times n}$  为恒等变换

因此, 只有当  $m > n$  时, 才能限制自编码器以有损的形式去挖掘输入数据的分布特征, 否则容易陷入只寻找恒等变换的情况。

### 4.3 水泵音频信号异常检测验证及结果分析

可以采用声音数据的频谱图作为输入数据训练自编码器。与前文去噪算法使用小波系数对比, 前者涉及到对声音数据本身的调整, 小波变换有更好的适用性和操作精细度, 后者属于分类问题, 需要根据数据特征进行类别划分, 小波系数和频谱图虽然均反应了声音特征, 但小波系数数据维度巨大, 需要耗费巨大算力, 且频谱图本身已足够进行特征分类。

将实验台水泵去噪后的声音数据进行分类, 如下表所示:

表 4.1 水泵样本数据分类

	正面样本	负面样本	其他样本
数据个数	274	834	1060

正面样本为各个噪声条件下正常水泵的声音样本，负面样本为各个噪声条件下的异常水泵的声音样本，其他样本为不同强弱的背景噪声。分别计算其频谱图，作为每个数据的一维特征。

根据输入数据特征维度，构造自编码器网络如下所示：




图 4.3 自编码器网络构造

将正面样本的特征数据的 70% 作为训练集，30% 作为测试集，负面样本及其他样本也作为测试集。输入数据维度为 1024（频谱图为长度 1024 的一维数据），构造特征层维度为 128，以此作为限制，损失函数采用 MSE，优化算法采用 Adam，学习率调整为 0.001，训练结果如下，可见，模型的损失函数数值快速收敛。




图 4.4 自编码器训练结果

不同于一般神经网络，自编码器的输出并不是分类标签，而是解码器的重构结果，因此使用自编码器的时候需要再计算重构结果与输入数据的 MSE，并根据正负样本 MSE 的差别，划定一个合理阈值，作为异常判别的标准。在训练集与测试集上进行模型测试，测试结果如下图所示：




图 4.5 自编码器测试结果

图中，纵坐标为重构结果与输入数据的 MSE 取  $\log_{10}$ ，红色点代表负面样本及其他样本，绿色点代表正面样本，两类数据结果存在明显划分，可见自编码器的确能准确进行正面样本和非正面样本的检测，由此可以选取阈值  $-1.4304$  作为异常判别标准。基于该阈值标准，自编码器的异常准确率达到 100%。



## 第5章 基于倒谱预白化的水泵振动信号去噪

### 5.1 水泵振动信号采样

#### 5.1.1 水泵振动检测方法

水泵的振动<sup>[68]</sup>来自三个方面，一是电机内部转子或定子的磁力不平衡、供电电压波动等电气问题，二是电机和泵体本身机械加工产生的误差、安装质量不高、长久使用磨损等机械问题，三是安装位置、管道水含污含气等产生的水力问题。这些问题都会导致水泵产生周期性的振动和噪音。其振动方向包括垂直方向的单自由度线性振动和扭转振动，这两种振动相耦合，会导致水泵振动出现两个共振频率，增加了水泵振动的复杂性。工程上为了减少水泵振动的相互干扰和对建筑的损害，一般需要安装隔振器，即在基础支撑面和水泵间安装的弹性元件，并且在水泵底座上安装惰性块，合理的隔振器设计和惰性块安装可以将水泵两个方向的振动解耦，并且达到较好的隔振效果。因此，只有在直接接触水泵或连接水泵的刚性支架结构上可以测得水泵原始振动情况，

水泵振动的测量指标一般为振动位移、振动速度、振动加速度三种（均为幅值），根据测量需求不同可以测量其中一种或多种指标，振动位移一般适用于低频水泵检测，振动加速度一般更能体现高频振动特征，振动速度在较宽频率下均有着不错的适用性。振动位移、振动速度、振动加速度分别可以采用电涡流型传感器、振动速度传感器、振动加速度传感器进行测量。

##### （1）电涡流型传感器

该传感器基于线圈互感原理将位移变化转换为电信号，因此也要求被测对象具有导电性，其适用于低频振动检测条件。

##### （2）振动速度传感器

在电涡流型传感器结构基础上，增加弹簧阻尼等组件，直接将振动速度转换为电信号，但由于弹簧阻尼部件的存在，其工作频段受到一定限制，不适用于频率过低的振动测试。

##### （3）振动加速度传感器

大多数此类传感器原理不同于前两者，其采用压电效应，外界的加速度导致内部晶体发生形变，从而产生电信号，以此采集加速度信号，其响应时间较短，且工作频段相对较宽。

在检测位置上, 根据国家标准 IS07919 系列《旋转机械转轴径向振动的测量和评定》标准要求<sup>[69]</sup>, 对水泵振动的测定一般选择“振动能量向弹性基础或系统其它部件进行传递的地方”, 即轴承座、底座和法兰口, 并且轴承座可视为主要测点, 其能直接反应水泵转动的直接振动特征, 底座及法兰口可作为辅助检测点。在检测方向上, 标准也规定了轴向、水平、垂直三种方向, 但工程上制冷机房水泵一般检测轴向和垂直方向居多。

本文采用的便是振动速度传感器, 该传感器外观及技术参数如下图表所示, 该传感器通过底部强磁性底座吸附在水泵上, 从而将水泵振动传入内部振动接收器。由于本文目标制冷机房水泵转动频率在 49r/s, 根据经验可得振动速度可以较好体现其振动特性。采集点是水泵轴承座位置的轴向、垂直两个方向和底座垂直方向的振动数据。

表 5.1 振动速度传感器技术参数

条目	技术参数
电源	DC24±6V
输出信号	4-20 mA
量程	0-20 mm/s
频率响应	10HZ-1KHZ
测量精度	满量程 2%



图 5.1 振动速度传感器

### 5.1.2 水泵振动采样原理

振动速度传感器所采集的数据为连续模拟量，需要将模拟量转换为离散数字量，这就要求选择合适的采样频率对该模拟量进行采样。结合第三章香农采样定理要求，需要确保采样频率大于模拟量中有效信号的最大频率的两倍。

首先采用 2500Hz 采样率进行采样得到振动时域图，转换为频谱图（对数功率谱）后，观察有效信号频率分布范围，水泵基频接近 50Hz，一般 10 倍频内包含有效信号，结合实际数据发现有效频段基本集中在 500Hz 左侧，最终可确定 500Hz 为合理采样频率。




图 5.2 不同采样率下对数功率谱

因此，本文采用振动速度传感器，取采样频率为 500Hz，单次采样时间为 10s，在制冷机房现场共采集 828 个振动数据。

在实验室水泵实验平台上共采集 789 个振动数据，如下所示：

表 5.2 实验台水泵振动数据集

水泵状态	正常状态 F0	水含泥沙 F2	基础松动 F3
数据个数	279	345	165

表中，人为产生水泵三种状态正常运行状态 F0，基础松动后运行状态 F3，管道内水含泥沙后运行状态 F2，并测量时水泵均处于稳态运行中。

## 5.2 水泵振动信号数据分析

### 5.2.1 误差及噪声来源分析

在检测水泵振动信号的过程中往往会引入诸多误差及噪声，其主要来源于四个方面：

- (1) 仪器本身测量精度导致的误差；
- (2) 不同情况下仪器安装效果不同引入系统误差；
- (3) 周围环境存在振动噪声，且噪声变化导致不同时刻采集的振动数据存在变化；
- (4) 水泵硬连接部件的结构特性导致有效信号中混合一些谐振信号。

在这些误差及噪声来源中，较为可控的是来源（2），需要确保分析振动数据时，其来源于同一个测点，且安装条件尽可能相近，对比相同条件下不同检测位置的数据可以发现来源（2）带来的差异。下图中，两个测点在时域上和频域上均有着一定差异。




图 5.3 不同测点时频域差异

图中反应的差异本质上是振动传递到不同测点的距离差异和不同测点本身振动特性的差异，因此在涉及到数据时频分析的过程中，最好采用同一测点数据。

对于来源（1）而言，其主要影响了振动信号的绝对数值，对计算水泵振动幅度等带来明显误差，但在分析振动信号间的相对差异时，其影响相对较低。

对于来源（3），本文研究场景制冷机房中，水泵均进行隔振处理，因此相邻水泵间的振动影响可以忽略。

对于来源（4），通过管道、支架、泵体等传递到轴承检测点的振动无法忽略，这部分振动混合在轴承振动的有效信号当中，并且在频域上会在有效信号频段周边形成大量离散频率分量，影响了后续振动异常分析，因此需要进行去噪处理。

## 5.2.2 振动去噪要求

通过管道、支架、泵体等传递到轴承检测点的振动噪声中，一方面包含临近共管连接水泵或临近连接的制冷机组的衰减振动信号，这一部分可能还保留着其固有的振动特征；另一方面包含远端设备振动混合衰减后的振动信号，这部分振动由于成分较多、经过长距离传输和相互影响，其原本振动特征已经被淹没在随机噪声之中，因此可以看作是随机振动。

本文所测得振动信号数据，其噪声中可能包含了少量其他设备固有振动特征以及随机振动噪，其在组成可以表示成下式：

$$V'(f) = V(f) + \sum_{i=0}^k V_{0,i}(f) + N_0(f) + \sum_{i=0}^k V_{1,i}(f) + N_1(f) + N_2(f) \quad (5.1)$$

式中， $V'(f)$ 为测得振动信号数据， $V(f)$ 为所需分析的水泵转轴振动信号， $V_{0,i}(f)$ 代表该水泵振动在其检测点的某个离散频率分量， $N_0(f)$ 为其随机噪声信号数据， $V_{1,i}(f)$ 代表相邻设备振动在检测点的某个离散频率分量 $N_1(f)$ 为其随机噪声信号数据， $N_2(f)$ 为远端随机振动噪声。多种随机噪声间相互叠加，也可视为随机噪声，因此该式转变为：

$$V'(f) = V(f) + \sum_{i=0}^k V_{0,i}(f) + \sum_{i=0}^k V_{1,i}(f) + N(f) \quad (5.2)$$

