

CAICT 中国信通院



工业大数据创新竞赛
Industrial Big Data Innovation Competition



工业互联网产业联盟
Alliance of Industrial Internet

工业大数据 创新竞赛白皮书

(2018-2019)

编写单位：

中国信息通信研究院

工业大数据创新竞赛组委会

工业互联网产业联盟

2020年8月



编写说明

我国工业互联网正在从概念普及进入实践深耕的发展阶段，在这一进程中，大数据作为一种新的资产、资源和生产要素，技术创新和应用实践日趋活跃，正成为驱动制造业智能化变革的重要动力。为充分激发数据要素价值，贯彻落实《国务院关于深化“互联网+先进制造业”发展工业互联网的指导意见》，中国信息通信研究院自2017年起在工业和信息化部指导下，已连续举办了三届工业大数据创新竞赛，这也是首个由政府主管部门指导的工业大数据领域的权威全国性创新竞赛。

竞赛在组织方式上充分借鉴了发达国家推动工业大数据创新应用的先进模式，开发出诸多聚焦行业细分领域的算法模型，吸引了海内外近6800人参赛，同时品牌逐渐走向国际，第三届竞赛与全球工业大数据领域顶尖活动PHM（故障预测与健康管理）亚太学术论坛合作，仅线上答辩直播吸引超过5万人观看，为工业大数据领域的相关研究人员和创业者们提供了成果转移转化的交流平台，在产业界逐渐形成品牌影响力。

第一届竞赛后，结合获胜选手分析模型和方法发布《工业大数据竞赛白皮书（风机结冰故障分析指南）》引起社会广泛关注。时隔两年，为进一步总结优秀第二届、第三届工业大数据创新竞赛算法，中国信息通信研究院组织参赛者编写了《工业大数据创新竞赛（2018–2019）白皮书》，希望将两届竞赛的经验与技术成果固化并加以推广，与业界共同推动工业大数据发展。

《工业大数据创新竞赛（2018–2019）白皮书》收录了机床加工刀具寿命预测赛题的5种获奖解法以及转子部件脱落故障预测赛题的7种获奖解法，为学术研究和产业实践提供参考。白皮书的编写过程得到大赛组委会和参赛选手的大力支持，相关参赛人员根据自己对竞赛题目的解法，给出了详细、清晰的方法流程与结果讨论。

我国工业大数据竞赛的发展仍处于起步阶段，大赛组委会愿真诚吸取各界的反馈意见，持续提升大赛水平，并将大赛成果以白皮书等形式定期与社会各界分享。



编写单位：中国信息通信研究院
工业大数据创新竞赛组委会
工业互联网产业联盟

指导专家：王建民 余晓晖 李 杰 侍乐媛 李清源 赵 敏 韩 庆 郭 翹 王友升
邢 镔 郭朝晖 刘 杰 吴振宇 李城梁 徐长恺 郭 翹 晋文静 胥 佳
崔必如 郑弘孟 孙可意 周映彤 谢彦守 江侑紘 林焱辉 黄亦翔 孟繁亮
赵志海 金 超 田春华 傅若玮 韩 庆

编写组成员（排名不分先后）：

李 铮 杨艳冉 刘 迎 孙 昕 赵 男 吴文龙 周训淼 邓惠民 王晓明
金 超 胡江雪 王旻轩 鲍亭文 王晓明 杨立宁 刘思辰 刘 锋 万 伊
程 骋 沈国锐 马贵君 蔡 鑫 曾 雄 刘重党 姚 荣 牛家禾 胡 翔
戴 俊 宋 哲 申颖君 钮鹏飞 刘正锋 景宏杰 潘彤阳 蔺思宇 刘 涛
李素洁 杨晨旺 崔晓龙 季天泽 Myungyon Kim Jongmin Park Yongjin

Shin Alliance of Industrial Internet

序

中国工业大数据创新竞赛自创办以来，就被寄予了厚望，很欣喜地看到它正在蓬勃发展。它作为产业界与学术界的重要桥梁之一，对工业大数据这一跨学科领域创新人才的培养起到了重要的作用。

在近几年中，我有幸参与大赛的筹划和评审工作，代表 IMS 中心和富士康工业互联网为大赛提供帮助。大赛获得的关注程度以及选手们的出色表现都令人感到惊喜。如今，信通院将第二届和第三届大赛中的优秀成果集结成为《工业大数据创新竞赛白皮书 2018-2019》，相信能够为从事工业大数据应用研究的企业和学者们提供有价值的参考。

在工业互联网的发展过程中，人工智能技术与工业结合的探索得到了进一步推进，工业人工智能的理念兴起。我对它的关键要素做出了一个总结，可以归纳为“ABCDEF”六大技术要素，来阐释工业人工智能是由多个技术元素整合而成的一个系统工程。这六个字母分别代表 Analytics（建模分析）、Big Data（大数据）、Cloud（云计算）、Domain Knowledge（领域知识）、Evidence（事实依据）、Feedback（反馈闭环）。前三个技术要素同时也是 AI 技术的三个要素（数据、计算能力和算法），但是与工业人工智能有所区别。在分析建模方面，前者以算法为核心，后者以场景和问题为核心；在数据技术方面，前者围绕解决“4V”挑战，后者则是管理“3B”特性；在计算平台方面，前者以云计算和集中式的运算能力为主，后者以“端”到“云”的融合架构为主。后三个要素则是带有鲜明的工业特质的技术要素，也是人工智能与工业系统相融合的接口。在这两次的工业大数据竞赛评审中，我非常欣慰地看到多支优胜队伍，在解决相关问题时，并没有局限于基础机器学习方法的套用，而是非常深入地学习了相关的领域知识。还有的获胜队伍结合数据驱动的方法弥补对机理了解的不足。这些研究工业数据问题的方法和精神，我非常赞赏。

中国未来要实现智能制造需要什么样的人？在这两届大赛中我也有了更深的体会。我认为，若要真正实现智能制造，中国仍需要一批工业大数据的年轻生力军，不仅拥有扎实的算法基础和学习能力，还能够下到工厂，进入制造知识的内核。用算法的能力补偿有经验的专家，相互碰撞与融合，只有这样才能推动智能制造高质量发展。

工业的未来属于年轻人。我非常欣慰地看到，信通院举办的工业大数据竞赛每年都有数千位参赛选手参与竞赛，更有 90% 以上是学生。愿各位工业大数据领域的开发者、实践者，可以一直保持对数据的好奇心，愿意冒险，愿意吃苦，发掘数据中的根本原因，为生产带去更大效益。

衷心祝愿中国工业大数据创新竞赛越办越好，成为全球产学研共同推崇的传统和品牌，为中国智能制造产业生态源源不断地输送优秀人才。



Jay Lee（李杰），2020年8月

目 录

| | |
|--------------------------------------|----|
| ■ 编写说明 | 1 |
| ■ 序 | 3 |
| ■ 目 录 | 4 |
| ■ 第一篇章 第二届工业大数据创新竞赛 | 7 |
| 一、第二届竞赛赛题介绍 | 7 |
| 二、第二届竞赛英雄榜 | 10 |
| 三、第二届竞赛优秀解法集——刀具剩余寿命预测题目 | 11 |
| (一) 基于经验模态分解的非参数模式匹配刀具寿命预测方法 | 11 |
| (二) 基于多传感器融合的刀具寿命预测方法 | 31 |
| (三) 基于前馈神经网络的刀具剩余寿命预测 | 42 |
| (四) 基于 DTW 退化特征和 CNN+SVR 网络的刀具剩余寿命预测 | 53 |
| (五) 基于 DWT-LSTM 网络的刀具剩余使用寿命预测 | 59 |

CONTENTS / 目录

| | |
|---------------------------------------|------------|
| ■ 第二篇章 第三届工业大数据创新竞赛 | 66 |
| 一、第三届竞赛赛题介绍 | 66 |
| 二、第三届竞赛英雄榜 | 69 |
| 三、第三届大赛优秀解法集——转子部件脱落故障预测 | 70 |
| (一) 基于 LightGBM 分类算法的转子部件脱落故障识别方法 | 70 |
| (二) 基于生成对抗网络的转子故障脱落研究方法 | 79 |
| (三) 基于多模型投票与梯级分类算法的转子部件脱落故障预测 | 89 |
| (四) 基于全息故障特征提取的转子部件脱落智能识别方法 | 99 |
| (五) 基于多模型融合的转子部件脱落故障识别方法 | 108 |
| (六) 基于变分模态分解与时间 - 全谱分析的旋转机械转子部件脱落故障预测 | 115 |
| (七) 基于多传感器信号变化分析的转子系统异常检测 | 137 |
| ■ 第三篇章 工业大数据产业创新生态及平台 | 148 |
| 一、工业大数据产业创新生态 | 148 |
| 二、工业大数据产业创新平台 | 149 |

习近平总书记在中共中央政治局第二次集体学习时强调，要深入实施工业互联网创新发展战略，系统推进工业互联网基础设施和数据资源管理体系建设，发挥数据的基础资源作用和创新引擎作用，加快形成以创新为主要引领和支撑的数字经济。中国是制造大国，也是数据资源大国和应用大国，预计到 2020 年，我国数据总量全球占比将达 20%，将成为数据量最大、数据类型最丰富的国家之一。工业大数据正成为引领工业互联网创新发展的基础战略资源和新型生产要素。

在工业和信息化部指导下，中国信息通信研究院（简称“信通院”）举办了第二届和第三届工业大数据竞赛。大赛以“赋能与赋智，构建工业大数据应用生态”为主题，以“开放共享、协作共赢”为原则，是首个由政府主管部门指导的工业大数据领域的权威的全国性创新竞赛。竞赛在组织方式上充分借鉴了发达国家推动工业大数据创新应用的先进模式，基于制造企业真实数据资源和需求场景，面向全社会征集优秀解决方案，在发掘专业技术人才的同时，助力与解决制造企业实际问题。

第二届和第三届大赛分别于 2018 年 11 月和 2019 年 5 月启动，累计吸引了来自海内外近 5000 名参赛选手，其中 80% 以上来自于高校学生，涉及计算机、自动化控制、机械工程、统计、动力工程等多个领域。第二届竞赛设置两道赛题，分别为富士康的机床加工刀具寿命预测，和积微物联（四川攀枝花钢铁旗下企业）的钢卷吞吐量预测。第三届竞赛与全球工业大数据领域顶尖活动 PHM（故障预测与健康管理）亚太学术论坛合作，设置了转子部件脱落故障预测一道赛题，仅线上答辩直播吸引超过 5 万人观看，为工业大数据领域的相关研究人员和创业者们提供了成果转移转化的交流平台，在产业界逐渐形成品牌影响力。此外竞赛还获得了来自于华为、北京工业大数据创新中心、昆仑数据、天泽智云、蒂森克虏伯、ABB、PTC、美国国家仪器（NI）等国内外企业、研究机构的支持。

在第二届和第三届大赛中，由信通院组织建设的“工业大数据产业创新平台”承担了相关赛务的组织和管理工作，提供了数据下载、竞赛结果评分、参赛交流、算法培训、算法工具等多种支持。

第一篇章 第二届工业大数据创新竞赛

一、第二届竞赛赛题介绍

第二届大赛共有两道赛题，所属不同行业和建模领域的问题，具有很强的代表性。

赛题一：钢卷仓储吞吐量趋势预测

赛题问题来自成都积微物联集团股份达海产业园。该产业园是以钢材仓储、金属加工、配送、物流金融、电子商务及总部基地多功能为一体的综合产业园。为提升园区运作效率，提前规划库位分配和装备准备，需要对未来4周的吞吐量进行合理的预测。

赛题要求选手通过对达海产业园历年的历史销售、订单、仓储、吞吐量等数据（经过脱敏处理）分析建模，并结合国家未来发展趋势、钢铁供需市场等外在因素，实现对未来一个月内，达海产业园各品类的钢铁吞吐量的预测分析。预测任务主要有两个：

1. 按照两大类货品类型（冷卷、热卷），分别预测未来4个周钢铁的周入库量和周出库量（重量）；
2. 按照两大类货品类型（冷卷、热卷），分别预测未来7天的日入库量和日出库量（重量）。

赛题为选手提供了两大类数据，包括：

仓储数据：库存数据表、入库数据表、出库数据表，数据包括业务单据号、货主、对应产品、重量、数量、单据创建时间、单据完成时间、业务单据状态等信息。

基础数据：字段数据表，解释各个表字段的含义；储户费用表，主要提供储户费用相关的数据。

赛题同时鼓励参赛选手从政府官方网站、互联网等渠道获取获取外部公开数据使用，包括钢铁市场数据、大宗物资运输数据、经济发展政策、贸易新闻等。

赛题通过以下方式进行评分。比赛中会开放六次测试集，第一次开放的测试集为初赛阶段的测试集，该阶段的分数不计入最终的成绩排名。决赛阶段开放五次测试集，最终的成绩排名由该决赛阶段五次测试集的得分的平均值决定。针对每次测试集的评分方案如下：

周吞吐量的预测和天吞吐量的预测均采用 SMAPE 作为评分准则，具体计算公式如下：

$$SMAPE = \frac{1}{T} \sum_{k=1}^T \left| \frac{A_k - P_k}{\max(M, \frac{A_k + P_k}{2})} \right|$$

其中： A_k 是实际值， P_k 是预测值， k 是预测结果序列的索引， $k=1, 2, 3, \dots, 44$ ， T 是预测结果序列的长度， $T=44$ 。 M 为常数， $M=800$ 。最后排行榜的得分计算方式如下：

$$Score = (2 - SMAPE) * 50$$

赛题二：机加工刀具剩余寿命预测

在切削加工领域，刀具的状态及其寿命是加工过程中主要关注的对象，刀具寿命（磨耗程度）是影响加工工件质量的关键因子，刀具失效可能造成工件表面粗糙度和尺寸精度的下降，或造成更严重的工件报废或机床受损。采取过度的保护策略又会造成刀具剩余寿命的浪费以及不必要的换刀停机时间浪费。因此如果能够精准预测刀具的剩余寿命，将有效地优化工作排程且降低刀具采购成本。

赛题提供了机床控制器 (PLC) 信号和外置传感器 (Sensor) 信号，包括加工过程中的工况信息和传感器数据。数据来源为实际 CNC 加工过程中，一把全新的刀具开始进行正常加工程序，直到刀具寿命终止时停止数据采集。并将这 9 组数据，分成 4 组训练数据 (training data) 以及 5 组测试数据 (testing data)。4 组训练数据将提供加工过程的 PLC 信号以及震动传感器的原始信号值，同时提供当组实验数据的完整加工「刀具全寿命时间」，单位为时间 (minutes)。震动传感器的原始信号值因数据量极大，仅提供每 5 分钟任取 1 分钟的片段数据做为训练样本，并依据时间顺序 1.csv, 2.csv.... n.csv 提供，其中最后一个 csv 文档即为实验结束前最终 5 分钟的撷取数据内容。在数据采样频率方面，PLC 信号采样频率为 33Hz，震动传感器采样频率 25600Hz。



图 1-1-1 振动传感器安装位置及方向

位置：主轴上，靠近主轴端面处；方向：主轴振动传感器安装方向如下所示，以下视角均为站在机床正面看过去的方向。

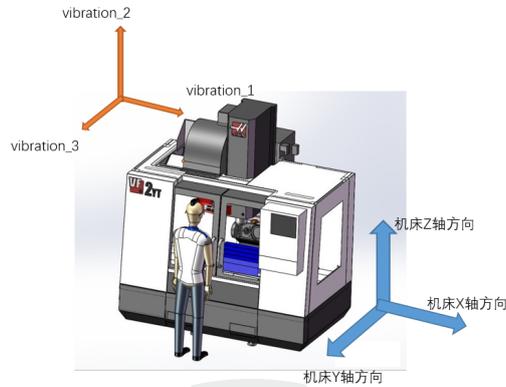
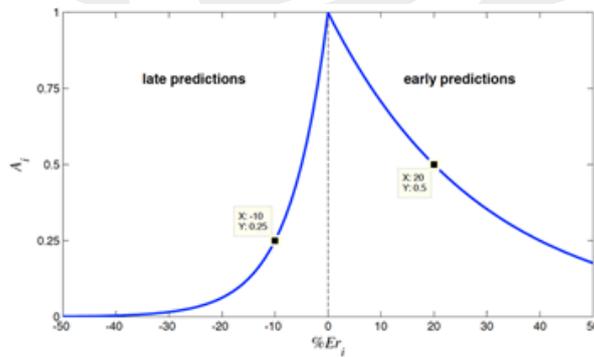


图 1-1-2 振动信号方向示意图

赛题评分方法如下：

$$A_i = \begin{cases} \exp^{-\ln(0.5) \cdot \left(\frac{Er_i}{5}\right)} & , \text{if } Er_i \leq 0 \\ \exp^{+\ln(0.5) \cdot \left(\frac{Er_i}{20}\right)} & , \text{if } Er_i > 0 \end{cases}$$



以上计算公式中：

1. i 是测试的第 i 把刀；
2. $Er_i = \text{真实值 (第 } i \text{ 把刀)} - \text{预测值 (第 } i \text{ 把刀)}$ 。当预测值 $>$ 真实值时，为过晚预测 (late prediction)；当预测值 $<$ 真实值时，为过早预测 (Early prediction)；
3. 每个预测的分值以百分制计算。例如：当 A 为 1 时，得分为 100； A 为 0.51 时，得分为 51；
4. 竞赛评分系统给出选手得分分值为所有测试组得分的平均值。



二、第二届竞赛英雄榜

本届大赛开发出诸多针对钢卷仓储吞吐量预测以及刀具剩余寿命预测的算法模型，为工业大数据领域的相关研究人员和从业者们提供了重要参考。以下为本届大赛优胜的参赛团队：

赛题一：钢卷仓储吞吐量趋势预测

| 奖项 | 团队名称 |
|-----|---|
| 一等奖 | 香港记者（北京大学，团队）（张弛、王润森） |
| 二等奖 | 阮琳雄（树根互联，个人） Mixtures（上海优也信息科技有限公司，团队）（孟杭、涂修建） 青春二十（西安交通大学，团队）（沈智宪、乔百杰、安波涛） |
| 三等奖 | 郭琦（北京国双科技有限公司深圳分公司，个人） 因斯波儿（浪潮集团，团队）（孙宁远、尹青山、王天卿） 秦金绪（浙江工商大学，个人） 浪哩个啷（浪潮集团，团队）（安程治、吴振东、段强） |

赛题二：机加工刀具剩余寿命预测

| 奖项 | 团队名称 |
|-----|---|
| 一等奖 | 411小分队（中科院声学所，团队）（刘思辰、万伊、刘峰） |
| 二等奖 | mzc（华中科技大学，团队）（马贵君、蔡鑫、曾雄） 杨立宁（上海交通大学，个人） |
| 三等奖 | 秋裤 ers（清华大学，团队）（刘重党、牛家禾、姚荣） 沈国锐（华中科技大学，个人） |

三、第二届竞赛优秀解法集 ——刀具剩余寿命预测题目

针对本次大赛刀具剩余寿命预测题目，本书共收录了 4 个团队的优秀解法。这些解法均采用了机理分析与机器学习相结合的方法，充分体现了工业大数据建模的跨学科特点，方法具备较强的借鉴意义。

| # | 方法名称 | 团队名称 |
|---|----------------------------------|---------|
| 1 | 基于经验模态分解的非参数模式匹配刀具寿命预测方法 | 杨立宁 |
| 2 | 基于多传感器融合的刀具寿命预测方法 | 411 小分队 |
| 3 | 基于前馈神经网络的刀具剩余寿命预测 | 沈国锐 |
| 4 | 基于 DTW 退化特征和 CNN+SVR 网络的刀具剩余寿命预测 | MZC |
| 5 | 基于 DWT-LSTM 网络的刀具剩余使用寿命预测 | 秋裤 ers |

（一）基于经验模态分解的非参数模式 匹配刀具寿命预测方法

1. 团队介绍

| 成员姓名 | 团队角色 | 职位 |
|------|------|-------|
| 杨立宁 | 队长 | 硕士研究生 |

杨立宁，男，1994 年 11 月 12 日出生，2017 年本科毕业于上海交通大学机械与动力工程学院工业工程与管理系，现就读于上海交通大学机械与动力工程学院工业工程与管理系，研究生二年级。研究方向为高维时空数据的统计与建模，导师，李艳婷副教授。

2. 背景简介与文献调研

2.1 机床刀具状态监测技术发展趋势

21 世纪的前 10 年，伴随着国家经济的高速发展，机床工具行业持续 10 余年快速增长。2012 年以来，在经济新常态大背景下，行业进入转型升级阶段。其主要特征是需求总量下降，需求档次提高，增长速度有所降低。随着中国制造 2025 的提出，越来越多的资金投入到我

国机械设备的自主研发中。高端数控机床作为检验一个国家综合制造水平的指标，越来越受到重视。目前，我国的机床需求量正逐年上升，但是我国的高端机床研制尚不成熟。大量的高端机床需要进口，如图 1-3-1 所示，国外的机床企业占据了国内的大部分高端机床的市场份额。

2016年中国机床市场各企业市场份额

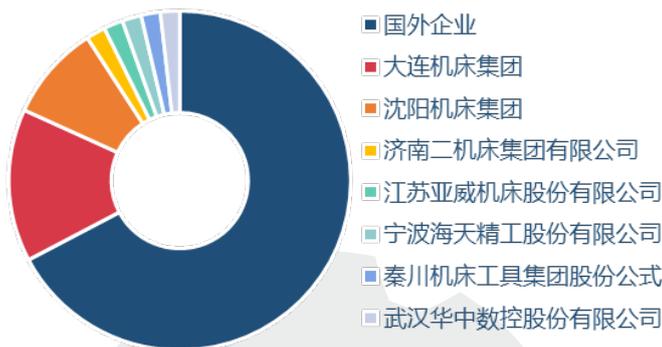


图 1-3-1 中国机床市场份额 (来源: ResearchInChina)

刀具是自动加工系统中最容易磨损和部件失效的。刀具状态监测可以有效保证自动加工过程顺利进行，同时可以有效提高生产效率、降低成本、保证产品质量。研究表明，由数控机床故障引起的停机时间为总停机时间为 20%–30%^[1]。刀具在加工过程中会因为摩擦产生磨损，引起切削力增大，甚至出现振动现象，导致加工工件表面精度降低，粗糙度增加，使机床的切削设备无法正常工作。如图 1-3-2 所示，根据德国著名学者 W. Koenig H.K.Tonshoff 教授的研究，有效的刀具状态监测可使数控系统配置设备减少 10%–60% 的停机时间，提高生产效率 50% 以上^[2]。

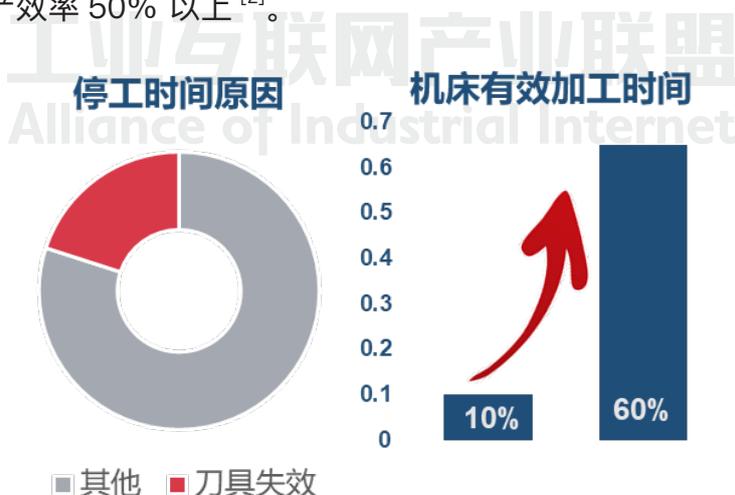


图 1-3-2 机床停机时间占比

在金属切削刀具磨损和破损的过程中是不可避免的现象，它给自动处理带来了许多不利的影 响，刀具的工作异常会对在很大程度上降低加工质量以及生产效率，严重的情况下会对机构的运行以及人身生命安全产生极大危害，造成难以估量的损失，在美国肯纳公司的研究表明，刀具监控系统可以节省超过 30% 的加工成本。刀具状态监测的重要性不言而喻，就如美国学者 B.M.Kramer 在研究第三十五年度会议上说的一样，没有技术比提高计算机集成制造系统的生产率 的刀具磨损状态的精确估计更重要。刀具状态监测技术的应用，对提高企业的经济效益也会有很大的帮助，主要有如下一些意义：

- (1) 减少废品率以及加工成本，提升加工质量；
- (2) 降低设备停机时间，提高设备利用率以及生产效率，延长刀具寿命；
- (3) 防止机械事故，保证了加工系统的最大安全；
- (4) 工厂自动化，减少人为干预对机床^[3]。

机械状态监测与故障诊断就像医学诊断一样，人们获得医疗诊断的启示，并结合系统工程、信息论、控制理论、电子技术、计算机技术、信息处理技术、人工智能和现代科学技术的发展成为一个综合性的独立学科^[4]。近年来，专家学者们对自动化加工设备的状态监测与预测技术领域进行了非常多的研究工作，作为先进自动化加工技术的关键技术，人们也清楚地认识到了其重要的实际意义，该领域也逐步形成和完善，而且在发展过程中因实际情况的变化不断解决着新的问题以及实现更高的要求。

2.2 设备故障预警建模方法

健康管理 (health management) 策略大致经历了三个阶段的演变，如图 1-3-3 所示：

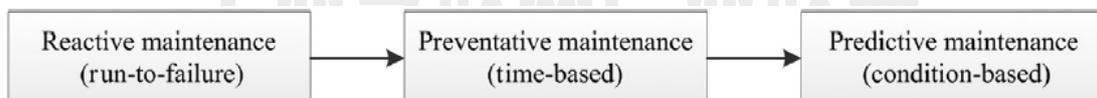


图 1-3-3 维护策略的演变

第一个阶段为反应性维护 (Reactive maintenance)，即工作到失效为止 (run to failure)。这是最传统的维护策略，当检测到加工器械失效，即采取停机维修或更换。原则上来说，这种维护策略能保证加工器械的使用时间最大化。但是，由于其本质是一种被动性维护策略，加工器械在失效过程有可能产生对整个加工机械的损坏，或是使得产品质量产生较大影响。如果加工机械是冗余的并且失效产生的影响是不大的，该种策略可以实施。但是对于刀具加工过程，一旦刀具发生损毁，其损毁之前的一段时间很可能已经处于失效状态，如果采取反应性维护策略，则会导致失效之前部分加工产品的质量产生较大波动甚至产生废品。

第二个阶段为预防性维护 (Preventative maintenance) , 即为了尽快检测出工件是否失效, 可以提前设定一个检测间隔, 达到检测间隔时间即进行重复性检查。显然, 这种策略比反应性维护要保守。一旦在某个检测过程中发现了早期失效特征, 则进行停机维修或更换失效零部件。所以在此种策略下, 检测的时间间隔设定变得尤为重要。过大的时间间隔可能导致失效时刻被错过, 造成宕机的后果; 而过小的时间间隔会导致频繁的检测及更换, 产生大量的时间和人力财力成本。而且, 对于某些高速运转设备, 检测需要停机, 频繁的检测也会使得停机时间大大增加, 最终导致企业的生产率下降。

第三个阶段为预测性维护 (Predictive maintenance) , 亦被称为基于条件的维护 (conditioned based maintenance, CBM) , 即基于监测信息采取维护策略。通过监测加工过程中的各种数据和参数变化, 利用已经构建好的退化模型, 对当前机器所处健康状态进行预测, 当预测结果显示失效快要发生时, 停机进行维护。相较于前两种维护策略, 预测性维护具有明显的优势。一方面其能通过历史规律数据预测宕机的发生, 在其真正发生之前予以维护避免失效的发生, 另一方面其不需要频繁的检测而是利用预测的剩余寿命时间 (Residual useful life, RUL) 给出最优的维护时刻。

基于预测性维护, 预诊和健康管理 (prognostics and health management, PHM) 被提出, 其主要分为 5 个步骤, 分别为: 数据获取, 信号处理, 诊断, 预测和维护决策, 如图 1-3-4 所示。

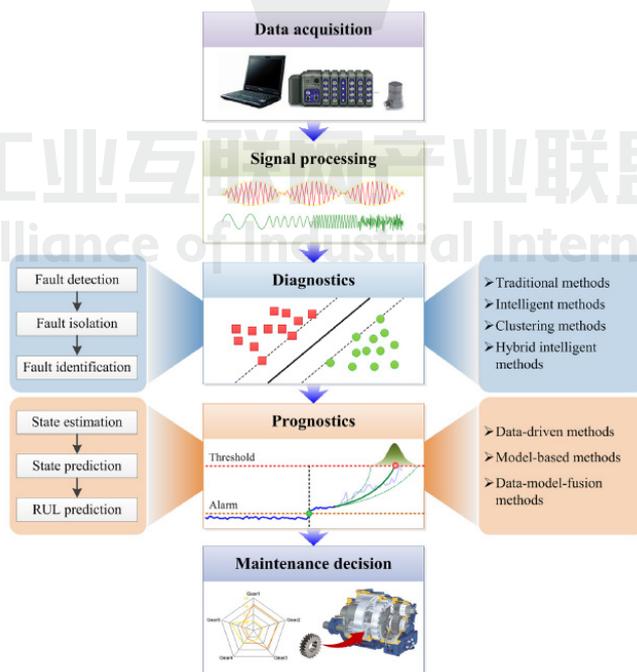


图 1-3-4 PHM 的流程范式^[13]

信号处理过程的目的是从原始信号中获取能够反映加工机械当前健康状态的特征。目前，信号处理的方式可以总结为三种：时域分析、频域分析和时频域分析。Lei 总结了信号处理的方法框架^[5]，如下图：

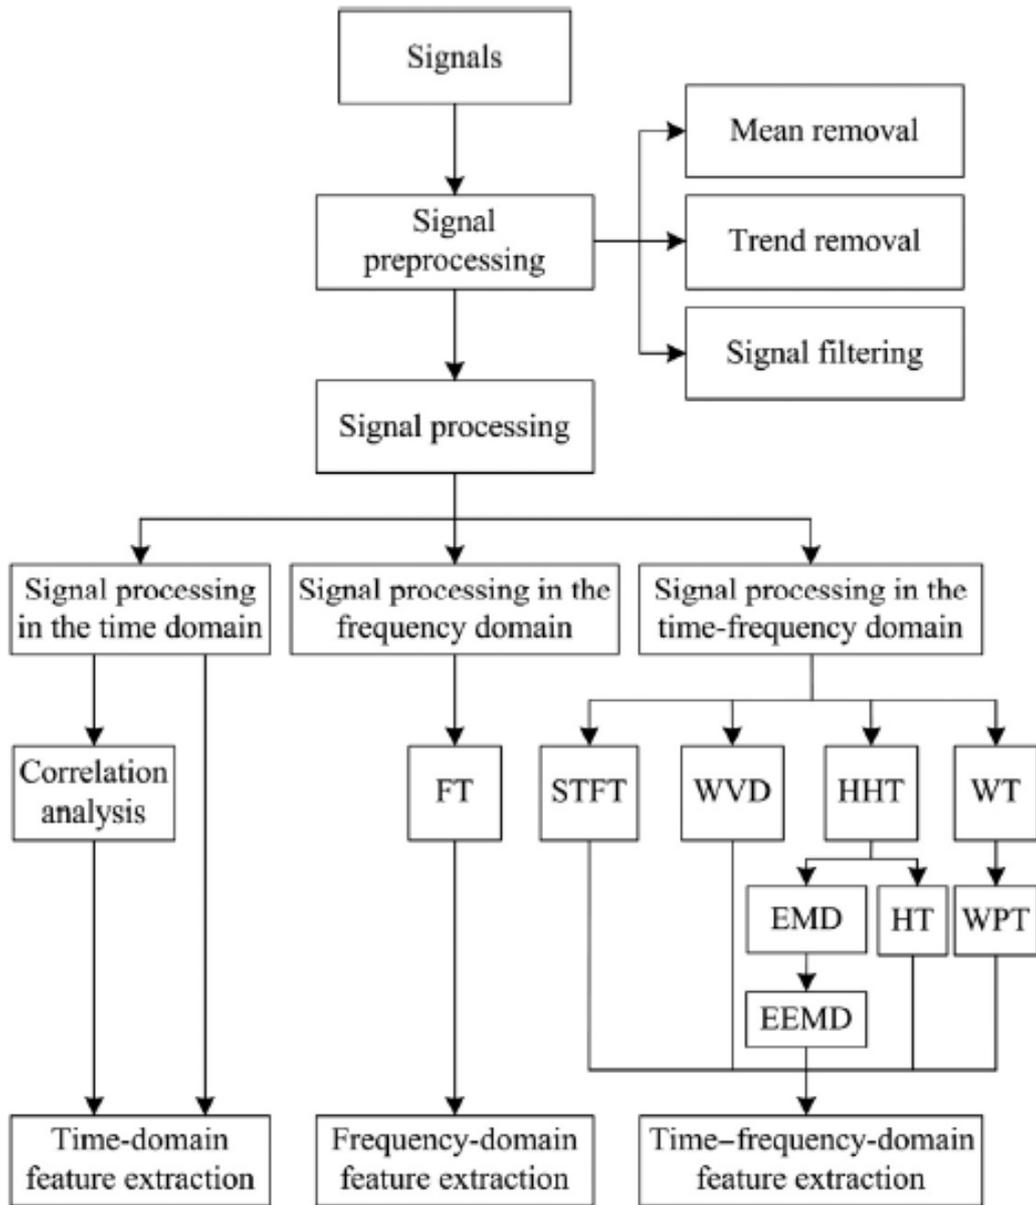


图 1-3-5 信号处理与特征提取

（来源：INTELLIGENT FAULT DIAGNOSIS AND REMAINING USEFUL LIFE PREDICTION OF ROTATING MACHINERY，西安交通大学出版社）

传统的时域分析方法是直接基于采样数据进行分析。由于实际获取的信号大多通过传感器以预设的采样频率进行采样，所以获得的信号可以看作一个离散时间序列。时间序列的均

值 (mean) , 峰值 (peak) , 均方误差 (root mean square, RMS) , 峰度 (kurtosis) 和偏度 (skewness) 被证明可以一定程度反映加工器械的健康状态。这些统计量被称为信号的时域特征。除此之外, 时间序列分析中的常见模型也被引入到信号分析中, 比如自回归模型 (autoregressive model, AR) , 移动平均自回归模型 (autoregressive moving average model, ARMA) 等。更多的时间序列模型请参考^[6]。

频域分析方法是信号处理领域常用的方法, 最著名的则为傅里叶变换, 该方法奠定了频域分析在信号处理中的地位。频域处理的基本思想为将信号转换到频域进行分析, 基于原始信号的频率进行处理。相较于传统的时域分析方法, 频域分析方法最大的优势在于能将信号基于频率进行分解, 获取一系列频率分量, 进而对不同的频率带进行分析, 更具有物理可解释性并提高了分析精度。其中, 较为常用的频域分析方法包括快速傅里叶变换 (fast Fourier transform, FFT)^[7] 以及希尔伯特变换 (Hilbert transform, HT)^[8] 等。频域分析方法的一个限制在于其只能处理平稳的信号, 当信号不平稳时, 其处理性能大大下降, 无法使用。

针对于频域分析方法的弊端, 以及实际场景中获取的信号大多不平稳的现实, 时频分析方法被引入到信号处理中。时频分析方法能够同时对信号的时域和频域进行分析, 能够更好的反映机器的失效模式。常用的时频分析技术包括短时傅里叶变换 (short-time Fourier transform, STFT)^[9], 小波分解 (wavelet transform)^[10] 及其变体, Wigner-Ville 分布^[11] 以及希尔伯特-黄变换 (Hilbert-Huang transform, HHT)^[12] 等。更多信号处理相关研究请参考胡广书所著现代信号处理教程 (第二版)。

信号处理提取健康特征之后, 需要基于特性对机器的健康状态进行诊断和建模。诊断是一个识别特征空间和失效空间关系的过程。好的诊断能够基于特定的特征识别出该特征下的失效模式。由于大数据时代的到来, 一些机器学习技术被引入故障诊断过程中, 使得特征的诊断变得更加智能化和非专家化。这里常用的机器学习算法包括: 聚类算法, 支持向量机 (support vector machine, SVM) 等分类算法以及深度学习和混合方法等。