由于测点位于泵轴承座上， $V_{0,i}(f)$ 主要采集的是转轴的振动信号， $V_{1,i}(f)$ 即便是相邻泵的振动也会在一段传播过程中逐渐损失其高频振动部分，因此 $V_{1,i}(f)$ 为低频段为主的信号，在工程上，利用振动信号进行泵的异常检测过程中，往往关注振动数据中的基频（泵转动频率）、半频和多倍频，低频段（半频以下）的特征可以视为影响较小。

综上，振动信号数据的去噪要求在于：

- (1) 去除随机振动噪声；
- (2) 去除振动信号中的离散频率分量。

## 5.3 倒谱预白化原理

### 5.3.1 倒谱分析原理

倒谱预白化<sup>[70]</sup>适用于该振动去噪场景。在本文语义中，倒谱（Cepstrum）是将振动信号进行快速傅里叶变换，取对数后再进行快速逆傅里叶变换的结果，其

计算式如下：

$$C_0(q) = F^{-1}(\log(X_R(f) + iX_t(f))) \quad (5.3)$$

式中， $C_0(q)$ 为振动信号的倒谱， $X_R(f)$ 为振动信号傅里叶变换后的实部， $iX_t(f)$ 为虚部。

对于泵等旋转设备，其实际运行条件下，容易处于前述复杂振动状态，再加上各类机械故障，导致了多种振动信号叠加，这种振动叠加在机理上往往是非加性的，因为不同振动空间方向、频率、相位等均不同。其叠加结果在频域上以谐波调制作为展现，如下图所示<sup>[71]</sup>：




图 5.4 频域下的谐波调制

如图所示，在叠加的主要频率点上，周边还会出现对称谱线（边频带），当叠加多个主要频率时，频谱图便会出现大量边频带，即前文所述的离散频率分量。这些边频带具有一定分布规律，因此，也可以用频谱分析的方式来描述，即对该频谱图再进行快速逆傅里叶变换，可以得到描述该分布的“频谱图的逆频谱图”。在异常检测中，我们需要的是频谱图的主要频率点，而倒谱的操作可以很好的识别其中的主要频率，主要频率点为倒谱图中的几个峰值。

### 5.3.2 倒谱预白化操作

倒谱预白化，在本文语义中即计算振动信号的倒谱图，并将倒谱图中边频带对应的倒谱带置零，从而在振动信号频谱图中去除边频带，最终去除频谱数据中的噪声部分。由于倒谱预白化后需要重构回原始振动信号或者振动频谱数据，因此需要保留相位谱信息，故需要在复数域上进行计算，其流程图如下：




图 5.5 倒谱预白化流程

其计算流程如下：

(1) 计算振动信号的倒谱, 式中  $C(q)$  为倒谱,  $C_R(q)$  和  $iC_t(q)$  分别为倒谱的实部和虚部,  $C_m(q)$  为倒谱的幅值, 也是下文中需要调整的部分,  $C_p(q)$  为倒谱的相位;

$$X(f) = X_R(f) + iX_t(f) = 10\log_{10}(F(V(t)))$$

$$C(q) = C_R(q) + iC_t(q) = F^{-1}(\log(X_R(f) + iX_t(f))) \quad (5.4)$$

$$C_m(q) = |C(q)|$$

$$C_p(q) = \arctan\left(\frac{C_t(q)}{C_R(q)}\right)$$

(2) 由于主要频率点在倒谱中占据较大分量, 因此采用阈值的方式选取出主要频率点, 式中  $\lambda$  为计算出的阈值,  $C_m'(q)$  为阈值调整后的倒谱幅值:

$$\lambda = \frac{3}{4}(\max(C_m(q)) - \min(C_m(q))) + \min(C_m(q)) \quad (5.5)$$

$$C_m'(q) = \begin{cases} 0, & C_m(q) < \lambda \\ C_m(q), & C_m(q) \geq \lambda \end{cases}$$

(3) 从新的倒谱  $C_m'$  和倒谱相位  $C_p(q)$  中计算新的倒谱  $C'(q)$ , 并重构频谱  $X_m$ , 最终得到去噪后的振动信号  $V'(t)$ :

$$C'(q) = C_m'(q)e^{iC_p(q)}$$

$$X_m'(f) = |e^{F(C'(q))}|$$

$$X_p'(f) = \arctan\left(\frac{X_t(f)}{X_R(f)}\right) \quad (5.6)$$

$$X'(f) = X_m'(f)e^{iX_p'(f)}$$

$$V'(t) = \left| 10^{\frac{F(X'(f))}{10}} \right|$$

## 5.4 振动信号去噪计算

以某个振动信号为例, 其时域图如下:




图 5.6 某振动信号时域波形图

对其计算对数幅值谱和实倒谱，如下图：




图 5.7 某振动信号对数幅值谱及实倒谱

通过上述预白化操作后，可以得到去噪后的对数幅值谱，下图进行去噪前后对比：




图 5.8 某振动信号去噪前后对数幅值谱对比



由两图对比可以发现，去噪后，整体幅值下降，并且特征频率点变得更加显著，如 100Hz 和 200Hz 处的幅值分量相较其他分量更加明显。可以得出，倒谱预白化可以通过去除边频带来有效去噪。

## 第6章 基于量化经验分析的水泵振动信号异常检测

### 6.1 基于经验分析的水泵异常判断

工程上对水泵振动频谱图的分析一般需要先计算水泵的基频，根据检测点的位置不同，基频含义也不同，如检测点位置在泵体叶轮的轴承座上，则基频代表该叶轮的转动频率，如在电机轴承座上，则代表电机转轴转动频率，本文检测点均为电机轴承座，因此基频按照电机转动频率计算，为49Hz。

对于常见的几类水泵机械故障，其在振动频谱图上会出现对应的分量特征，一般体现在一倍频、二倍频或多倍频位置上出现明显分量特征<sup>[72]</sup>，其特征及可能的故障如下表所示：

表 6.1 水泵异常振动频谱判断

故障类型	一倍频	二倍频	多倍频
转轴或轴承异常	-	++	-
流体对叶轮激振	-	-	++
基础松动	++	-	+

表中整理了工程上根据水泵振动频谱图和经验判断进行异常分析的方法，其中一倍、二倍等均是基频为基数。该表格中，出现一倍频和二倍频特征的故障类型判别较为确定，但对于其他类型故障，由于故障可能单一存在也可能同时多个存在，因此其确定性不高。并且，这一过程为人为判别过程，对于频率特征均不明显的水泵振动频谱图，容易出现无法判别的情况。

人为识别水泵振动频谱图特征的过程本质上是一种模式识别，理论上，可以量化该过程，实现自动自适应的判断。

### 6.2 量化经验分析算法的实现

#### 6.2.1 算法基本原理和流程

在水泵振动异常检测算法开发过程中，由于当前制冷机房水泵故障情况较少，且一般也不具备采集故障发生瞬间水泵的振动数据的条件，因此当前本文缺少目

标机房水泵振动故障数据。在实验室水泵实验台上采集的数据虽然包含一些故障类型，但由于水泵机械故障大多数为不可逆故障，因此也较难形成完备的故障数据集。在小样本数据集下，单纯依赖多分类模型效果一般，而前文中对频谱图进行经验分析从而进行异常检测的方法具有较高鲁棒性和可靠性，用模式识别的方法代替人工判断部分具有高可用性。如下图所示，整个流程可分为数据准备、量化过程、规则构建三部分：




图 6.1 量化经验分析异常检测算法流程图

首先是数据准备部分。计算振动信号的频谱图，将其划分为一倍频区、二倍频区、多倍频区三个区域，其划分范围为一倍频往外扩展 0.5 倍频区域，二倍频往外扩展 0.5 倍频区域，二倍频区右侧均为多倍频区，如下图所示。对频谱图进行区域划分，是基于经验分析中，判断其在某个倍频上具有显著特征具有独立性，只关注该倍频处的分量相对大小。其计算公式如下（ $f_0$ 为基频）：

$$\begin{aligned}
 V(f_1) &= V(f), f \in [0.5f_0, 1.5f_0) \\
 V(f_2) &= V(f), f \in [1.5f_0, 2.5f_0) \\
 V(f_3) &= V(f), f \geq 2.5f_0
 \end{aligned}
 \tag{6.1}$$




图 6.2 倍频区划分（频谱图取对数）

其次是量化过程。对于某个倍频区，根据样本来源，划分正负样本数据集（正面样本为：存在一倍频显著对应故障的数据；负面样本为：不存在一倍频显著对应故障的数据），并且分别提取其特征，并且保证该特征较好的区分正负样本。由此得到特征匹配度（衡量该数据与“该倍频处出现明显较高的幅值”这一事实的接近程度）和分类阈值（对样本进行分类的依据）。

最后是规则构建，将量化的结果替换经验分析中较为模糊的判断依据，构建准确的分类规则，从而进行自动化异常检测。

### 6.2.2 量化过程




图 6.3 量化过程

以一倍频区为例 ( $v(f_1)$ )，量化过程中，需要对倍频区内的频谱图进行特征提取。经验分析中根据对于一倍频处的幅值是否显著大于其他幅值来进行判断，可以仿照该过程进行量化。

信号特征提取中常用“峰值因子 (C)”来表征峰值在波形中的极端程度：

$$C = \frac{x_{peak}}{x_{rms}} \quad (6.2)$$

$$x_{rms} = \sqrt{\frac{1}{n} \sum_{i=1}^n x_i^2}$$

式中,  $x_{rms}$  为信号的均方根值,  $x_{peak}$  为信号的峰值。可以对该特征进行改造, 限定  $x_{peak}$  为一倍频处小范围区间的峰值, 从而使其可以评估一倍频处峰值在一倍频段的极端程度。

$$C_{limit} = \frac{x_{limit\_peak}}{x_{rms}} \quad (6.3)$$

式中,  $C_{limit}$  为改造后的峰值因子, 定义为限定峰值因子,  $x_{limit\_peak}$  为一倍频处小范围信号段, 其区间根据水泵转动时的稳定性和振动速度传感器的精度、漂移范围调整, 根据实际信号数据状况, 取一倍频处  $\pm 3\text{Hz}$  范围。