预测阶段即利用现有的数据对当前机器状态进行估计。其和诊断过程不同。诊断过程主要用于识别各种特征和机器健康状态之间的关系, 只有故障发生后才可以进行, 诊断过程无法阻止宕机等情况的发生。而预测是利用预测的方法对机器未来的性能进行预测, 从而获得机器失去其运行能力之前的可用时间, 即 RUL。常用的方法包括三种, 数据驱动 (data-driven method) 的方法, 模型驱动 (model-driven method) 的方法以及融合方法 (hybrid method) 。

关于三种方法的研究现状及综述，请参考 D.A. Tobon-Mejia, etl(2012)^[13] 以及 Yaguo Lei, etl(2018)^[14]。

维护策略制定阶段即根据预测结果，制定合理的维护策略以保证损失的最小化。更多关于维护策略的研究这里不再展开。

3. 数据解析

本次竞赛提供的数据为铣刀刀具的真实加工数据，其特点主要有以下几点：

- (1) 由于是真实加工数据，数据的噪声较大，信噪比较低，同时由于振动数据的采样频率存在波动，导致采样的数据中存在频率干扰等现象；
- (2) 信号的数据量较大，规模上百万，导致一些信号处理的方法需要优化；
- (3) 虽然竞赛提供了全寿命周期的刀具数据，但是并没有标定健康状态；
- (4) 对于刀具的信号处理方法尚不成熟，其故障模式也不清楚。针对刀具数据特点，处理难点如下：
 - ① 由于信号的信噪比较低，需要效果较好的滤波器设计；
 - ② 由于信号的数据量较大，需要对后续处理算法进行优化；
 - ③ 由于健康状态没有标定，需要自定义数据标签；
 - ④ 由于刀具的信号特征不清楚，导致信号的特征提取是一个难点。



图 1-3-6 刀具与滚珠轴承故障对比

4.1 技术路线概述

针对以上总结的刀具数据的特点和难点，本文提出了基于经验模态分解的非参数模式匹配寿命预测方法。该方法主要分为训练和测试两部分。在训练过程中，对刀具全寿命周期训练数据集进行经验模态分解，然后对分解得到的不同频率段信号分别计算其时域、频域特征，利用给定的判断准则，包括单调性、可分性等对每一个特征进行评估，选择最优特征，如图 1-3-7 所示。经过计算发现：分解后得到的低频信号与刀具磨损过程具有很高的相关性。

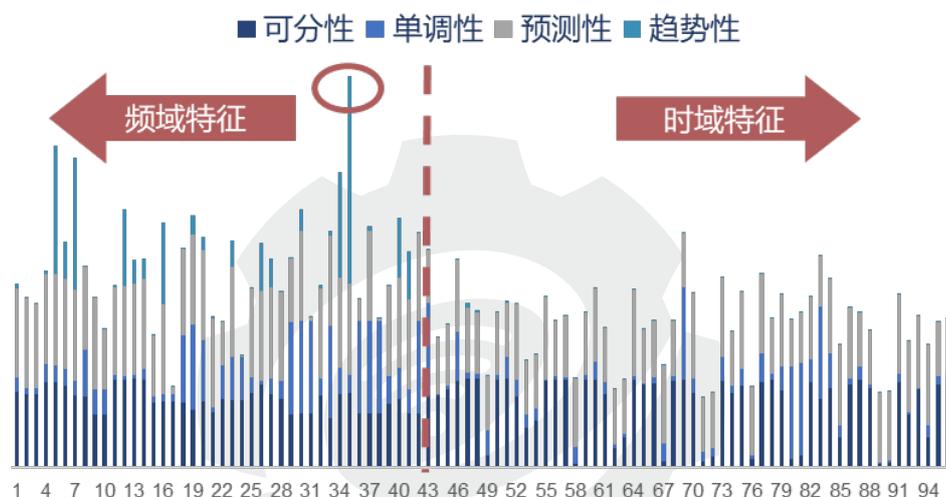


图 1-3-7 特征选择

基于此发现，对分解后的低频信号进行时域和频域的特征提取以及特征降维来保留表征刀具磨损过程的主要特征，再构造出主要特征与刀具剩余寿命的关联函数。在测试过程中，利用相同的经验模态分解方法以及特征提取和降维方法来构造测试数据集的主要特征。接着，本文提出了一种新的相关性函数对测试集刀具主要特征与训练集刀具主要特征进行匹配来预测测试集刀具的剩余寿命值。结果表明，基于经验模态分解的非参数模式匹配寿命预测方法可以准确地预测测试刀具的剩余寿命。并且，与其他基于机器学习的预测方法相比，提出的方法仅需较少的训练时间而达到较高的预测精度，有利于进一步实现在线自适应训练集更新过程。针对本次比赛数据的具体加工场景，即铣刀的铣削加工过程，其信号不能假设平稳，与轴承或齿轮的磨损具有较大差别，所以考虑一种能够寻找与寿命变化变化相对应模式的模式匹配方法对剩余寿命进行预测。本文的技术路线图如图 1-3-8：

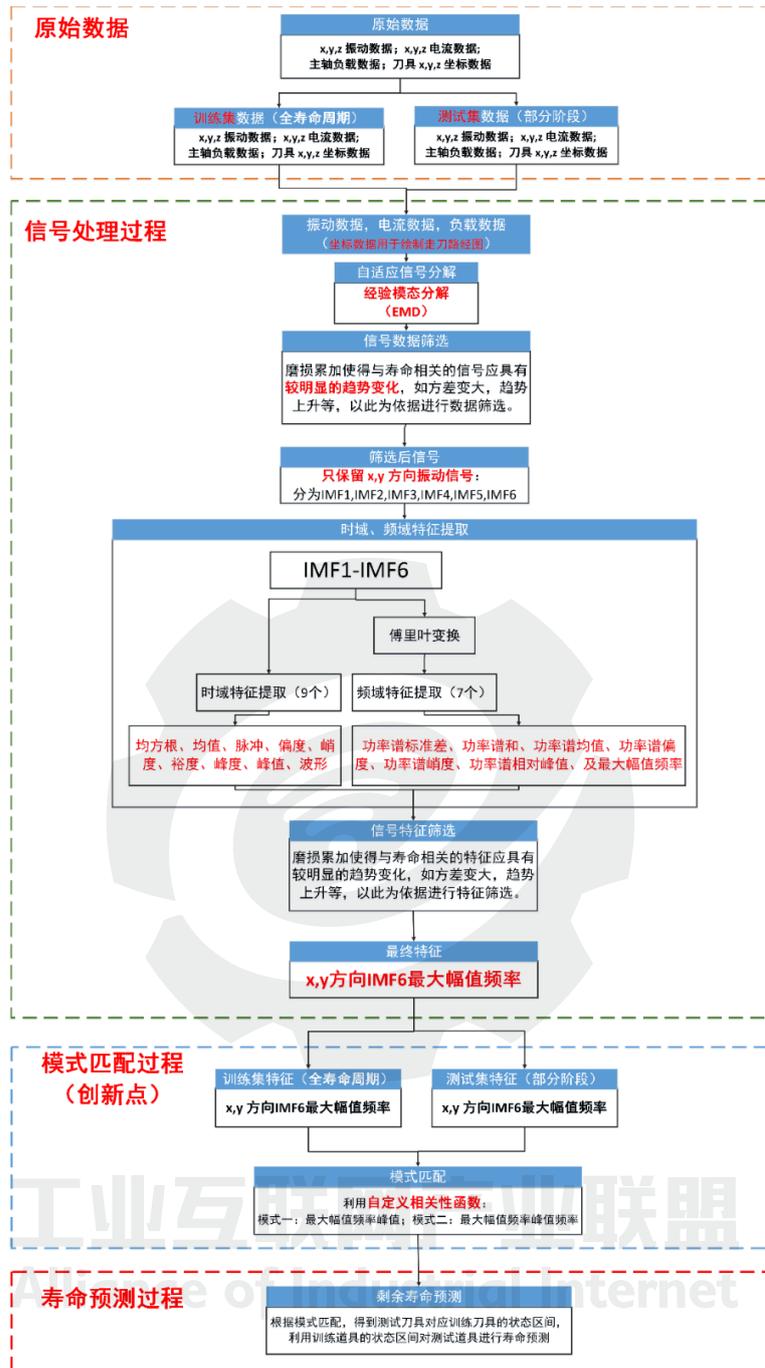


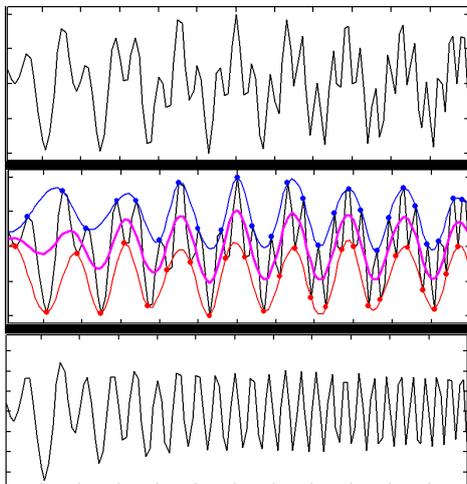
图 1-3-8 技术路线图

4.2 特征提取方法

- 经验模态分解 (EMD)

概念: EMD, (Empirical Mode Decomposition), 经验模态分解, 美国工程院院士黄锷博士于 1998 年提出的一种信号分析方法。EMD 是一种自适应的数据处理或挖掘方法, 非常适

合非线性，非平稳时间序列的处理，本质上是对数据序列或信号的平稳化处理。如图 1-3-9 所示。



图图 1-3-9 EMD 分解示意图

原理：任何信号都是由一些不同的基本模式分量组成的；每个模式可以是线性的，也可以是非线性的，该方法的关键是它能使复杂信号分解为有限个本征模函数 (Intrinsic Mode Function, 简称 IMF)，所分解出来的各 IMF 分量包含了原信号的不同时间尺度的局部特征信号。EMD 分解方法是基于以下假设条件：

- (1) 数据至少有两个极值，一个最大值和一个最小值；
- (2) 数据的局部时域特性是由极值点间的时间尺度唯一确定；
- (3) 如果数据没有极值点但有拐点，则可以通过对数据微分一次或多次求得极值，然后再通过积分来获得分解结果。

基本流程：

第一步：确定时间序列 $x(t)$ 的所有局部极值点，然后将所有极大值点和所有极小值点分别用一条曲线连接起来，得到的上、下包络线。记上、下包络线的均值为 $m(t)$ 。

第二步：用原始时间序列 $x(t)$ 减去包络线的均值 $m(t)$ ，得到 $h_1(t) = x(t) - m(t)$ ，检测 $h_1(t)$ 是否满足基本模式分量的两个条件。如果不满足，使作为待处理数据，重复第一步，直至 $h_1(t)$ 是一个基本模式分量，记 $f_1(t) = h_1(t)$ 。

第三步：用原始时间序列 $x(t)$ 分解出第一个基本模式分量 $f_1(t)$ 之后，用 $x(t)$ 减去 $f_1(t)$ ，得到剩余值序列 $x_1(t)$ 。把 $x_1(t)$ 当作一个新的“原始序列”，重复上述步骤，依次提取出第 2、第 3，直至第 n 个基本模式分量。最后剩下原始信号的余项 $r_n(t)$ 。

由此，时间序列 $x(t)$ 可表示成 n 个基本模式分量 $f_i(t)$ 和一个余项 $r_n(t)$ 的和，即：

$$x(t) = \sum_{i=1}^n f_i(t) + r_n(t)$$

其中，每一项 $f_i(t)$ 即为本征模态函数 (IMF)，每一层分解得到的 IMF 包含原信号局部分量，同时频率随着分解层数呈负相关。即第一层的 IMF 信号频率最高，逐层降低。

· 特征提取

首先通过经验模态分解 (EMD) 对信号进行分解，共得到 7 层 IMF，每一层相当于原信号不同频段的局部分量。第一层、第二层 IMF 为高频段信号，第三层，第四层为中频段，第五层、第六层为低频段信号。分别对高中低三个频段的 IMF 进行时域分析，与此同时，对获取的时域信号进行傅里叶变换生成对应的频域信号，然后对频域信号进行分析，最终共提取了 9 种时域和 7 种频域特征，其中，时域特征为：波形、峰度、峰值、均方根、均值、脉冲、偏度、峭度、裕度；频域特征为：功率谱标准差、功率谱和、功率谱均值、功率谱偏度、功率谱峭度、功率谱相对峰值、最大幅值频率，具体特征计算公式见表 2-1-1 和表 2-1-2：

| 时域特征 | 计算公式 |
|------|--|
| 峰值 | $X_p = \frac{1}{n} \sum_{j=1}^n x_{pj}$ |
| 均值 | $X_m = \frac{1}{n} \sum_{i=1}^n x_i $ |
| 均方根值 | $X_{rms} = \sqrt{\frac{1}{n} \sum_{i=1}^n x_i^2}$ |
| 峰度 | $C_f = \frac{X_p}{X_{rms}}$ |
| 峭度 | $K = \frac{1}{n} \frac{(x_i - \mu)^4}{\sigma^4}$ |
| 波形因子 | $W_s = \frac{X_{rms}}{X_m}$ |
| 脉冲因子 | $I = \frac{X_p}{X_m}$ |
| 裕度 | $L = \frac{X_p}{\left \frac{1}{n} \sum_{i=1}^n \sqrt{ x_i } \right ^2}$ |
| 偏度 | $S_k = \frac{1}{n} \frac{(x_i - \mu)^3}{\sigma^3}$ |

表 2-1-1: 时域特征及计算公式:

| 频域特征 | 计算公式 |
|---------|---|
| 最大幅值频率 | $S_{MAX} = \max(S(f)_i)$ |
| 功率谱和 | $S_{SBP} = \sum_{i=1}^n (S(f)_i)$ |
| 功率谱均值 | $S_{\mu} = \frac{1}{n} \sum_{i=1}^n (S(f)_i)$ |
| 功率谱方差 | $S_V = \sum_{i=1}^n \frac{(S(f)_i - S_{\mu})^2}{n - 1}$ |
| 功率谱偏度 | $S_S = \frac{1}{n} \sum_{i=1}^n \frac{(S(f)_i - S_{\mu})^3}{S_V^{3/2}}$ |
| 功率谱峭度 | $S_K = \frac{1}{n} \sum_{i=1}^n \frac{(S(f)_i - S_{\mu})^4}{S_V^2}$ |
| 功率谱相对峰值 | $S_{RSPPB} = \frac{S_{MAX}}{S_{\mu}}$ |

表 2-1-2: 频率特征及计算公式

· 特征筛选:

为了选择出有效的指标表征预测的适用性, 设定一组指标用来评估提取特征, 包括: 可分性和单调性^[3, 4]。

(1) 可分度 (Separability)

可分性首先故障诊断领域, 因为故障诊断是一个分类问题。通常是通过区分两个类别之间差异 (例如健康组件与退化的组件) 的能力对特征进行评估, Fisher 准则是最常用的方法之一。

$$J_k(p, q) = \frac{|\mu_{p,k} - \mu_{q,k}|^2}{\sigma_{p,k}^2 + \sigma_{q,k}^2}$$

其中, p 和 q 是分类的标签, $\mu_{p,k}$ 及 $\mu_{q,k}$ 分别为第 k 个特征的均值, $\sigma_{p,k}$ 和 $\sigma_{q,k}$ 为第 k 个特征的方差。针对寿命预测, 对可分性评估关注的不是将数据分为两类, 而是时间区间之间数据的分离是否连续。可分度的均值决定了一个特征衡量故障传播的能力, 如以下公式所示:

$$S = \frac{\sum_{t=1}^T S_t}{T}$$

$$S_t = \frac{\alpha}{L} - \frac{x}{N_t}$$

$$x = 0 \left(\text{if } \frac{\alpha}{L} \neq 1 \right), x = a \left(\text{if } \frac{\alpha}{L} = 1 \right)$$

其中， T 代表整个时间序列的段数， α 是 25%~75%连续时间段中的分布重叠的样本数。 N_t 为 25%~75%时间段内总的样本数目。

(2) 单调度 (Monotonicity)

与寿命相关的信号具有较为明显的单调性，以此为准则进行特征的筛选。单调性的定义公式如下：

$$\text{Monotonicity} = \left| \frac{\#of \frac{d}{dx} > 0}{N - 1} - \frac{\#of \frac{d}{dx} < 0}{N - 1} \right|$$

通过上述准则进行特征的筛选。通过三个训练集的筛选，发现训练集 1 的最大幅值频率具有较为明显的单调性，如图 1-3-10，原因可能是刀具在铣削的过程中，随着磨损量的增大，最大幅值会有一个逐渐增大的过程。所以最大幅值频率是一个有用的特征。虽然在训练集 2 和训练集 3 中，该特征不明显，分析认为是由于加工过程的不同。但是最大幅值频率应该是一个与寿命高度相关的特征。下图 1-3-11 利用比赛提供的 PLC 的坐标数据绘制了三个训练集的走刀路径 (xy 方向投影)。

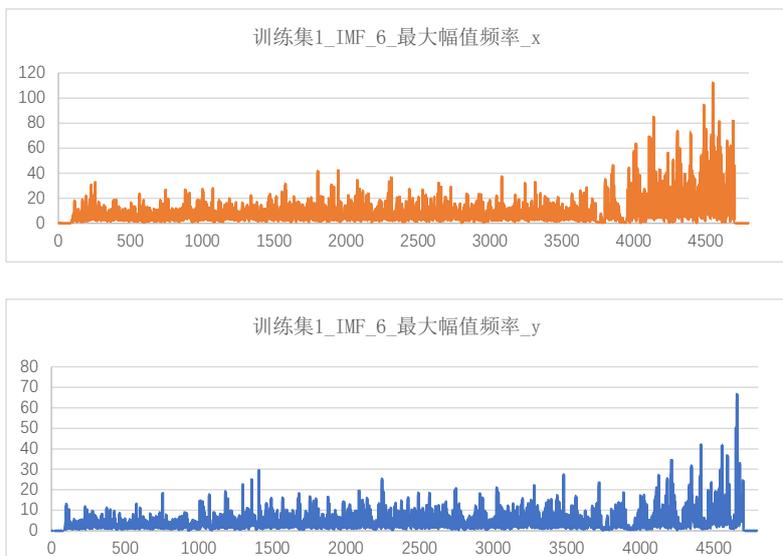


图 1-3-10 训练集 1, x, y 振动数据的 IMF6 最大幅值频率图

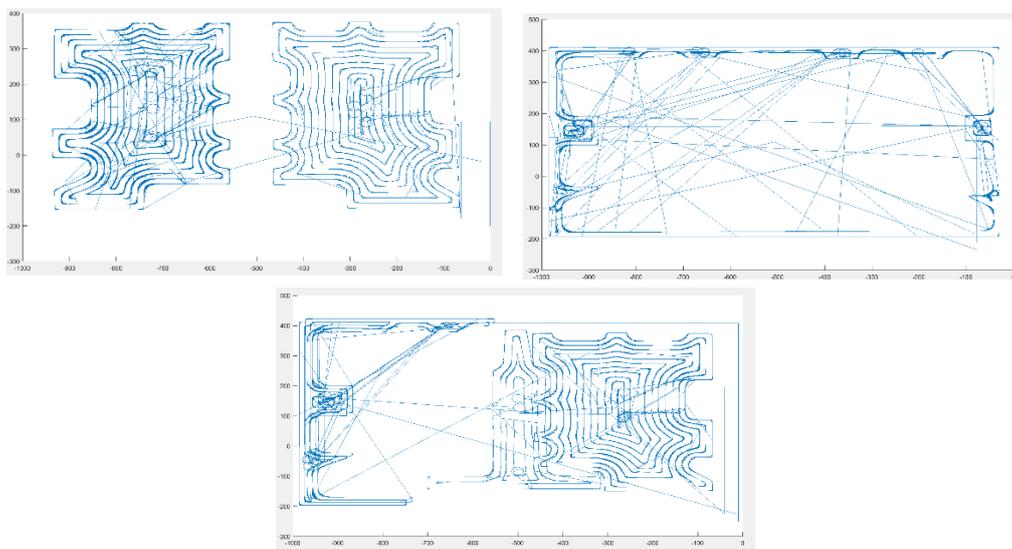


图 1-3-11 三个训练集的加工走刀路径

4.3 基于自定义相关函数的非参数模式匹配

传统的机器学习方法需要大量的相关特征以及输出标注，然后进行模型的选择与训练，由于数据量较大，相关特征很多不能明显的反映寿命变换，本文提出了一种基于自定义相关函数的非参数模式匹配方法，通过该方法，可以将测试刀具的特征信号与训练集刀具的特征信号进行匹配，利用定义的相关函数对模式匹配程度进行评估，进而选择最优的模式匹配区间并将训练集的该区间定位测试刀具当前所处区间。

本文最终选择的特征为 IMF6 的最大幅值频率信号，IMF6 为 EMD 分解的低频段，该频段随时间有较为明显的趋势变化，所以本文认为随着加工过程的进行，刀具逐渐磨损的信号变化主要反映在低频段。与此同时，本文在进行信号比对的过程中发现，IMF6 最大幅值频率的峰值以及峰值之间的间隔距离能较为明显的区分不同的寿命区间。如图 3 所示，正常平稳加工下，寿命前期的幅值峰值虽然有波动，但是波动很小，峰值也比后期小很多，在寿命中后期，峰值的出现频率增大，间隔变小，被认为是刀具磨损情况加剧，已进入寿命后期的表现。

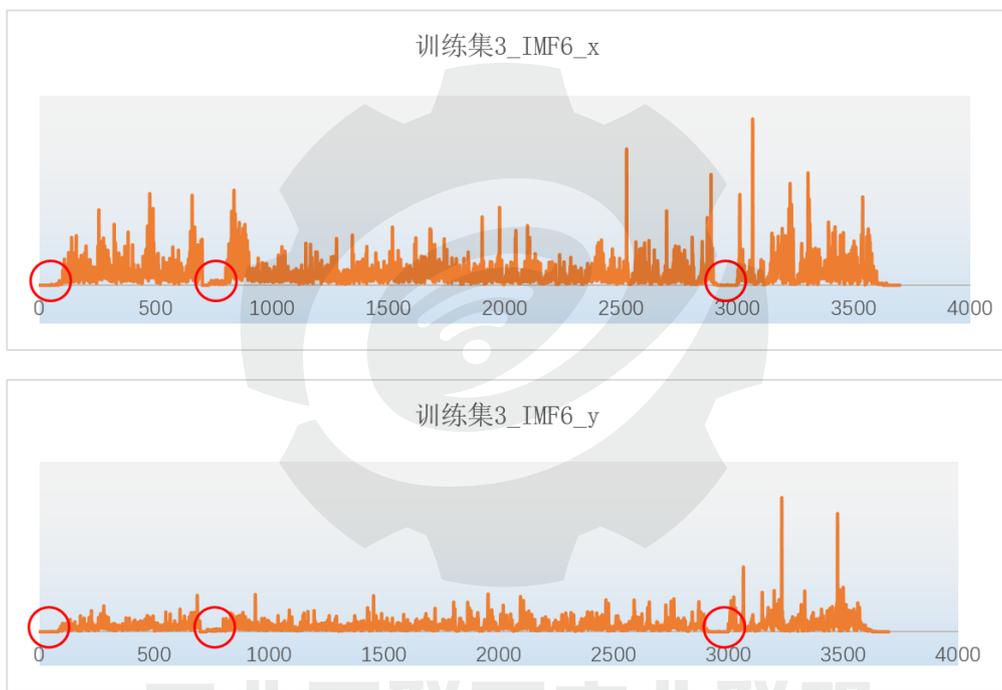
根据上述分析，本文定义的用来评估匹配程度的相关函数分为两部分：第一部分用来评估最大幅值频率信号的峰值，即模式一；第二部分用来评估最大幅值频率信号的峰值频率，即模式二，最终用于评价模式匹配程度的函数为两种模式的加权和：

$$\text{相关性} = \alpha \times \text{模式一} + (1 - \alpha) \times \text{模式二}$$

其中模式一和模式二的定义及详细说明见第五、六节。

考虑数据为实际加工过程真实数据，中间存在频率骤降的突发情况，见 1-3-1，于是在上述定义下，针对实际问题，在模式匹配过程中，给予以下两点改进：

- 对于中途频率骤降的现象，只考虑停机前后部分的模式匹配，停机段的信息不再进行考虑；
- 对于测试集数据比较稳定的情况，即波动不大时，对训练数据先进行数据的截断处理，对训练集波动较大的部分不予考虑，减小搜索可行域。



工业互联网产业联盟
Alliance of Industrial Internet
图 1-3-12 特征信号中的频率骤降

综上所述，模式匹配流程如下图：

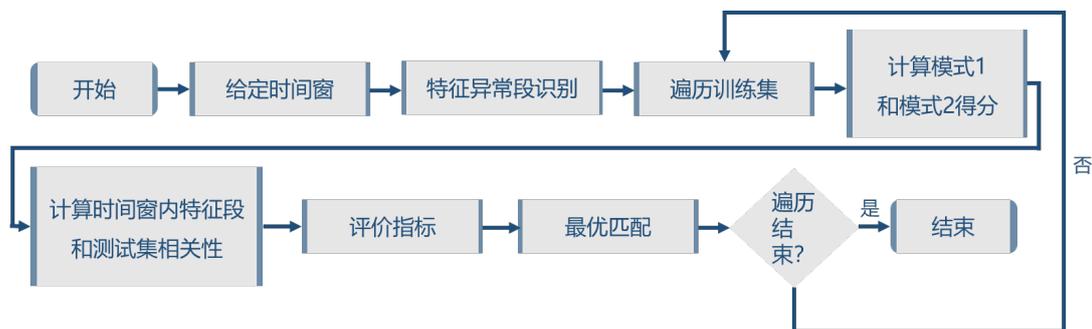


图 1-3-13 模式匹配流程图

5. 验证

5.1 初赛结果

初赛共有 5 个测试集，分别对应 5 把同样工况下的同样铣刀，表 2-1-3 给出了预测剩余寿命值。

表 2-1-3：初赛剩余寿命预测及最终得分（单位：分钟）

| filename | answer |
|----------------|----------------|
| TestingData01 | 103 |
| TestingData02 | 51 |
| TestingData03 | 190 |
| TestingData04 | 77 |
| TestingData05 | 48 |
| Score : | 69.5877 |

其中，评价函数为：

$$A_i = \begin{cases} \exp^{-\ln(0.5) \cdot (\frac{Er_i}{5})} & ,if Er_i \leq 0 \\ \exp^{+\ln(0.5) \cdot (\frac{Er_i}{20})} & ,if Er_i > 0 \end{cases}$$

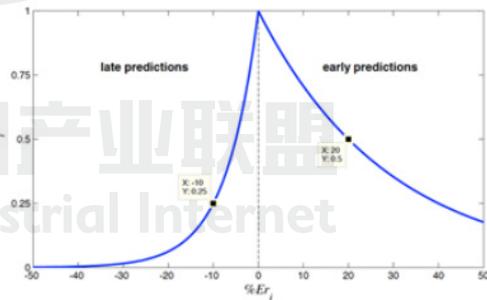


图 1-3-14

从结果得分可知，其预测误差大概为多预测 4 分钟到少预测 10 分钟左右。

5.2 决赛结果

决赛共有 4 个测试集，分别对应 4 把同样工况下的同样铣刀，表 2-1-4 给出了预测剩余寿命值。

表 2-1-4: 决赛剩余寿命预测及最终得分 (单位: 分钟)

| filename | answer |
|----------------|----------------|
| FinalData01 | 45 |
| FinalData02 | 65 |
| FinalData03 | 35 |
| FinalData04 | 10 |
| Score : | 45.6203 |

6. 结果分析与经验总结

通过为期 2 个月的竞赛, 我加深了对信号处理的认识并提高了分析问题, 解决问题的能力。在比赛前中期我试验了很多机器学习的方法, 如支持向量机^[15], 神经网络^[16], 或者较为普遍的统计学习方法, 如贝叶斯方法^[17], 马尔可夫链^[18], 半马尔可夫链^[19]以及卡尔曼滤波^[20]等。问题在于我发现不同的训练集之间的同一统计特征, 比如均方误差, 差距太大, 不能将 3 个训练集的特征进行合并, 只能单独进行训练。但是在训练过程中, 标签的选择又是一个难题, 我尝试了自己将状态分类, 也尝试了直接利用剩余寿命作为标签, 在有限次的测试中效果不理想, 得分在 25 分左右。我认为原因有以下几点:

(1) **标签定义** 支持向量机或者深度神经网络等机器学习算法属于监督学习方法, 本次比赛并没有直接的标签, 需要自行定义。所以标签的定义可能不太合理; 大多文献中标签的选择是提前已知的, 比如刀具的磨损量, 或者是提前分类好的。这也是今后主要研究的一个问题;

(2) **特征缩放方法** 特征提取之后的数据预处理过程, 我训练使用的神经网络或支持向量机模型都对特征采用了标准缩放方法进行特征处理, 采用标准缩放的前提是数据大致服从正态分布, 经过检验, 比赛数据虽然整体服从正态分布, 但是阶段性数据不一定服从, 所以特征缩放方式可能存在不合理之处;



(3) **模型超参数的选取** 支持向量机模型需要选择核函数以及惩罚尺度, 训练次数, 训练批量大小等参数; 而神经网络需要选择隐含层个数, 隐含层神经元个数, 训练次数, 训练批量大小等参数。在有限的测试机会中, 超参数的选择可能有问题, 导致模型陷入局部最优解而没有达到全局最优。在竞赛中期我尝试使用集成模型降低超参数设置的影响, 分别使用的集成决策树模型, 集成支持向量机模型等, 较单独的模型, 提升结果在 15% 左右, 但是训练时间较长, 同样存在之前的三个问题导致结果无法达到预期。

对于目前所采用的基于经验模态分解的非参数模式匹配刀具寿命预测方法, 相较于机器学习方法, 该方法有以下几个优点: 一是该方法属于非参数方法, 所以避免了机器学习大量的参数学习过程, 节省了宝贵的时间; 二是找到了能高度反映寿命变化的信号特征及相关模式, 对于刀具在铣削过程的信号变化情况有了进一步的了解, 为今后研究其物理规律提供了一定的启发; 三是该方法可扩展性较强, 经过测试, 也可以用于轴承、齿轮等加工过程的剩余寿命预测。

但是该方法还有改进之处。目前该算法只能给出一个测试刀具剩余寿命的点估计, 而更合理的应该是一个考虑不确定因素的区间估计。在分析清楚不同阶段对应刀具寿命的分布后, 可以在原有算法基础上增加不确定性的因素, 进而得到刀具寿命预测的估计区间, 对于刀具的维护与更换更加具有指导意义。

最后, 再次感谢竞赛组委会对我竞赛期间问题的耐心讲解以及给予我决赛答辩的宝贵机会; 感谢我的老师们对我的悉心指导, 给予了我很多理论方面的帮助; 感谢我的家人和朋友的无私帮助与全力支持。



参考文献

[1] 刘宇·数控机床刀具状态监测与诊断系统的研究[D]. 南京理工大学, 2016.

[2] 彭琳·可转位涂层刀片耐用度的分析与研究[D]. 西安石油大学, 2013.

[3] 赵宇·机械制造业中自动化技术的应用[J]. 电子技术与软件工程, 2017(18):138.

[4] 赵辉·基于 EDA 技术的数字系统设计[J]. 电子设计工程, 2012, 20(02):34-37+41.

[5] Lei Y·Intelligent fault diagnosis and remaining useful life prediction of

rotating machinery[M]. Butterworth–Heinemann, 2016.

[6] Brockwell P J, Davis R A, Calder M V. Introduction to time series and forecasting[M]. New York: springer, 2002.

[7] Rai V K, Mohanty A R. Bearing fault diagnosis using FFT of intrinsic mode functions in Hilbert–Huang transform[J]. Mechanical Systems and Signal Processing, 2007, 21(6): 2607–2615.

[8] Yu D, Cheng J, Yang Y. Application of EMD method and Hilbert spectrum to the fault diagnosis of roller bearings[J]. Mechanical systems and signal processing, 2005, 19(2): 259–270.

[9] Lei Y, Lin J, He Z, et al. Application of an improved kurtogram method for fault diagnosis of rolling element bearings[J]. Mechanical Systems and Signal Processing, 2011, 25(5): 1738–1749.

[10] Lin J, Qu L. Feature extraction based on Morlet wavelet and its application for mechanical fault diagnosis[J]. Journal of sound and vibration, 2000, 234(1): 135–148.

[11] Tang B, Liu W, Song T. Wind turbine fault diagnosis based on Morlet wavelet transformation and Wigner–Ville distribution[J]. Renewable Energy, 2010, 35(12): 2862–2866.

[12] Lei Y, Zuo M J. Fault diagnosis of rotating machinery using an improved HHT based on EEMD and sensitive IMFs[J]. Measurement Science and Technology, 2009, 20(12): 125701.

[13] Tobon–Mejia D A, Medjaher K, Zerhouni N. CNC machine tool's wear diagnostic and prognostic by using dynamic Bayesian networks[J]. Mechanical Systems and Signal Processing, 2012, 28: 167–182.

[14] Lei Y, Li N, Guo L, et al. Machinery health prognostics: A systematic review from data acquisition to RUL prediction[J]. Mechanical Systems and Signal



Processing, 2018, 104: 799–834.

[15] Van Tung Tran, Hong Thom Pham, Bo–Suk Yang, Tan Tien Nguyen, Machine performance degradation assessment and remaining useful life prediction using proportional hazard model and support vector machine, Mechanical Systems and Signal Processing, Volume 32, 2012, Pages 320–330.

[16] N. Gebraeel, M. Lawley, R. Liu and V. Parmeshwaran, "Residual life predictions from vibration–based degradation signals: a neural network approach," in IEEE Transactions on Industrial Electronics, vol. 51, no. 3, pp. 694–700, June 2004.

[17] D.A. Tobon–Mejia, K. Medjaher, N. Zerhouni, CNC machine tool's wear diagnostic and prognostic by using dynamic Bayesian networks, Mechanical Systems and Signal Processing, Volume 28, 2012, Pages 167–182.

[18] D. Banjevic, A. K. S. Jardine; Calculation of reliability function and remaining useful life for a Markov failure time process, IMA Journal of Management Mathematics, Volume 17, Issue 2, 1 April 2006, Pages 115–130.

[19] Ying Peng, Ming Dong, A prognosis method using age–dependent hidden semi–Markov model for equipment health prediction, Mechanical Systems and Signal Processing, Volume 25, Issue 1, 2011, Pages 237–252.

[20] R. K. Singleton, E. G. Strangas and S. Aviyente, "Extended Kalman Filtering for Remaining–Useful–Life Estimation of Bearings," in IEEE Transactions on Industrial Electronics, vol. 62, no. 3, pp. 1781–1790, March 2015.