在经验分析中, 由于频谱图数据波动范围较大, 人们无法直接观察得频谱图的有效数值, 其关注点往往为频谱图的上包络面, 因此需要对振动信号数据取上包络面数据。如下图所示:




图 6.4 频谱图上包络面计算

对正面样本和负面样本数据集分别取上包络面后的, 计算限定峰值因子。其在频次直方图上分布如下:




图 6.5 正负样本频率直方图（去除四分位点数据）

图中，横坐标为限定峰值因子，纵坐标为频次。红色直方图代表负面样本（不存在一倍频显著对应故障的数据）的限定峰值因子及其频次；灰色直方图代表正面样本。图中正负样本均以作箱线图去除上下四分位点的方式进行了可能的离群值剔除。可见采用限定峰值因子作为特征，可以有效区分正负样本，下一步可以确定分类阈值和匹配度。

在水泵振动异常检测这一场景下，合理的分类阈值应该是使得误分类率最低的阈值。对分类算法的结果评估中，存在四个部分样本结果：

- 1、真正例（True Positive, TP）：将正面样本分类为正；
- 2、假正例（False Positive, FP）：将负面样本分类为正；
- 3、真负例（True Negative, TN）：将负面样本分类为负；
- 4、假负例（False Negative, FN）：将正面样本分类为负。

在故障诊断领域，往往可以允许有一定的误报警，但希望不漏过一个实际故障。本算法中，正面样本代表故障，因此不希望出现正面样本被分类为负，即假负例尽量接近 0。

$$fr = FNR = \frac{FN}{FN + TN + FP + TP}$$

$$C_{limit,thres} = Q1(C_{p,limit,0}, C_{p,limit,1}, \dots, C_{p,limit,n}) \quad (6.4)$$

$$C_{limit,high\_thres} = Q3(C_{n,limit,0}, C_{n,limit,1}, \dots, C_{n,limit,n})$$

式中，fr 为误分类率，FNR为假负率，分类阈值可以直接确定为正面样本频率直方图中限定峰值因子的下限，即 $C_{limit,thres}$ 为正面样本限定峰值因子的第一

个四分位点。

匹配度计算同样可以基于该原理，对于某条振动数据的限定峰值因子 $C_{limit,k}$ ，若其处于 $C_{limit,thres}$ （假负例为0的分界线），可以认为其刚好能归类为正样本，定义此时匹配度为0，当 $C_{limit,k}$ 处于 $C_{limit,high\_thres}$ （定义为假正例为0的分界线，即负面样本第三个四分位点），可以认为其刚好不存在假正的可能性，定义此时匹配度为1，其示意图如下图所示：

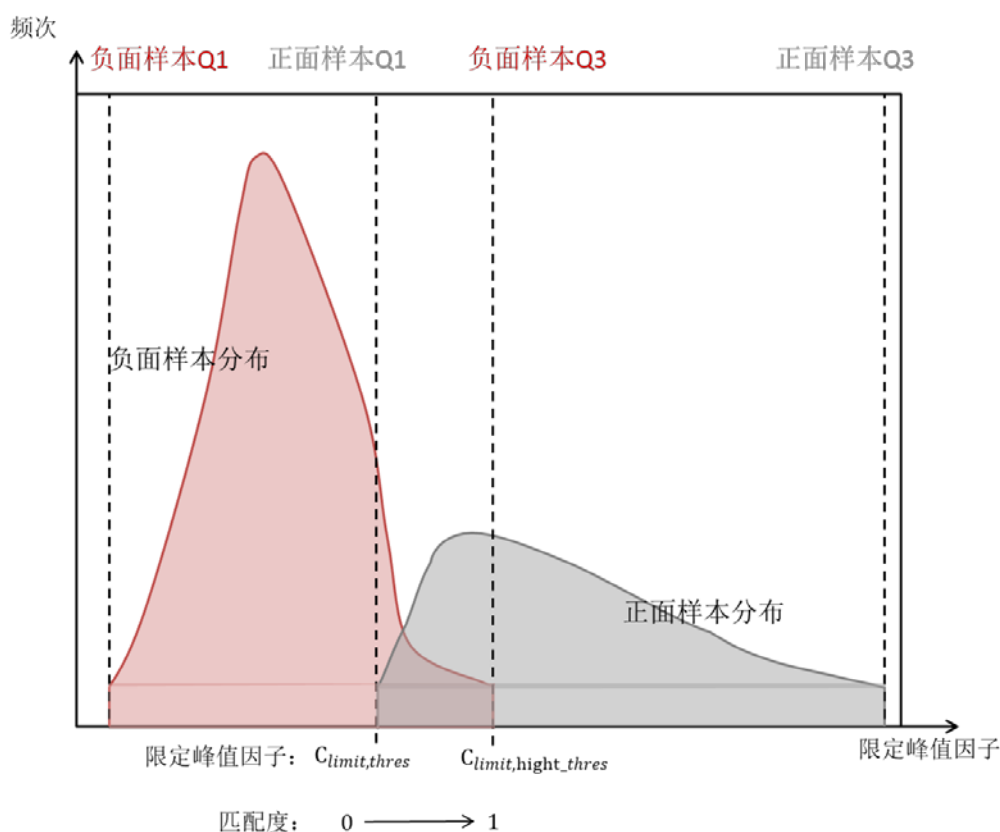


图 6.6 匹配度构造示意图一

故匹配度计算式如下：

$$C_{limit,k} = \frac{x_{limi\_peak,k}}{x_{rms,k}} \quad (6.5)$$

$$f = \begin{cases} 0, & C_{limit,k} < C_{limit,thres} \\ \frac{C_{limit,k} - C_{limit,thres}}{C_{limit,high\_thres} - C_{limit,thres}}, & C_{limit,high\_thres} > C_{limit,k} > C_{limit,thres} \\ 1, & C_{limit,high\_thres} < C_{limit,k} \end{cases}$$

此外，若正面样本数据和负面样本数据分布直方图出现分离，则需要调整分类阈值取值和匹配度取值，如下图所示，此时 $C_{limit,high\_thres}$ 应对应正样本第一个四分位点， $C_{limit,thres}$ 应对应负面样本第三个四分位点。

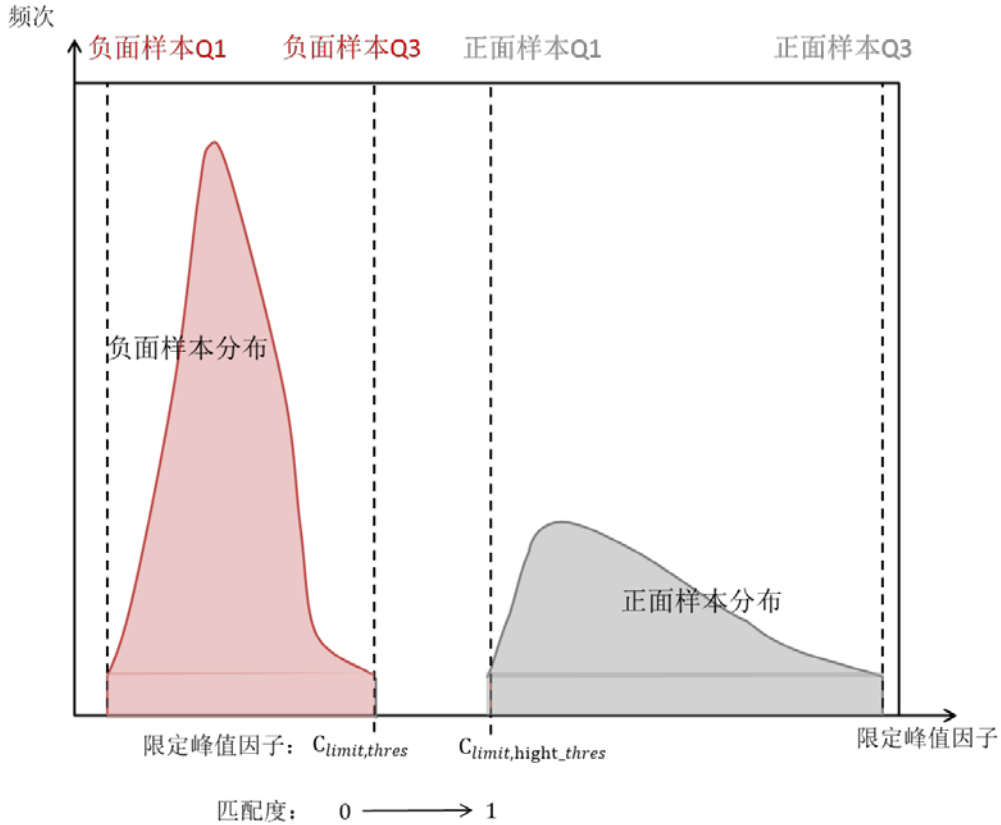


图 6.7 匹配度构造示意图二

对于二倍频情况同样如此，但对于多倍频情况，考虑到多倍频段出现显著倍频特征的位置不定，因此直接采用峰值因子起到限定峰值因子的作用，之后同样按照上文进行量化。

### 6.2.3 规则构建

每个倍频条件下均可以计算出一个匹配度 $f_i$ ，可以对水泵异常振动频谱判断表进行修改，如下表所示：

表 6.2 水泵振动数据倍频匹配度表

倍频区域	匹配度	匹配条件	显著匹配条件
一倍频	$f_0$	$f_0 > 0$	$f_0 = 1$
二倍频	$f_1$	$f_1 > 0$	$f_1 = 1$
多倍频	$f_2$	$f_2 > 0$	$f_2 = 1$