（二）基于多传感器融合的刀具寿命预测方法

1. 团队介绍

团队名称：411 小分队

| 成员姓名 | 团队角色 | 职位 |
|------|------|-----------------------|
| 刘思辰 | 队长 | 中科院声学所噪声与振动重点实验室博士研究生 |
| 刘锋 | 队员 | 中科院声学所噪声与振动重点实验室博士后 |
| 万伊 | 队员 | 中科院声学所噪声与振动重点实验室博士研究生 |

411 小分队由中科院声学所噪声与振动重点实验室的两名博士与一名博士后组成。声学所是从事声学 and 信息技术处理研究的综合性研究所，其中噪声与振动重点实验立足声学所现有的噪声与振动相关研究积累，重点开展噪声源特性与传播途径、声学材料结构特性、噪声与振动控制技术、噪声检测与分析技术等方面的研究工作。

刘思辰：博士研究生，主要研究方向是声信号处理，本次主要负责方案设计与算法实践；

刘 锋：博士后，主要研究方向是振动声学信号处理，工程经验丰富，本次主要负责方案设计与特征工程；

万 伊：博士研究生，主要研究方向为信号与信息处理，本次主要负责数据处理与特征提取。

2. 背景简介与文献调研

在切削铣削等加工场景，刀具的状态及其磨损程度是影响工件质量的关键因子，也是加工过程中主要关注的对象。刀具的健康维护是保证产品加工精度的重要因素之一，刀具失效可能造成工件表面粗糙度和尺寸精度的下降，或造成更严重的工件报废或机床受损。刀具的有效管理可以提高生产效益、降低运维成本。但采取过度的保护策略又会造成刀具剩余寿命和不必要的换刀停机时间的浪费。精准预测刀具的剩余寿命，将有效地优化工作流程安排且最大限度的利用刀具。

刀具使用寿命是指一把新刀从投入切削到报废为止的总的实际切削时间，其预测方法，可以大致分为基于物理模型的方法、由数据驱动的方法两种^[1]。传统刀具寿命预测方法一般是试图建立刀具剩余寿命与切削速度、切削深度以及进给量等加工参数之间的显式数学模型^[2]。但模型参数的识别通常需要大量的实验或经验数据，通常很难为复杂的现实系统建立精确的物理退化模型^[3]。刀具的各种加工参量不便完全获取，其非线性的退化过程也给建模带来了一定困难。数据驱动的方法避免了准确建立物理模型的困难，可以构建更简单的基于数据的模型来估计复杂系统的使用寿命，目前已被广泛的应用^[4]。数据驱动的方法可主要分为机器学习与统计学习两大类，机器学习方法包括支持向量回归机^[5]、人工神经网络^{[6][7][8]}、隐马尔可夫模型^{[9][10]}等；统计学习方法主要包括维纳滤波^[11]、卡尔曼滤波^[12]等。除机器学习方法与统计学习方法外，人工智能方法属于数据驱动方法的另一个分支，深度神经网络与循环神经网络在轴承的寿命预测与故障诊断中得到了应用^{[13][14][15][16]}。

3. 数据解析

在实际的工业现场中，物理传感器采集到的各种信号中包含大量干扰，刀具的磨损退化导致的信号变化很难通过经典信号处理方法识别。工业大数据的 3B 特性（Bad Quality 质量差、Broken 碎片化、Below the Surface 隐性）为深入分析数据的内在机理带来了相当的挑战^[17]。竞赛提供了 3 把同规格刀具在采用同种加工工艺进行加工时，刀具从全新到报废所采集到的全生命周期数据。其中，A 刀与 B 刀在工作 240 分钟后，C 刀在工作 185 分钟后报废。以 A 刀为例，各刀的具体数据内容如下表 1 所示：

表 2-1 刀具 A 的具体数据内容

| 数据说明 | 文件类型 | 文件数 | 包含数据 | 物理意义 |
|---|---------------------------|-----|--------------|---------|
| 刀具加工过程中，每 5 分钟任取 1 分钟数据形成一份文件，置于 Sensor 中；并将对应时刻的控制器数据放入 PLC 中。 | Sensor 传感器数据 采样频率 25600Hz | 48 | Vibration_1 | X 方向振动 |
| | | | Vibration_2 | Y 方向振动 |
| | | | Vibration_3 | Z 方向振动 |
| | | | Current | 电流 |
| | PLC 控制器数据 采样频率 不固定于 33Hz | 1 | Time | 记录时间 |
| | | | spindle_load | 主轴负载 |
| | | | X | X 轴坐标 |
| | | | Y | Y 轴坐标 |
| | | | Z | Z 轴坐标 |
| | | | csv_no | 对应的文件序号 |

数据说明中每 5 分钟任取 1 分钟的数据采集方法如图 1-3-15 所示，文件 1 来自刀具工作的第 1-5min，文件 2 来自第 6-10min，以此类推。也就是说，我们无法得知这些数据的准确工作时间，只有一个大致的时间范围，现有标签并不十分精准，也可以说这是一个含噪的标签。

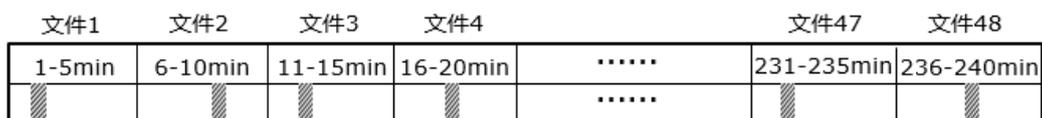


图 1-3-15 “任取 1 分钟”示意图

在标签的选取方面，我们以 A 刀和 C 刀为例。A 刀工作寿命为 240 分钟，C 刀寿命为 185 分钟，简单以剩余的工作分钟数作为标签不如将其转换为一个比值，用剩余的寿命除以该刀的总寿命，提出一个类似于“磨损比”的概念，如下表 2-2 所示，以此作为数据的标签，更能实际的表征刀具的磨损状态。至此，我们的任务就演变为解决一个在含噪的数据标签中进行 0-1 之间的“磨损比”预测的回归问题。

表 2-2 标签的选取

| 文件序号 | A 刀 剩余寿命标签 | A 刀 磨损比标签 | C 刀 剩余寿命标签 | C 刀 磨损比标签 |
|------|---------------|-----------------|---------------|-----------------|
| 1 | 235 | $235/240=0.979$ | 180 | $180/185=0.973$ |
| 2 | 230 | $230/240=0.958$ | 175 | $175/185=0.946$ |
| 3 | 225 | $225/240=0.938$ | 170 | $170/185=0.919$ |
| 4 | 220 | $220/240=0.917$ | 165 | $165/185=0.892$ |

4. 方法

4.1 技术路线概述

技术方案主要分为数据预处理、特征提取与预测算法三部分。考虑到时间标签含噪，将测量时间假定为区段中值以抑制噪声，将寿命预测问题转化为求取 0-1 之间“磨损比”的回归问题。首先结合控制器数据进行数据筛选，去除其中的异常文件与异常值等；然后进行时、频、时频域特征提取与时间序列分析，实际采用的混合特征如下图 1-3-16 所示；为提升数据质量，在特征提取后并不直接输入网络，而是将样本多帧联合进行 MIX UP 数据增强后输

入到 DNN 网络中进行训练；最后基于 Bagging 方法将数据集进行分组，训练出多个模型并分别预测“磨损比”，对多个模型进行线性加权融合平均后即可得出刀具剩余寿命。

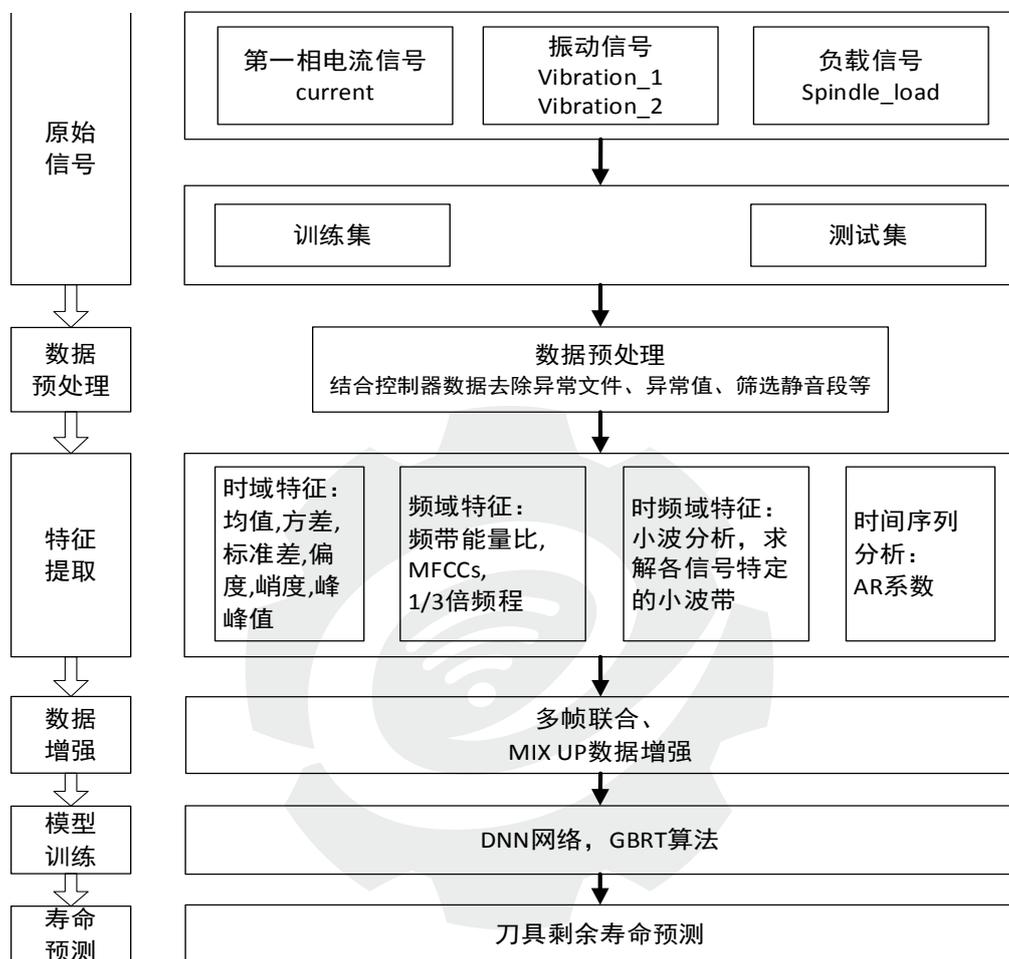


图 1-3-16 技术框架

4.2 数据预处理

在数据进行预处理之前，我们首先将传感器数据与控制器数据进行联合观察，发现现有数据主要存在着如下几种情况有待处理：

(1) 传感器数据含噪，质量较差，且控制器数据采样频率不稳定于 33Hz，导致传感器数据与控制器数据难以在时间上对齐。

(2) 传感器数据中的 y 方向振动异常情况较多，根据加工机理进行推测，可能是传感器导线接头松动，信号时断时续导致的。

(3) 数据集中存在着在某次测量过程中刀具并未进行加工移动的异常文件

针对现有数据特点，鉴于 y 方向的振动异常数据较多，且 y 方向振动应与 x 方向振动有相似性，所以不再考虑 y 轴方向振动，仅对电流 current，与 x 方向振动 v1 与 z 方向振动 v2 数据进行处理。

数据预处理阶段的具体处理流程如下图 1-3-17 所示。首先联合控制器数据中的刀具坐标，绘制刀具测量各文件时的移动轨迹，删除数据集中刀具并未进行加工的异常空文件；然后将某刀的所有文件进行合并，去除数据中的极大值；再利用控制器数据中的主轴负载信号筛选出数据集中的静音段，人工选择删去部分静音段；令帧长为 0.5s，对该刀的所有数据进行分帧；最后，根据现有的若干样本，生成对应的标签文件。

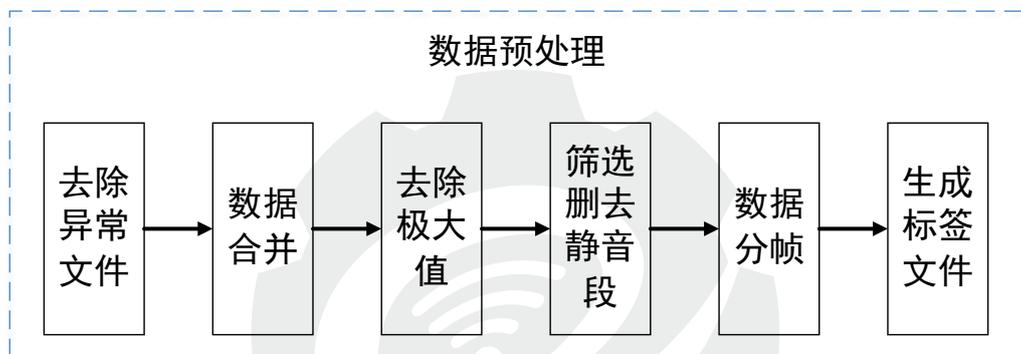


图 1-3-17 数据预处理阶段流程图

由于我们现有的标签并不十分精准，只有一个大致的时间范围如 1-5min, 6-10min 等，这里我们将测量时间选取为该范围的中值，将其设定为 3min, 8min 等以此类推，再统一除以刀具总寿命，以此“磨损比”作为数据的标签，对应样本生成标签文件。

4.3 特征提取

传统刀具寿命预测方法一般是试图建立刀具剩余寿命与切削速度、切削深度以及进给量等加工参数之间的关系。针对此次刀具寿命预测任务而言，所拥有的信息只有振动、电流以及控制器数据，无法简单提取出传统寿命预测方法中常用的加工参量。信息的缺失导致难以根据刀具的加工机理进行建模，只有尽可能的挖掘、利用手中的数据，从数据出发进行回归建模分析。

在特征的选取方面，为了研究刀具寿命与振动和电流信号的关系，使用时域信号处理、频域信号处理、时频信号处理及时间序列分析等方法提取了电流信号与振动信号的时域统计指标、MFCC 系数、1/3 倍频程谱、频带能量比等指标为特征。将刀具磨损类比为结构的损伤，参考结构损伤分析方法，使用时间序列分析，计算振动信号的 AR 系数作为特征。各信号的

特征组成如下表 2-3 所示：

表 2-3 C1 各信号的特征组成

| 第 1-6 维 | 第 7 维 | 第 8-19 维 | 第 20-45 维 | 第 46-75 维 |
|---------------------|-------|----------|-----------|-----------|
| 均值，标准差，方差，偏度，峭度，峰峰值 | 频带能量比 | MFCCs 系数 | 1/3 倍频程 | AR 系数 |

此外，我们对数据进行频谱分析，发现刀具的磨损特征在特定的频段内表现较为明显，针对特定频带，使用小波包分析提取了该频段的振动和电流信号，并对该频段的振动和电流信号进行时域统计指标分析，并以此作为样本的特征之一。至此，传感器数据中的特征提取完毕，由上表所述的各类时频域特征，以及特定小波带中提取的时域统计特征组成。

我们可以从传感器数据中提取各种各样的特征及特征组合，来直接确定当前刀具的磨损情况。但仅做到准确预测当前“磨损比”是不够的。因为加工工况必然会影响到刀具的磨损情况。我们做寿命预测，一定暗含着一个“加工强度”大致不变的前提，或者说，刀具的“磨损趋势”必须是大致稳定的。否则在某极限加工条件下，刀具可能立马就报废了，这就失去了做寿命预测的基本意义。

根据机床的加工机理，我们推测控制器数据中的主轴负载可以在一定程度体现加工过程的切削力或切削深度等影响刀具磨损趋势的参量，主轴负载应该是我们所谓的“加工强度”或“磨损趋势”的集中体现。所以我们一定要尽力联合起现有的传感器数据与控制器数据，才能合理建立模型。在务必联合传感器与控制器数据的共识下，鉴于控制器数据与传感器数据无法准确对齐，我们仅对刀具的各个文件求取主轴负载的平均值，并将这个值作为一个新的特征维度加入到特征包中。

分别对数据集中的电流数据 c1，x 方向的振动信号 v1 与 z 方向的振动信号 v2 进行特征提取，再分别对上述 3 种信号进行小波包分解，并对提取出的特定频带的数据进行小波带的时域指标统计，联合平均负载，得到的特征组成如表 2-4 所示：

表 2-4 各样本的所有特征维度

| 维度 | 1-75 | 76-150 | 151-225 | 226-231 | 232-237 | 238-243 | 244 |
|-------|------|--------|---------|---------|---------|---------|------|
| 信号提取自 | c1 | v1 | v2 | c1 小波带 | v1 小波带 | v2 小波带 | 平均负载 |

4.4 预测算法

在算法选择方面，我们首先尝试了 GBRT 算法，以此作为剩余寿命预测的 Baseline，再利用 DNN 网络进行回归建模。在建立模型的初期，在得到特征包后，对各样本进行随机打乱，直接输入至 4 层 DNN 网络中进行模型训练，此时 DNN 网络的预测结果略差于 GBRT 算法。在深入分析后，我们发现以上 DNN 网络训练方法有两点略显不足：

(1) 我们认为要想准确的预测出刀具的剩余寿命，需要做的不仅是一个当前状态预测，更是一个趋势性的分析，联合输入多个样本或许对性能会有所改善。

(2) 对于回归问题而言，现有数据的标签种类有限，并未均匀的覆盖待预测的 0-1 区间。若能将样本进行随机组合，可以丰富填充特征与标签的多样性，或可改善模型。

针对以上两点不足，我们提出了如下的改进方式：

(1) 与音频信号处理相类似的，我们在对各样本提取特征后，不再将数据进行随机打乱，而是按时序的将文件进行排列，多帧联合依次输入以便更好的利用样本的前后帧信息。

(2) 采用 MIX UP 方法进行数据增强。利用 MIX UP 方法，在每个 batch 输入到网络前，对该 batch 的特征与标签进行同样的线性组合，这不仅可以完善数据集的多样性，更能减少了在预测未见数据时的不确定性，提高系统的泛化能力。

经实验验证，采用以上两点改进措施后，DNN 网络的性能得到了较大改善，预测结果更佳。同时，为增强算法的泛化能力，我们基于 Bagging 思想，将已知的 3 把刀具的训练数据进行排列组合，训练出多个模型。而后分别对决赛刀具进行寿命预测，对同一文件内的样本求取均值，获得该文件的平均“磨损比”。由于决赛数据中各刀具均有 10 个文件，将各文件的平均“磨损比”转化为刀具的寿命，然后去掉预测寿命的最大值与最小值，再求取剩余结果的均值以降低预测误差，来最终预测刀具寿命。

5. 验证

将数据集等间距采样分为 5 份，4 份做训练，1 份为测试。以 GBRT 算法为基线，各决策树最大深度为 5，最多 500 棵树，学习率 0.1，训练结果如图 1-3-18 所示。此外，利用 4 层 DNN 模型进行训练，各层节点数分别为 2048，2048，1024，1024；采用 L2 正则化，基于 MAE 指标，利用 Adam 方法进行优化，训练结果如下图 1-3-19。

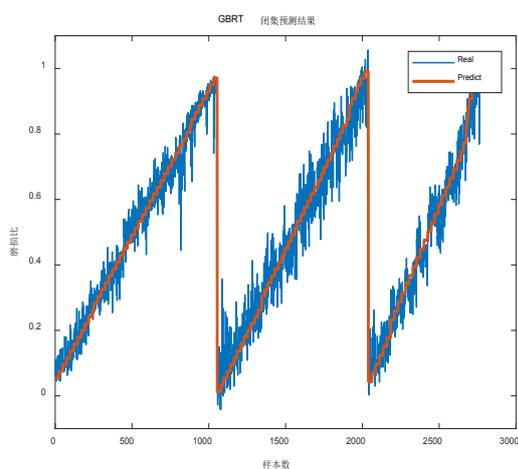


图 1-3-18 GBRT 算法预测结果

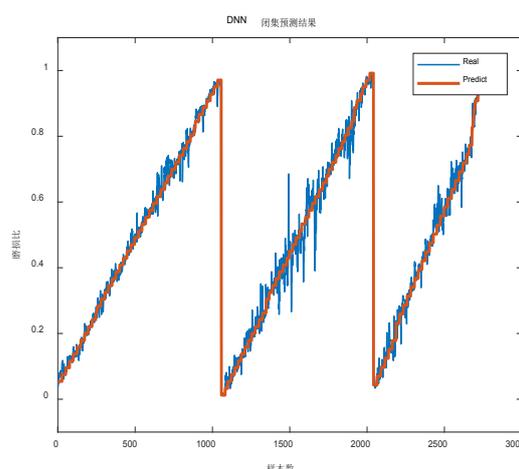


图 1-3-19 DNN 网络预测结果

将已知标签的三把刀的训练数据进行不同的排列组合，可训练出多个预测模型，分别对决赛刀具进行预测后，可采用求均值的方式减小随机噪声对预测的影响。下图 1-3-20 为以训练数据的某种组合进行训练的模型，对决赛数据的预测输出。在得到如下图所示的预测结果后，在初步预测结果的基础上进行中值或均值滤波等操作，去除噪声，使预测更加准确。

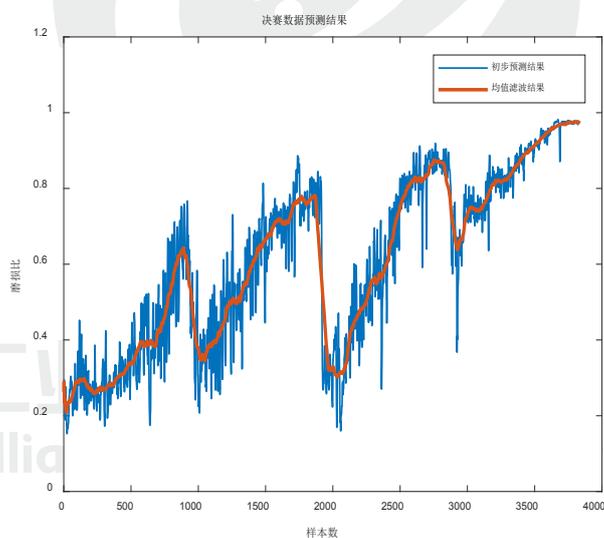


图 1-3-20 模型对决赛数据的预测结果

6. 结果分析与经验总结

在本次竞赛过程中，我们查阅视频资料了解数控机床上铣刀的工作过程，将竞赛目标明确为解决利用含噪标签进行 0-1 之间“磨损比”预测的回归问题。从分析原始数据出发，逐

个文件的查看数据情况，有针对性的对数据进行了清洗、分帧等预处理。基于队员们的信号处理经验，我们对预处理后的数据进行各种时域、频域和时频域特征提取，将刀具磨损类相比于结构损伤，引入时间序列分析技术，并合理地利用控制器数据中的主轴负载信息，将其均值加入到特征集中，以弥补不确定的工况带来的影响，花费大量的精力深入探讨特征，试图找出各类特征与磨损量之间的映射关系。在最开始进行模型训练时我们得到的结果与我们选定的 Baseline 也就是 GBRT 算法相比并不理想，于是我们又引入了多帧联合与 MIX UP 数据增强模块，提升了系统的预测性能与泛化能力。

竞赛中使用普通 i7 处理器对数据进行预处理与特征提取，总耗时 4 分半，平均每个样本耗时 200ms 左右。网络模型训练与预测使用的是容天 Multi GPU SCS4450 超算服务器，将决赛数据 4 把刀的样本输入到训练好的模型中进行预测的时长大约为 5 到 6s，平均到每个样本大概耗时在几毫秒量级。

从十二月初决定参加比赛开始到决赛答辩结束撰写本文的三个多月时间，队员们都收获颇丰，工业互联网这一概念在我们的脑海中逐步清晰，对如何利用工业大数据为产业赋能也有了更实际的体会。就本次竞赛而言，对可用数据及其特征进行深入的分析是本次我们得到的重要经验，我们不仅要从信号处理的角度去看待问题，更要尝试去学习理解机床的加工机理，获取领域知识，了解各类信号中蕴含的物理信息才能更全面的利用手中的数据去解决问题。

本文提出的方案还有很多可以改进的地方，例如数据预处理阶段时人为介入了静音段的删除工作，可能会对模型的泛化能力产生一定影响；特征集中的部分维度可能并不包含有用信息，导致了一定冗余；此外，由于时间的限制，适合于处理序列信息的循环神经网络 (Recurrent Neural Network, RNN) 与长短时记忆网络 (Long Short-Term Memory, LSTM) 还并未进行尝试，后续工作可以针对这些问题进行展开。

7. 参考文献

[1] An D, Kim N H, Choi J H. Practical options for selecting data-driven or physics-based prognostics algorithms with reviews[J]. Reliability Engineering & System Safety, 2015, 133: 223-236.



[2] Taylor, Frederick Winslow. Über Dreharbeit und Werkzeugstähle: Autorisierte deutsche Ausgabe der Schrift:" On the art of cutting metals, ". J. Springer, 1908.

[3] Luo, J., Bixby, A., Pattipati, K., Qiao, L., Kawamoto, M. and Chigusa, S., 2003, October. An interacting multiple model approach to model-based prognostics. In SMC'03 Conference Proceedings. 2003 IEEE International Conference on Systems, Man and Cybernetics. Conference Theme–System Security and Assurance (Cat. No. 03CH37483) (Vol. 1, pp. 189–194). IEEE.

[4] Javed K, Gouriveau R, Zerhouni N. State of the art and taxonomy of prognostics approaches, trends of prognostics applications and open issues towards maturity at different technology readiness levels[J]. Mechanical Systems and Signal Processing, 2017, 94: 214–236.

[5] Benkedjough T, Medjaher K, Zerhouni N, et al. Health assessment and life prediction of cutting tools based on support vector regression[J]. Journal of Intelligent Manufacturing, 2015, 26(2): 213–223.

[6] Drouillet C, Karandikar J, Nath C, et al. Tool life predictions in milling using spindle power with the neural network technique[J]. Journal of Manufacturing Processes, 2016, 22: 161–168.

[7] Huang, R., Xi, L., Li, X., Liu, C.R., Qiu, H. and Lee, J., 2007 . Residual life predictions for ball bearings based on self-organizing map and back propagation neural network methods. Mechanical systems and signal processing, 21(1), pp.193–207.

[8] Sun, H., Zhang, X. and Niu, W., 2016. In-process cutting tool remaining useful life evaluation based on operational reliability assessment. The International Journal of Advanced Manufacturing Technology, 86(1–4), pp.841–851.

[9] Wang, M. and Wang, J., 2012. CHMM for tool condition monitoring and remaining useful life prediction. The International Journal of Advanced Manufacturing

Technology, 59(5–8), pp.463–471.

[10] Al-Zubaidi, S., Ghani, J.A. and Haron, C.H.C., 2014. Prediction of tool life when end milling of Ti6Al4V alloy using hybrid learning system. Arabian Journal for Science and Engineering, 39(6), pp.5095–5111.

[11] Huang Z, Xu Z, Ke X, et al. Remaining useful life prediction for an adaptive skew-Wiener process model[J]. Mechanical Systems and Signal Processing, 2017, 87: 294–306.

[12] Baptista M, Henriques E M P, de Medeiros I P, et al. Remaining useful life estimation in aeronautics: Combining data-driven and Kalman filtering[J]. Reliability Engineering & System Safety, 2019, 184: 228–239.

[13] Ren L, Sun Y, Cui J, et al. Bearing remaining useful life prediction based on deep autoencoder and deep neural networks[J]. Journal of manufacturing systems, 2018, 48: 71–77.

[14] Guo L, Li N, Jia F, et al. A recurrent neural network based health indicator for remaining useful life prediction of bearings[J]. Neurocomputing, 2017, 240: 98–109.

[15] Chen J, Jing H, Chang Y, et al. Gated recurrent unit based recurrent neural network for remaining useful life prediction of nonlinear deterioration process[J]. Reliability Engineering & System Safety, 2019, 185: 372–382.

[16] 吴军, 苏永衡, 朱永猛, et al. 基于信息融合的刀具剩余寿命在线预测方法 [J]. 华中科技大学学报 (自然科学版), 2017(4).

[17] 李杰. 工业大数据 [M]. 北京: 机械工业出版社, 2015年, 1–228.

(三) 基于前馈神经网络的刀具剩余寿命预测

1. 团队介绍

团队名称：**沈国锐**

| 成员姓名 | 团队角色 | 职位 |
|------|------|--------|
| 程骋 | 指导老师 | 博士后研究员 |
| 沈国锐 | 队长 | 硕士研究生 |

团队的两位成员都来自于华中科技大学人工智能与自动化学院。指导老师程骋于 2018 年获得英国帝国理工学院博士学位，2018 年起在华中科技大学人工智能与自动化学院担任博士后研究员，从事锂电池寿命预测、机械故障诊断以及迁移学习等方面的研究工作。沈国锐同学 2017 年起在人工智能与自动化学院的硕士在读生，研究方向是优化理论、系统辨识、分布参数系统的预测以及神经网络的理论理解与应用。

2. 背景简介与文献调研

在机械加工时，刀面和工件之间存在剧烈的摩擦，加之切削区内有很高的温度和压力，所以在切削过程中，刀具会出现变形。一般将刀具磨损过程分为三个阶段：初期磨损阶段、正常磨损阶段和剧烈磨损阶段。初期磨损阶段和正常磨损阶段的刀具都处于有效工作期。而剧烈磨损阶段，刀具变钝，切削力变大，切削温度升高，磨损量急剧上升。此时，机床出现噪声和震动较大的现象，表明刀具已经磨损失效^[4]。磨损的刀具会降低零件的尺寸精度和表面的光滑性，致使产品达不到对工艺的要求。当刀具磨损较为严重时，会造成材料的大量浪费甚至是加工机床的损坏，加大生产成本。通过引入刀具寿命预测并实时监控，在刀具磨损严重之前及时换刀，可以有效提高生产效率、保证产品质量，这对于机械加工智能化有重大意义。

目前，有多种方法可对刀具剩余寿命进行预测^[4]，分别是物理知识的模型、基于辨识预测的模型、以及时间序列预测模型，详见参考文献^[1]以及其中推荐的相关文献。

基于物理知识的模型，首先需要对刀具加工的环境进行详细的了解，了解详细的铣削过

程，刀具与工件之间的接触情况，然后进行合理的假设，分析刀具在加工过程中受力的变化，找出那些影响刀具剩余寿命的关键因素，从而从数学物理方程上推导出剩余寿命受关键因素影响的方程式，然后进行预测。基于辨识预测的模型的主要步骤有两步，辨识和预测。第一步是辨识，辨识就是按照一个准则在一组模型类中选择一个与数据拟合最好的模型^[2]。这意味着，辨识有三个要素—数据，模型类和准则。当完成了第一步辨识过程之后，就可以用得到的模型对系统将来的状态进行预测（在这里是剩余使用寿命），这就是第二步。时间序列预测模型则是一种定量预测，其基本原理是一方面承认事物发展的延续性，运用过去时间序列的数据进行统计分析，推断出系统将来的发展趋势；另一方面，又要考虑实际过程中的偶然因素而产生的随机性，为了消除随机波动的影响，利用历史数据进行统计分析，并对数据进行适当处理，进行趋势预测^[3]。

当然，这三种方法并不是完全独立的。例如，基于系统辨识的方法常常要依赖于先验知识，对模型做出判断和筛选，然后进行辨识，通常是知道模型类，只需要辨识参数，这说明它与物理知识的模型联系紧密。又如，基于时间序列的预测模型，也需要进行参数辨识步骤，所以在某种程度上，这也是一种辨识。事实上，很多机器学习算法特别是有监督学习也可以从系统辨识的角度理解，例如神经网络模型，是利用误差方向传播来辨识权重和偏置值。从实施难度上来看，基于物理知识的预测模型最困难，这种方法对假设的合理性和完全性依赖程度高，并且难以找到一个可以恰当描述的切削规律的系统方程。而基于系统辨识和时间序列的预测模型则最受欢迎，也最容易实施，例如，文献^[5]、^[6]和^[7]均采用 ARMA 模型预测滚动轴承的剩余寿命。文献利用神经网络模型建立轴承剩余寿命的预测模型，采用支持向量机建立了刀具剩余寿命的预测模型。

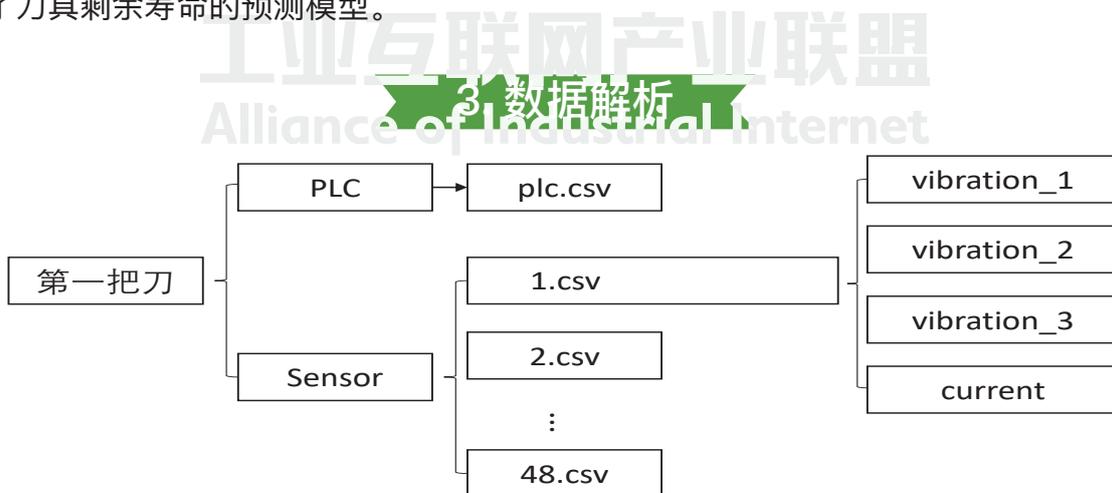


图 1-3-20 刀具剩余寿命预测数据的文件结构

本次竞赛提供的数据是根据 CPS 框架收集的控制器 (PLC) 信号和外置传感器 (Sensor) 信号, 收集加工过程中的工况信息和传感器数据, 初赛共提供 9 组 CNC 加工数据, 数据来源为实际 CNC 加工过程中, 一把全新的刀具开始进行正常加工程序, 直到刀具寿命终止时停止数据采集。更多详细的数据信息描述, 可以参考竞赛官网^[8]。

在给定的刀具训练数据中, 一共有三把刀的数据, 第一把刀文件目录下包含 plc 和 sensor 两个数据文件夹。plc 中仅含一个 csv 数据文件, 而 sensor 中有 48 个 csv 数据文件, 每个 csv 文件包含四个维度的信号, v 分别是 ibration_1, vibration_2 和 vibration_3 分别代表 x, y 和 z 三轴方向的颤振信号, current 代表电流信号, 如图 1-3-20 展示的那样。第二、第三把刀的数据文件结构与此类似。具体来看, 图 1-3-21 分别展示了外置传感器的 x, y 和 z 三轴的原始信号, 它们在初始时刻、剩余时候寿命的一半、以及使用寿命结束时信号变化情况。可以得出两个基本的观察结果: 首先观察 vibration_1, 可以发现在初始时刻, 切削震动信号振幅整体较小, 震动均匀, 随着剩余寿命的减少, 振幅变大, 剩余寿命快结束时, 振幅变大, 并且震荡开始不均匀。

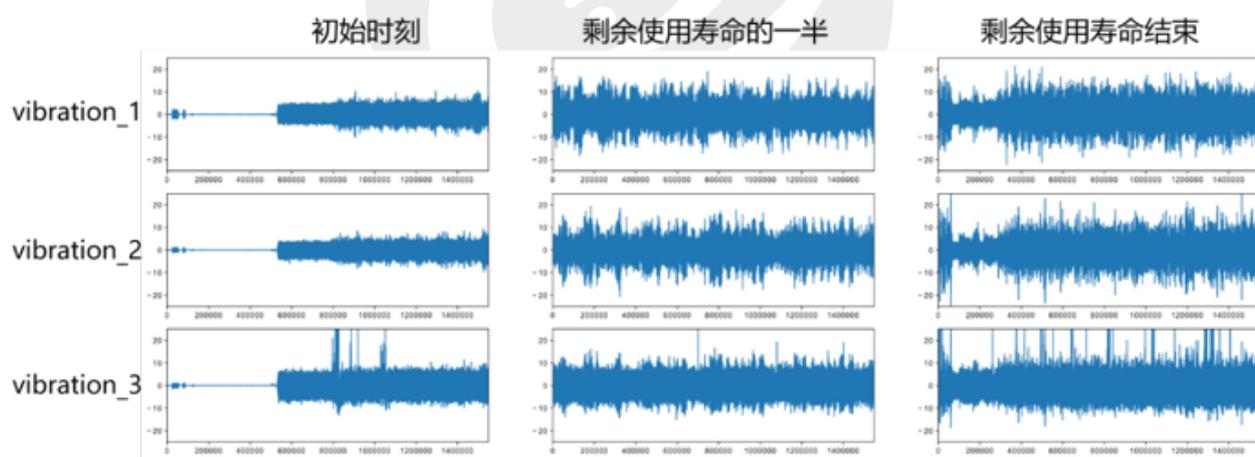


图 1-3-21 外置传感器 Sensor 的三轴原始信号展示

接下来, 再对比 x, y 和 z 三个轴, 可以发现它们的震动具有同时性, 幅值 (幅度的绝对值) 几乎同时接近零, 同时增大或变小。那再具体到单幅图, 每一幅图 1-3-22 这样的图都是由超过 150 万个数据点绘成, 数据量非常大。在这幅图里, 刀具处于两种状态, 在连续一段时间里, 幅值非常小 (幅值接近于 0), 说明刀具虽然在转动, 但是没有与物体接触, 我们称之为空转状态, 另外一种则是切削状态, 这个时候刀具的振幅较大。

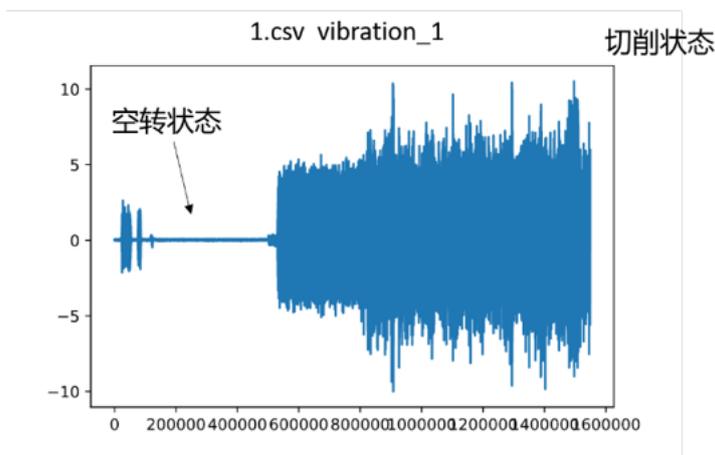


图 1-3-22 x 轴震动信号展示

| 序号 | 数值 |
|--------|----------------|
| 996935 | 8.553855e+151 |
| 996936 | -9.451283e+238 |
| 996938 | -9.196936e+144 |
| 997664 | NaN |
| 997885 | NaN |

图 1-3-23 信号异常值

另外，在训练数据集中包含了一些异常值，包括空值，数据幅值异常大的情况。图1-3-23中列出了几个异常值，左边是它们的在文件中的序号，有的是空值 NaN，有的数值达到了10的100次方以上，这种情况下，设置阈值，对每个 csv 文件绝对值降序排列，统计发现异常值的比例低于 1%。



4.1 数据预处理：

根据以上的数据理解部分，我们知道了数据的基本特性，用这些特性就可以进行数据预处理。首先，我们没有用 PLC 控制器信号的数据，只选用了 sensor 信号中的 xyz 三轴的震动信号，这是因为 sensor 数据量大，并且 sensor 数据与 plc 数据难以一一对应起来。其次，仅选用处于切削状态采集到的数据作为训练数据，这是因为刀具与工件接触时的震动情况，才能反映刀具的健康状态，损坏的刀具震动不均匀。最后，利用 sensor 中数据量大的特点，计算它的均值和方差来代表整体数据的特性。

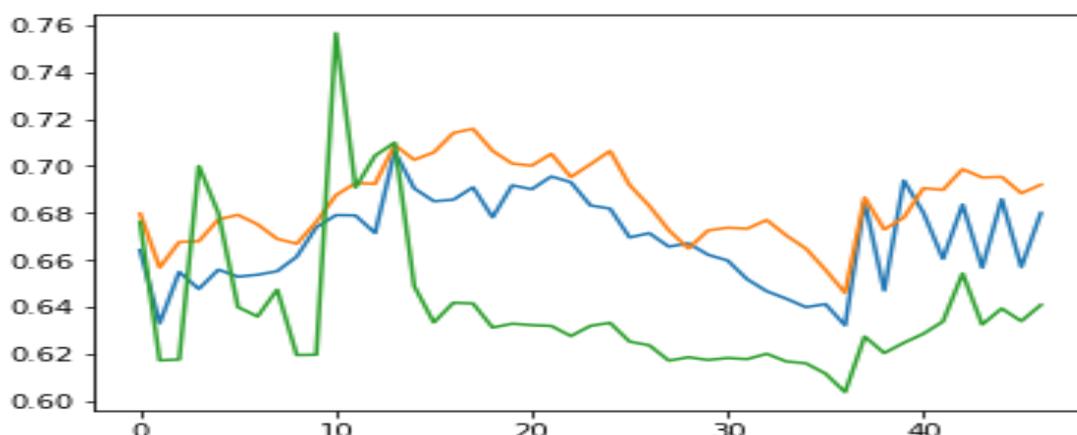


图 1-3-24 选取的数据与整体数据的方差比值保持在 60% 以上

具体来说，对单个 csv 文件中的数据取绝对值，然后降序排列，计算排名区间位于 5% 到 35% 的数据。这样做有三个目的：第一，剔除异常值，经过降序排列之后，异常值位于前 1%。第二，剔除空转状态的数据，这些数据位于后 30%。另外，第三个优点，如图 1-3-24 所示，通过这些规则选取的数据，经过计算发现，该区间的数据的方差对整体方差的贡献率达到 60% 甚至 70%，可以很好的代表整体数据。

4.2 输入输出数据的确定：

将前面的数据预处理流程运用到单个 vibration 的数据处理，可以得到相应的方差和均值两个数据，所以三个轴方向的震动信号，一共可以得到 6 个维度的数据。记为行向量：

$$x_k = (x_{k1}, x_{k2}, x_{k3}, x_{k4}, x_{k5}, x_{k6})$$

这就是输入数据，作为特征信号。对于第一、第二把刀， k 有 48 种不同的取值，第三把刀则有 37 种取值，所以一共有 133 组输入特征数据。本次竞赛的任务是预测刀具的剩余有效使用寿命，所以它们的标签应该定义为对应到 133 个给定的剩余寿命，计算公式为：

$$y_k = \begin{cases} 240 - (k \cdot 5) & \text{第一、二把刀, } k = 1, \dots, 48 \\ 185 - (k \cdot 5) & \text{第三把刀, } k = 1, \dots, 37 \end{cases}$$

有了输入特征和对应的标签，自然而然，就可以用常见的有监督学习方法进行数据拟合。后文为了简化叙述，将得到的训练数据集记为 (x, Y) ，分别储存了训练数据的所有特征和标签。从系统辨识的角度看，给定恰当的模型类，在有监督框架下数据的拟合问题同样也是一个参数辨识问题。

4.3 模型构建:

不同的数据科学工程师在进行数据拟合时，选取的模型各不相同，这与他们的从业经验具有很大关系。事实上，没有一个模型，可以在所有的给定数据上都取得最好的拟合效果，这也是没有免费的午餐所描述的^[9]。所以，通常的做法是不断尝试经典的拟合方法。常见的有监督学习框架又分为线性拟合和非线性拟合。注意到，线性与非线性是相较而言的，在这里，线性拟合指的是函数输出相对于模型未知参数是线性的，并不意味着模型本身就一定是线性的。例如，

$$f(x_1, x_2, a_1, a_2) = a_1 x_1^2 + a_2 x_2$$

其中 (a_1, a_2) 是未知参数。函数 f 相较于 (a_1, a_2) 是线性的，而对于 (x_1, x_2) 来说却是非线性的，这也是一个容易被误解的地方。在这种情况下，经典的最小二乘法^[10]，以及近些年逐渐受欢迎的稀疏回归算法（如 Lasso^[11,12,13,14]，Ridge^[12,13] 等），都可以用于拟合线性回归问题。而在非线性拟合领域，最受欢迎的莫过于近些年影响巨大的神经网络模型，随着深度学习的发展^[15,16]，神经网络在图像分类^[17]、目标识别^[18]、语义分割等多个领域实现了巨大突破。另外，普适逼近理论^[19]又从理论上证明前馈神经网络可以估计紧集上的任意连续函数。所以在模型选择方面，我们偏向于使用前馈神经网络拟合得到的数据。

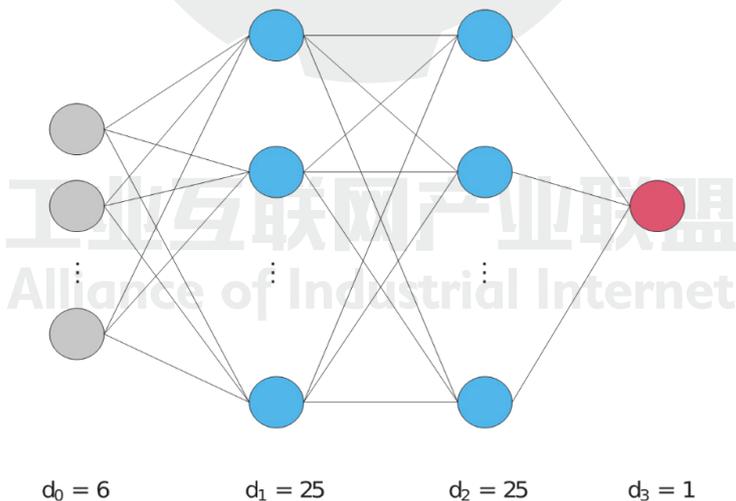


图 1-3-25 神经网络结构图

具体来说，给定训练数据集 (X, Y) ，我们构造了一个含有两个隐藏层的神经网络，输入层有 6 个神经元，中间蓝色的两个隐藏层各含 25 个神经元，最后一层有一个神经元用来输出刀具剩余寿命，其数学表达式为：

$$h_1 = \sigma(Xw_1 + b_1)$$

$$h_2 = \sigma(h_1w_2 + b_2)$$

$$\hat{Y} = h_2w_3 + b_3$$

其中激活函数为 sigmoid

$$\sigma(x) = \frac{1}{1 + e^{-x}}$$

网络结构如图 1-3-26 所示，特征数据经过一系列线性函数和非线性激励函数函数的复合，最终由特征反应出剩余使用寿命的数值。

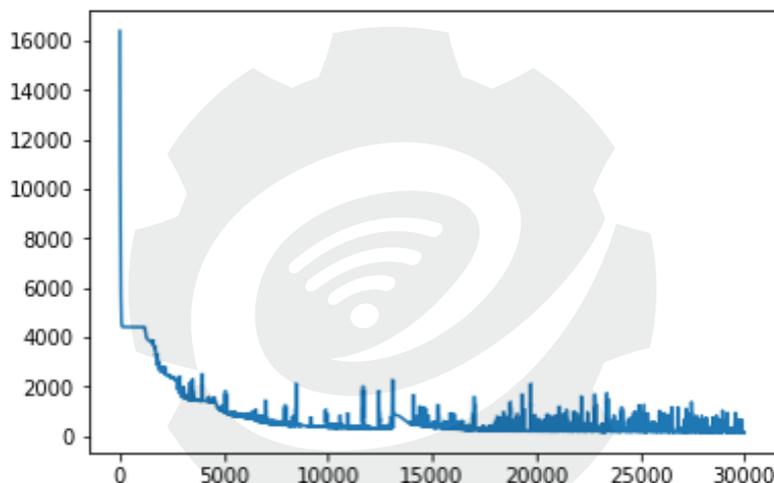


图 1-3-26 拟合误差收敛效果

在构建好前馈神经网络以后，需要相应的学习算法获得未知权值和偏置。目前为止，误差反向传播（BP）算法是最成功的神经网络学习算法，所以在现实任务中使用神经网络时，大多是使用 BP 算法进行训练。目前主流的深度学习工具包如 TensorFlow，PyTorch，Caffe 等都是基于此开发的，我们选用的工具是 TensorFlow。图 1-3-26 展示了一个训练过度的拟合过程，横轴表示迭代次数，纵轴表示损失函数。可以看到，在经历了大约 10000 次迭代之后，模型已经收敛了，其后的两万次迭代没有明显改变误差函数值。在这种情况下，应当将迭代次数设置在一万次左右，在节省时间的同时又可以避免模型训练过度。

总结起来，我们的模型主要有三个优点。第一，在非线形拟合阶段，选用了前馈神经网络，充分利用了普适估计的理论保证，通过函数逼近的方法来拟合刀具剩余寿命的表达函数，最终实现预测任务。第二，训练速度较快。这一点主要是由于两方面的原因引起的：一方面是因为输入数据量维度较低，训练样本也不大，另一方面是根据数据量小而选择了模型连接

方式较为简单的全连接网络结构，没有使用卷积神经网络等结构复杂的大型网络（大型网络主要用于处理高维数据如图像数据等）。这两个性质共同决定了模型的收敛速度会比较快。

但是，从前面的数据处理流程来看，我们的方法有两个明显的不足。首先是没有充分利用所有数据，抛弃了控制器信号（PLC）以及外置传感器（Sensor）中的电流信号，仅仅选用了 Sensor 采集到的三轴振动信号，这样容易造成数据挖掘不充分，潜在信息得不到充分利用也会导致预测结果不够精确。其次是选用的数字特征较少，只有均值和方差，在进行决赛答辩时，我们发现其他组的成员选用的数字特征更多，得到的预测效果更好。

5. 验证

验证方法主要通过和最小二乘法、稀疏回归算法 Lasso 和 Ridge 的对比。在决赛的初期，我们进行了大量的尝试，特别是线性模型的尝试，例如经典的最小二乘法，

$$\min \|Xw - Y\|_2^2$$

又如近些年在辨识领域应用广泛的稀疏辨识算法 Lasso

$$\min \|Xw - Y\|_2^2 + \lambda|w|_1$$

和 Ridge

$$\min \|Xw - Y\|_2^2 + \lambda\|w\|_2^2$$

它们都是稀疏压缩变量选择算法，即通过加入惩罚项进而使得一些影响较小或者没有影响的自变量系数趋近于零，进而实现对模型系数进行压缩和变量选择。

在竞赛初期，我们首先尝试的是将原始数据直接输入线性模型。将原始数据分为输入、输出对，得到非常多的训练数据，并且，每个训练数据的输入特征维度又非常高。然后假设特征与剩余寿命标签呈简单的线性关系，然后逐一尝试上面列举的三种方法。整个过程中，碰到了两个问题：第一，最小二乘和 Ridge 算法的执行过程中或多或少涉及矩阵求（伪）逆，高维矩阵的求逆并不是一件简单的事，逆运算要求矩阵满秩，伪逆运算通常采用奇异值分解，占用内存高。而采用 Lasso 算法，由于惩罚项是不光滑的，通常涉及梯度下降，导致时间成本较高。第二个问题体现在预测的效果不好，这主要是由原始数据没经过预处理以及将特征和标签直接线性相连的简单结构这两个原因造成的。所以，最开始提交的结果排名较为靠

后，不是很理想。后来，在进行数据预处理并且改用复杂模型后，预测结果变得更好。

6. 结果分析与经验总结

在参赛过程中，硬件计算资源的配置如下表格所示，程序在运行大约 100s 后结束。其中，这 100s 的时间主要用于图 3-6 中的前一万次收敛迭代训练，不包含其后的两万次迭代，同时也不包含数据预处理时间。由于竞赛给定的数据量大的原因，读取数据本身耗费的时间特别多，超过了数据预处理的时间。

| 操作系统 | Ubuntu 16.04 LTS | 编程语言 | Python |
|---------|------------------|------|-------------|
| 深度学习工具包 | TensorFlow | 显卡 | 一块 GTX 1080 |

在答辩时，组委会的评委给了我们很多建议。其中，令我们印象最深刻的是，我们太注重方法论，而忽略了对生产车间的实际加工情况的调研与了解，缺乏与相关从业人员的信息交流。单纯的依靠不断尝试并改变模型来换取较好拟合效果，以预测结果为导向而不是以实际情况为依据进行合理分析。这样的做法容易造成时间的浪费，在某种程度上，还失去了了解工业实际应用背景的机会。毕竟，工业数据竞赛的一个目的是为了促进理论与工业生产之间的结果，建立模型的最终结果要落到实际应用中才能发挥最终的意义。总结下来，本次参赛过程有两点体会，与各位读者共勉：

(1) 应了解实际加工情况。有条件的同学应考虑参观实际加工车间，机床加工过程和数据采集流程，或者与车间工作人员、相关专业人员等深入交流。其次，充分利用互联网资源，以观看刀具加工视频的形式了解其工艺流程。

(2) 开放视角，扩充模型的选择。最开始提交的结果排名都在 100 名开外，非常的失望，这个时候要及时分析原因。我们的原因就是最开始使用了简单的线性拟合方法来尝试，这个时候应该及时尝试更多、更复杂的方法，在不同方法之间形成对比，最好有合理验证来判断模型的好坏，而不是单纯的猜测。我们的模型就是缺乏合理验证导致前期模型选择没有导向性，浪费了很多时间。同时在选择模型时也要考虑数据的特点：数据简单就选用线性模型、复杂且高维就选用非线性模型。

7. 参考文献

- [1] Sikorska, J. Z., Melinda Hodkiewicz, and Lin Ma. "Prognostic modelling options for remaining useful life estimation by industry." *Mechanical systems and signal processing* 25.5 (2011): 1803–1836.
- [2] Ljung, Lennart. "System identification." *Signal analysis and prediction*. Birkhäuser, Boston, MA, 1998. 163–173.
- [3] Box, George EP, et al. *Time series analysis: forecasting and control*. John Wiley & Sons, 2015.
- [4] 王晓强 . 刀具磨损监测和剩余寿命预测方法 [D]. 华中科技大学 ,2016.
- [5] 刘然 . 刀具磨损状态识别及预测研究 [D]. 西南交通大学 ,2014.
- [6] 李威霖 . 车铣刀具磨损状态监测及预测关键技术研究 [D]. 西南交通大学 ,2013.
- [7] 敖银辉 , 汪宝生 . 钻头磨损检测与剩余寿命评估 [J]. *机械工程学报* ,2011,47(01):177–181.
- [8] <http://www.industrial-bigdata.com/competition/competitionAction!showDetail34.action?competition.competitionId=3>
- [9] https://en.wikipedia.org/wiki/No_free_lunch_theorem
- [10] Stigler, Stephen M. "Gauss and the invention of least squares." *The Annals of Statistics* (1981): 465–474.
- [11] Tibshirani, Robert. "Regression shrinkage and selection via the lasso." *Journal of the Royal Statistical Society: Series B (Methodological)* 58.1 (1996): 267–288.
- [12] Rudy, Samuel H., et al. "Data-driven discovery of partial differential equations." *Science Advances* 3.4 (2017): e1602614.
- [13] Brunton, Steven L., Joshua L. Proctor, and J. Nathan Kutz. "Discovering

governing equations from data by sparse identification of nonlinear dynamical systems." Proceedings of the National Academy of Sciences 113.15 (2016): 3932–3937.

[14] Boyd, Stephen, et al. "Distributed optimization and statistical learning via the alternating direction method of multipliers." Foundations and Trends® in Machine learning 3.1 (2011): 1–122.

[15] L. Yann, B. Yoshua and H. Geoffrey, "Deep Learning," Nature, vol. 521, no. 7533, pp. 436–444, 2015.

[16] K. He et al, "Deep residual learning for image recognition," on the Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR), pp. 770–778, 2016.

[17] S. Karen, and A. Zisserman, "Very deep convolutional networks for large-scale image recognition," arXiv:1409.1556, 2014.

[18] L. Zeming et al, "Detnet: Design backbone for object detection," on the Proceedings of the European Conference on Computer Vision (ECCV), pp. 334–350, 2018.

[19] Cybenko, George. "Approximation by superpositions of a sigmoidal function." Mathematics of control, signals and systems 2.4 (1989): 303–314.

(四) 基于 DTW 退化特征和 CNN+SVR 网络的刀具剩余寿命预测

1. 团队介绍

团队名称: MZC

| 成员姓名 | 团队角色 | 职位 |
|------|------|-------|
| 马贵君 | 队长 | 博士二年级 |
| 蔡鑫 | 队员 | 本科四年级 |
| 曾雄 | 队员 | 本科三年级 |

团队成员均来自华中科技大学机械学院。

2. 背景简介与文献调研

刀具寿命是影响加工工件质量的关键因子, 刀具失效可能造成工件表面粗糙度和尺寸精度的下降, 或造成更严重的工件报废或机床受损。在一次不间断的同工序加工过程中, 切削力随着刀具磨损量的增加而增加, 因此切削力信号能够代表刀具的退化过程^[1, 2]。现有的刀具剩余寿命预测方法主要可分为基于模型的方法和基于数据驱动的方法。基于模型的方法, 如刀具物理模型、经验模型(指数退化模型)等, 在本次竞赛中实现难度较大。基于数据驱动的方法利用统计方法和机器学习方法对观测数据进行剩余寿命预测, 其主要的思想是从传感器信号中提取物理特征, 如时域特征、频域特征和时频域特征, 再建立线性退化指标基于机器学习方法进行特征映射和剩余寿命预测^[3, 4]。

3. 数据解析

工业数据的采样频率高, 环境噪声大, 数据量大, 对数据分析造成了很大的挑战。对于本次竞赛数据, 同样也面临同样的问题, 而且对于同种工况下的不同样本之间的信号差异较大。本组的核心思想是从数据中提取退化指标; 基于信号和退化指标建立映射关系, 以建立不同样本之间的关系; 最后对退化指标进行回归预测。本组的技术路线如图 1-3-27 所示。

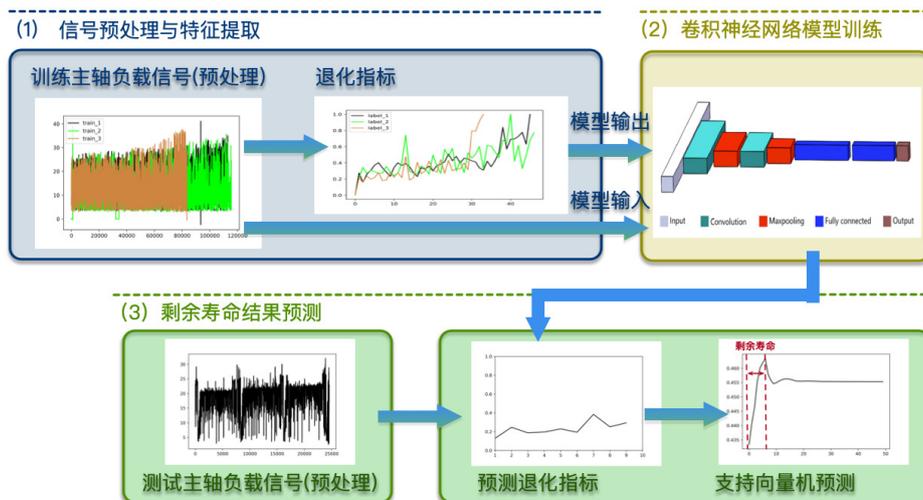


图 1-3-27 算法框架图

本组技术路线的算法框架如图 1-3-27 所示，分为三部分：（1）信号预处理和特征提取。包括训练刀具主轴负载信号的预处理和基于预处理信号提取的退化指标；（2）卷积神经网络模型训练。经过预处理的主轴负载信号和提取的退化指标分别作为卷积神经网络的输入和输出进行模型的训练；（3）测试刀具的剩余寿命结果预测。将经过预处理的测试刀具主轴负载信号输入到训练好的卷积神经网络模型中得到测试刀具的退化指标。基于支持向量机回归算法，对训练集刀具的退化指标进行训练后去预测测试集刀具的退化指标，得到最终的剩余寿命。具体数据特点及分析方法如下：

特点一：本次竞赛提供数据的 PLC 采集频率设定在 33 Hz，但受到控制器硬件性能影响，采样频率偶有不稳定情况发生，每 5 min 的主轴负载信号长度不一致，为后续算法实现，需要长度的统一。

分析方法：三次 B 样条插值法。三次 B 样条插值就是将原始长序列分割成若干段构造多个三次函数（每段一个），使得分段的衔接处具有二阶导数连续的性质（即光滑衔接），相对于常用的线性插值和阶梯插值等更加实用。其满足如下对应关系：

$$P(t) = P_0 * F_{0,3}(t) + P_1 * F_{1,3}(t) + P_2 * F_{2,3}(t) + P_3 * F_{3,3}(t)$$

$$F_{0,3}(t) = \frac{1}{6}(-t^3 + 3t^2 - 3t + 1)$$

$$F_{1,3}(t) = \frac{1}{6}(3t^3 - 6t^2 + 4)$$

$$F_{2,3}(t) = \frac{1}{6}(-3t^3 + 3t^2 + 3t + 1)$$

$$F_{3,3}(t) = \frac{1}{6}t^3$$

我们以训练样本中最大长度（2457）作为基准，使用三次 B 样条曲线插值法对主轴负载数据进行插值，同时剔除负载信号极小的样本（我们视之为刀具空转状态或采集故障）。

特点二：本次竞赛数据提供了刀具加工过程中的电流、振动和主轴负载信号，需要从中提取符合刀具退化过程的退化指标。

分析方法：动态时间规整算法（DWT）计算数据之间的相似度，以提取以 5 分钟为单位的退化指标。DWT 的基本思想是对离散的数据点求最短距离，两个样本之间的数据点进行滑动求解，第一个样本的第 i 个点和第二个样本的第 j 个点的距离关系满足如下方程：

$$g(i, j) = \min \begin{cases} g(i - 1, j) + d(i, j) \\ g(i - 1, j - 1) + 2d(i, j) \\ g(i, j - 1) + d(i, j) \end{cases}$$

根据上述关系求解两个样本之间的距离，也就是相似度。本过程我们提出从原始数据中提取一条以 5 min 为单位的稀疏曲线作为训练样本的标签。我们使用动态时间规整方法在每个训练集中以第一个 5 min 数据作为基准进行相似度度量。得到三组退化曲线，并进行最大最小归一化处理，结果如图 1-3-28 所示。

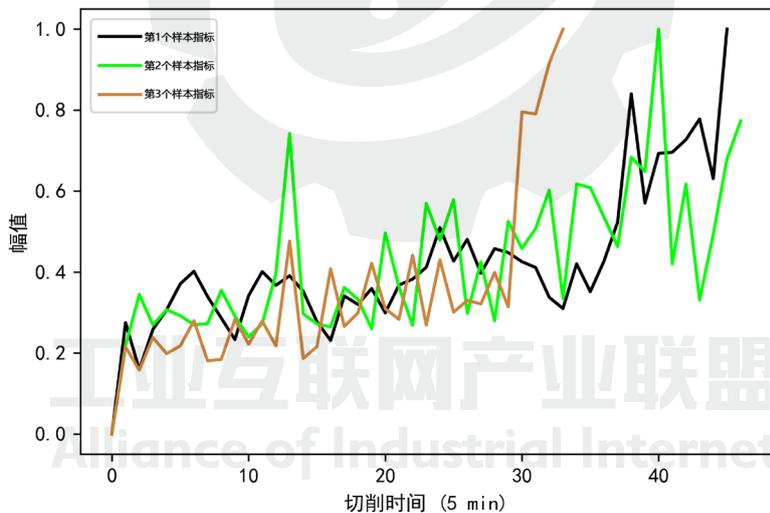


图 1-3-28 基于 DTW 方法的训练集刀具退化曲线

特点三：测试集样本是加工过程中间某一段的信号，不能同训练集样本一样基于第一段信号提取退化指标。需要一种方法能够学习训练集的信号 - 退化指标的对应关系，预测测试集的退化指标，最后对退化指标进行滑窗预测。

分析方法：使用卷积神经网络学习训练集的信号 - 退化指标之间的映射关系，训练模型，预测测试集信号的退化指标。卷积神经网络应用于传感器信号的优点有以下三个方面：（1）

自动特征提取。由于传感器信号具有高噪声、高采样频率的特点，提取时频域特征具有很大的不确定性，而卷积神经网络能够克服特征提取困难、精确度受限的技术问题。；（2）训练速度快。由于卷积神经网络的卷积核在运算过程中能够参数共享，大大减少了运算的参数，因此整个训练过程不到 5min；（3）拟合能力强。卷积神经网络能够通过多个非线性函数的组合得到输入输出近似的映射关系，而不需要任何精确的函数关系，拟合精度就可以达到理想状态。本组采用的神经网络结构如图 1-3-29 所示。

利用支持向量机回归进行寿命预测。对于训练集退化指标和预测的测试集退化指标，我们选择支持向量机回归方法以滑窗的方式进行滚动预测，我们选择滑窗大小为 10。



图 1-3-29：卷积神经网络结构

4. 方法

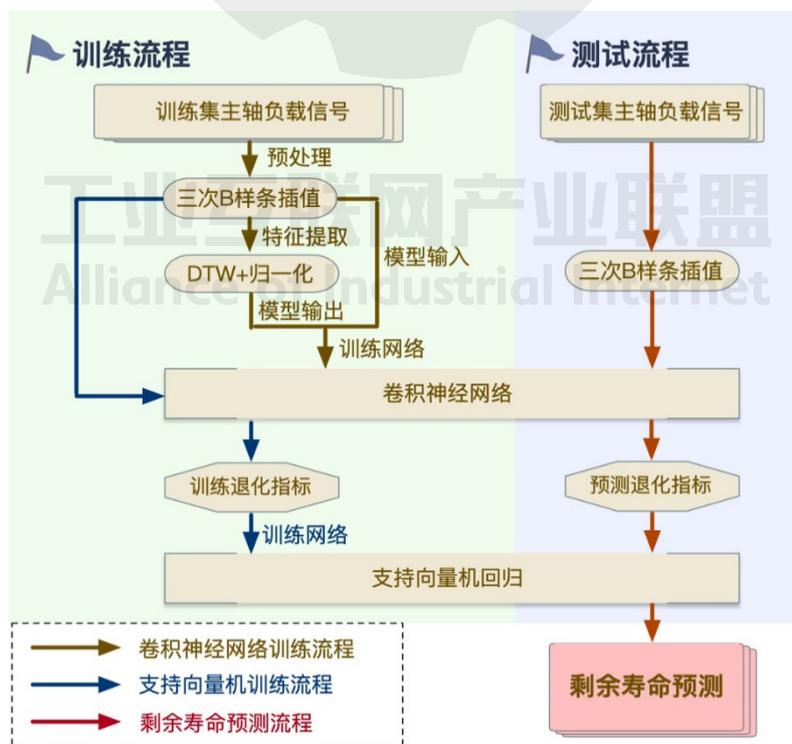


图 1-3-30：算法流程图

本组的具体算法流程如图 1-3-30 所示，整体分为训练流程和测试流程。在训练流程中，分为以下五个部分：

- (1) 首先训练集的主轴负载信号经过三次 B 样条插值法得到等长度的主轴负载信号；
- (2) 使用动态时间规整 (DTW) 方法从经过预处理的主轴负载信号中提取退化指标；
- (3) 将 (1) 和 (2) 中得到的数据分别作为卷积神经网络的输入和输出，进行模型的训练；
- (4) 将 (1) 得到的主轴负载信号输入到训练好的模型中得到预测的训练样本退化指标；
- (5) 使用支持向量机回归将 (4) 得到的退化指标进行回归模型的训练。

在测试流程中，分为三个部分：

- (1) 使用三次 B 样条插值法对原始的测试集主轴负载信号进行插值；
- (2) 将预处理的测试信号代入到训练好的卷积神经网络模型中，得到测试信号的退化指标；
- (3) 将测试信号的退化指标代入到训练好的支持向量机回归模型中，以滑窗的方式预测未知的退化指标，计算监测点和最大退化指标的时间差，以此得到测试刀具的剩余寿命。

该方法的有以下三个特点：首先，本组从 5 种信号中选择主轴负载信号作为基准信号，主轴负载信号的时域退化特性更加明显；其次，本组使用 DTW 方法提取更加接近退化过程的虚拟非线性退化指标，防止训练过程的过拟合；最后，本组使用的方法不需要复杂的手工特征提取过程，基于卷积神经网络的训练自动提取信号特征，效率高。



本组采用基于交叉验证的网格搜索方法进行支持向量回归模型参数的确定。在训练过程中，我们采用滑动窗口的方法建立训练样本集。对于三个训练样本的退化指标，使用基于交叉验证的网格搜索达到最优的拟合效果和参数，基于此模型对测试集的退化指标以滑动预测的方式进行寿命预测。

本组分别使用线性退化指标和非线性退化指标拟合模型并对比了训练效果，发现使用线性退化指标很难拟合，预测退化的过程效果差。



6. 结果分析与经验总结

本组采用的卷积神经网络对基于时间的退化指标进行训练的过程中观察到一定的过拟合现象，但未进行详细原因分析。后续可在原始数据的滤波，数据清洗，退化指标的滤波进行改进，并尝试融合刀具物理模型进行剩余寿命预测。

7. 参考文献

[1] Kline W A, DeVor R E. The effect of runout on cutting geometry and forces in end milling[J]. International Journal of Machine Tool Design and Research, 1983, 23(2-3): 123-140.

[2] Zhu K, Liu T. Online tool wear monitoring via hidden semi-Markov model with dependent durations[J]. IEEE Transactions on Industrial Informatics, 2018, 14(1): 69-78.

[3] Zhu K, Mei T, Ye D. Online condition monitoring in micromilling: A force waveform shape analysis approach[J]. IEEE Transactions on Industrial Electronics, 2015, 62(6): 3806-3813.

[4] Zhou J H, Pang C K, Zhong Z W, et al. Tool wear monitoring using acoustic emissions by dominant-feature identification[J]. IEEE transactions on instrumentation and measurement, 2011, 60(2): 547-559.