表 6.3 匹配度与异常关系表

故障类型	一倍频	二倍频	多倍频
转轴或轴承异常	-	$f_1 > 0$	-
流体对叶轮激振	-	-	$f_2 > 0$
基础松动	$f_0 > 0$	-	-

### 6.3 水泵振动数据异常检测验证

对水泵振动信号数据进行数据增强（将数据原始片段连接后，加窗移动划分出新的数据）后计算频谱图、划分倍频区，并根据故障状态划分正负样本数据集，对于正负样本，再按照 7:3 划分训练集与测试集，在训练集上计算其限定峰值因子，进而计算分类阈值及匹配度根据分类规则，在测试集上进行验证，数据集划分如下表所示：

表 6.4 数据集划分表

	一倍频段	二倍频段	多倍频段
正面样本训练集	74	264	176
负面样本训练集	498	308	396
正面样本测试集	33	114	76
负面样本测试集	214	133	171

在训练集和测试集上的分类结果如下所示，在训练集上分类准确率达到 78.4%，假负率为 0%。在测试集上分类准确率达到 80%，假负率为 0%。该算法达到较好效果。




图 6.8 一倍频区训练测试分类结果

对于二倍频段和多倍频段，其数据集分布和分类结果分别如下：




图 6.9 二倍频区直方图及分类结果（测试集准确率 84.8%，假负率 0%）




图 6.10 多倍频区直方图及分类结果（测试集准确率 83.0%，假负率 0%）

最终分类准确率如下：




图 6.11 异常检测准确率

## 第7章 多源数据融合算法

### 7.1 多源数据融合层次选择

在本文多源数据融合语义中，多源数据融合指的是多传感器数据的融合，实现对设备状态更加可靠的故障诊断，并扩展其故障诊断范围。

如前文所述，多源数据融合在层次上分为三种融合结构。

1. 数据层融合：对采集的数据进行融合，再整体提取特征，并进行诊断识别。数据层融合要求传感器采集的数据为同质数据，代表同一个物理量，若为时间序列数据，则还需要保持同步性。

2. 特征层融合：对采集的数据分别提取特征后，进行特征融合，并进行诊断识别，在故障诊断中，各类传感器时序数据所提取的特征需要有一定的时间同步性。

3. 结论层融合：对采集的数据分别提取特征，并进行诊断识别后，将各个结论进行融合，对于水泵等设备，各类传感器时序数据的诊断结论可以代表该设备一定时间范围内的状态特征，因此对于非同步采集的情况具有较高适用性。

本文采用巡检机器人采集图像、音频、振动等数据，并结合 BA 数据进行基于多源数据的故障诊断。其中，图像、音频、振动和 BA 数据均来自于不同传感器，且其数据类型也完全不同。各个数据采集需要遵从巡检机器人的运动路线和采集顺序，因此缺乏时间同步性。采用结论层融合适用于该应用场景。

### 7.2 多源数据分析

#### 7.2.1 电功率数据

电功率作为水泵运行过程中直接监测变量，可以直接反应水泵诸多状态特征。制冷机房内的冷冻泵、冷却泵一般采用三相电源供电。根据水泵厂商相关资料，水泵电功率相关的故障一般为电源缺陷（如缺相、电压波动等）、轴承或转轴磨损。

根据水泵设备的额定电功率参数，结合其历史运行电功率数据可以构建出异常检测的方法。本文结合目标制冷机房的水泵运行瞬时功率数据进行分析，其数据如下图所示（片段）。




图 7.1 水泵电功率数据（片段）

由于数据中缺乏故障状态下的数据，因此可以从正常状态数据出发，通过数据清洗后，剔除启停瞬间的非稳态数据，并且排除停止状态的数据，对运行状态下的数据进行特征提取，提取出代表水泵电功率的均值特征和波动特征，并计算合理的分类阈值，实现电功率异常检测。

电功率均值特征可按照相对额定功率水平进行计算，如下式：

$$p_i = \frac{P_i}{P_e} \quad (7.1)$$

式中， $p_i$ 为逐时相对功率， $P_i$ 为逐时功率， $P_e$ 为额定功率。

电功率波动特征可用于衡量短时间内的数据波动情况，因此需要对原始数据进行加窗，沿着时间轴滑动产生多个窗，每个窗可以采用窗范围内的逐时相对功率 $p_i$ 的标准差作为电功率波动特征：

$$p_{j,std} = \sqrt{\frac{1}{n} \sum_{i=0}^{n-1} (p_{j,i} - \bar{p}_j)^2} \quad (7.2)$$

式中， $p_{j,std}$ 为第  $j$  个窗的波动特征， $\bar{p}_j$ 为第  $j$  个窗的平均逐时相对功率， $p_{j,i}$ 为第  $j$  个窗的第  $i$  个逐时相对功率。

对上图新风水泵（额定功率 18.5kW）电功率数据以天为划分计算其 $p_i$ 分布及 $p_{j,std}$ 分布，其中 $p_{j,std}$ 的窗范围为 30min，如下图所示：




图 7.2 逐时相对功率分布

上图的子图均为对应变量的频次分布图，由上至下为每日的分布图，横轴为对应变量值，纵轴为出现频次，每条曲线均为频次直方图的拟合曲线。可以明显发现，该水泵存在两种工作模式，出现双峰的情况代表制冷机房同时存在开启两台新风水泵和单独开启该水泵，2台水泵工作时，单台承担负荷较小，因此其逐时相对功率较小，单独工作时，有时可达到较高的负荷。对于该水泵这两种状态均为正常工作状态，因此只需关注其逐时相对功率是否超出历史数据界线即可。

计算其逐时相对功率的总体分布，从而确定正常状态界线，如下图所示：




图 7.3 逐时相对功率总体分布

该分布图存在两个峰，峰之间出现了一个低谷，这是制冷机房内根据末端需求和水泵运行时间自动调整的结果。该曲线中包含了该水泵合理相对功率范围，从异常检测的角度出发，可以采用概率统计方法。

单特征的概率统计异常检测<sup>[73-74]</sup>常见方法为一元正态分布模型，如下图：




图 7.4 正态分布

假定一系列样本数据满足正态分布，则可计算其正态分布函数：

$$\mu = \frac{1}{m} \sum_{i=1}^m x^{(i)}$$

$$\sigma^2 = \frac{1}{m} \sum_{i=1}^m (x^{(i)} - \mu)^2 \quad (7.3)$$

$$f(x) = \frac{1}{\sqrt{2\pi}\sigma} \exp\left(-\frac{(x - \mu)^2}{2\sigma^2}\right)$$



式中,  $f(x)$ 代表位置参数为 $\mu$ , 尺度参数为 $\sigma^2$ 的正态分布,  $x^{(i)}$ 代表第  $i$  个样本数据。

当输入一个新样本时, 若其值落在 $\pm 3\sigma$ 外, 则可认为其是异常的, 因为 $\pm 3\sigma$ 的范围已经可以涵盖大部分数据, 在此范围外为小概率事件, 这往往是故障引起的样本数据异常。

对于标准正态分布, 其 $[-\infty, -3\sigma]$ 和 $[+3\sigma, \infty]$ 范围所占面积分别占据 0.26% 的分布面积, 因此在本水泵分布中, 也可找到满足这一百分比的界线, 作为最小阈值与最大阈值。结合第 2 章中基于能效的故障初步分析, 其中根据电功率是否显著低于额定电功率来判断水泵是否处于低能效运行状态, 因此在技术路线第二阶段中诊断水泵机械电气等故障的判别中, 可以不用重复判别此项, 故仅针对水泵是否相对电功率过高判断。




图 7.5 逐时相对功率异常阈值划分

同理, 对于电功率波动特征 (逐时相对功率滑窗标准差), 也可得到如下逐时分布图及总体分布:


逐时相对功率标准差 $p_{j,std}$ 逐日分布

图 7.6 逐时相对功率滑窗标准差分布




图 7.7 逐时相对功率标准差异常阈值划分

水泵电功率异常的状态一般为电功率过高和电功率波动，其对应常见故障来源一般为转轴或轴承磨损或电源缺相、电压波动。

### 7.2.2 热成像数据

热成像数据为图片数据，配合同视角下的可见光图像，可以将水泵等设备从背景中剥离出来，从而分析水泵电机部分热区发热特征，进而进行故障分析。

以往的研究者通过常用目标检测算法<sup>[75-78]</sup>，如 R-CNN、YOLO 等神经网络模型实现了水泵等设备的目标检测，达到了较好的图像分离效果，如下图所示。




图 7.8 基于 R-CNN 的水泵目标检测

对分割出的水泵图像，可以进一步计算其热区特征，以往的研究者采用热区平均温度、最高温度、标准差、热区高温区面积、热区更高温区面积作为显著特征，积累不同类型故障的特征数据，并采用K近邻搜索确定分类超平面。

考虑到数据水泵热成像数据特征对数据来源具有高依赖性以及各类故障数据的较难获得，提取的特征中越包含设备特有属性、越依赖负面样本且分类算法越具有黑箱特性，则算法越缺乏通用性。在小样本数据情况下追求通用性，往往需要牺牲故障诊断结果的细致性。在当前可获取足量正面样本的条件下，构建一个具有正面样本依赖的算法具有可行性。其所依赖的正面样本能够在实际部署中获取，通过一段时间的积累便可实现算法的迁移。因此在本文在先前研究者确定水泵热区的基础上，采用热区温度点三分位点以上的数据均值（高温区）作为唯一特征，仅判别水泵是否异常发热。

同样，根据大量历史数据的高温区平均温度，可得到其分布图，并根据前文所述概率统计中 $3\sigma$ 原则进行阈值选定。

基于热成像数据能判断出水泵电机是否发生过热，导致水泵电机过热的原因主要有电源缺相、转轴或轴承磨损，再者便是定子或转子的电磁故障。

### 7.2.3 音频数据

第四章中基于自编码器的水泵音频信号数据异常诊断算法实现了对水泵音频异常的诊断，能够有效区分正常状态和异常状态的水泵声音。根据文献资料，导致水泵声音异常的原因主要来自于转轴或轴承磨损、叶轮激振。由于音频数据得出结论只为正常与否，因此诊断出异常时，可以认为与上述两个故障类型关联度较大。