（五）基于 DWT-LSTM 网络的刀具剩余使用寿命预测

1. 团队介绍

团队名称：秋裤 ers

| 成员姓名 | 团队角色 | 职位 |
|------|------|-------|
| 刘重党 | 组长 | 博士研究生 |
| 姚荣 | 组员 | 硕士研究生 |
| 牛家禾 | 组员 | 硕士研究生 |

刘重党：清华大学自动化系 2016 级博士研究生，研究兴趣为机器学习，故障预测与健康管管理。在本次比赛中担任队长，负责特征选择，预测算法设计与开发；

姚荣：清华大学自动化系 2017 级硕士研究生，研究兴趣为深度学习，故障诊断。在本次比赛中负责 RUL 预测算法设计与开发；

牛家禾：清华大学自动化系 2017 级硕士研究生，研究兴趣为集成学习，树模型，故障预测。在本次比赛中负责数据清洗与预处理，特征提取等工作。

2. 背景简介与文献调研

作为计算机数控设备的主要部件，加工工具的健康管理在工业生产中备受关注。刀具磨损破裂等失效会对产品质量、设备效率、生产成本等造成较大影响。此外，刀具不可预测的健康状况也会对加工设备的其它部件带来影响，从而造成整个加工流程的不稳定。随着物联网技术的发展，更好的传感技术有望实现对刀具运行过程的实时监测。基于监测数据对加工刀具进行剩余使用寿命的预测，有助于对刀具进行预测性维护，从而提高其运维效率与加工效率。

3. 数据解析

3.1 数据预处理

数据主要分为 PLC 数据 (time、spindle_load、x、y、z) 与传感器数据 (vibration_1、

vibration_2、vibration_3、current_1、current_2、current_3) , 其中传感器的数据可分为振动量与电流量两类。

在数据采样频率方面, PLC 信号采样频率为 33Hz, 震动传感器采样频率 25600Hz, 因此需要首先对二者的数据在时间维度上进行对齐。在初期本文采用的方案为: 将每个刀具 PLC 中对应于每个 csv 的数据与 Sensor 中对应的 csv 的数据均平均分为 600 份(每份对应的时间约为 0.1 秒), 对每一份中的数据区段提取相关特征。最终将每个刀具中 Sensor 的数据与 PLC 的数据组合为 $600 \times k \times n$ 的矩阵。其中 k 为 csv 的个数; n 为提取的特征的数目。

由于每个 csv 中的数据为每 5 分钟任取 1 分钟的片段数据, 在训练集进行 RUL 标注时, 本文采用该 5 分钟的期望值作为整个 csv 的标注。如训练集每把刀具的最后一个 csv 文件对应的 RUL 值应为 2.5 分钟。

考虑到 PLC 数据与 Sensor 中数据对齐之间存在误差, 即某一负载值区段(PLC 中的数据)对应的振动与电流信号区段(Sensor 中的数据)并不能严格对齐。因此本文针对采用 PLC 中的数据和仅采用 Sensor 中的数据两种情况分别进行 RUL 预测实验。

其次本文对原始数据中的异常值进行了清洗。如其中的电流量等偶尔会出现非正常极大值与非正常极小值(绝对值大于 10^{-10}), 这些值会影响对该片段数据的统计量的提取。因此本文舍弃了包含该种异常值的行(本文以绝对值 10^2 为界限进行异常值的划分)。

3.2 特征提取与选择

图 1-3-31 为特征提取与选择的主要流程。其主要可分为三个步骤:

(1) 将预处理后的数据进行分片(每个 csv 中的数据分 600 片), 对每片数据进行时频信息提取, 主要采用三种方法: 离散小波变化(DWT)^[1]、小波包分解(WPD)^[2]、经验模态分解(EMD)^[3]。

(2) 对每片数据提取 16 个特征量。并通过斯皮尔曼系数、单调性、自相关性三种属性进行特征筛选。

(3) 通过自编码器对筛选后的特征进行非线性降维, 最终得到的结果用于模型训练。

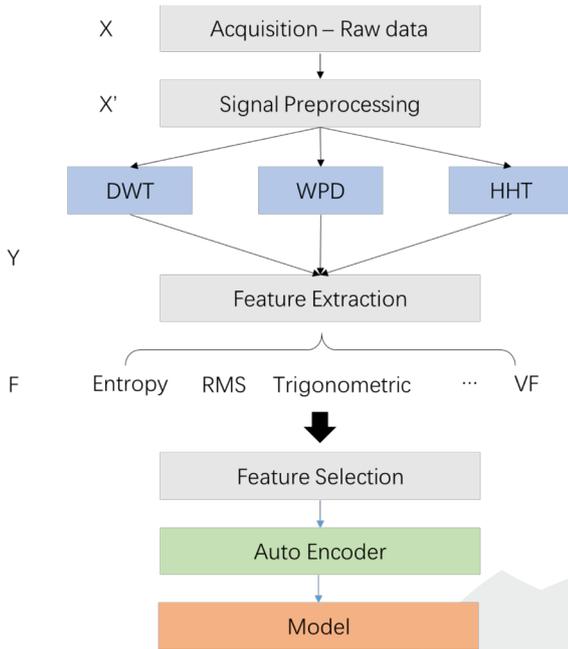


图 2-5-1 特征选择与提取框架

对于时频信息提取后的数据，本文针对每段数据提取以下 16 个统计量作为预选特征。详情见表 2-5-1。

表 2-5-1 提取的统计特征

| | | | |
|-----|--|------------------|---|
| MV | $x_1 = \sum_{i=1}^N y(i)/N$ | MF | $x_9 = x_5/x_3$ |
| MES | $x_2 = \sqrt{\sum_{i=1}^N (y(i) - x_1)^2}/N$ | RMSF | $x_{10} = \sqrt{\frac{\sum_{i=2}^N \dot{y}^2(i)}{4\pi^2 \sum_{i=1}^N y^2(i)}}$ |
| SMR | $x_3 = \left(\sum_{i=1}^N y(i) \right)^2/N$ | RVF | $x_{11} = \frac{\sum_{i=2}^N \dot{y}^2(i)}{4\pi^2 \sum_{i=1}^N y^2(i)} - \frac{\sum_{i=2}^N \sum_{i=2}^N \dot{y}(i)y(i)}{2\pi \sum_{i=1}^N y^2(i)}$ |
| RMS | $x_4 = \sqrt{\sum_{i=1}^N (y(i))^2}/N$ | σ (asinh) | $x_{12} = \sigma(\log [y_i + (y_i^2 + 1)^{1/2}])$ |
| MA | $x_5 = \max y(i) $ | σ (atan) | $x_{13} = \sigma\left(\frac{i}{2} \log \left(\frac{i+y_j}{i-y_j}\right)\right)$ |
| SF | $x_6 = \sum_{i=1}^N \frac{(y(i) - x_1)^3}{(N-1)x_2^3}$ | Energy | $x_{14} = \sum_{i=1}^N y(i)^2$ |
| KF | $x_7 = \sum_{i=1}^N \frac{(y(i) - x_1)^4}{(N-1)x_2^4}$ | Kurtosis | $x_{15} = \frac{\sum_{i=1}^N (y(i) - x_1)^4}{(N-1)\sigma^4}$ |
| CF | $x_8 = x_5/x_4$ | Entropy | $x_{16} = -\sum_{i=1}^K p(y_k) \log_b p(y_k)$ |

针对三种信息分解方法后提取出的特征，本文通过如下三种指标进行特征选择：

Spearman's coefficient

$$R_s(x_i) = \frac{|\sum_{j=1}^N (t_j - \bar{t}_j)(x_i(t_j) - \bar{x}_i)|}{\sqrt{\sum_{j=1}^N (t_j - \bar{t}_j)^2 \sum_{j=1}^N (x_i(t_j) - \bar{x}_i)^2}}$$

其中 t_j 表示时间序列， x_i 表示第 i 维特征。

(2) Autocorrelation

$$R_a(x_i) = \frac{\sum_{i=1}^N (x_i(t_j) - x_i(t_{j-1}))^2}{N}$$

(3) Monotonicity

$$R_M(x_i) = \frac{1}{N-1} \left| \sum_{i=1}^N \delta(x_i(t_{j+1}) - x_i(t_j)) - \sum_{i=1}^N \delta(x_i(t_j) - x_i(t_{j+1})) \right|$$

其中 $\delta(\cdot)$ 为单位阶跃函数。

最终本文选择每个指标的前 30 个属性，将三种指标筛选结果的并集作为优质特征合集，进一步采用自编码器进行降维。

4. 方法

4.1 技术路线

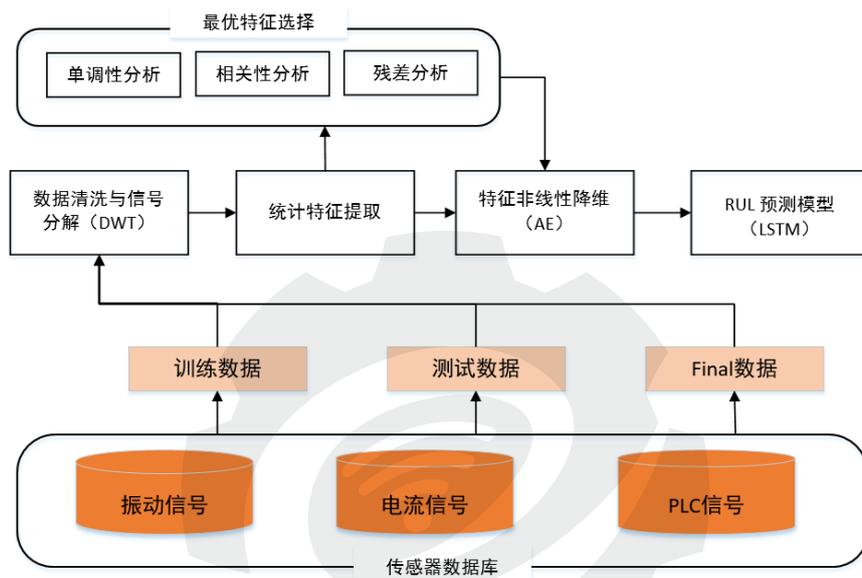


图 1-3-32 刀具 RUL 预测技术路线

本文基于 CPS 框架收集控制器 (PLC) 和外置传感器 (Sensor) 收集的加工过程中的工况信息和传感器数据, 构建刀具磨耗状态评估与寿命预测模型, 以诊断刀具的磨耗状态, 图 1-3-32 给出了刀具寿命预测的技术路线。首先, 基于已有的传感器数据构建训练集与测试集, 进行数据清洗, 包括去噪、异常值剔除、数据结构整理等操作。得到清洗后的数据并用离散小波分解 (Discrete Wavelets Transform, DWT) 进行信号分解, 从而获得时频信号。接着根据时频信号提取系列统计特征, 如均值、中值、方差、能量、RMS 等。统计特征获取后, 利用单调性、相关性、残差等分析方法进行最优特征选择, 从而得到性能较优的特征集合。然后, 基于自编码器对获取的特征集合进行非线性降维, 实现有效特征再提取并减少计算复杂度。最后, 利用长短期记忆网络 (Long Short-Term Memory, LSTM)^[4] 对刀具的剩余寿命进行预测。

总的来说, 本方法具有如下几点技术亮点:

- (1) 使用了 DWT 进行信号分解, 获得时频信息, 进而提取系列统计特征;
- (2) 利用单调性、相关性、残差等分析方法进行最优特征选择;

(3) 利用自编码器进行非线性降维；

(4) 利用对序列数据更加敏感的 LSTM 对刀具 RUL 进行预测。

另外，由于预测模型主要分析振动信号，因此除刀具以外，模型对于轴承、齿轮等机械部件也具有一定的泛化能力。

4.2 预测模型 -LSTM

长短期记忆网络 (LSTM) 是一类特殊的循环神经网络 (Recurrent Neural Network, RNN) 结构，在传统 RNN 中，每一个循环的神经网络单元表现为简单的链式结构，例如只有一个 tanh 层。因此传统 RNN 结构中一个单元接收到 t 时刻的网络输入 x_t ，并输出一个值 h_t ，RNN 的循环结构允许信息从一个网络状态转移到下一个网络结构，是一类经典的链式结构。RNN 已经被证明了在一些经典序列数据如文本、语言等数据上有着良好的表现。但是值得注意的是，由于在 RNN 的单元之间只有状态信息的传播，所以其不同单元之间的关联信息始终是有限的，某个单元能够使用的之前时刻的单元信息始终是有限的，这个问题被称作长期依赖问题，长期依赖问题的出现也直接催生了 LSTM。

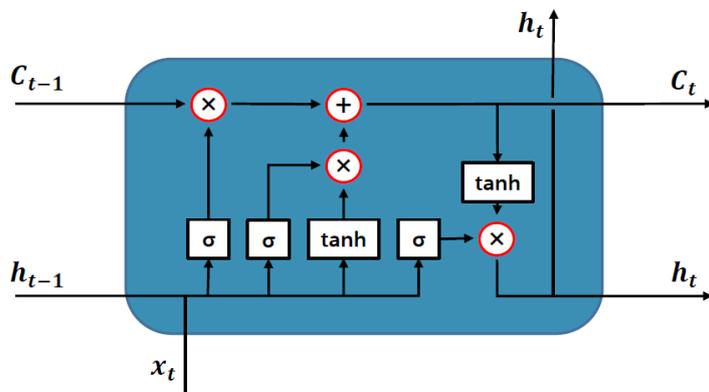


图 1-3-33 LSTM 的单元结构

如图 1-3-33 所示， x_t 、 h_t 和 C_t 分别表示第 t 个单元的输入、输出和状态信息。为了解决长期依赖问题，LSTM 在 RNN 的基础上，引入了门结构以实现不同单元之间的信息更好地传递，包括遗忘门、输入门和输出门。其中遗忘门实现了对于上一个单元状态信息的信息丢弃，输入门决定哪些信息会参与新单元状态的计算；而输出门则决定了单元的输出信息。由于门结构的引入，LSTM 的单元之间的信息传递变得更加科学，换言之，LSTM 有了“记忆”的能力，从而在一些时序数据上的处理上表现出了更加优异的性能^[5]。在本项目中，虽然在上一步中进行了特征的提取，但是得到的依旧是时序上的数据，非常适合 LSTM 的应用。

本文采用了 LSTM 对得到的特征进行处理，在 LSTM 的输出层后连接了两层的全连接网络，用于最终的剩余使用寿命预测，作为最终的输出结果。

5. 验证

除了上述剩余使用寿命预测方法以外，作为探索，本文同样采用了 LGBM，双向 LSTM 和支持向量回归算法（Support Vector Regression, SVR）对数据进行了训练。在算法对比实验过程中，本文选取了三把刀具中的第二把刀具数据作为测试集，其他两把刀具作为训练集，对几种算法进行测试，计算第二把刀具的退化过程中各个时刻的平均 RUL 预测得分 score，其定义如下：

$$\bar{S} = \frac{1}{T} \sum_{t=1}^T S(x_t, \hat{x}_t)$$

其中， $S()$ 表示 RUL 计算中定义的 score 计算函数， x_t, \hat{x}_t 分别表示 t 时刻的真实 RUL 值以及算法预测得到的 RUL 值，通过比较各个算法在测试集得到的平均得分，本文最终选定了 LSTM 作为最终的机器学习算法模型，并应用于最终的测试集进行 RUL 预测。

6. 结果分析与经验总结

在参加本次比赛的过程中，收获颇丰，但是也有诸多不足之处。未来方法可由如下几个改进方向：

第一，提升对数据的利用度，如 PLC 数据；在 PLC 数据当中，包含了 x, y, z 三维空间上的数据，其中蕴含了刀具的走刀路径等，根据其可对工况等进行分析，在本次比赛当中由于时间问题，没有对这些数据进行分析与利用；

第二，尝试引入多层 LSTM 网络，增强预测模型的长时间依赖性；

第三，可采用物理模型与混合模型的方法构建表征刀具磨损状态的健康因子（Health Index）。

另外，值得一提的是，经过实验分析发现，电流信号的加入并没有提高模型预测性能。

模型训练和预测过程中所采用的硬件资源及计算时间如下：

| | |
|-----|----------|
| CPU | I9 7940X |
| GPU | TITAN XP |
| 内存 | 128G |

计算速度:

| | |
|-------|--------------------|
| 数据预处理 | 30 ~ 40s (单个 csv) |
| 非线性降维 | 30 ~ 71s |
| 模型训练 | 240 ~ 300s |
| 模型预测 | 1 ~ 2s (单把刀具) |

7. 参考文献

[1] Javed K , Gouriveau R , Zerhouni N , et al. Enabling Health Monitoring Approach Based on Vibration Data for Accurate Prognostics[J]. IEEE Transactions on Industrial Electronics, 2015, 62(1):647–656.

[2] Benkedjough T , Medjaher K , Zerhouni N , et al. Health assessment and life prediction of cutting tools based on support vector regression[J]. Journal of Intelligent Manufacturing, 2015, 26(2):213–223.

[3] Wu J , Su Y , Cheng Y , et al. Multi-sensor information fusion for remaining useful life prediction of machining tools by adaptive network based fuzzy inference system[J]. Applied Soft Computing, 2018, 68:13–23.

[4] Hochreiter S, Schmidhuber J. Long short-term memory.[J]. Neural Computation, 1997, 9(8):1735–1780.

[5] Zhang P, Xue J, Lan C, et al. Adding Attentiveness to the Neurons in Recurrent Neural Networks[J]. arXiv preprint arXiv:1807.04445, 2018.

第二篇章 第三届工业大数据创新竞赛

一、第三届竞赛赛题介绍

大型旋转机组，如压缩机、蒸汽汽轮机、燃气轮机等是流程工业如能源、化工、发电等行业的核心装备。因设备高速旋转、动能巨大，转子部件脱落故障给设备安全运行带来巨大威胁。由于部件脱落而导致的机组多级动静叶片 / 叶轮损伤的维修成本高、耗时长，因此而造成企业经济效益的重大损失。转子部件脱落的早期征兆难以捕捉，是故障预测的世界性难题。如果能通过大数据方法，实现此故障征兆的早期发现和程度预测，将带来显著的安全价值和经济效益。

此次竞赛的比赛任务主要分两步：

第一步：根据训练数据所训练出的模型，识别哪些机组有转子部件脱落故障征兆；

第二步：根据故障征兆强度，对数据进行时间先后排序。

数据描述：本次竞赛所使用的数据来自大型透平旋转机组一般采用承载力强的滑动轴承。机组出厂时会在转子两端轴承位布置 2 对电涡流位移传感器，用来测量转子径向振动，图 2-1-1；在轴端布置 2~3 支电涡流位移传感器用来测量转子轴向振动、位移值，图 2-1-2。

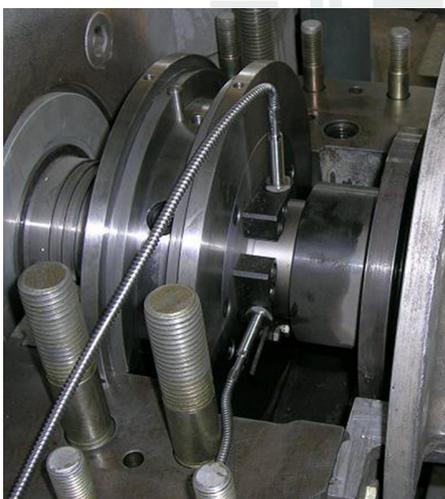


图 2-1-1

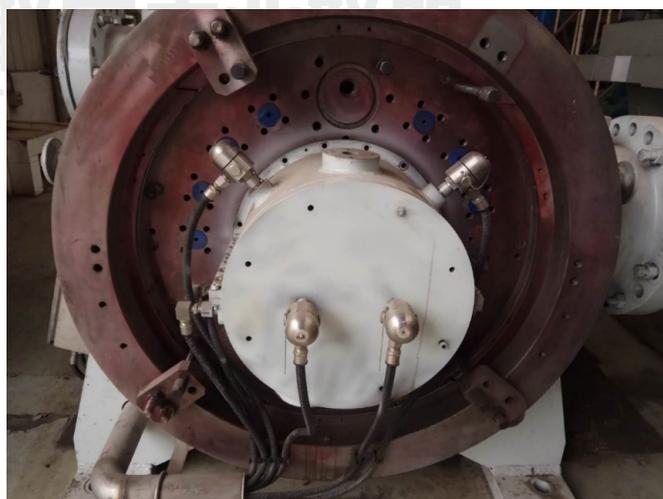


图 2-1-2

电涡流位移传感器信号接入 SG8000 数据采集器进行数据调理、采集与存储。

数据字段：

- Cycles: 转子转动的周数，
- Speed: 转速 (RPM Round per Minutes) ，
- Samples: 总采样点数，
- Wave: 波形数组

初赛训练数据描述：第一阶段的竞赛提供了 5 台机组的数据，其中有 2 台故障机组 M1, M2 是发生转子部件脱落故障之前半年内的数据。另外 3 台机组 M3, M4, M5, 在获取数据之后的至少一年以上，未发生此类故障。数据文件夹名称：M1a~M5e（角标表示距离故障发生的时间的远近不同，依照字母顺序，a 表示数据采集自临近故障发生时，“e”表示数据采集自故障发生前较久远时）

| Time to fault Unit name | Near to fault | Fault development period | | | Far from fault |
|----------------------------|---------------|--------------------------|-----|-----|----------------|
| | | M1b | M1c | M1d | |
| M1 | M1a | M1b | M1c | M1d | M1e |
| M2 | M2a | M2b | M2c | M2d | M2e |
| M3 | M3a | M3b | M3c | M3d | M3e |
| M4 | M4a | M4b | M4c | M4d | M4e |
| M5 | M5a | M5b | M5c | M5d | M5e |

初赛测试数据描述：共有 5 台机组的数据，每台机组有 5 组数据。数据文件夹名称：M6_1~M10_5

| | | | | |
|-------|-------|-------|-------|-------|
| M6_1 | M6_2 | M6_3 | M6_4 | M6_5 |
| M7_1 | M7_2 | M7_3 | M7_4 | M7_5 |
| M8_1 | M8_2 | M8_3 | M8_4 | M8_5 |
| M9_1 | M9_2 | M9_3 | M9_4 | M9_5 |
| M10_1 | M10_2 | M10_3 | M10_4 | M10_5 |

决赛数据描述：共有 6 台机组的数据。每台机组提供 5 组数据。数据文件夹名称：M11_1~M16_5

| | | | | |
|-------|-------|-------|-------|-------|
| M11_1 | M11_2 | M11_3 | M11_4 | M11_5 |
| M12_1 | M12_2 | M12_3 | M12_4 | M12_5 |
| M13_1 | M13_2 | M13_3 | M13_4 | M13_5 |
| M14_1 | M14_2 | M14_3 | M14_4 | M14_5 |
| M15_1 | M15_2 | M15_3 | M15_4 | M15_5 |
| M16_1 | M16_2 | M16_3 | M16_4 | M16_5 |



评分规则：

假设机组数 = n ；目标数（即有转子部件脱落征兆的机组数） = m

第一步：每个准确的判断得分为 $1/n$ ，第一步结果为 $R_1, R_1=c/n$ 。（ c 为判断正确的个数）

第二步：仅当选中目标机组时的排序输入给分，非目标机组排序得分为零。以单台机组进行给分 S ，根据时间顺序由近至远正确且连续的序列的个数多少给出得分。最临近的一个必须正确，否则得分为零。

| | | | | | |
|-------------|-----|-----|-----|-----|---|
| 正确且连续的序列的个数 | 1 | 2 | 3 | 4 | 5 |
| 得分 S | 0.2 | 0.4 | 0.6 | 0.8 | 1 |

目标机组得分为 $S_1 \sim S_m$

第二步结果为 $R_2, R_2=((S_1+S_2+\dots+S_m))/m$

总分为 R 为两步得分的乘积， $R=R_1 \times R_2$

初赛和决赛的自动评分展示 R_1, R_2 和 R ，以 R 进行排名。

二、第三届竞赛英雄榜

本届大赛开发出诸多针对转子部件脱落故障预测的算法模型，为工业大数据领域的相关研究人员和从业者们提供了重要参考。以下为本届大赛优胜的参赛团队：

赛题：转子部件脱落故障预测

| 奖项 | 团队名称 |
|-----|---------------------|
| 一等奖 | 胡翔（西安因联信息科技有限公司，个人） |
| 二等奖 | Sirius（苏州大学，团队） |
| | 大橘不胖只是壮（华中科技大学，团队） |
| 三等奖 | 南京松树（南京大学，团队） |
| | tea（首尔大学，团队） |
| | xjtupj（西安交通大学，团队） |

工业互联网产业联盟
Alliance of Industrial Internet



三、第三届大赛优秀解法集 —— 转子部件脱落故障预测

针对第三届大赛转子部件脱落故障预测题目，本白皮书共收录了7个团队的优秀解法。这些解法各不相同，各有巧思，充分体现了工业大数据建模的跨学科特点，方法具备较强的借鉴意义。

| # | 方法名称 | 团队名称 |
|---|---------------------------------|-----------------------|
| 1 | 基于 LightGBM 分类算法的转子部件脱落故障识别方法 | 胡翔 (西安因联信息科技有限公司, 个人) |
| 2 | 基于生成对抗网络的转子故障脱落研究方法 | Sirius (苏州大学, 团队) |
| 3 | 基于多模型投票与梯级分类算法的转子部件脱落故障预测 | 南京松树 (南京大学, 团队) |
| 4 | 基于全息故障特征提取的转子部件脱落智能识别方法 | xjtupj (西安交通大学, 团队) |
| 5 | 基于多模型融合的转子部件脱落故障识别方法 | 湃方算法部 (湃方科技, 团队) |
| 6 | 基于变分模态分解与时间-全谱分析的旋转机械转子部件脱落故障预测 | 我在华中大 (华中科技大学, 团队) |
| 7 | 基于多传感器信号变化分析的转子系统异常检测 | tea (首尔大学, 团队) |

(一) 基于 LightGBM 分类算法的 转子部件脱落故障识别方法

1. 团队介绍

团队名称: 18702990538 个人小组

| 成员姓名 | 团队角色 | 职位 |
|------|------|---------------------|
| 胡翔 | 队长 | 西安因联信息科技有限公司工业算法工程师 |

18702990538 个人组是西安因联信息科技有限公司的一名工业算法工程师胡翔。

西安因联信息科技有限公司是一家专注于设备预测性维护领域的工业互联网企业。因联通过提供创新的有线、无线感知产品，实现工业设备智能化在线监测和预测性维护，基于工

业大数据驱动，提供机理模型和数据模型为用户实现智能预警、智能诊断和一系列工业云服务，帮助工业企业提升生产效率、保障安全生产、优化生产决策，助力企业向智能制造升级转型。

胡翔：硕士研究生，毕业于西安交通大学机械工程学院，主要工作集中在工业领域设备的预测性维护算法研究上，在石化、水泥、钢铁行业的设备大数据分析和价值挖掘具备了较多项目实战，尤其是在设备智能预警、智能诊断、性能分析等应用场景上具有较多研究和实战项目经验。针对性解决了工业领域预测性维护部分难点问题，并且发表了多篇发明专利。

2. 背景简介与文献调研

大型旋转机组，如压缩机、蒸汽汽轮机、燃气轮机等是流程工业如能源、化工、发电等行业的核心装备。因设备高速旋转、动能巨大，转子部件脱落故障给设备安全运行带来巨大威胁^[1]。由于部件脱落而导致的机组多级动静叶片/叶轮损伤的维修成本高、耗时长，因此而造成企业经济效益的重大损失^[2]。转子部件脱落的早期征兆难以捕捉，是故障预测的世界性难题。如果能通过大数据方法，实现此故障征兆的早期发现和程度预测，将带来显著的安全价值和经济效益。

大型旋转机组轴系容易发生断裂的部件主要由转子叶片、围带、平衡块和靠背轮上的挡风板等，可分为转子跨度内和背靠轮两种失重类型来考察^[3]。大型汽轮发电机组都配有振动监测保护系统、汽机振动数据采集和故障诊断系统。目前基于振动特征识别脱落故障是主要的分析手段之一，有学者提出利用谐分量平衡法识别转动部件脱落故障，这种方法能精确计算出转动部件脱落故障轴向位置和质量，正确诊断突发性振动故障，并且通过建立旋转机械转动部件脱落振动模型，仿真分析了转动部件脱落位置对轴承振动响应的影响。分析结果表明，转子中部转动部件脱落，主要激发一阶不平衡分量，对临界转速下振动影响较大；转子端部部件脱落，同时激发一阶不平衡分量和二阶不平衡分量，对临界转速与工作转速振动均有较大影响^[4]。据统计目前国产大型机组和国外大型机组中叶片断裂故障几乎全发生在低压缸内，这些故障在诊断和处理过程中容易误判为轴承开裂、开焊或其他故障，即使诊断为叶片断裂，也未必会采取揭缸操作，最后可能导致二次严重事故的发生^[5]。在文献^[6]中提到使用无损探伤技术对大型旋转机组叶片进行故障检测，但是这种检测技术只能在机组停机时进行，应用时有较大的局限性，无法实时在线识别检测。目前对大型机组转子部件脱落，尤其是转子叶片断裂的识别检测，主要还是集中在利用机组的振动监测系统采集的机组转子位移数据进行转动部件脱落的识别和检测^[7]。目前通过有限元仿真技术建立转动部件脱落振

动模型，对转动部件脱落的振动特性进行分析的研究非常普遍，通过仿真分析可以给出转动部件脱落位置对转子振动的影响，并对提取相关振动特征进行分析，为现场机组转子部件脱落振动信号分析提供理论基础^[8]。

3. 数据解析

大型透平旋转机组一般采用承载力强的滑动轴承。机组出厂时会在转子两端轴承位布置 2 对电涡流位移传感器，用来测量转子径向振动，图 2-3-1；在轴端布置 2~3 支电涡流位移传感器用来测量转子轴向振动、位移值，图 2-3-2。

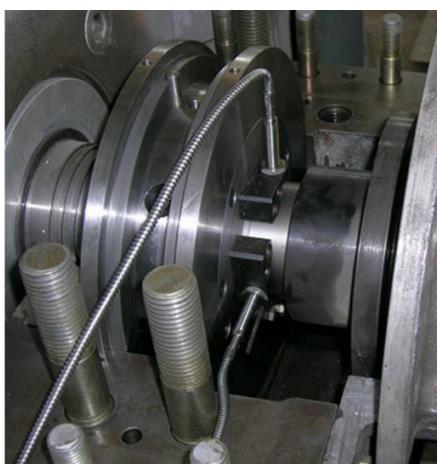


图 2-3-1

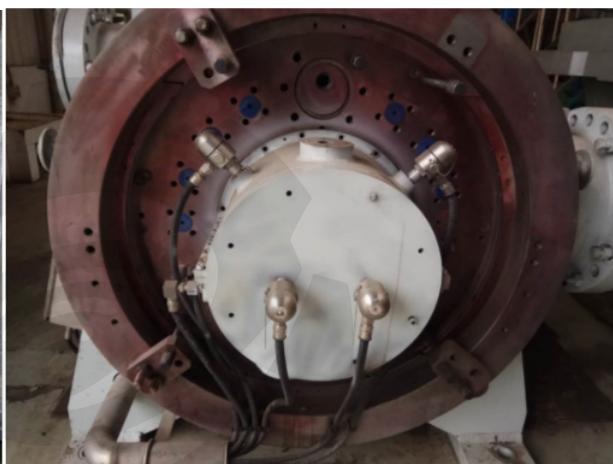


图 2-3-2

机组振动位移数据对应的信息包括转子转动的周数、转速、总采样点数、波形数组。根据所提供的信息可以确定位移振动的采样频率和采样方式（等时间间隔采样或等角度采样）。

第一阶段的竞赛提供了 5 台机组的训练数据，其中有 2 台故障机组 M1，M2 是发生转子部件脱落故障之前半年内的数据。另外 3 台机组 M3，M4，M5，在获取数据之后的至少一年以上，未发生此类故障。

数据文件夹名称：M1a~M5e（角标表示距离故障发生的时间的远近不同，依照字母顺序，a 表示数据采集自临近故障发生时，“e”表示数据采集自故障发生前较久远时）。

| 距故障发生时间 机组名称 | 临近故障发生 | 故障发展期 | | | 距故障发生较久远 |
|-----------------|--------|-------|-----|-----|----------|
| | | | | | |
| M1 | M1a | M1b | M1c | M1d | M1e |
| M2 | M2a | M2b | M2c | M2d | M2e |
| M3 | M3a | M3b | M3c | M3d | M3e |
| M4 | M4a | M4b | M4c | M4d | M4e |
| M5 | M5a | M5b | M5c | M5d | M5e |

测试数据共有 5 台机组的数据，每台机组有 5 组数据。数据文件夹名称：M6_1~M10_5。

| | | | | |
|-------|-------|-------|-------|-------|
| M6_1 | M6_2 | M6_3 | M6_4 | M6_5 |
| M7_1 | M7_2 | M7_3 | M7_4 | M7_5 |
| M8_1 | M8_2 | M8_3 | M8_4 | M8_5 |
| M9_1 | M9_2 | M9_3 | M9_4 | M9_5 |
| M10_1 | M10_2 | M10_3 | M10_4 | M10_5 |

决赛提供 8 台机组的数据。每台机组提供 5 组数据。

决赛需要判断 8 台机组那些机组存在转子部件脱落故障，对存在转子部件脱落的机组还需要对提供的数据依据脱落故障的严重程度进行排序。

测试数据可供进行算法模型的调试，在决赛阶段可以作为训练数据加入算法模型增加训练数据量，提升算法模型的准确度。

4. 方法

4.1 线路路线

基于对赛题的分析和理解，为解决赛题划定目标可将问题分解为两个。

①是检测转子部件是否脱落？②是若存在故障，需要识别故障征兆强度，以此对所提供的机组数据进行排序。问题①可看成二分类问题。问题②可看成分类概率大小排序问题。

选择分类概率大小作为故障征兆大小的依据在于：

(1) 相比较于基于特征融合形成单一故障指标进行故障判别和故障强度识别的方法，本方法本质特点在于数据驱动，而特征融合适合简单故障机理，并不适合此次转子部件脱落的复杂机理。

(2) 相较于通过机器学习回归算法对数据进行训练和预测的方法，由于需要对训练数据赋予严重程度标签，但是由于提供数据存在中断，导致标签过少，回归算法预测效果不佳。

因此利用分类概率大小作为故障征兆强度指标，是最符合所提供数据集的特点的一种解决方法。

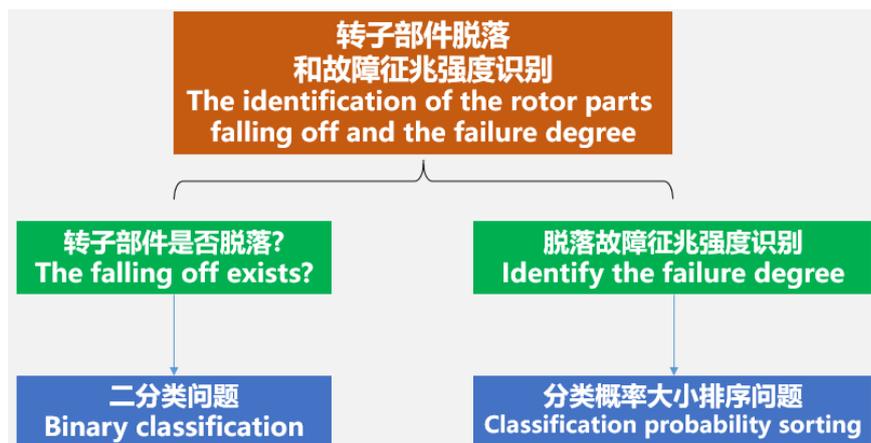


图 2-3-3 技术路线

4.2 数据预处理

预处理主要包括数据的整合和数据的可视化。

由于提供数据测点名称不一致，测点数据也不一致，所以第一步对数据进行了标准化整理，将测点名称标准化；第二步是对振动位移数据进行可视化分析，考虑到大机组的振动采样特性和典型的位移振动分析方法特点，通过总采样点与转子旋转周数相除得到了采样频率为每转 32 点（等角度采样），获取采样频率后利用 FFT 变换获取位移振动阶次谱，观察故障样本和正常样本阶次谱的区别差异，为特征提取提供方向。

(1) 分析故障机组和无故障机组的阶次谱发现，故障机组的阶次谱较无故障机组的一倍转频幅值明显偏大，且一倍频在阶次谱能量中占据主导，见图 2-3-4。在阶次谱中提取了 1 倍转频，2 倍转频，3 倍转频等特征，并观察这些特征在有故障机组和无故障机组中历史趋势，进而选择有效特征；

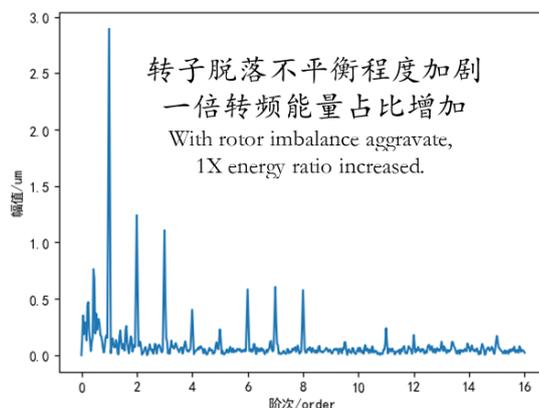


图 2-3-4 一倍转频在转子脱落故障中变化特性

(2) 根据转子在两个相互垂直的方向 X 向和 Y 向的位移振动，合成轴心轨迹，发现无故障机组轴心轨迹在各个时段几乎没有较大变化如图 2-3-5，而出现转子部件脱落故障机组的轴心轨迹在各个时段经历较大变化。

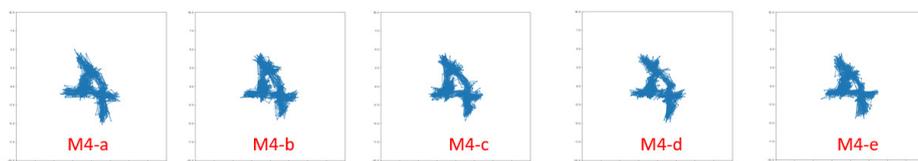


图 2-3-5 无故障机组各时段典型轴心轨迹

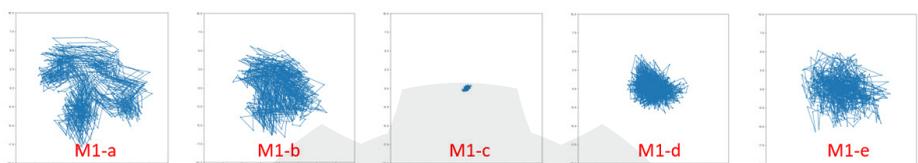


图 2-3-6 故障机组各时段典型轴心轨迹

4.3 特征提取

对所有机组的转速特征进行分析发现，部分设备的转速中存在转速不变情况，转速为恒定值。查阅相关资料发现，从大型机组工作机理出发，在机组实际运行过程中不存在转速完全无波动情况。因此可定义转速恒定的数据为异常数据，需要删除，避免干扰和影响正常运行数据建立的分类模型。

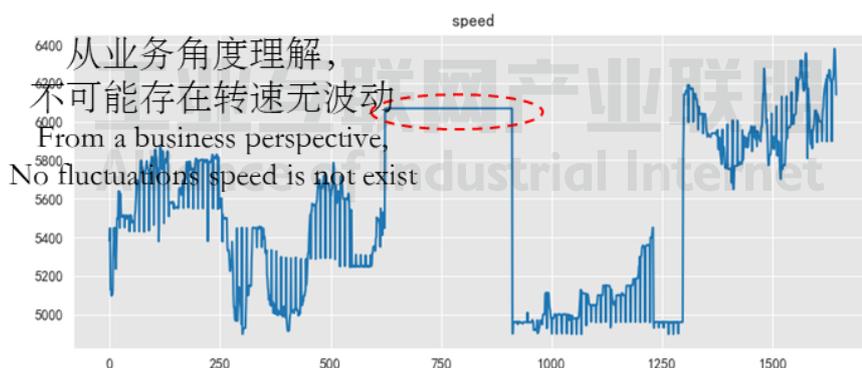


图 2-3-7

根据对带标签的训练数据进行分析发现，位移振动阶次谱中，一倍转频能量及其占比对故障具有较高的区分度。因此针对振动时域数据和频域数据进行两大类特征提取。位移振动时域中，提取了位移振动的峰峰值作为特征；位移振动频域中，提取了 1 倍转频、2 倍转频、