### 7.2.4 振动数据

第六章中基于量化经验分析的水泵振动信号数据异常诊断算法实现了对水泵振动异常的诊断，能够进行水泵基础松动、转轴或轴承磨损、叶轮激振等故障识别。

## 7.3 多源数据结论层与故障关联分析

### 7.3.1 单向关联分析

根据 7.2 所述多源数据结论层与水泵故障的对应关系，可得到如下关联图：




图 7.9 多源数据故障关联图

关联图中，左侧为数据类别，中间为基于各类算法所得出的各类数据的结论层，右侧为实际故障类别。

从图中可以初步发现，一些实际故障类别被多个结论层连接，这些关联联机代表了多源数据对故障诊断可信度的提升效应；另一些实际故障类别仅由单个结论层连接，这是由于各类传感器无法产生全冗余数据导致的，这也侧面反映了多源数据对实际故障诊断类别的扩展。

那么如何量化多源数据对故障诊断可信度的贡献呢？概率描述天然对这类问题具有适配性。多源数据融合常见算法如 D-S 证据理论、贝叶斯网络等均包含着概率思想。通过概率进行量化描述前，需要对该图的关联性质进行分析。

从故障类别与故障特征的关系来看，本文的关联流程具有单向性，即可以根据某类数据得到一定特征，并基于该特征得出某一故障判定，但反之，当发生了某一个故障后，无法得出该特征必然会出现显著异常。一方面，这是由于数据驱动算法依赖于样本数据，而大多数条件下无法获取完备的样本，在非完备样本条件下训练的模型，其有效特征必然低于实际特征数，即便可以将有效特征构成子空间内的数据映射到某个结论，但从结论侧映射回的特征可能不会有显著异常，因为异常情况出现在了另一部分未考虑的特征上。另一方面，则是这类故障影响不全体现在该完备特征空间上。




图 7.10 单向关联示意图

### 7.3.3 可信度累积分析

从可信度的角度来量化各类数据结果对故障诊断的贡献，需要从传感器数据误差、特征提取中数据损失以及异常识别算法误差进行综合考量。

数据获取上，振动传感器、音频采集器、热成像仪以及 BA 系统电功率传感器均存在一定的采集误差和漂移现象，其导致了采集数据在绝对数值和变化趋势上的误差。

在数据处理上（即特征提取及结论得出），不同算法数据预处理、特征提取过程不同，这一过程导致数据利用率出现差异，并且，基于特征的分类方法也不同，这导致分类算法本身可信度的差异。

结合这两部分分析，若直接从理论上推导各阶段可信度并进行累积，则需要先将传感器与标定好的同类型传感器进行对比分析，得出数据点偏差，再追踪数据点偏差经过预处理、特征提取后在特征处的累积效应，最后再追踪其在算法结果上的累积效应，并将其与算法本身误差进行解耦分析和累积计算，这显然不具有可操作性，特别是对于采用黑箱模型的算法模块。

本文在各个来源数据异常诊断算法开发过程中，对振动、噪声算法进行数据验证，理论上，当测试集为完备数据（包含水泵各个状态下的数据）时，其数据验证结果可近似为该来源数据从传感器到结论层的可信度累积。




图 7.11 可信度累积过程

如图所示，整个流程中传感器误差、数据损失、算法误差带来的可信度降低最终累积到结论层的准确率上，由于测试集和其对应的实际异常状态为完备数据集，因此最终的准确率也能等效于可信度最终累积值。故可定义可信度 $\alpha_i$ 代表第  $i$  类数据结论的可靠程度，其计算方法为通过完备测试集对算法进行验证，计算的准确度。

实际条件下，难以获取水泵状态及物理量的完备数据集，但长期来看，随着时间推移，现场积累的数据将越接近完备数据集，因此可以采用迭代的方法。

先基于当前非完备测试集给出各类来源数据结论层的可信度 $\hat{\alpha}_i$ ，在实际部署时，通过历史数据的持续积累，不断向真实可信度逼近。基于其流程图如下所示：




图 7.12 可信度迭代更新过程

## 7.4 结论层的条件概率融合算法

从图 7.10 中可以发现，若将多源数据结论层视为一个事件，则这些事件间均为独立非互斥，即事件间的发生具有独立性且互不相排斥。

从故障识别结果出发，以“转轴或轴承磨损”为例，结论层的“电功率过大”、“电机过热”、“声音异常”、“振动二倍频显著”均与其存在关联。这些事件不具有互斥性，因此相关联事件发生越多，越说明发生了“转轴或轴承磨损”的故障。




图 7.13 转轴或轴承磨损关联

将这些事件结合可信度进行加权求和可以初步量化该故障发生的可能性，然而，上述事件并不能构成“转轴或轴承磨损”故障的完备事件集，因为该故障还会引起其他未观测的事件。

从故障诊断角度出发，其目的是基于部分特征来进行故障分类，因此，只要部分特征出现了异常，便可认为发生了对应故障。因此只要计算各个事件均误判断的概率 $P(\prod \bar{x}_i)$ ，即可得到其融合概率 $1 - P(\prod \bar{x}_i)$ 。

$$P(x_i) = \alpha_i \cdot 1$$

$$P(\prod \bar{x}_i) = \prod_{i=0}^n (1 - P(x_i)) \quad (7.4)$$

$$P_m = 1 - P(\prod \bar{x}_i)$$

由此可以得到各个故障类别的融合概率计算表：



表 7.1 故障类别融合概率计算表

故障类别	关联结论	计算式
电压波动	电功率波动过大	$P_{m,a} = \alpha_1$
电源缺相	电功率过大	$P_{m,b} = 1 - (1 - \alpha_2)(1 - \alpha_3)$
	电机过热	
转轴或轴承磨损	电功率过大	$P_{m,c} = 1 - (1 - \alpha_2)(1 - \alpha_3)(1 - \alpha_4)(1 - \alpha_5)$
	电机过热	
	声音异常	
	振动二倍频显著	
叶轮激振	声音异常	$P_{m,d} = 1 - (1 - \alpha_4)(1 - \alpha_6)$
	振动多倍频显著	
基础松动	振动一倍频显著	$P_{m,e} = \alpha_7$

## 第8章 结论与展望

### 8.1 结论

建筑智能化是未来建筑行业发展的一个重要趋势，其中建筑运维，特别是暖通空调运维也对智能化提出了需求。针对制冷机房运维场景，创新性地使用巡检机器人进行运维巡检工作，可以将运维人员从机械重复工作中解放出来，同时也降低了运维用人成本，提高运维效率。

本文基于巡检机器人在制冷机房的自动巡检及故障诊断这一研究基础，结合其所采集的热成像、声音、振动数据以及传统 BA 系统运行数据，开发了基于多源数据的故障诊断算法流程。

在 BA 数据与机器人采集数据的诊断流程搭建中，从能效诊断出发，通过逐级判别的方式将传统既有 BA 数据设备故障诊断流程与基于机器人采集数据的新诊断流程进行结合。对于机器人采集数据的故障诊断及多源数据融合算法形式，本文确定了结论层融合的数据融合层次，由此确定了机器人参与设备运维及故障诊断的算法流程。

在基于声音诊断的水泵异常诊断中，本文基于水泵运行声音与背景噪声的特性，参考小波去噪方法，开发了神经网络-小波变换去噪算法，能够有效学习目标水泵的纯净声音特征，并去噪背景噪声的干扰；对于去噪后的声音数据，采用自编码器进行声音异常检测，有效识别出异常状态下的水泵声音，识别准确率在测试集上达到 100%。

在基于振动的水泵异常检测中，本文基于倒谱预白化方法对水泵振动进行去噪处理，在多个案例上去噪效果显著，加强了频谱图上的倍频特征；在异常识别算法开发中，基于量化经验分析的思想，将工程中基于多个倍频特征进行人工异常分析的过程进行量化，实现自动分析过程，其平均故障分类准确率达到 82.6%。

在多源数据融合算法开发中，本文基于概率统计的异常检测思想，对电功率及热成像数据进行异常检测；结合振动数据和声音数据，对多源数据结论层结果可信度进行分析和量化，并采用概率事件的思想，开发了多源数据结论层融合算法，该算法有效量化了多源数据对制冷机房故障诊断可信度的提升效果。

以上内容为巡检机器人采集数据后的故障诊断框架及算法流程，为巡检机器人提供了智能化诊断能力，辅助其更好的实现制冷机房运维智能化。

## 8.2 展望

从研究角度上看,本文在结合巡检机器人的制冷机房故障诊断领域取得了一定的研究结果,相较传统基于单一来源数据的故障诊断方法,本文在 BA 数据的基础上增加了声音、振动、热成像等数据,结合数据融合算法,增强故障诊断可靠性和范围。

但对于音频数据,考虑到数据去噪前的信噪比一般,因此未深入分析其包含的水泵运行状态特征,仅进行异常识别,可以从传感器层面解决声音信噪比不高的问题,从而提高水泵声音数据的利用率;进一步的,水泵声音和振动数据将具有一定关联度,可以深入探究其数据关系,实现在数据层或特征层的数据融合。

从工程应用角度上看,本文所开发算法及框架具有较高可部署性,在声音的去噪及异常检测算法中,考虑到现场负面样本的难以获取性,开发具有正面样本依赖的算法,使之对于一般制冷机房,均能从正面样本中训练本文去噪及异常检测模型;在振动的去噪及异常检测算法中,其具有一定的通用性,其算法不显著包含训练数据中设备的相应特征,对于新的使用场景下,可根据实际水泵的基频调整其倍频区范围,便可实现算法迁移;在多源数据的选择上,本文采用的 BA 数据为较方便获取的数据,因此也方便在不同机房间进行算法迁移。

但对于整体框架及算法流程,可以在目标机房进行更长久的数据采集和验证工作,从而进行更全面的验证。

从长期来看,机房内设备随着运行时间增加,会出现性能变化,在运维可接受范围内,当设备性能变化达到一定程度后,基于旧历史数据的算法便会开始失去有效性,因此可以进一步探究算法的历史数据更新步长和时间间隔。