3 倍转频的幅值，以及 1 倍转频、2 倍转频、3 倍转频占位移振动总能量的百分比。

4.4 预测算法

在算法选择方面，我选择了 LightGBM 算法作为转子部件脱落的预测算法。相比较其他分类算法，LightGBM 具有高效并行的优势，同时 LightGBM 使用 GBDT 框架，在分类和回归问题中具有非常高的准确度。LightGBM 提出的主要原因就是为了解决 GBDT 在海量数据遇到的问题，让 GBDT 可以更好更快地用于工业实践。在防止模型过拟合方面，LightGBM 在 Leaf-wise 之上增加了一个最大深度限制，在保证高效率的同时可以防止过拟合。基于上述考虑，选择了 LightGBM 作为建立单模的算法。

5. 验证

将数据集随机采样分为 5 份，任选 4 份做训练，1 份为测试，进行 5 折交叉验证。整个验证过程其实很简单，与传统机器学习验证方法并没有太大区别。唯一需要注意的是，划分训练集和验证集需要保证各个类别的数据量保持平衡，这样才能保证建立的模型没有偏差。

二分类问题中最大挑战在于数据集的划分，如何选取训练数据集，对结果的影响非常之大。最后选取了最接近故障时间的数据作为二分类的正例数据进行训练。这样选取的原因是，理论上转子部件脱落故障征兆在最接近故障发生时刻表现最强，因此最接近故障时间的数据与实际故障数据是最相似的。在分类概率大小排序问题中，最大的挑战在于如何筛选特征，因为特征的选择关系到模型的性能结果和模型泛化能力，考虑到目标是区分故障征兆强度，对于机械部件故障来说越接近故障发生时刻，征兆的表现也越强，因此特征若是与故障时间呈现较强的单调性，它能区分故障的能力也就越强，也越能区分故障处于哪个阶段，综合上述分析选择了故障数据中单调性更强的特征进行建模和预测。

初赛训练集和测试集的划分方式为：将 M1a、M2a 和 M3、M4、M5 作为训练集，M6、M7、M8、M9、M10 作为测试集。决赛训练集和测试集的划分方式为：将 M1a、M2a、M7a、M9a、M10a 和 M3、M4、M5、M6、M8 作为训练集，M11、M12、M13、M14、M15、M16、M17、M18 作为测试集。训练集数据组成特点在于只选取了时间上最靠近故障的 a 组数据（即理论上转子部件脱落故障征兆最强的数据）作为分类的正例，无故障数据作为分类反例。这种训练数据组成方式可以很有效的增强模型对故障机组的识别检测能力，更好的区分了故障与无故障之间的差异。为基于分类概率识别故障机组和故障征兆强度

提供了非常好的建模数据基础。

模型优化方面，首先考虑了对特征的筛选，主要包括两个方面。一是根据特征在故障数据上的单调程度进行筛选，保证特征与故障征兆强度具有正确的相关关系；二是考虑特征在未知工况上的泛化能力，因此剔除了有量纲数据，因为有量纲特征与机组的运行条件具有非常强关联，为了保证建立的模型在不同运行工况条件下能输出一致的结果，因此尽量选择无量纲特征作为建模参数。

6. 结果分析与经验总结

在本次竞赛过程中，我通过查阅文献资料了解了大型旋转机组转子部件脱落引发的振动机理，将主要提取特征参数集中在振动幅值和相对幅值变化上，并且通过机组轴心轨迹的可视化有效掌握了故障演变机理，这些业务知识的理解和分析都对后续的数据预处理、特征工程、特征选择和优化起到了非常关键的作用。根据对赛题所涉及的工业领域业务和机理的分析和理解，最终我将竞赛目标明确为：

- (1) 解决利用机组轴系多个互相垂直测点的位移振动数据识别转子部件是否脱落的分类问题；
- (2) 解决利用机组轴系多个互相垂直测点的位移振动数据识别转子部件脱落故障征兆强度的分类概率大小排序问题。

在实际的分析过程中，首先从整理分析赛题原始数据出发，在合理整理组织原始数据的基础上，通过可视化手段逐个机组查看各个参数变化情况，据此有针对性的对数据进行了清洗预处理，为特征提取建立坚实的分析基础。基于位移振动信号处理方法，我对预处理后的数据进行时域、频域特征提取，将以故障机组中最靠近故障的 a 组数据和无故障机组所有数据作为建模数据，有效的提升了模型对无故障机组的识别能力。

从参加比赛开始到决赛答辩结束，整个过程认识了很多工业届和学术界相关从业者，大家互相交流，收货非常多。在我的工作中和所参与的多个竞赛中，重点工作都在特征工程上。通过多次数据分析经验的积累和总结，我发现凡是区分度明显的特征都是和业务强相关的，这次比赛我尤其注重对问题的业务分析和理解，最终提取了多个区分度强的业务特征，最终获得了第一名的好成绩，更是印证了我的这个想法。

本文所提的方案还存在诸多需要进一步改进的地方，距离可在工业领域商用还存在非常

大的距离。首先第一点是算法模型的精度上需要提升，以满足工业应用的更高要求，这一点上需要更加深入的理解和分析转子部件脱落故障的发生机理，在数据分析上提取出更具区分度和解释力的特征；其次是算法模型并不仅仅只考虑转子部件脱落故障，还需要考虑除此之外的其余故障对算法模型的影响，这是因为工业领域中面临的机组故障往往比较复杂，转子部件脱落的主要表现和质量不平衡高度相似，是否具有其他类型的故障存在并影响现有的分析结果，这需要详尽的分析和论证，只有解决了这个关键问题，现有的算法模型才有可能在工业实际中得到应用。

7. 参考文献

- [1] 田得旺, 王春燕, 宋亚彬, et al. 大型旋转机组的状态监测与故障诊断 [J]. 石油化工自动化, 2007(04):86-89.
- [2] 吕建萍, 田得旺, 王国荣. 大型旋转机组的安全保护 [J]. 石油化工自动化, 2006(05):104-106.
- [3] 黄桥生, 章亚林, 牟申周, et al. 超临界机组低压转子叶片断裂原因分析 [J]. 铸造技术, 2019, 40(04):105-108.
- [4] 童小忠, 应光耀, 吴文健, et al. 汽轮机转动部件脱落故障的识别方法 [J]. 振动、测试与诊断 (5):85-89+169.
- [5] 范春生. 300MW 机组低压转子叶片断裂的故障诊断及振动分析 [J]. 动力工程学报, 2010(01):18-23.
- [6] 王宏星, 葛海华. 650 MW 核电汽轮机低压次末级动叶片根部断裂原因分析与处理 [J]. 机械工程师, 2017(12):171-174.
- [7] 万书亭, 詹长庚, 豆龙江. 旋转机构转子部件脱落的幅值谱研究与变幅信号谱的简单分析 [J]. 科学技术与工程, 2013(21):46-51.
- [8] 田永伟, 尹鹏. 汽轮机旋转部件脱落引起的振动机理研究 [J]. 汽轮机技术, 2014(2):145-146.

(二) 基于生成对抗网络的转子故障脱落研究方法

1. 团队介绍

团队名称: Sirius

| 成员姓名 | 团队角色 | 职位 |
|------|------|-------------------------|
| 戴俊 | 队长 | 苏州大学工业测控与设备诊断技术研究所博士研究生 |

Sirius 队由苏州大学工业测控与设备诊断技术研究所博士研究生组成。苏州大学工业测控与设备诊断技术研究所成立于 2016 年 12 月,是在工业测控及应用、设备诊断和振动噪声控制等研究基础上成立的校级研究机构。研究所的主要针对轨道交通车辆和轨道交通供电系统的科学和工程问题开展研究工作,具体研究方向包括轨道车辆系统测试与控制、高铁关键部件状态监测与故障诊断、深度学习方法及其应用、振动噪声控制和轨道交通供电系统分析等方面。戴俊,博士研究生,主要研究方向是振动信号处理,深度学习方法及其应用。竞赛指导教师:朱忠奎,苏州大学教授、博士生导师,主要研究方向为机械系统状态监测与故障诊断、振动信号分析与处理、车辆系统动力学。王俊,苏州大学副教授、硕士生导师,主要研究方向为机电系统信号处理、状态监测、故障诊断与智能维护。

2. 背景简介与文献调研

大型旋转机组,如压缩机、蒸汽汽轮机、燃气轮机等是能源、化工、发电等行业的核心装备。设备高速旋转、动能巨大,一旦发生转子部件脱落故障将会给设备安全运行带来巨大威胁。为了准确捕获转子系统的健康状态信息,机械健康监测系统需要获取海量监测数据,促使机械健康监测领域进入工业大数据时代,即以传感系统获取监测数据为基础、机器学习积累经验知识为途径、智能判别设备健康状态为目的,来保障机械设备运行的可靠性^[1-3]。

2006 年, Hinton^[4] 在《Science》杂志上发表了关于深度学习的文章,开启了深度学习在学术界和工业界的浪潮,深度学习开始被广泛运用于图像识别、语义分析等方面。为了高效、准确地从机械大数据中挖掘有效状态信息,深度学习在机械故障诊断中也得到了广泛的应用^[5]。卷积神经网络 (Convolutional neural network, CNN)^[6,7]、深度置信网络 (Deep belief network, DBN)^[8-11]、自动编码器 (Auto-encoder, AE)^[12-14] 等网络模型已经应用到机械故障诊断领域。

生成对抗网络 (Generative adversarial network, GAN) 是由 Goodfellow 等人在 2014 年提出的一种新型网络结构^[15], 是一种基于博弈场景的无监督特征学习算法。随着对抗学习思想的不断完善, GAN 已经在图像生成、图像辨识和风格迁移等领域有了较多的应用^[16]。在机械故障诊断领域, GAN 也开始展示出巨大的应用潜力^[17,18]。

3. 数据解析

转子脱落故障预测比赛中所采用的数据集包含径向数据和轴向数据, 其中径向振动数据通过布置在转子两端轴承位 2 对电涡流位移传感器进行采集; 轴向数据通过在轴端布置 2~3 支电涡流位移传感器进行采集。

训练数据集中包含有 5 台机组的数据, 其中机组 M1, M2 是发生转子部件脱落故障之前半年内的数据。另外 3 台机组 M3, M4, M5, 在获取数据之后的至少一年以上, 未发生此类故障, 即正常数据。每一台机组数据中包含有五个文件, 代表机组不同的五个健康阶段。以编号 M1 机组数据为例, 包含 M1a、M1b、M1c、M1d、M1e 五个文件。角标表示距离故障发生的时间的远近, 依照字母顺序, a 表示数据采集自临近故障发生时, e 表示数据采集自故障发生前较久远时。每个阶段又包含三种数据, 即转子联端位移数据、转子非联端位移数据和转子轴向振动数据。每个文件中的信号的数据长度为 1024。

以 M1a 中的数据为例, 具体数据内容如表 2-1 所示:

表 2-1 M1a 文件具体数据内容

| 数据类型 | 文件数 | 包含数据 | 物理意义 |
|--------------|-----|--------|-----------|
| 压缩机联端 X/ Y | 321 | Freq | 采样率 |
| | | Speed | 轴转速 |
| | | Sample | 数据长度 |
| | | Cycels | 数据所包含圈数 |
| | | Wave | 联端径向振动数据 |
| 压缩机非联端 X/ Y | 321 | Freq | 采样率 |
| | | Speed | 轴转速 |
| | | Sample | 数据长度 |
| | | Cycels | 数据所包含圈数 |
| | | Wave | 非联端径向振动数据 |
| 压缩机轴位移 A/B/C | 320 | Freq | 采样率 |
| | | Speed | 轴转速 |
| | | Sample | 数据长度 |
| | | Cycels | 数据所包含圈数 |
| | | Wave | 轴向振动数据 |

4. 方法

4.1 技术路线概述

技术方案从数据处理、生成对抗网络与故障检测三部分进行介绍。转子设备常常服役于重载、高速、高温等复杂环境，其内部零部件不可避免地会出现损伤进而影响到整个系统的正常工作，甚至引起重大事故。在实际工业应用中，机械设备因受设备结构不同、故障发生位置不同等因素的影响，每台机组的旋转特性也各不相同，给故障识别带来困难，如图 2-3-8 是机组 M1, M2 在临近故障时的轴心轨迹图，可以看出临近故障发生时两台机组的旋转特征存在较大的区别。

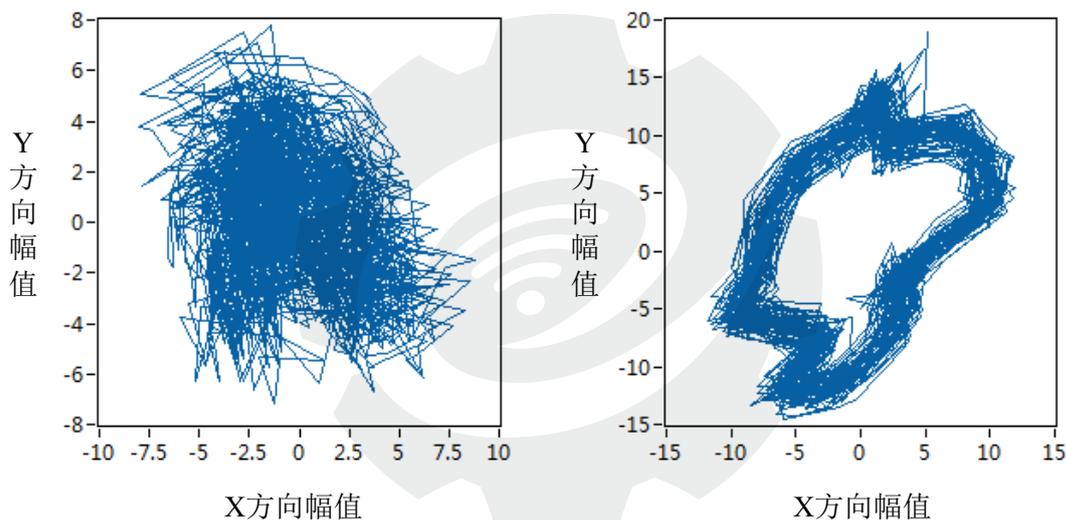


图 2-3-8 机组 M1, M2 的轴心轨迹图

近年来，深度学习理论在特征挖掘、知识学习中所表现出来的优势为机械设备智能运维提供了一个新手段。现有的研究表明：通过深度学习方法进行“特征学习”所得到的特征更能表征设备健康状况，深度学习在特征学习上展现出来的这一优势使得其在机械设备健康状态监测与故障诊断中具有很好的应用前景^[2]。

本技术方案针对每台机组的旋转特性不同的特点，采用生成对抗网络结构来学习样本特征。模型采用转子某一阶段的信号作为学习样本。测试过程中，采用更新随机向量的方法来减少噪声干扰，通过计算其他阶段与训练阶段的差距来判断转子的健康状态并获取不同阶段之间的相对排序，再结合转子轴心轨迹的变化状态给出转子健康状态排序。检测流程图如图 2-3-9 所示。

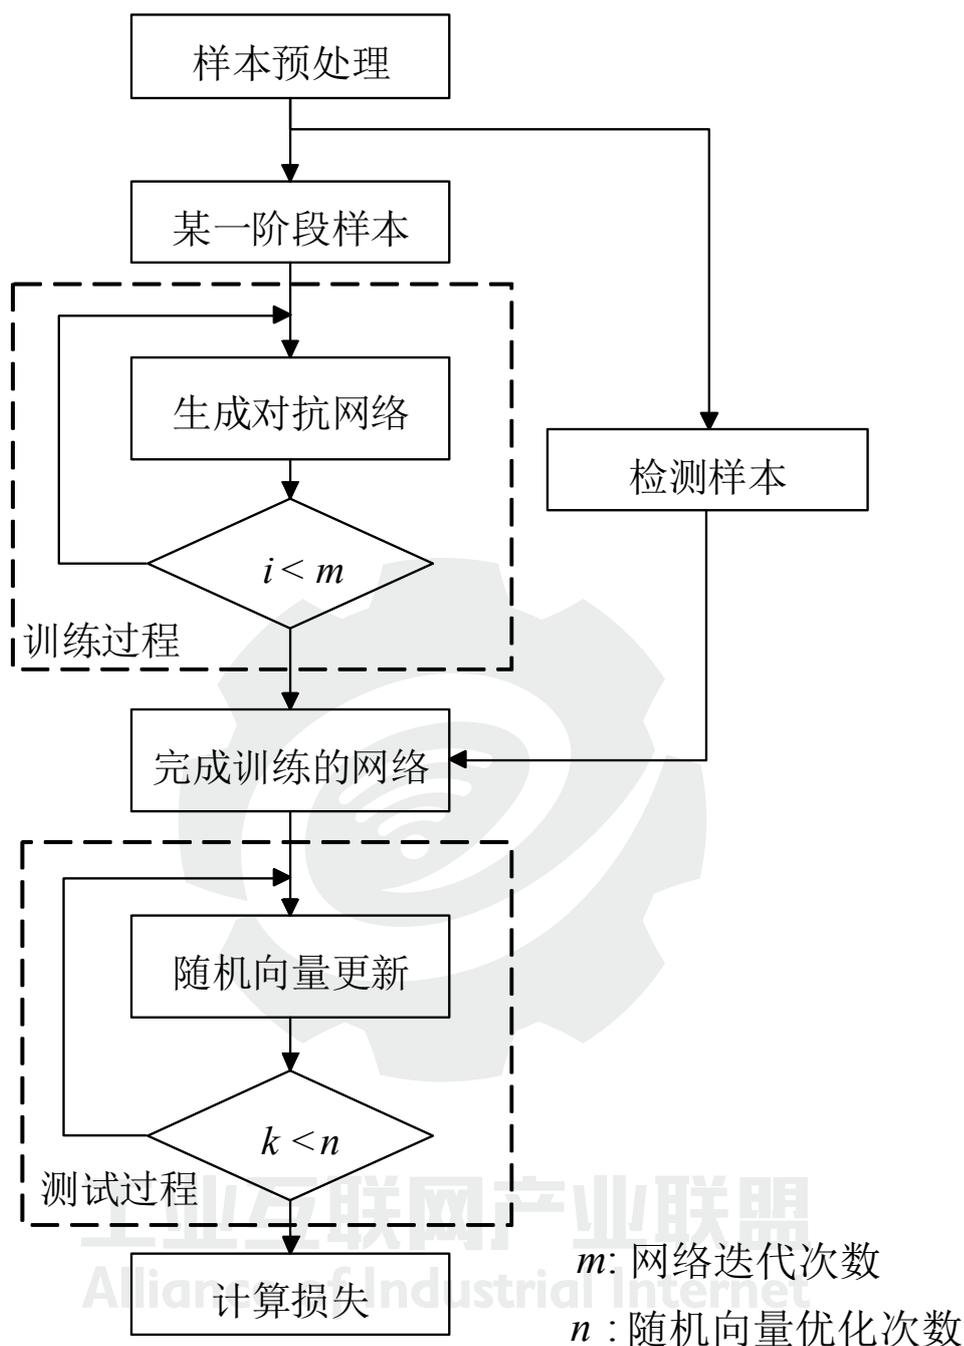


图 2-3-9 检测流程图

4.2 数据预处理

数据处理过程中，为了更好地反映转子的某一时刻的运动状态，数据处理过程中首先将同组的径向振动进行结合（即对 x 方向数据与 y 方向数据进行结合），获得一个长度为 2048 的向量。随后将相邻两个向量合并，从而得到一个长度为 4096 的向量，并将这个向量转换为 64*64 的数值矩阵，以便于后续的网络学习。不同健康状态数值矩阵如图 2-3-10 所示。

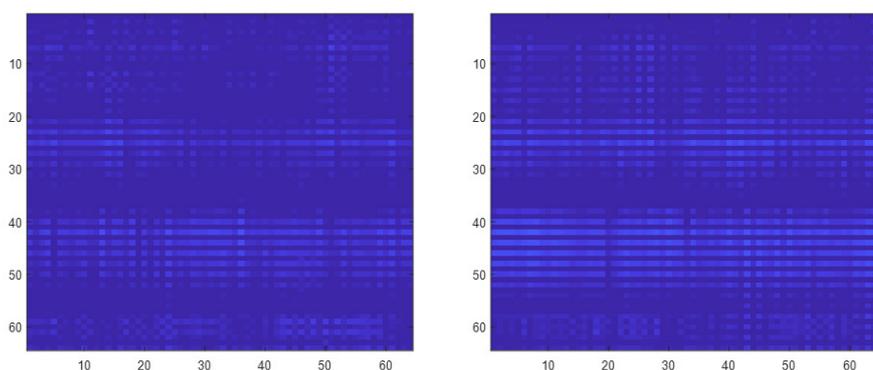


图 2-3-10 同一转子不同健康状态数值矩阵 (M1e, M1a)

4.3 生成对抗网络

基于特征工程的检测模型需要操作者选取一定量的特征参数来进行模型训练，而由于每台机组的旋转特征存在差异，根据这些特征参数训练出的模型很难完整反映每一台机组的健康状态，即存在模型泛化能力不足的问题。

为了避免这个问题，本方案采用无监督学习方法，结合生成对抗网络模型，对每个机组进行细化的模型训练。通过生成网络和鉴别网络对抗训练方法来学习旋转机械某一个阶段振动信号的数据分布，建立诊断模型。检测过程中，当模型输入新的测试信号与训练时所学习的信号有较大差距时，模型参数不适用于新的信号，从而在测试过程中会出现较大的损失，以此实现对机械状态的有效检测。相较于传统方法，本方案中的模型可以针对每一台机械单独建立模型，自适应地从信号中提取特征，提高了检测的准确率。

生成对抗网络由生成网络 G 和判别网络 D 组成，其结构如图 2-3-11 所示。

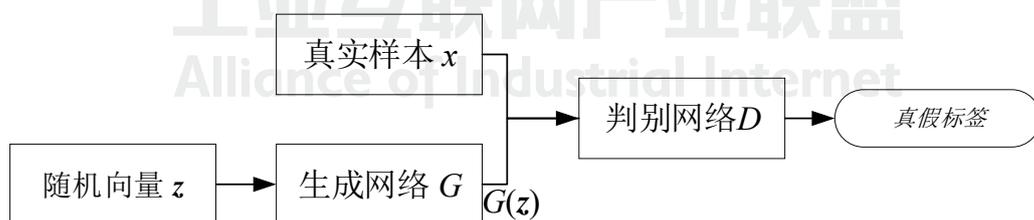


图 2-3-11 生成对抗网络结构

本模型一共包含两个结构：(1) 生成网络，其输入是服从高斯分布的随机向量 z ，生成网络通过对随机向量进行解码，生成伪造的数值矩阵 $G(z)$ ，目的是使伪造的数值矩阵和真实数值矩阵具有相同的维度和相似的数据分布；(2) 判别网络，其输入是真实的数值矩阵 x 和由生成网络生成的伪造矩阵 $G(z)$ ，其作用是对两个矩阵进行鉴别，给出输入来自于真

实数据的概率。

模型在训练过程中，生成网络与判别网络交替更新，对定义的损失函数进行反向传播来优化网络参数。通过固定生成网络，来最小化判别网络损失，使判别网络能对信号的真实性和否给出准确的判别；通过固定判别网络，来最大化判别网络损失，使生成网络生成接近于训练样本的数据分布的伪造信号，以让判别网络无法判断信号的真实性和否。网络优化的目标函数如下：

$$\arg \min_G \max_D V(D, G) = \min_G \max_D \{E_{x \sim p_{data}} (\log D(x)) + E_{z \sim p_z} [\log(1 - D(G(z)))]\}$$

式中， x 代表真实信号的数值矩阵； z 代表随机向量； $D(\cdot)$ 代表判别网络给出其所输入信号来自于真实数据集的概率； $G(\cdot)$ 代表生成对抗网络输出的伪造矩阵。

4.4 故障检测

经过训练后，模型学习到了训练信号的数据分布，此时我通过向生成网络输入一个随机向量可以得到一个和训练数据具有相似数据分布的伪造数据。

检测环节我们采用国外学者 Akcay^[19] 所提出的异常检测方案。首先，我们通过向网络输入一个随机向量，从而得到一个伪造的数值矩阵；其次，我们计算该伪造数值矩阵与我们所检测样本的均方误差损失；再次，我们通过计算出的均方误差损失优化第一步中生成网络所输入的随机向量；最后，经过一定次数迭代后，我们计算优化后数值矩阵和检测样本的均方误差损失。检测方案的结构如图 2-3-12。

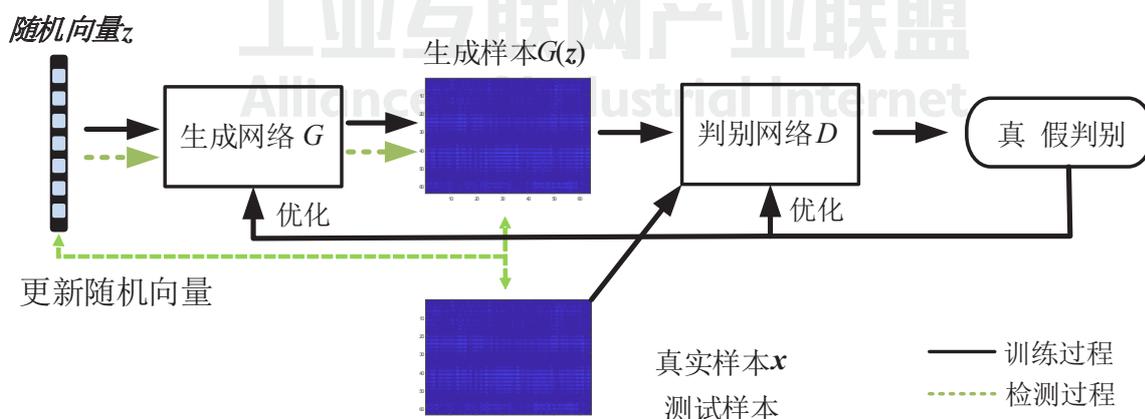


图 2-3-12 检测方案的结构

通过对随机向量进行优化可以减少噪声对测试结果的干扰。由于网络在训练过程中只采用了某一阶段的样本，当其他阶段的测试样本和训练样本差距较小时，网络能准确重建出这一阶段测试样本，因此优化后数值矩阵和检测样本的数值矩阵差距较小；相反，当测试样本和训练样本差距较大时，网络无法准确重建出测试样本，从而实现了异常检测，且两者数据相似度相差越大，计算出的均方误差值也越大，可以据此来给出不同阶段之间的相对排序，再结合转子轴心轨迹图可以判断出故障的先后顺序。

5. 验证

验证部分我们采用 M15 数据进行检测，以 M15_1 文件夹中的数据作为训练数据，通过数据处理一个获得 144 组训练数据。网络内部采用 DCGAN 架构，网络中包含卷积层，批归一化层和激活层。卷积层中卷积核大小为 5×5 ，两个卷积层之间连接批归一化层和激活层，实验中采用 LeakyRelu 激活函数。采用 Adam 优化算法对损失进行反向传播优化网络。检测时，计算所得优化后的生成样本与检测样本之间的均方误差损失，结合信号的轴心轨迹图来对信号进行排序。如图 2-3-13 是归一化后的损失值，图 2-3-14 是 M15 的不同阶段的转子轴心轨迹。

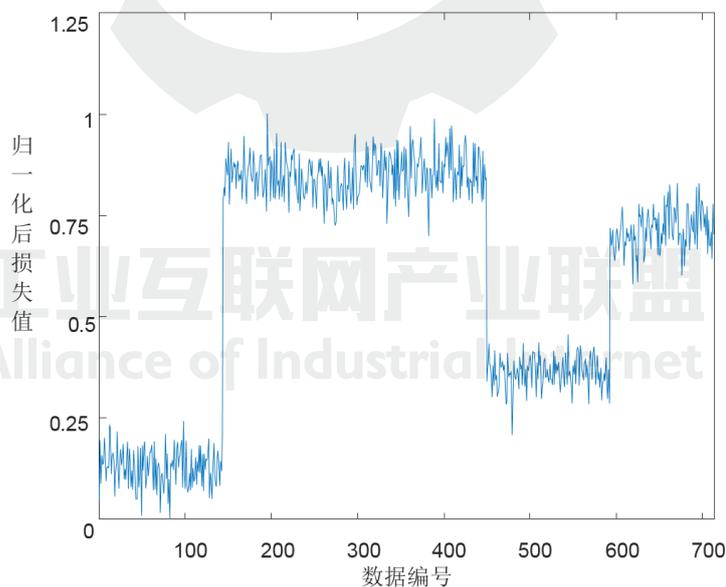
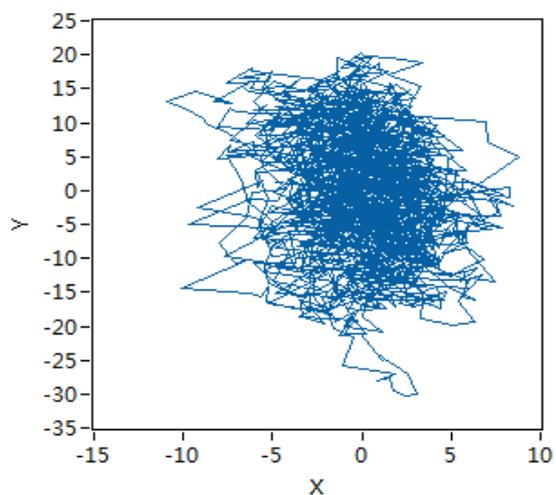
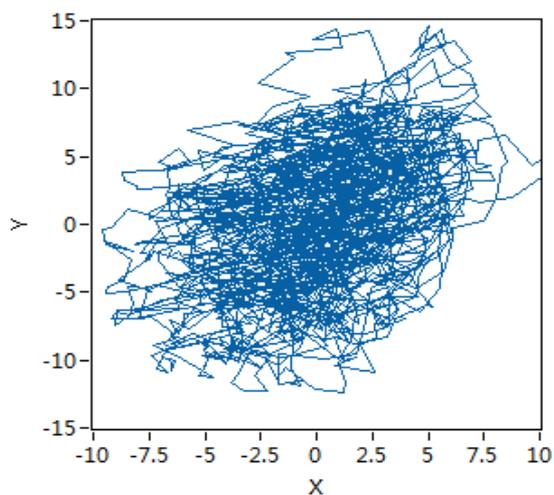


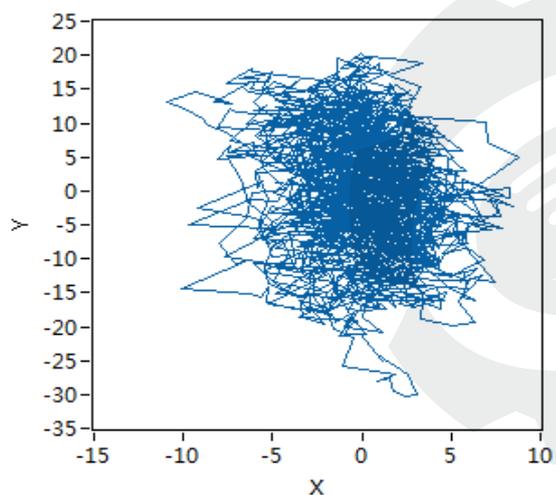
图 2-3-13 归一化后的损失值



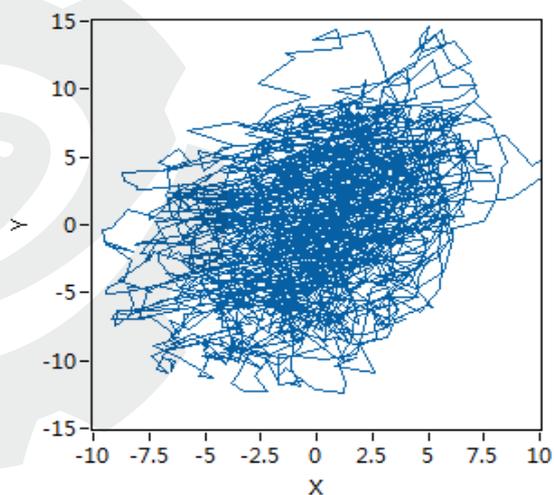
M15-1 轴心轨迹



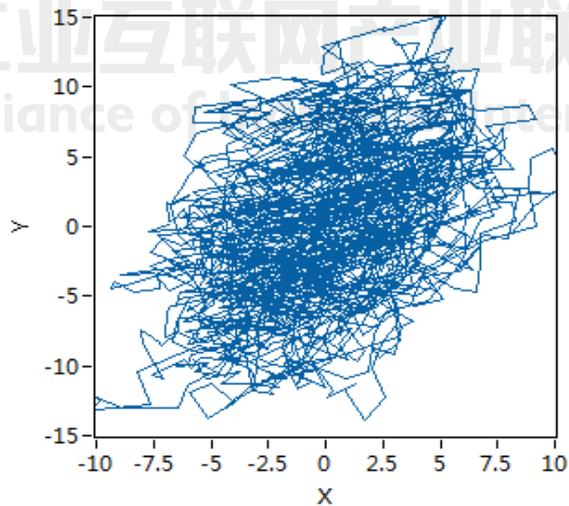
M15-2 轴心轨迹



M15-1 轴心轨迹



M15-2 轴心轨迹



M15-5 轴心轨迹

图 2-3-14 M15 不同阶段的转子轴心轨迹

通过图 2-3-13 可以大致判断, M15-2 和 M15-3 处于相似的健康状态; M15-1 和 M15-4 于相似的健康状态; M15-5 则介于两个状态之间。再结合图 2-3-14 中转子轴心轨迹幅值的变化给出健康状态排序。

6. 结果分析与经验总结

首先非常感谢竞赛主办方提供这个机会, 在竞赛中接触到了实际工业场景中的数据。随着 5G 等信息技术的不断发展, 如何利用工业大数据为产业赋能成为了亟待解决的问题。

相较于以往实验室中所处理的一维振动信号, 此次比赛采用了电涡流传感器的位移数据。对原始数据研究后, 首先考虑到了传统的转子轴心轨迹图, 但是比赛中数据量大, 采用人工分析法很难区别相似的轴心轨迹状态。而基于特征工程故障检测方法需要人为选取信号中的特征, 会带来一定的主观性, 不能保证适用于每台机组。因此在比赛中采用了深度学习的方法, 其原因主要有两个。第一, 深度学习技术在图像领域已经得到广泛运用, 采用数值矩阵的方式可以将故障检测问题转换到图像处理领域; 第二, 深度学习技术相较于特征工程, 可以自适应地从信号提取特征, 避免了人为选取的主观性, 而且采用对每台机组单独建模的方式进一步提高了检测的准确性。

计算中使用 i5-8400 处理器结合 GTX 1060 显卡对模型进行训练, 迭代 500 次耗时约 10 分钟。检测过程中, 每个检测样本检测时随机向量更新 100 次耗时约 1 分钟。

本文提出的方案还有很多可以改进的地方, 例如数据预处理阶段目前工作还比较少, 可以在数值矩阵上进行进一步处理, 来提高检测的准确率。

7. 参考文献

[1] 雷亚国, 贾峰, 周昕, 等. 基于深度学习理论的机械装备大数据健康监测方法[J]. 机械工程学报, 2015, 51(21): 49-56.

[9] 雷亚国, 贾峰, 孔德同, 等. 大数据下机械智能故障诊断的机遇与挑战[J]. 机械工程学报, 2018, 54(5): 94-104.

[10] 陈雪峰. 智能运维与健康管理的[M]. 北京: 机械工业出版社, 2018.

[11] Hinton G, Salakhutdinov R R. Reducing the dimensionality of data with neural networks[J]. Science, 2006, 313(5786): 504-507.

[12] Zhao R, Yan R, Chen Z, et al. Deep learning and its applications to machine health monitoring[J]. Mechanical Systems and Signal Processing, 2019, 115: 213–237.

[13] Liu R, Meng G, Yang B, et al. Dislocated time series convolutional neural architecture: An intelligent fault diagnosis approach for electric machine[J]. IEEE Transactions on Industrial Informatics, 2017, 13(3): 1310–1320.

[14] Jiang G, He H, Yan J, et al. Multiscale convolutional neural networks for fault diagnosis of wind turbine gearbox[J]. IEEE Transactions on Industrial Electronics, 2018, 66(4): 3196–3207.

[15] Tamilselvan P, Wang P. Failure diagnosis using deep belief learning based health state classification[J]. Reliability Engineering and System Safety, 2013, 115(7): 124–135.

[16] Gan M, Wang C. Construction of hierarchical diagnosis network based on deep learning and its application in the fault pattern recognition of rolling element bearings[J]. Mechanical Systems and Signal Processing, 2016, 72: 92–104.

[17] Tang S, Shen C, Wang D, et al. Adaptive deep feature learning network with Nesterov momentum and its application to rotating machinery fault diagnosis[J]. Neurocomputing. 2018, 305: 1–14.