从更长远的角度上看,随着巡检机器人更加智能化,可以将机器人的控制逻辑和本文算法框架结合起来,使之能自主进行特定的运维工作,更加灵活的进行故障诊断并基于结果进行工作内容调整。

## 致谢

不知不觉中，两年半的硕士生涯即将结束，同济的六年本硕时光也将迎来最终幕，这段时光是我最宝贵的财富。

首先，很感谢我的导师许鹏教授。在我的硕士生涯期间，许老师给予了我极大的指导和鼓励，在我遇到问题时，许老师总是能用儒雅且不失风趣的话语为我细心指点，让人如沐春风；在面临新的挑战时，许老师也鼓舞我跳出舒适域，让我认识到了更好的自己。我一直很感激许老师能够接收我在课题组进行的学习，在此向您致以诚挚的谢意。

其次，很感谢陪伴我两年半的 A434 课题组的大家们。感谢沙华晶师姐在我刚进组时为我介绍课题组的师兄师姐们，并在课题研究上给予许多建议；感谢陈永保师兄像兄长一样关照我们；感谢杨志伟师兄在实验室管理交接时认真的讲解；感谢顾洁帆师姐在我研究工作和就业上给予的建议，在平时生活中的关心；感谢罗为师姐总是面带笑容地关心我们，鼓舞我们的精神；感谢陈智博师兄和我一起进行项目研究，一起交流工作经验，在工作上给予了很多帮助；感谢陈喆师兄和我交流电子设备和各种黑科技讯息；感谢贾乾然师弟，和我一起捣鼓机器人，并一起交流神经网络方面的知识，并且总是能带来欢乐；感谢陈志森师弟和我一起交流和分享人生规划；感谢何睿凯师弟经常和我探讨人生；感谢肖桐师妹为我的研究提供帮助，为我的论文图表提供很赞的绘制工具；感谢郭明月师妹为我提供课题相关文献，并积极关注我的论文进度；很感谢关航师妹在我参与的项目财务工作上的高效处理和负责态度。还要感谢我的同门王鸿鑫，为我解答了很多工作流程上的疑惑，提供给力的支援，以及我的另一个同门戴明坤，一起经历项目工作，并常常约我运动。

最后，要感谢我的父母支持我读研，在我读研期间对我无微不至的关心和鼓励。还要感谢吴泽君同学，陪伴我经历了整个大学生涯，一直是我前进的支撑和动力。

伤感不应是离别的基调，一叶浮萍归大海，人生何处不相逢。愿江湖重逢之日，大家均已拥抱各自的美好！

2021 年 1 月

## 参考文献

- [1] Chen Y M, Lan L L. A fault detection technique for air-source heat pump water chiller / heaters [J]. *Energy and Buildings*, 2009, 41( 8) : 881-887
- [2] 赵云峰. 基于运行数据的离心式机组故障诊断研究 [D]. 长沙: 湖南大学, 2011
- [3] 康嘉. 主元分析在制冷故障检测与诊断中的应用研究 [D]. 上海: 上海交通大学, 2011
- [4] 晋欣桥, 杜志敏, 孙勇. 基于主成分分析法的变风量空调系统传感器故障诊断 [J]. *上海交通大学学报*, 2005, 39( 8) : 1222-1225
- [5] Wang S W, Xiao F. AHU sensor fault diagnosis using principal component analysis method [J]. *Energy and Buildings*, 2004, 36( 2) : 147-160
- [6] Wang S W, Xiao F. Detection and diagnosis of AHU sensor faults using principal component analysis method [J]. *Energy Conversion and Management*, 2004, 45( 17) : 2667-2686
- [7] Xu X H, Xiao F, Wang S W. Enhanced chiller sensor fault detection, diagnosis and estimation using wavelet analysis and principal component analysis methods [J]. *Applied Thermal Engineering*, 2008, 28( 2) : 226-237
- [8] 张夏泉. 空调系统中传感器故障检测与诊断方法研究 [D]. 东北大学, 2009.
- [9] 禹法文. 基于主元分析的多联机系统传感器故障检测与诊断 [D]. 华中科技大学, 2018.
- [10] X J Luo, K F Fong. Novel pattern recognition-enhanced sensor fault detection and diagnosis for chiller plant [J]. *Energy and Buildings*, 2020, 228.
- [11] H. Han, B. Gu, Y.C. Hong et al. 2011. Automated FDD of multiple-simultaneous faults (MSF) and the application to building chillers. *Energy and Buildings* 43:2524-2532.
- [12] H. Han, Z.K. Cao, B. Gu et al, 2012. PCA-SVM-based automated fault detection and diagnosis (AFDD) for vapor -compression refrigeration systems. *HVAC&R Research* 16:295-313.
- [13] Y. Zhao, S.W. Wang and F. Xiao, 2013. Pattern recognition-based chillers fault detection method using support vector data description (SVDD). *Applied Energy* 112:1041-1048.
- [14] Y. Zhao, S.W. Wang and F. Xiao, 2012. A novel fault detection strategy for centrifugal chiller based on support vector data description (SVDD). *International Conference on Applied Energy CAE2012*, SuZhou, China
- [15] G.N. Li, Y.P. Hu, H.X. Chen, et al., 2016. An improved fault detection method for incipient centrifugal chiller faults using the PCA-R-SVDD algorithm. *Energy and Buildings* 116:104-113.
- [16] Sheng-Fa Yuan, Fu-Lei Chu. Support vector machines-based fault diagnosis for turbo-pump rotor [J]. *Mechanical Systems and Signal Processing*, 2005, 20(4).
- [17] Ke Yan, Wen Shen, Timothy Mulumba, et al. ARX model based fault detection and diagnosis for chillers using support vector machines [J]. *Energy & Buildings*, 2014, 81.
- [18] Zhao Y, Wen J, Xiao F, et al. Diagnostic Bayesian Networks for Diagnosing Air Handling Units Faults -Part I: faults in dampers, fans, filters and sensors [J]. *Applied Thermal Engineering*, 2017, 111: 1272-1286
- [19] Zhao Y, Wen J, Wang S W. Diagnostic Bayesian networks for diagnosing air handling units faults Part II: Faults in coils and sensors [J]. *Applied Thermal Engineering*, 2015, 90( 5) :

145-157

- [20] Yan R, Ma Z J, Zhao Y, et al. A decision tree based data-driven diagnostic strategy for air handling units [J]. *Energy and Buildings*, 2016, 133: 37-45
- [21] Ng K H, Yik F W H, Lee P, et al. Bayesian Method for HVAC Plant Sensor Fault Detection and Diagnosis[J]. *Energy and Buildings*, 2020.
- [22] 柴伟, 池彬彬. 基于区间预测模型的污水处理厂传感器故障检测[J]. *计算技术与自动化*, 2020, 39(01): 23-28.
- [23] XU X H, XIAO F, WANG S W. Enhanced chiller sensor fault detection, diagnosis and estimation using wavelet analysis and principal component analysis methods [J]. *Applied Thermal Engineering*, 2008, 28(2): 226-237.
- [24] ZHAO J S, CHEN B Z, SHEN J Z. Multidimensional non-orthogonal wavelet-sigmoid basis function neural network for dynamic process fault diagnosis [J]. *Computers and Chemical Engineering*, 1998, 23(1).
- [25] 杨云雨, 杜志敏, 晋欣桥. 基于小波神经网络方法的空调系统传感器漂移故障诊断[J]. *能源技术*, 2008, (1): 27-30+34.
- [26] 李冬辉, 李晟. 基于小波神经网络的空调系统传感器故障诊断[J]. *传感器与微系统*, 2007, (4): 54-57.
- [27] Zhu Y, Jin X, Du Z. Fault diagnosis for sensors in air handling unit based on neural network pre-processed by wavelet and fractal[J]. *Energy & Buildings*, 2012, 44(Jan.):7-16.
- [28] LIU J W, CHEN W R, CAO T Q. A discrete hidden Markov model fault diagnosis strategy based on K-means clustering dedicated to PEM fuel cell systems of tramways [J]. *International Journal of Hydrogen Energy*, 2018, 43(27): 12428-12441.
- [29] YAN R, MA Z J, Georgios K, et al. A sensor fault detection strategy for air handling units using cluster analysis [J]. *Automation in Construction*, 2016, 70: 77-88.
- [30] LUO X J, FONG K F, SUN Y J, et al. Development of clustering-based sensor fault detection and diagnosis strategy for chilled water system[J]. *Energy and Building*, 2019, (186): 17-36.
- [31] JIANG L L, CAO Y X, YIN H K, et al. An improved kernel K-mean cluster method and its application in fault diagnosis of roller bearing [J]. *Engineering*, 2013, 5(1): 44-49.
- [32] 刘涵. 水电机组多源信息故障诊断及状态趋势预测方法研究[D]. 华中科技大学, 2019.
- [33] 潘永泰, 朱长勇, 惠学齐等. 基于音频信号的破碎机故障识别技术研究[J]. *煤矿机械*, 2020, 41(08): 161-164.
- [34] 陈静. 基于声音信号分析的牵引变压器故障诊断方法研究[J]. *电气应用*, 2020, 39(02): 25-29.
- [35] 刘登, 崔宏维, 姚恩涛. 基于 ITD 的风机叶片气动音频信号故障诊断研究[J]. *电子测量技术*, 2019, 42(23): 68-73.
- [36] 赵国欣. 变频水泵状态监测与故障诊断[D]. 西安科技大学, 2018.
- [37] Shijie Hao, Feng-Xiang Ge, Yanmiao Li, et al. Multisensor bearing fault diagnosis based on one-dimensional convolutional long short-term memory networks[J]. *Measurement*, 2020, 159.
- [38] Shaowei Liu, Hongkai Jiang, Zhenghong Wu, et al. Rolling bearing fault diagnosis using variational autoencoding generative adversarial networks with deep regret

- analysis[J].Measurement,2021,168.
- [39] HALL D L, Llinas J. An introduction to multisensor data fusion[J]. Proc IEEE,1997,85(1):6-23.
- [40] Varshney P K. Multisensor data fusion[J].J Ecler Commu Eng,1997,9(6):245-253.
- [41] 赵书涛,王二旭,陈秀新等.声振信号联合 1D-CNN 的大型电机故障诊断方法[J].哈尔滨工业大学学报,2020,52(09):116-122.
- [42] 王占伟.冷水机组故障检测与诊断方法研究[D].西安建筑科技大学,2017.
- [43] 刘石磊.基于 D-S 证据融合的风力发电机组的故障预测[D].沈阳:沈阳工业大学,2017.
- [44] 李洋.基于贝叶斯网络的电机故障诊断方法研究[D].沈阳:沈阳工业大学,2012.
- [45] 王沅召.基于 D-S 证据理论和贝叶斯网络的电机故障诊断研究[D].沈阳:沈阳工业大学,2014.
- [46] 李俊卿,李忠徽,全宗义.基于支持向量机和 D-S 证据理论的双馈风机定子匝间短路故障诊断[J].电机与控制应用,2018,45(5):99-103.
- [47] 李黎,张烈平.基于灰色关联和 D-S 证据理论的感应电机转子故障诊断[J].计算机测量与控制,2012,20(6):1492-1494.
- [48] 卜乐平,刘开培,侯新国.采用 D-S 证据推理的电机转子故障诊断[J].振动、测试与诊断,2011,31(1):23-26.
- [49] 张文胜,龚涛,胡错.基于 D-S 证据理论的直流电机故障诊断研究[J].中国舰船研究,2010,5(4):72-74.
- [50] 稀斗,王向军.基于 DS 证据理论的直流电机故障诊断研究[J].电机与控制应用,2008,35(2):49-51.
- [51] 黄志彦,张柏书,于开山等. D-S 证据理论数据融合算法在某系统故障诊断中的应用[J].电光与控制,2007(02):146-149.
- [52] 李曹县,魏鸿榕.谈 BAS 系统在我国现阶段应用中存在的一些问题[J].福建工程学院学报,2003(04):45-47.
- [53] Shengwei Wang, Jingtian Cui. A Robust Fault Detection and Diagnosis Strategy for Centrifugal Chillers[J]. HVAC&R Research,2011,12(3).
- [54] Naveed Khuram, Akhtar Muhammad Tahir, Siddiqui Muhammad Faisal, et al. A statistical approach to signal denoising based on data-driven multiscale representation. Digital Signal Processing, 2021, 108.
- [55] Hyun Kwon, Hyunsoo Yoon, Ki-Woong Park, Acoustic-decoy: Detection of adversarial examples through audio modification on speech recognition system.Neurocomputing,2020,417.
- [56] 麻付强.脉冲噪声环境下麦克风阵列的 DOA 估计技术研究[D].北京科技大学,2020.
- [57] 张立智,徐卫晓,井陆阳等.基于 EMD-SVD 和 CNN 的旋转机械故障诊断[J].振动.测试与诊断,2020,40(06):1063-1070+1228.
- [58] APPLICATION OF THE ENVELOPE AND WAVELET TRANSFORM ANALYSES FOR THE DIAGNOSIS OF INCIPIENT FAULTS IN BALL BEARINGS[J]. R. RUBINI,U. MENEGHETTI. Mechanical Systems and Signal Processing . 2001 (2)
- [59] Tie Qiang Sun, Rong Liu, Zhi Qi Qiu. Shaft Vibration Signal Denoising Based on Wavelet Analysis[J]. Applied Mechanics and Materials,2013,2307.
- [60] 刘天舒. BP 神经网络的改进研究及应用[D].东北农业大学,2011.
- [61] Sra Suvrit, Nowozin Sebastian, Wright Stephen J, et al. Optimization for Machine

- Learning[M].The MIT Press:2011-09-30.
- [62] 吕晓玲, 宋捷. 大数据挖掘与统计机器学习[M]. 中国人民大学出版社:大数据分析统计应用丛书, 201607..
- [63] Alla Sridhar, Adari Suman Kalyan, Alla Sridhar, et al. Beginning Anomaly Detection Using Python-Based Deep Learning:With Keras and PyTorch[M].Apress:2019-10.
- [64] Audio mixing for interactive multimedia communications. Gonzalez A J, Hussein A W. JCIS'98, North Carolina . 1998
- [65] 徐保民, 王秀玲. 一个改进的混音算法[J]. 电子与信息学报, 2003 (12) :1709-1713.
- [66] Reducing the dimensionality of data with neural networks. Hinton G E, Salakhutdinov R R. Science . 2006
- [67] 胡昭华, 宋耀良. 基于 Autoencoder 网络的数据降维和重构[J]. 电子与信息学报, 2009, 31 (05) :1189-1192.
- [68] 王振成, 张雪松, 刘爱荣等. 工程测试技术及应用[M]. 重庆大学出版社:机械设计制造及其自动化专业应用型本科系列规划教材, 201408.
- [69] GB/T 11348. 1-1999, 旋转机械转轴径向振动的测量和评定 第 1 部分: 总则[S].
- [70] 唐贵基, 邓飞跃, 张超等. 基于倒谱预白化和奇异值分解的滚动轴承故障特征提取方法[J]. 中国电机工程学报, 2014, 34 (35) :6355-6361.
- [71] Oppenheim A V, Willsky A S, Hamid S. Signals and systems, Processing series[J]. 1997.
- [72] 张建茹. 水泵振动原因分析与减振方法研究[D]. 大连理工大学, 2013.
- [73] An overview of flow-based anomaly detection[J] . Rohini Sharma,Ajay Guleria,R.K. Singla. Int. J. of Communication Networks and Distributed . 2018 (2)
- [74] Anomaly detection[J] . Varun Chandola,Arindam Banerjee,Vipin Kumar. ACM Computing Surveys (CSUR) . 2009 (3)
- [75] So, Albert T.P., Chan, W.L., Chow, T.T. Computer-vision-based HVAC control system (1995) ASHRAE Transactions, 101 (Pt 2), pp. 661-678.
- [76] Junqi Wang, Norman Chung Fai Tse, Tin Yan Poon et al. A Practical Multi-Sensor Cooling Demand Estimation Approach Based on Visual, Indoor and Outdoor Information Sensing. Sensors,2018, 18(11:3591-3615.
- [77] Wooyoung Jung, Farrokh Jazizadeh. Vision-based thermal comfort quantification for HVAC control. Building and Environment, 2018, 142:513-523.
- [78] 邢素霞. 红外热成像与信号处理 [ M] .北京国防工业出版社, 2011



## 附录 A 部分代码节选

第一部分：水泵音频去噪模型训练代码（节选）

#构建数据集

```
class Mydataset(Dataset):
```

```
    def __init__(self,s_n_data,use_original_coeffs=True,data_encode =
None,data_decode=None,data_loader = None,coeffs_loader=None):
```

```
        super(Mydataset,self).__init__()
```

```
        self.df = s_n_data
```

```
        self.len = len(self.df)
```

```
        self.data_encode = data_encode
```

```
        self.data_decode = data_decode
```

```
        self.data_loader = data_loader
```

```
        self.coeffs_loader = coeffs_loader
```

```
        self.use_original_coeffs = use_original_coeffs
```

```
    def __len__(self):
```

```
        return self.len
```

```
    def __getitem__(self,index):
```

```
        if self.use_original_coeffs:
```

```
            x = self.df[index][0][0]
```

```
            x = torch.Tensor(x)
```

```
            y = self.df[index][1][0]
```

```
            y = torch.Tensor(y)
```

```
            return x,y,index
```

```
    def getcoeffs_x(self,index):
```

```
        coeffs_x_path = PATH + "噪声去噪_小波变换数据集/"+self.df[index][0][1]
```

```
        coeffs_x = self.coeffs_loader(coeffs_x_path)
```

```
        coeffs_x = [np.array(i) for i in coeffs_x]
```

```
        return coeffs_x,index
```

```
    def getcoeffs_y(self,index):
```

```
        coeffs_y_path = PATH + "噪声去噪_小波变换数据集/"+self.df[index][1][1]
```

```
        coeffs_y = self.coeffs_loader(coeffs_y_path)
```

```

        coeffs_y = [np.array(i) for i in coeffs_y]
        return coeffs_y,index
    def getwave_x(self,index):
        __,__,__,wave_x = self.data_loader(self.df[index][0][2])
        return wave_x,index
    def getwave_y(self,index):
        __,__,__,wave_y = self.data_loader(self.df[index][1][2])
        return wave_y,index
train_data = Mydataset(trainset_list,use_original_coeffs=True,data_encode =
data_encode,data_decode = data_decode,data_loader = open_wave,coeffs_loader = coeffs_loader)
test_data = Mydataset(testset_list,use_original_coeffs=True,data_encode =
data_encode,data_decode = data_decode,data_loader = open_wave,coeffs_loader=coeffs_loader)
train_loader = DataLoader(train_data,batch_size=BATCH_SIZE,shuffle=True,num_workers=0)
test_loader = DataLoader(test_data,batch_size=BATCH_SIZE,shuffle=False,num_workers=0)
print('dataload done')

#构建模型
class FC(nn.Module):
    def __init__(self,input_len):
        super(FC,self).__init__()
        self.fc = nn.Sequential(
            nn.Linear(input_len, 512),
            nn.ReLU(True),
            nn.Linear(512, 256),
            nn.ReLU(True),
            nn.Dropout(p=0.5),
            nn.Linear(256, input_len)
        )
    def forward(self, x):
        out = self.fc(x)
        #out = F.log_softmax(out,dim=1)
        return out

```

第二部分：水泵音频异常检测模型训练代码（节选）

#构建数据集

```
class Mydataset(Dataset):
    def __init__(self,dataset_list):
        super(Mydataset,self).__init__()
        self.df = dataset_list
        self.len = len(self.df)
    def __len__(self):
        return self.len
    def __getitem__(self,index):
        x = torch.Tensor(self.df[index][0])
        label = self.df[index][1]
        return x,label

train_data = Mydataset(dataset_list)
eval_data = Mydataset(eval_dataset_list)
all_data = Mydataset(all_dataset_list)
train_loader = DataLoader(train_data,batch_size=BATCH_SIZE,shuffle=False,num_workers=0)
eval_loader = DataLoader(eval_data,batch_size=1,shuffle=False,num_workers=0)
all_loader = DataLoader(all_data,batch_size=1,shuffle=False,num_workers=0)
```