[18] Shao H D, Jiang H K, Zhang H, et al. Rolling bearing fault feature learning using improved convolutional deep belief network with compressed sensing[J]. Mechanical Systems and Signal Processing, 2018, 100: 743–765.

[19] Jia F, Lei Y G, Lin J, et al. Deep neural networks: A promising tool for fault characteristic mining and intelligent diagnosis of rotating machinery with massive data[J]. Mechanical Systems and Signal Processing, 2016, 72–73: 303–315.

(三) 基于多模型投票与梯级分类算法的转子部件脱落故障预测

1. 团队介绍

团队名称：南京松树

| 成员姓名 | 团队角色 | 职位 |
|------|------|---------------|
| 宋哲 | 队长 | 南京大学商学院教授 |
| 申颖君 | 队员 | 南京大学商学院博士研究生 |
| 钮鹏飞 | 队员 | 南京松树科技有限公司程序员 |
| 刘正锋 | 队员 | 南京大学工程管理学院研究生 |

“南京松树”团队由一名教授与三名研究生组成。其中，宋哲教授是南京大学教授、博士生导师，专注于工业大数据分析、机器学习、系统建模和优化相关研究；申颖君，博士研究生，主要研究方向是大数据分析、数据建模和优化分析，本次主要负责特征工程和数据建模；钮鹏飞，南京松数科技有限公司程序员，硕士毕业于英国伦敦政治经济学院数学系运筹与分析专业，研究方向为运筹优化和机器学习，本次主要负责方案设计和建模预测；刘正锋，硕士研究生，主要研究方向为机器学习和大数据分析，本次主要负责数据处理和建模预测。

2. 背景简介与文献调研

大型旋转机组，如压缩机、蒸汽汽轮机、燃气轮机等是流程工业如能源、化工、发电等行业的核心装备。旋转机械故障多发于有转子系统的机械设备在运行过程中出现异常的工作状态，其表现形式多为产生异常的噪声、异常的振动、油温急剧升高等。转子是发动机的主要部件，振动故障在运行过程中最为常见，据统计，发动机故障中有 70% 来自振动故障，其中 80% 来自转子振动故障。转子的振动故障主要包括转子不平衡故障、转子不对中故障、摩擦故障、轴承故障几种，主要表现为机械的运行频率、幅度、方向等发生变化，转子系统故障的特征是多个故障具有相同的征兆，这是由多种原因引起的；并且，旋转机械的结构复杂，故障发生具有一定的阶段性，部分故障的发生有一个渐进的过程。这些特征增加了转子系统状态监测和故障诊断的难度。^[1] 如何在转子振动故障发生之前及时发现故障信息，减少问题的严重性，对整个发动机的健康管理具有特殊的意义，必须及时进行监测、检查和排除，

以提高发动机的可靠性和运行安全。^[1-3]

转子系统振动信号频谱是转子故障诊断的重要信息，振动检测信号中含有振幅、频率、相位角和阻尼比等参数。一般的振动测量是由测振传感器接收的以上参数都是时间的复杂函数，因此，频谱分析是重要的振动信号分析方法。^[4]自1970年来，出现了许多发动机监测诊断系统，基于状态的维护（condition based maintenance）经过数十年的发展，被广泛应用于振动等工业实践中，并扩展为“基于条件的增强维护（CBM+）”，该概念侧重通过在实践中引进先进的维护技术、方法和程序，预测故障以主动排除故障。^[5-6]目前，关于转子故障诊断的方法主要包括以下3种：

（1）基于物理或数学模型的故障诊断

基于模型的方法可以通过形成原理分析并通过残差协作进行故障诊断来重建目标数学模型。该方法是高精度所必需的，它主要用于相对简单的系统中，包括参数估计、状态估计和奇偶空间方法。^[6,7]转子系统动力学模型主要是从系统机理、故障原因和转子系统状态的影响角度出发的物理或数学模型。主要通过安装特定传感器，通过相应的数学或物理变换（如频谱分析、特征值提取等），或直接设定上下阈值，确定转子将要发生故障或发生故障的部位，基于控制图的原理进行异常报警。^[1,8]

（2）基于知识的故障诊断

传统的故障诊断通常是由经验丰富的人员完成的，随着人工智能技术的发展和在转子故障诊断领域的应用。专家系统得到了广泛的应用，专家知识可以被汇总并转化为计算机可以识别的信息，以支持动态扩展，模拟该领域的专家进行故障推理，完成智能故障诊断，它可以大大减少人力和物力的投入。有文献设计了基于故障树和规则的故障诊断专家系统，也有文献提出使用卡尔曼滤波器和遗传算法来诊断故障。^[9]基于知识的方法的主要特征是通过总结和转换专家的先验知识来展示系统，然后基于“知识”详细监测模型故障。^[10]故障树分析和专家系统是基于知识进行故障诊断的典型方法，其无需建立精确数学模型的。

（3）基于大数据分析技术的故障诊断

在2010年以后，大数据、云计算等技术的逐渐成熟，数据挖掘、机器学习和深度学习等技术被广泛应用于工业领域。机器学习算法大致上可以分为有监督学习、无监督学习和半监督学习三种。其中有监督学习算法包括线性回归、决策树、随机森林、支持向量机、人工

神经网络等。无监督学习算法包括聚类算法和关联规则算法。^[5-7,9-11] 目前,使用人工神经网络进行故障诊断的方法有很多,最常用方法是:多层感知器神经网络、BP神经网络和径向基函数 RBF (Radial Bases Function) 神经网络,也有学者将人工神经网络与各种其他方法相结合。^[12-15] 基于大数据分析技术的故障诊断方法目前在许多领域中得到推广和应用。其主要特点是需要收集大量有用的信息,对数据进行预处理,然后进行进一步的数据分析和挖掘,最后对系统故障进行诊断,主要包括统计分析和机器学习。

本质上,故障诊断技术是一种模式分类和识别问题,即将系统的运行状态分为正常和异常两种类型,而异常样本对应于故障状态,因为转子故障诊断是一个分类问题。传统的分类算法包括决策树,逻辑回归,贝叶斯,神经网络等。有人提出利用转子频谱建立决策树分析进行转子故障诊断,考虑到单决策树的抗干扰能力弱,本文在对转动设备的故障时间区间预测使用的算法是随机森林 (RF),它是分类的组合,已经在许多领域得到了广泛的应用。

3. 数据解析

初赛阶段,主办方提供的训练数据包括 5 个机器的数据,其基本特征如表 3-2 所示,从表中我们可以知道机组 M1、机组 M2 是故障机组,机组 M3、M4 和 M5 为未发生故障的机组。每个机组中装载了 6 或 7 个传感器,分别采集转子的径向和轴向位移的相关参数其中,位移测点名称及各测点采集的转子振动参数如表 3-1 所示,可以观察到训练数据中,机组 M2 不含轴位移 C 测点的数据。每个测点监测的数据字段包括转子转动的周数 (cycles)、点数 (samples)、波形数组 (wave)、采样频率 (freq) 及转速 (speed)。根据各机组采集的数组的距离本机器发生故障的时间的远近,分别将临近故障发生时的数据标记为 a,较故障发生较久远的采集的数据标记为“e”,中间的发展期依次标记为“b”、“c”、“d”。

表 3-1. 电涡流传感器位移测点

| 测点号 | 位移测点 | 监测字段 |
|------|------------|------------------------|
| 测点 1 | 非联端 X | 转动周数、采集点数、波形数组、采样频率、转速 |
| 测点 2 | 非联端 Y | 转动周数、采集点数、波形数组、采样频率、转速 |
| 测点 3 | 联端 X | 转动周数、采集点数、波形数组、采样频率、转速 |
| 测点 4 | 联端 Y | 转动周数、采集点数、波形数组、采样频率、转速 |
| 测点 5 | 轴位移 A (波形) | 转动周数、采集点数、波形数组、采样频率、转速 |
| 测点 6 | 轴位移 B (波形) | 转动周数、采集点数、波形数组、采样频率、转速 |
| 测点 7 | 轴位移 C (波形) | 转动周数、采集点数、波形数组、采样频率、转速 |

表 3-2. 初赛训练数据集基本信息

| 机器 | 故障发生时间标签 | | | | 距离故障发生较久远 | 是否故障 | 测点数 |
|----|----------|-------|-------|-------|-----------|------|-----|
| | 故障发生期 | 故障发展期 | 故障发展期 | 故障发展期 | | | |
| M1 | a | b | c | d | e | 故障 | 7 |
| M2 | a | b | c | d | e | 故障 | 6 |
| M3 | a | b | c | d | e | 非故障 | 7 |
| M4 | a | b | c | d | e | 非故障 | 7 |
| M5 | a | b | c | d | e | 非故障 | 7 |

初赛需要测试的数据集是从另 5 台机组 M6 到 M10 上采集的数据，需要根据前 5 台机器的数据训练模型并对 M6 到 M10 的机组是否故障，针对故障机器，需要对其内各组数据距离故障发生的时间正确排序。决赛阶段需要预测 M11 到 M18 一共 8 个机器是否故障及各数组距离故障发生的时间。

通过对原始数据和赛题进行分析，本团队认为竞赛需要实现对机器是否有故障征兆及故障程度进行预测，可以将其分解为两个分类任务：

- (1) 二分类任务：实现对有脱落趋势（有故障）和无脱落趋势（无故障）的机器的分类；
- (2) 多分类任务：对于有故障的机器，实现对数据的故障发生时间段的预测。包括：故障发生期 a、故障发展期 b、故障发展期 c、故障发展期 d 和距离故障发生较久远 e，共 5 个时间阶段的预测。

4. 方法

4.1 “基于多模型投票规则的梯级分类”算法

为实现对机器有无故障二分类和对预测有故障的机器实现距离故障发生时间的正确排序，本团队设计了如下图 2-3-15 所示的“基于多模型投票规则的梯级分类”算法，主要包括预处理、特征工程、二分类问题求解与多分类问题求解四个步骤。首先，在预处理阶段，对训练数据，根据已知标签对来自不同测点的传感器采集的数据进行标签化，将故障机器对应的数据标记为“fault”，未发生故障的机器标记为“normal”，并根据数组距离故障发生的时间，标记时间为“a”，“b”，“c”，“d”，“e”，并实现数据的整合；然后，提取各传感器采集的原始波形数组的统计特征，并对波形数组进行傅里叶变换，并提取傅里叶变换的幅值和相位的相关

统计特征值，然后使用可视化工具、相关性分析等方法进行特征筛选，确定二分类建模预测和多分类建模预测的预测因子；然后，使用 K-NN、逻辑回归和 SVM 三种方法训练二分类预测模型，并对测试数据（初赛和决赛中需要预测的各机器数据）进行预测，使用投票原则确定测试数据输出；最后，对预测结果为故障的机器，使用随机森林算法首先预测波形数组是 a 时间段还是非 a 时间段的数组，然后对预测为非 a 时间段的数组依次实现二分类，直至实现 5 个时间段的数据的预测。

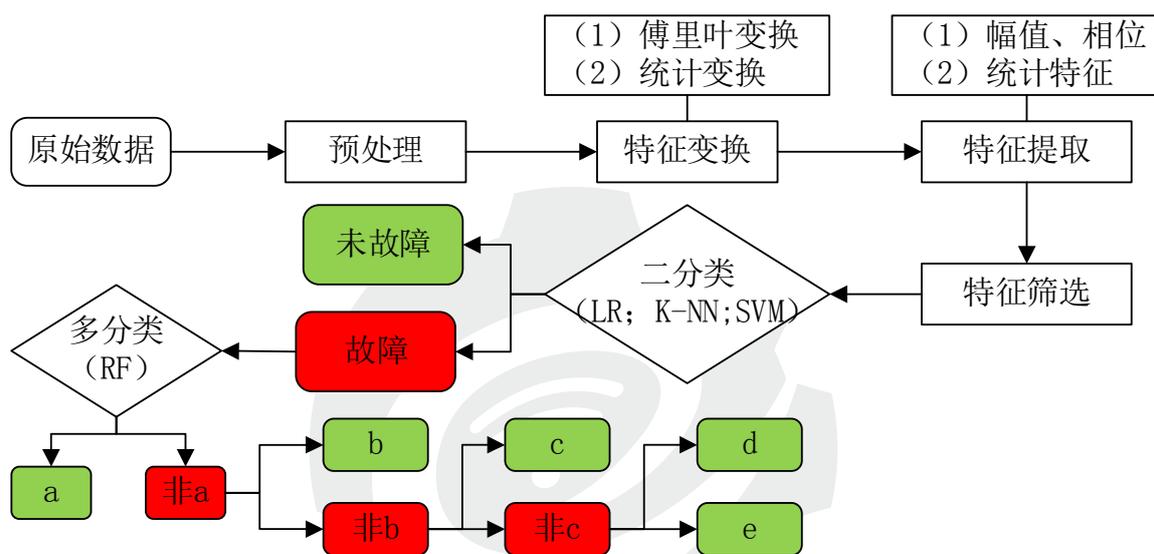


图 2-3-15 “基于多模型投票规则的梯级分类”算法流程

4.2 难点分析

①故障发生的具体时间模糊；

②训练数据不均衡。在训练集数据中，M1,M2 为故障机组，其余为正常机组，“normal”标签对应的数据与“fault”标签对应的数据存在差异；

③模型的通用性、泛化能力和简易性。模型的好坏不仅取决于算法和数据，还取决于对任务的需求。模型对训练数据拟合的过拟合将会导致泛化能力的下降。

4.3 特征工程

在特征提取部分，本团队首先提取每个采集点位的时间序列在统计上的采集频次、速度、最大值、最小值、均值、中位数、25%分位数 (Q1)、75%分位数 (Q3) 和方差，图 2-3-16 为正常与异常状态原始波形统计特征分布示例，从中可以看出均值不能很好地反应正常和异常状态下的机器测点数据差异。而其他特征下，压缩机联端的正常和异常分布是有差异的。

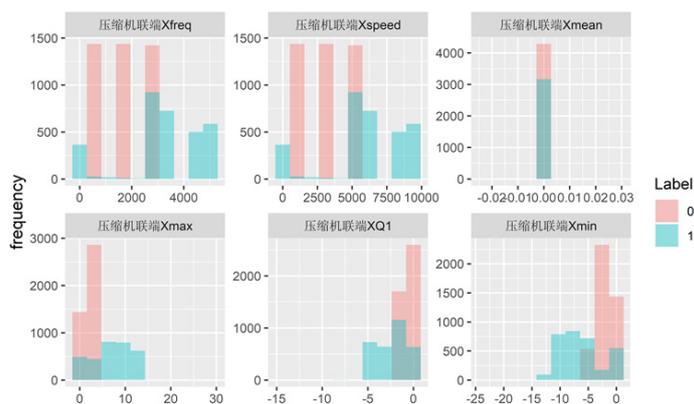


图 2-3-16 原始波形数组统计特征分布图 (0: 正常; 1: 故障)

考虑到以上情况，对振动信号取绝对值后，提取绝对值后的采集频次、速度、最大值、最小值、均值、中位数、25% 分位数 (Q1)、75% 分位数 (Q3) 和方差，其可视化结果如图 2-3-17 所示，可见取绝对值的特征有一定区分度。

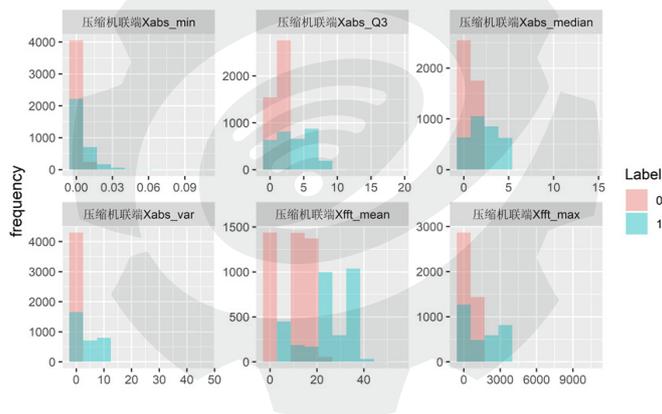


图 2-3-17 波形数组取绝对值统计特征分布图

考虑到信号是振动信号，所以对其进行傅里叶变换，并提取了傅里叶变换后的频率和相位的采集频次、速度、最大值、最小值、均值、中位数、25% 分位数 (Q1)、75% 分位数 (Q3) 和方差，其可视化结果如下图 2-3-18 和 2-3-19 所示。

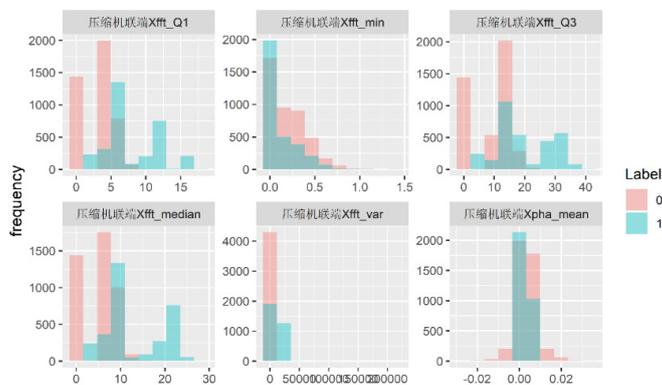


图 2-3-18 波形数组傅里叶变换的幅值统计特征分布图

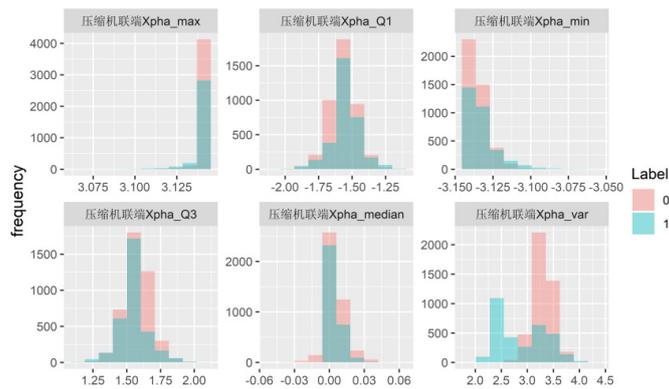


图 2-3-19 波形数组傅里叶变换的相位统计特征分布图

4.4 建模预测

对于故障预测算法，在数据集的选取上，由于每台机器 a 阶段的数据为最靠近故障发生点的数据，因此其数据特征对比也最为明显。选取训练数据集 (M1-M5) 的 a 阶段数据用作训练数据，测试集 (M6-M10) 的 a, b, c, d, e 阶段数据用作测试数据。在具体算法的选择上，采用逻辑回归、KNN 以及 SVM 算法进行训练并预测。对测试数据的每个区间段的每条记录预测其是否故障，取众数来判断整个区间段的状态。

对于区间预测算法，在数据集的选取上选取 M1, M2 区间 a, b, c, d, e 数据作为训练数据，M7, M9, M10 的 1, 2, 3, 4, 5 区间作为测试数据。在算法选择上，采用随机森林算法作为分类算法，训练并预测 M7, M9, M10 的 1, 2, 3, 4, 5 区间下每条数据的状态。统计 1,2,3,4,5 区间中数据状态分别为 a, b, c, d, e 的条数，以总数最大的状态作为该区间的最终状态。

5. 验证

为评估随机森林的有效性，本团队使用了其他几种分类器训练并进行比较。

使用 K-NN、逻辑回归和 SVM 对机器是否故障进行二分类，并根据结果进行投票的结果如下表 5-1 所示，使用训练数据训练的各模型均预测出 M7, M9, M10 属于故障机器，M6 和 M8 为非故障机器。对于决赛数据集，二分类算法预测 M11, M12, M13, M14, M15, M16, M17, M18 中的故障机器，预测 M11, M13 为非故障机器，其余 M12, M14, M15, M16, M17, M18 为故障机器。读取 1, 2, 3, 4, 5 区间中数据，并使用随机森林对区间排序，最终结果如下表 5-2 所示。

从初赛和决赛的结果，我们可以观察到，使用 M1 到 M5 的数据基于“多模型投票规则的梯级分类”算法，在区间预测上泛化能力不强，我们认为可能是选择投票的模型过于简单，后期可以使用相对复杂、抗干扰性更强的模型（如：深度学习、生成对抗神经网络等）作为投票的基础预测算法。

表 5-1. 初赛数据集的预测结果

| 机器 | 是否故障 | 故障发生阶段 | | | | |
|-----|------|--------|---|---|---|---|
| M6 | N | | | | | |
| M7 | Y | a | c | d | b | e |
| M8 | N | | | | | |
| M9 | Y | e | d | c | b | a |
| M10 | Y | b | a | d | e | c |

表 5-2. 决赛数据集的预测结果

| 机器 | 是否故障 | 故障发生阶段 | | | | |
|-----|------|--------|---|---|---|---|
| M11 | N | | | | | |
| M12 | Y | c | d | a | b | e |
| M13 | N | | | | | |
| M14 | Y | a | c | b | e | d |
| M15 | Y | d | c | b | a | e |
| M16 | Y | e | a | c | d | b |
| M17 | Y | c | d | b | a | e |
| M18 | Y | e | c | a | b | d |

6. 结果分析与经验总结

本团队使用的分析工具是 R 语言和 Python，使用的硬件为 64 位的华硕笔记本电脑 U3000。其中，数据整合和标签化使用 Python，然后使用 R 语言对整合好的数据进行特征变换、可视化、特征筛选和预测建模，为验证预测结果，同时使用 Python 进行建模预测，比较二者的计算时间和结果，基本没有差异。

使用“基于多模型投票规则的梯级分类”算法对机器是否故障，以及故障时间区间进行排序，能够保证模型输出结果的稳定性，并且，本团队使用的 K-NN、逻辑回归、SVM 和随机森林算法，相对于深度神经网络耗时较少，对硬件要求不高，在训练建模与预测阶段，使用 M1 到 M5 的数据训练模型并对初赛和决赛 18 个机器完成二分类和多分类共计用时 64'43s。

本团队总结认为可以从以下几个方面改进我们的预测模型：

(1) 原始数据去噪音，使用初赛数据构建的训练模型在初赛数据集上表现很好，但是在决赛数据集上表现很差，说明模型的泛化能力弱，本团队在初始阶段并未剔除一些可能存在的噪音，后期可以使用小波分析等工具，剔除噪音，有利于模型的优化。

(2) 在特征工程上，由于时间仓促，本团队未对数据进行小波变换，也未对特征进行深入分析，进行有效的特征筛选，我们认为在后期可以增加小波变换的特征值，如小波变换的能量值、位移和尺度参数等，在特征筛选上，可以使用基于强化学习思想的特征筛选、主成分分析等方法。

(3) 模型的泛化能力弱也可能是由于机器本身的参数、环境等差异导致的，可以使用机器聚类，使用类似的机器训练建模，预测类似的机器。

(4) 构建“物理原理 + 数据驱动”的混合模型，基于机理的特征变换和建模能够提高模型的稳定性、可解释性，是未来大数据分析技术在工业领域应用的一个重要方向。^[15] 构建“物理原理 + 数据驱动”的混合模型，并组合不同算法投票机制，引进深度神经网络等算法，有利于提高算法的预测能力。

7. 参考文献

[1] A. Kusiak, H. Zheng and Z. Song, “Online monitoring of power curves,” *Renewable Energy*, Vol. 34, No. 6, pp. 1487–1493, 2009.

[2] A. Kusiak, “Break Through with Big Data,” *Industrial Engineer*, Vol. 47, No. 3, pp. 38–42, 2015.

[3] A. Kusiak, “Share Data on Wind Energy,” *Nature*, Vol. 529, No. 7584, pp. 19–21, 2016.

[4] A. Kusiak, “Smart Manufacturing Must Embrace Big Data,” *Nature*, Vol. 544, No. 7648, pp. 23–25, 2017.

[5] A. Kusiak, “Big Data in Mechanical Engineering,” *ME Today*, March 2015.

[6] Y. H. Kuo and A. Kusiak, “From Data to Big Data in Production Research:



The Past and Future Trends,” International Journal of Production Research, Vol. 57, No. 15–16, pp. 4828–4853, 2019.

[7] W. Liu, W. Zhang, J. Han and G. Wang, “A new wind turbine fault diagnosis method based on the local mean decomposition,” Renewable Energy, Vol. 48, pp. 411–415, 2012.

[8] H. Long, L. Wang, Z. Zhang, Z. Song and J. Xu, “Data-Driven Wind Turbine Power Generation Performance Monitoring”, IEEE Transactions on Industrial Electronics, Vol.62, No. 10, pp. 6627–6635, 2015.

[9] S.J. Pan, and Q. Yang, “A Survey on Transfer Learning”, IEEE Transactions on Knowledge and Data Engineering, Vol.22, No. 10, pp. 1345–1359, 2010.

[10] P. N. Tan, M. Steinbach, V. Kumar, Introduction to data mining. Boston, MA: Pearson Education/Addison Wesley 2006.

[11] B. Tang, T. Song, F. Li and L. Deng, “Fault diagnosis for a wind turbine transmission system based on manifold learning and Shannon wavelet support vector machine,” Renewable Energy, Vol. 62, pp. 1–9, 2014.

[12] L. Wang, Z. Zhang, H. Long, J. Xu and R. Liu, “Wind Turbine Gearbox Failure Identification With Deep Neural Networks”, IEEE Transactions on Industrial Informatics, Vol.13, No. 3, pp. 1360–1368, 2017.

[13] L. Wang and Z. Zhang, “Automatic Detection of Wind Turbine Blade Surface Cracks Based on UAV-Taken Images”, IEEE Transactions on Industrial Electronics, Vol. 64, pp. 7293–7303, 2017.

[14] L. Wang, Z. Zhang, J. Xu and R. Liu, “Wind Turbine Blade Breakage Monitoring with Deep Autoencoders”, IEEE Transactions on Smart Grid, Vol. 9, No. 4, 2018, pp. 2824 – 2833.

[15] J.Yoon, D. He, B. Van Hecke, T.J. Nostrand, J. Zhu, E. Bechhoefer, “Vibration-based wind turbine planetary gearbox fault diagnosis using spectral averaging”, Wind Energy, Vol. 19, No. 9, pp. 1733–1747, 2016.

(四) 基于全息故障特征提取的 转子部件脱落智能识别方法

1. 团队介绍

团队名称: xjtupj

| 成员姓名 | 团队角色 | 职位 |
|------|------|-------------------------|
| 景宏杰 | 队长 | 西安交通大学装备智能诊断与控制研究所硕士研究生 |
| 潘彤阳 | 队员 | 西安交通大学装备智能诊断与控制研究所博士研究生 |

xjtupj 团队由西安交通大学装备智能诊断与控制研究所的一名硕士生与一名博士生组成。西安交通大学装备智能诊断与控制研究所是在监测诊断领域先驱屈梁生院士、早期故障智能预示开创者何正嘉教授等开创的研究方向基础上成立的，重点开展重大装备的智能检测与故障诊断、运行可靠性与服役安全分析等相关研究。景宏杰，硕士研究生，主要研究方向为装备剩余寿命预测、运行可靠性分析等，负责本项目的方案设计与算法实现；潘彤阳，博士研究生，主要研究方向为机械信号处理、智能诊断等，负责数据处理与特征提取。

2. 背景简介与文献调研

大型旋转机组，如压缩机、蒸汽汽轮机、燃气轮机等是流程工业如能源、化工、发电等行业的核心装备。因设备高速旋转、动能巨大，转子部件脱落故障给设备安全运行带来巨大威胁。由于部件脱落而导致的机组多级动静叶片/叶轮损伤的维修成本高、耗时长，因此而造成企业经济效益的重大损失。转子部件脱落的早期征兆难以捕捉，是故障预测的世界性难题。如果能通过大数据方法，实现此故障征兆的早期发现和程度预测，将带来显著的安全价值和经济效益。

在机械设备的早期故障识别与故障预测方面，目前常用的方法包括基于信号处理的机械设备故障诊断方法与基于深度学习的智能故障诊断方法。其中，信号处理方法依托于内积运算^[1]，通过傅里叶变换、全息谱分析、小波变换、经验模式分解等算法^[2-6]实现故障特征提取与故障识别，能够有效提取机械信号中所包含的故障特征，具有较好的可解释性，在工程



实践中已得到了诸多应用。然而，由于信号处理方法依赖于专家经验，在处理大量数据时效果不佳，因此难以处理大量数据。在智能诊断方法，学者们基于深度置信网络、卷积神经网络、循环神经网络等深度学习模型开展了诸多研究^[7-10]，利用神经网络的强大拟合能力，实现了机械设备的智能诊断与故障预测。

为了实现本项目所要求的转子早期故障识别与故障预测，本项目将综合利用信号处理技术与智能诊断方法，采用时频特征提取、全息谱技术等对监测信号进行特征提取，获得故障特征；之后，利用支持向量机、逻辑回归等方法实现故障识别；最后，利用深度神经网络实现故障的强度分析。

3. 数据解析

工业数据（主要是该组转子部件脱落故障预测数据）的特点、以及对应的分析方法。

通过对数据的初步分析，发现转子部件脱落故障预测数据具有瑕点多、波动大、噪声强、数据量大等特点。在工程实际中，由于难以长时间监测设备的运行状态，导致监测数据中存在一定的误差甚至错误，表现在本项目中为其他故障模式的干扰；此外，由于运行工况差异较大，导致不同机组之间信号的幅值差异巨大，即使对于同一台机组，由于不同时刻设备的健康状态不同，使得监测信号之间的波动较大；最后，由于设备运行中背景噪声较大，使得监测信号的信噪比较低，故障特征提取较为困难。

针对监测所存在的瑕点多、波动大、噪声强、数据量大的特点，本项目拟采用数据清洗方法，对监测数据进行预处理，提高数据的精确性；之后，采用全息谱等时频分析方法，进行特征提取，从微弱信号中获得故障特征；最后，使用智能诊断方法进行进一步分析，充分利用大量数据进行诊断与预测。

4. 方法

本项目拟采用数据清洗方法，对监测数据进行预处理，提高数据的精确性；之后，采用全息谱等时频分析方法，进行特征提取，从微弱信号中获得故障特征；最后，使用智能诊断方法进行进一步分析，充分利用大量数据进行诊断与预测。

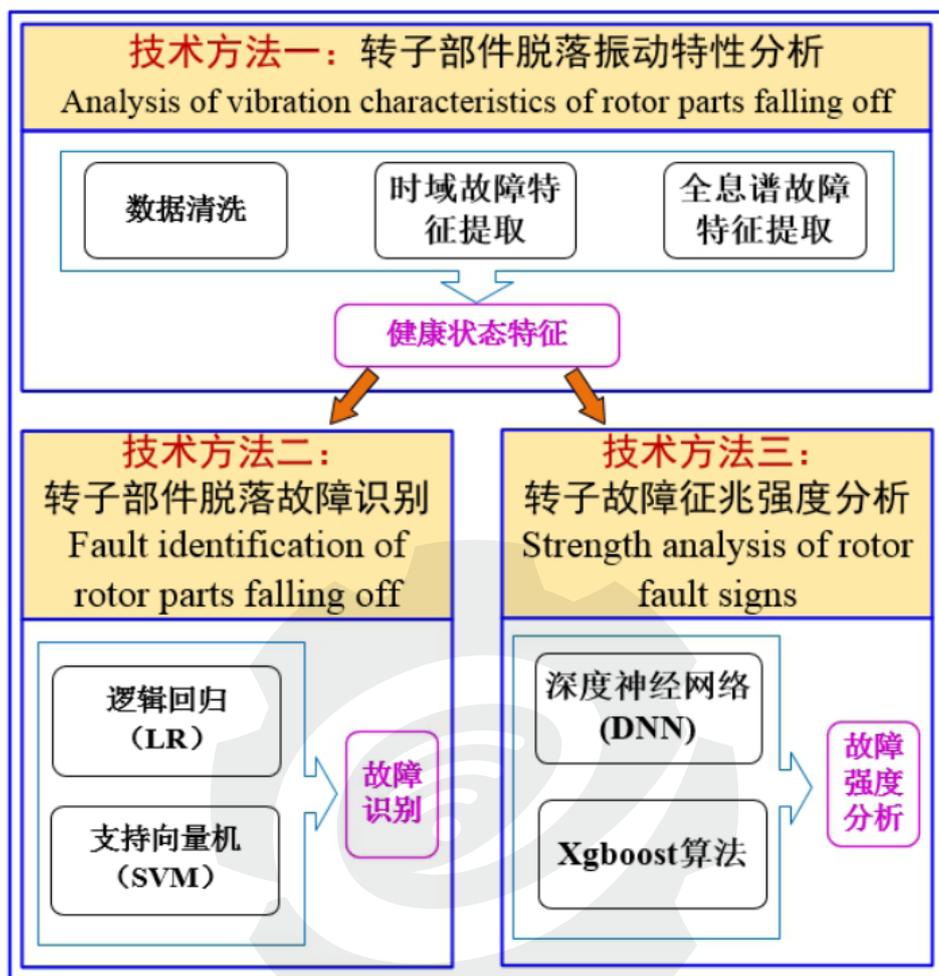


图 2-3-20

4.1 数据清洗

在数据清洗时，我们发现原始数据的转速波动较大，而转速不同势必改变信号特征，变转速下的故障诊断十分困难。因此，需要对数据进行预处理，截取平稳转速下的数据进行分析。下图是 M1,M2 机器不同阶段转速变化图，以及 M1 各阶段最大最小转速与波动幅值。

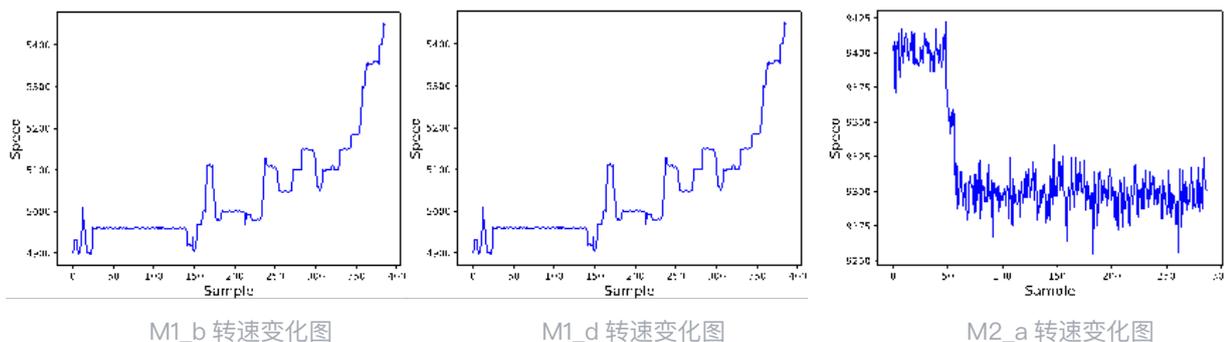


图 2-3-21

| 转子工况 | 最大转速 | 最小转速 | 波动幅值 |
|------|------|------|------|
| M1_a | 5876 | 4899 | 977 |
| M1_b | 5787 | 4913 | 874 |
| M1_c | 6069 | 6069 | 0 |
| M1_d | 5451 | 4898 | 553 |
| M1_e | 5379 | 5649 | 270 |

4.2 时频域特征提取

常见的无量纲时域特征指标：

波形指标 W 、峰值指标 C 、脉冲指标 I 、裕度指标 L 、偏斜度指标 S 、峭度指标 K 等，已被应用于旋转机械故障诊断中。

$$\text{波形指标 } W = \frac{x_{rms}}{\bar{x}} \quad \text{峰值指标 } C = \frac{x_p}{x_{rms}} \quad \text{脉冲指标 } I = \frac{x_p}{\bar{x}}$$

$$\text{裕度指标 } L = \frac{x_p}{x_y} \quad \text{偏斜度指标 } S = \frac{\alpha}{\sigma_x^3} \quad \text{峭度指标 } K = \frac{\beta}{\sigma_x^4}$$

频域指标通常会选择不同频带下能量占比等。而此次数据由于具有 X, Y 多传感器信息，因此可以采用全息谱技术综合诊断分析。全息谱技术由本研究团队屈梁生院士最早提出并获得国家技术发明二等奖，是一种将转子水平和垂直方向振动信号综合起来进行故障诊断的技术，是多传感器信息融合在大机组监测和诊断中的一种体现，特别适用于转子位移信号分析及特征提取。它是在 FFT 算法的基础上，通过内插技术，精确求得按自由方式（非等转角间隔整周期）采集的振动信号的幅值、频率、相位值，然后将转子截面水平和垂直方向振动信号的幅值、频率、相位信息进行集成，用合成的一系列椭圆来刻画不同频率分量下转子的振动行为。它巧妙地构造了多支承转子系统的单一截面和整机振动分析方法，体现了诊断信息的全面利用、综合分析的思想。