#构建自编码器网络

```
class AutoEncoder(nn.Module):
    def __init__(self,input_len):
        super(AutoEncoder,self).__init__()
        self.encoder = nn.Sequential(
            nn.Linear(input_len,128),
            nn.Tanh(),
            nn.Linear(128, 64),
        )
        self.decoder = nn.Sequential(
            nn.Linear(64, 128),
            nn.Tanh(),
            nn.Linear(128, input_len),
            #nn.Sigmoid()
        )
```

```
def forward(self, x):
    encoded = self.encoder(x)
    decoded = self.decoder(encoded)
    return encoded,decoded
```

### 第三部分：水泵振动异常检测代码（节选）

#去噪：读取振动再采样——seg 的文件，进行倒谱预白化处理

```
def get_data(file_name):
    data = pd.read_csv(file_name)
    N = len(data)
    f_s = 500
    y_values = np.array(data['vibra'])
    x_values = np.arange(0,10.0,10/N)
    return y_values,x_values,f_s

def ceps_while(file_name):
    y_values,x_values,f_s = get_data(file_name)
    N = len(y_values)
    f_values = np.linspace(0.0, f_s, N)
    #复数谱
    fft_values = fft.fft(y_values)
    #相位谱
    fft_angle_values = np.angle(fft_values)
    #幅值谱
    fft_r_values = np.abs(fft_values)
    #实倒谱
    fft_rceps_values = fft.ifft(np.log(fft_r_values))
    #倒谱编辑

    fft_rceps_values[1:] = 0
    #复原后的幅值谱
    new_fft_r_values = np.exp(fft.fft(fft_rceps_values))
    #残余对数谱
```

```

new_fft_values = abs(new_fft_r_values)*np.exp(1j*fft_angle_values)
new_y_values = abs(fft.ifft(new_fft_values))
new_new_fft_values = abs(fft.fft(new_y_values))
#log_new_new_fft_values = 10*np.log10(abs(new_new_fft_values))
#plt.plot(log_new_new_fft_values)
#plt.plot(10*np.log10(fft_values))
#new_y_values = np.real(fft.ifft(new_fft_values))
#plt.plot(f_values,log_new_new_fft_values)
return f_values,new_new_fft_values,f_s

#划分测试集和验证集 7:3
train_new_data_0 = new_data_0[0:int(len(new_data_0)/10*7)]
test_new_data_0 = new_data_0[int(len(new_data_0)/10*7):]

train_new_data_1 = new_data_1[0:int(len(new_data_1)/10*7)]
test_new_data_1 = new_data_1[int(len(new_data_1)/10*7):]

#计算负面样本 Q3 和正面样本 Q1
train_new_data_0.sort()
train_new_data_0_Q3 = np.quantile(train_new_data_0,0.75,interpolation='higher')
train_new_data_1_Q1 = np.quantile(train_new_data_1,0.25,interpolation='lower')

def make_f(data_0_Q3,data_1_Q1,fzyz):
    if data_0_Q3 < data_1_Q1:
        if fzyz < data_0_Q3:
            return 0
        elif fzyz > data_1_Q1:
            return 1
        else:
            return (fzyz-data_0_Q3)/(data_1_Q1-data_0_Q3)
    else:
        return make_f(data_1_Q1,data_0_Q3,fzyz)

#训练集中展示

```

```
train_result_dict = {'fzyz':[],'f':[],'label':[],'new_label':[]}
```

```
for i in range(len(train_new_data_0)):
```

```
    f = make_f(train_new_data_0_Q3,train_new_data_1_Q1,train_new_data_0[i])
```

```
    train_result_dict['fzyz'].append(train_new_data_0[i])
```

```
    train_result_dict['f'].append(f)
```

```
    train_result_dict['label'].append(0)
```

```
    if f > 0:
```

```
        train_result_dict['new_label'].append(1)
```

```
    else:
```

```
        train_result_dict['new_label'].append(0)
```

```
for i in range(len(train_new_data_1)):
```

```
    f = make_f(train_new_data_0_Q3,train_new_data_1_Q1,train_new_data_1[i])
```

```
    train_result_dict['fzyz'].append(train_new_data_1[i])
```

```
    train_result_dict['f'].append(f)
```

```
    train_result_dict['label'].append(1)
```

```
    if f > 0:
```

```
        train_result_dict['new_label'].append(1)
```

```
    else:
```

```
        train_result_dict['new_label'].append(0)
```

```
train_result = pd.DataFrame(train_result_dict)
```

```
#测试集中验证
```

```
test_result_dict = {'fzyz':[],'f':[],'label':[],'new_label':[]}
```

```
for i in range(len(test_new_data_0)):
```

```
    f = make_f(train_new_data_0_Q3,train_new_data_1_Q1,test_new_data_0[i])
```

```
    test_result_dict['fzyz'].append(test_new_data_0[i])
```

```
    test_result_dict['f'].append(f)
```

```
    test_result_dict['label'].append(0)
```

```
    if f > 0:
```

```
        test_result_dict['new_label'].append(1)
```

```
    else:
```

```
test_result_dict['new_label'].append(0)

for i in range(len(test_new_data_1)):
    f = make_f(train_new_data_0_Q3,train_new_data_1_Q1,test_new_data_1[i])
    test_result_dict['fzyz'].append(test_new_data_1[i])
    test_result_dict['f'].append(f)
    test_result_dict['label'].append(1)
    if f > 0:
        test_result_dict['new_label'].append(1)
    else:
        test_result_dict['new_label'].append(0)
test_result = pd.DataFrame(test_result_dict)
```

#### 第四部分：水泵电功率异常检测代码（节选）

```
os.chdir(r'F:\ftp_share\水泵故障实验\数据\电')
df = pd.read_excel('机房水泵数据.xlsx')
new_df = df[['时间','1#新风水泵-瞬时功率（kW）']]
new_df.columns = ['时间','功率']
new_df = new_df[new_df['功率'] > 1]

new_df['时间'] = pd.to_datetime(new_df['时间'])

new_df = new_df.reset_index(drop=True)

#额定·功率·18.5kw
new_df['p'] = new_df['功率'].values/18.5

start = pd.to_datetime('2020-06-10 00:00:00')
end = pd.to_datetime('2020-06-23 23:59:00')
delta_n = int(round((end-start)/np.timedelta64(24, 'h'),0))
```

```
now_df_list = []
for i in range(delta_n):
    now = start + i*np.timedelta64(24, 'h')
    now_df = new_df[(new_df['时间'] - now < np.timedelta64(24, 'h'))&(np.timedelta64(0, 'h')
<= new_df['时间'] - now )]
    if len(now_df) < 100:
        continue
    else:
        now_df_list.append(now_df)

#设置 x 轴边界
x_left = min(new_df['p'])-0.05
x_right = max(new_df['p'])+0.05

plt.figure(0,figsize = (8,12))
#plt.title('p_i')
for i in range(len(now_df_list)):
    plt.subplot(len(now_df_list), 1, i+1)
    plt.xlim(x_left,x_right)
    plt.ylabel(str(now_df_list[i]['时间'].iloc[0]).split(' ')[0])
    sns.distplot(now_df_list[i]['p'].values,hist = False,rug = False)
plt.show()

plt.figure(2,figsize = (6,4))
plt.xlim(x_left,x_right)
#plt.ylabel(str(now_df_list[i]['时间'].iloc[0]).split(' ')[0])
sns.distplot(new_df['p'].values,hist = False,rug = False)
plt.show()

###

#计算波动特征
```



```

window = 30
new_df['p_std'] = [0]*len(new_df)
for i in range(len(new_df)-window):
    new_df['p_std'].iloc[i] = new_df['p'].iloc[i:i+window].std()

new_new_df = new_df[new_df['p_std'] > 0]

start1 = pd.to_datetime('2020-06-10 00:00:00')
end1 = pd.to_datetime('2020-06-23 23:29:00')
delta_n1 = int(round((end-start)/np.timedelta64(24, 'h'),0))

now_df_list1 = []
for i in range(delta_n1):
    now1 = start1 + i*np.timedelta64(24, 'h')
    now_df1 = new_new_df[(new_new_df['时间'] - now1 < np.timedelta64(24,
'h'))&(np.timedelta64(0, 'h') <= new_new_df['时间'] - now1 )]
    if len(now_df1) < 100:
        continue
    else:
        now_df_list1.append(now_df1)

#设置 x 轴边界
x_left1 =0
x_right1 = 0.04

plt.figure(1,figsize = (8,12))
#plt.title('p_j,std')
for i in range(len(now_df_list1)):
    plt.subplot(len(now_df_list1), 1, i+1)
    plt.xlim(x_left1,x_right1)
    plt.ylabel(str(now_df_list1[i]['时间'].iloc[0]).split(' ')[0])
    sns.distplot(now_df_list1[i]['p_std'].values,hist = False,rug = False)
plt.show()

```

```
plt.figure(4,figsize = (6,4))
plt.xlim(x_left1,x_right1)
#plt.ylabel(str(now_df_list[i]['时间'].iloc[0]).split(' ')[0])
sns.distplot(new_new_df['p_std'].values,hist = False,rug = False)
plt.show()
```

## 个人简历与研究成果

### 个人简历:

李泓名, 男, 1995 年 10 月生。

2018 年 7 月毕业于同济大学 建筑环境与能源应用工程专业 获学士学位。

2018 年 9 月入同济大学读专业型硕士研究生, 专业为动力工程 。

### 专利:

- [1] 许鹏, 李泓名. 一种基于相变蓄冷原理的便携式气体空调服: 中国, ZL 2019 20718040.8. 2019-05-20