转子部件脱落故障本质上属于转子不平衡，表现为工频的全息谱椭圆较大、较圆。其二倍频、四倍频椭圆较大较扁，说明转子可能还存在不对中、变形等故障。在此次实验中，压缩机非联端 X 与压缩机非联端 Y，压缩机联端 X 与压缩机联端 Y 分别是两组相互垂直的振动信号。通过求解各阶频谱得到其幅值与相位，进行全息谱绘制。

转子部件脱落故障属于突发性不平衡，振动的时域波形近似为正弦波，振动值突然显著增大后稳定在一定水平上，能量集中在基频，会出现较小的高次谐波，强迫振动，对转速比较敏感。当脱落部件较大时，会进一步引起转子弯曲，特征频率主要为 1 倍频，并伴有 2 倍频。

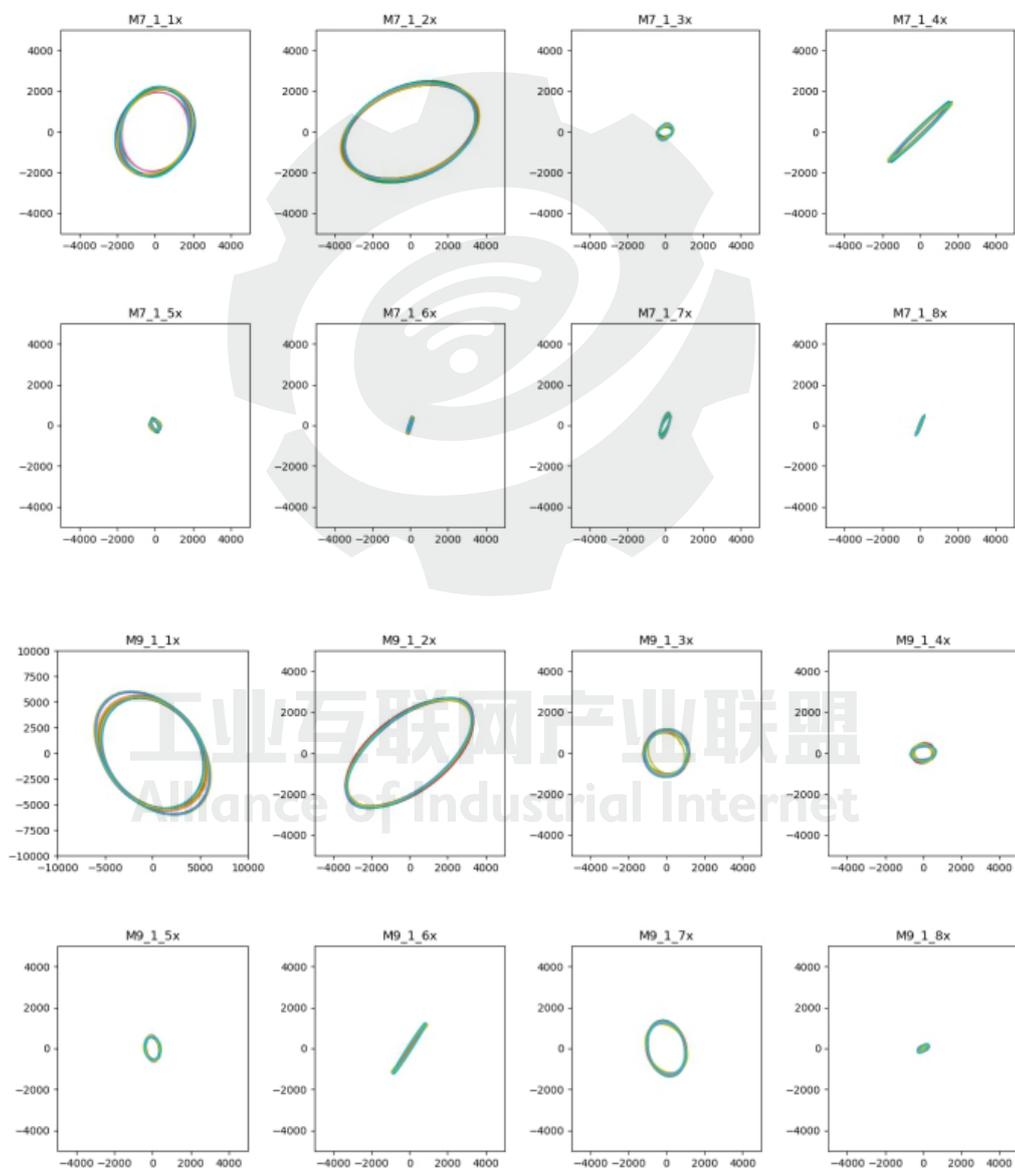


图 2-3-22

故障样本压缩机联端 X 与压缩机联端 Y 的全息谱，有一个显著的特点在二阶全息谱为较大的椭圆，方向偏右上。

而在正常样本中，二阶全息谱椭圆较小，长半轴半径均小于 500。

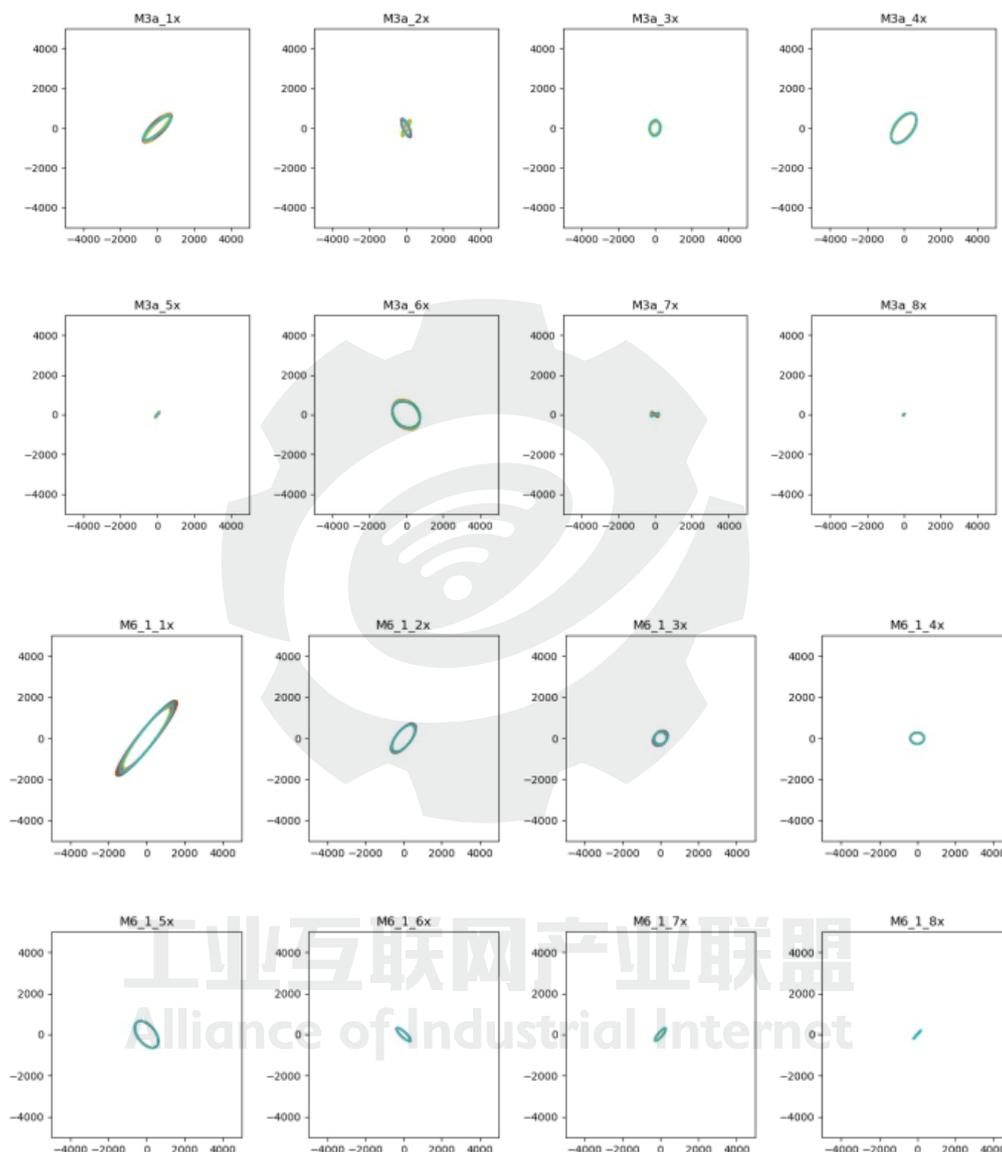


图 2-3-23

最终选择不同倍频下椭圆长半轴半径 a 和离心率 e 作为全息谱特征 参与后续模型训练。

4.3 模型选择

本次比赛内容主要包括两个任务，故障识别以及故障征兆强度预测。故障识别是一个分

类任务，每个机器只提取故障最严重的 a 阶段数据作为训练集，采用逻辑回归（LR）与支持向量机（SVM）来进行分类；故障强度征兆预测把它作为一个回归任务，选取有故障机器的 a~e 不同阶段作为训练集，并给予 0~1 的故障程度标签，采用 DNN 网络与 Xgboost 模型。

5. 验证

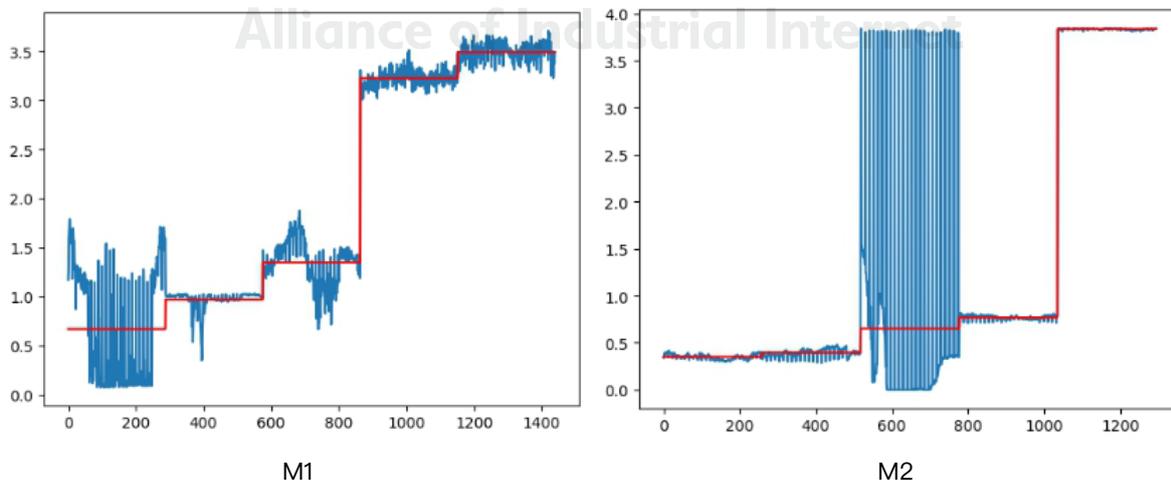
故障识别 任务采用的 M1~M5 的 a 阶段数据，其中 80% 作为训练集，20% 作为验证集。

| Accuracy rate | Training set | Validation set |
|---------------|--------------|----------------|
| LR | 0.933 | 0.946 |
| SVM | 0.929 | 0.954 |

| | M11 | M12 | M13 | M14 | M15 | M16 | M17 | M18 | |
|------|-----|-----|------|-----|------|------|-----|------|-------|
| 是否故障 | 1 | 0 | 1 | 0 | 1 | 0 | 0 | 0 | |
| LR | 1 | 0 | 0.98 | 1 | 1 | 0.07 | 0 | 1 | 0.75 |
| SVM | 0 | 0 | 0.97 | 1 | 0.83 | 0.01 | 0 | 0.93 | 0.625 |

可以看到，训练阶段故障识别准确率都较高，但应用到决赛数据中出现了明显的 M14，M18 的误诊。

故障程度预测任务采用的 M1 与 M2 的 a~e 不同阶段作为训练集，并给予 0~1 的故障程度标签，数值越小对应故障程度越严重。



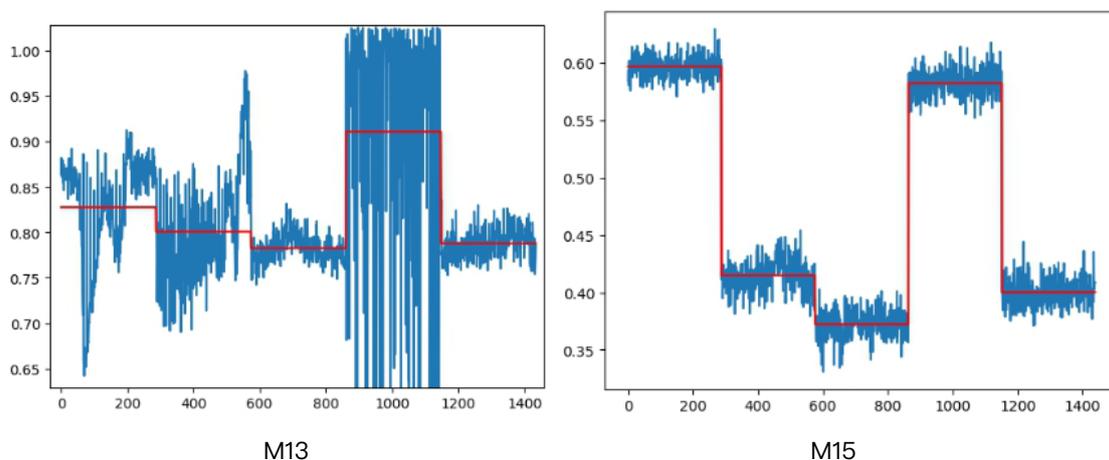


图 2-3-24

可以看出 M2 前两个阶段数据差异较小难以区分，在决赛数据中，M13 的 a,b 阶段，M15 的 b,c 阶段都差距很小，容易出现排序错误。

6. 结果分析与经验总结

本次比赛采用数据清洗方法，对监测数据进行预处理，提高数据的精确性；之后，采用全息谱等时频分析方法，进行特征提取，从微弱信号中获得故障特征；最后，使用智能诊断方法进行进一步分析，充分利用大量数据进行诊断与预测。最初并没想到采用全息谱技术，而是采用常用的时频域指标，对故障的描述不够充分，在观察到为滚动轴承下回转体诊断问题并具有 X, Y 多传感信息时，才想到针对性的方法，故障识别效果也有所提升。因此还是要多结合工程应用实际中的专家经验，采用更强大的工具能有效提高故障识别率。

竞赛中使用普通 i7 处理器对数据进行预处理与特征提取，总耗时 8 分钟。预测模型总耗时 5 分钟。

本文提出的方案还有很多可以改进的地方，在绘制全息谱时，最好将频谱归一化。故障程度预测中标签赋值有待改进。离散问题用回归拟合来处理这种方式欠妥。

7. 参考文献

[1] J. Chen, Z. Li, J. Pan, et al. “Wavelet transform based on inner product in fault diagnosis of rotating machinery: A review,” *Mech. Syst. Signal Process.*, vol. 70, pp. 1–35, 2016.

- [2] Y. Han, B. Tang, L. Deng. “Multi-level wavelet packet fusion in dynamic ensemble convolutional neural network for fault diagnosis,” *Measurement*, vol. 127, pp. 246–255, 2018.
- [3] 屈梁生, 邱海, 徐光华. 全息动平衡技术: 原理与实践 [J]. *中国机械工程*, 1998(01):70–73+9.
- [4] A. A. Silva, S. Gupta, A. M. Bazzi, et al. “Wavelet-based information filtering for fault diagnosis of electric drive systems in electric ships,” *ISA Trans.*, vol. 78, pp. 105–115, 2018.
- [5] Y. Lei, Z. He, Y. Zi. “Application of the EEMD method to rotor fault diagnosis of rotating machinery,” *Mech. Syst. Signal Process.*, vol. 23, no. 4, pp. 1327–1338, 2009.
- [6] W. Guo, W. T. Peter, A. Djordjevich. “Faulty bearing signal recovery from large noise using a hybrid method based on spectral kurtosis and ensemble empirical mode decomposition,” *Measurement*, vol. 45, no. 5, pp. 1308–1322, 2012.
- [7] S. Haidong, J. Hongkai, L. Xingqiu, and W. Shuaipeng, “Intelligent fault diagnosis of rolling bearing using deep wavelet auto-encoder with extreme learning machine,” *Knowledge-Based Systems*, vol. 140, pp. 1–14, 2018/01/15/ 2018.
- [8] Z. Chen and W. Li, “Multisensor Feature Fusion for Bearing Fault Diagnosis Using Sparse Autoencoder and Deep Belief Network,” *IEEE Transactions on Instrumentation & Measurement*, vol. 66, no. 7, pp. 1693–1702, 2017.
- [9] 杨平, 苏燕辰. 基于卷积门控循环网络的滚动轴承故障诊断 [J]. *航空动力学报*, 2019,34(11):2432–2439.
- [10] H. Jiang, H. Shao, X. Chen, and J. Huang, “Aircraft Fault Diagnosis Based on Deep Belief Network,” in *International Conference on Sensing, Diagnostics, Prognostics, and Control*, 2017, pp. 123–127.



(五) 基于多模型融合的转子部件脱落故障识别方法

1. 团队介绍

团队名称：湃方科技算法部

| 成员姓名 | 团队角色 | 职位 |
|------|------|-----------------------|
| 蔺思宇 | 队长 | 湃方科技（北京）有限责任公司算法部部门经理 |
| 刘涛 | 队员 | 湃方科技（北京）有限责任公司算法技术专家 |
| 李素洁 | 队员 | 湃方科技（北京）有限责任公司资深算法工程师 |
| 杨晨旺 | 队员 | 湃方科技（北京）有限责任公司高级算法工程师 |

湃方科技是一家专注于赋能传统工业智能化升级的高科技企业。公司创始团队来自于清华大学，拥有世界领先的工业智能芯片与工业智能算法技术，为传统工业行业提供包括智能芯片和智能算法的全栈式工业智能解决方案。湃方科技愿与智能制造生态合作伙伴携手为“百万台工业设备”提供全方位，全周期的智能化监测，利用人工智能助力客户实现生产与运营的提质、降本、增效和控险。围绕“中国制造 2025”的战略目标，湃方科技让智能化真正赋能到全球工业领域。

湃方科技算法部为湃方科技（北京）有限责任公司下属人工智能算法研发部门，团队成员皆为国内 985、211 及海外知名大学的博士及硕士，其中核心成员更是在 PHM、石油、风机、智能制造等行业浸淫多年，总结出了独有的工业生产人工智能方法论以及能够让用户快速领会的技术——业务无缝咨询机制，真正做到了用户痛点不清我们能梳理、用户痛点难解我们抓核心、用户痛点分散我们能整合的“三痛点”原则，实现用户真正意义上最符合自身的智能化解决方案建设。

2. 背景简介与文献调研

大型旋转机组，如压缩机、蒸汽汽轮机、燃气轮机是流程工业如能源、化工、发电等行业的核心装备。因设备高速旋转、动能巨大，转子部件脱落故障给设备安全运行带来巨大威胁^[1]。由于部件脱落而导致的机组多级动静叶片 / 叶轮损伤的维修成本高、耗时长，因此而造成企业经济效益的重大损失。转子部件脱落的早期征兆难以捕捉，是故障预测的世界性难题。

针对该项难题，行业内在近些年中也提出一些基于特征和先验公式的方法论。例如：谐波分量法及力平移原理^[2]，基于单平面质量脱落定位分析，推导出转动部件脱落故障轴向位置和质量计算公式，能精确的计算出转动部件脱落故障轴向位置和质量；范春生等人提出了汽轮机叶片脱落故障的振动特征^{[3][4]}；晋风华等人对汽轮机叶片进行了故障诊断分析^{[5][6]}；还有针对旋转机构转子部件缓慢脱落时系统信号的幅值变化进行研究，发现其频域内幅值亦发生某种有规律的变化，从而简单地模拟了系统在变幅情况下的信号，并将信号从频域傅氏变换的线性叠加性和能量守恒角度去对信号的频域内幅值的变化规律进行分析，并在频域内采用 FFT、比值校正法和频谱细化方法进行频谱图简单分析以验证两者准确性，加深对信号处理时内部运算的理解^[7]；也有人提出利用故障矢量诊断研究汽轮机叶片脱落位置的方法^[8]。这些无一不是建立在专业知识分析和小数据量实验基础之上的，如果能通过大数据方法，实现此故障征兆的早期发现和程度预测，相信将带来更加显著的安全价值和经济效益。

3. 数据解析

大型透平旋转机组一般采用承载力强的滑动轴承。机组出厂时会在转子两端轴承位布置 2 对电涡流位移传感器，用来测量转子径向振动，图 2-3-25。在轴端布置 2~3 支电涡流位移传感器用来测量转子轴向振动、位移值，图 2-3-26。电涡流位移传感器信号接入 SG8000 数据采集器进行数据调理、采集与存储。

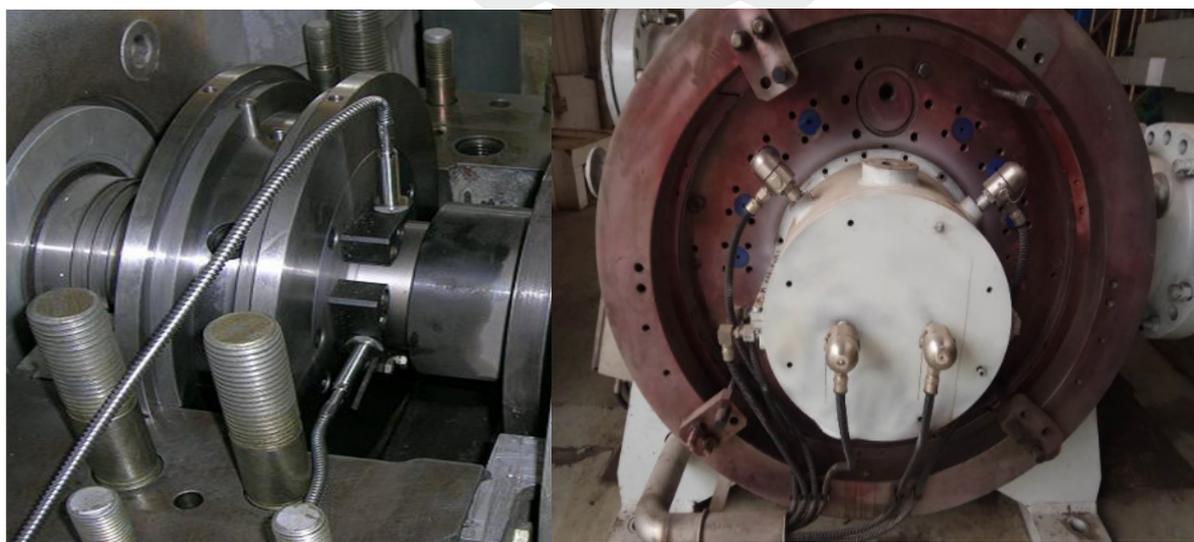
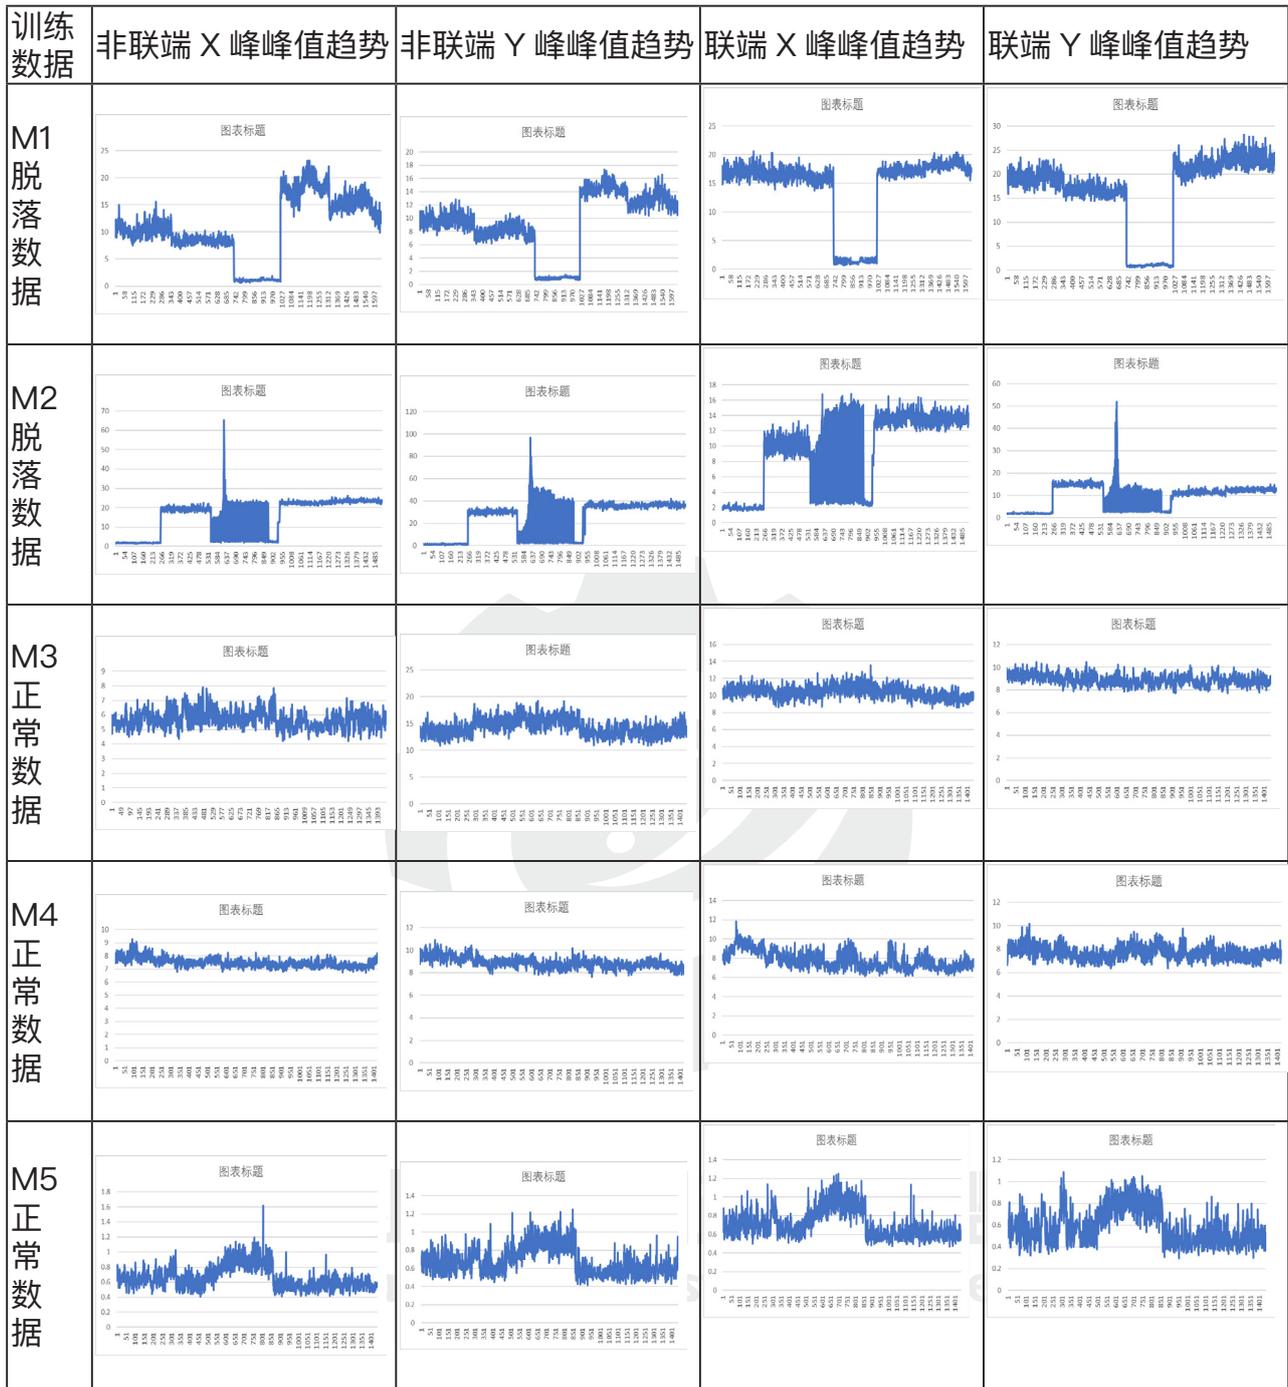


图 2-3-25 径向振动测量

图 2-3-26 轴向振动测量

系统采集机组联端 XY 向的振动和非联端 XY 向的振动。首先对训练数据进行峰峰值的计算，得到振动发展趋势，如下所示。



可以看出，在数据中存在突变点，因此在数据预处理方法上选用异常点去除，消除突变点对结果的影响。

4. 方法

选用回归的思路进行预测。模型训练框图如图 2-3-27 所示，模型测试框图如图 2-3-28 所示。

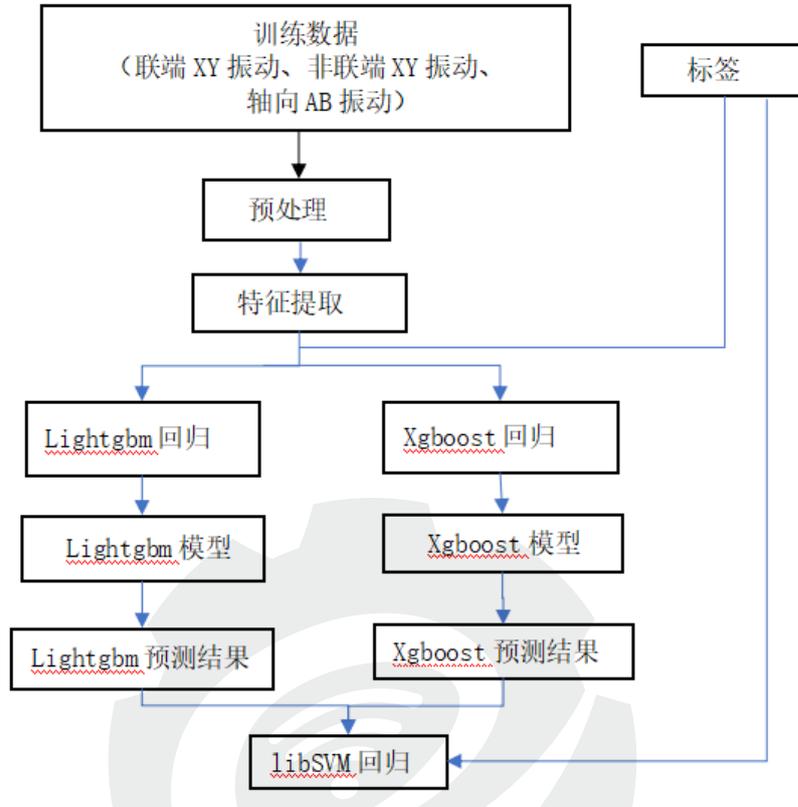


图 2-3-27 训练过程图

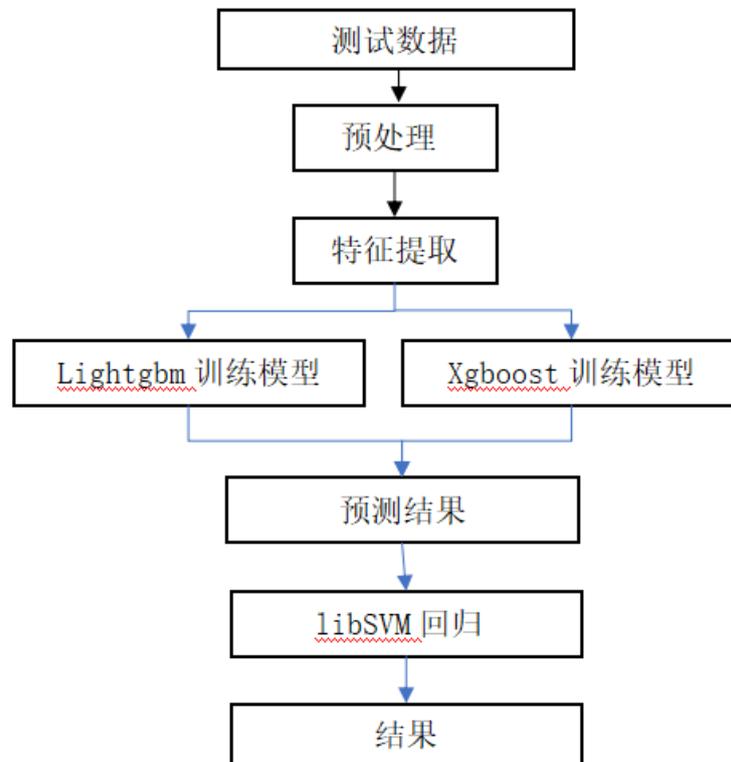


图 2-3-28 测试过程图



4.1 数据选择

选取联端 XY 振动、非联端 XY 振动、轴向 AB 振动。

4.2 特征提取

(1) 时域特征包括峰值、峰峰值、平均值、有效值、峰值指标、波形指标、脉冲指标、裕度指标、峭度指标。

(2) 频域方法选择的是 FFT 分析，由于转子故障的发生，常表现为一定的频谱分布特点，故将频率范围划分十一个特征频率段（或点）。以旋转频率的倍数计；依次为：0~40% f、40~50% f、50~100% f、1Xf、2Xf、更高倍频、1/2Xf、1/4Xf、更低倍频、奇数倍频和非常高的频率。对转子振动 Z 斗的频谱分析结果，按上述特征频段提取各段的最大幅值，计算幅值比，作归一化处理，得频率特征向量。将其与典型故障频谱特征分布加以比较识别，即可形成频谱特征。

(3) 小波特征，对信号进行小波或小波包分解，计算小波能量、小波熵。

4.3 故障诊断

分别将有故障趋势数据、无故障趋势数据分为 2 类，利用 Xgboost、lightgbm 进行数据模型训练。将测试数据代入训练模型中，得到不同的模型测试结果，最后对模型测试结果进行集成。

回归：数据选择无故障趋势的数据，数据标签设为 0~0.2，有故障趋势数据，数据标签设为 0.8~1.0。对训练数据进行模型回归训练。将测试数据代入训练模型中，得到不同的模型测试结果，最后对模型测试结果进行集成。

5. 验证

将训练数据中的 5 台机组进行标签设置，标签设置原则为数据选择无故障趋势的数据，数据标签设为 0~0.2，有故障趋势数据，数据标签设为 0.8~1.0。训练结果如图 2-3-29 所示。

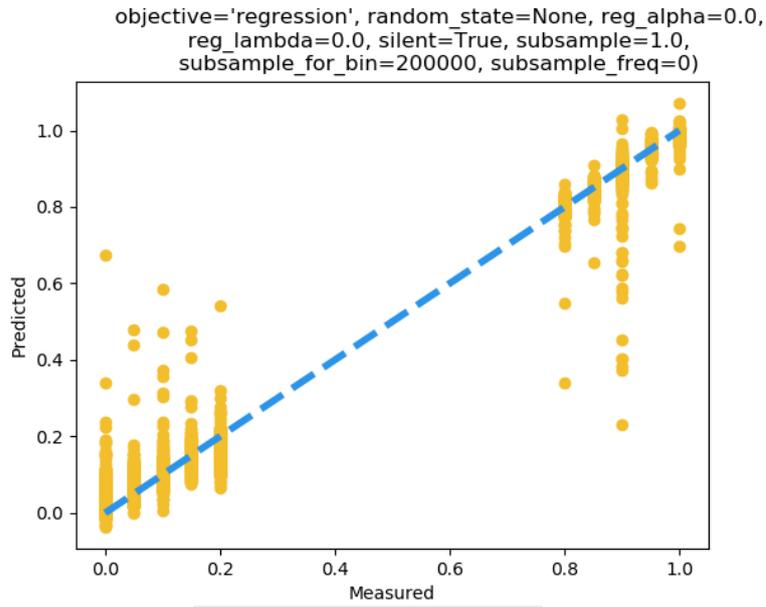


图 2-3-29 模型训练

预测以 M11 为例，计算得到各阶段振动特征后，利用训练模型进行预测，分别得到预测结果如图 2-3-30 所示。

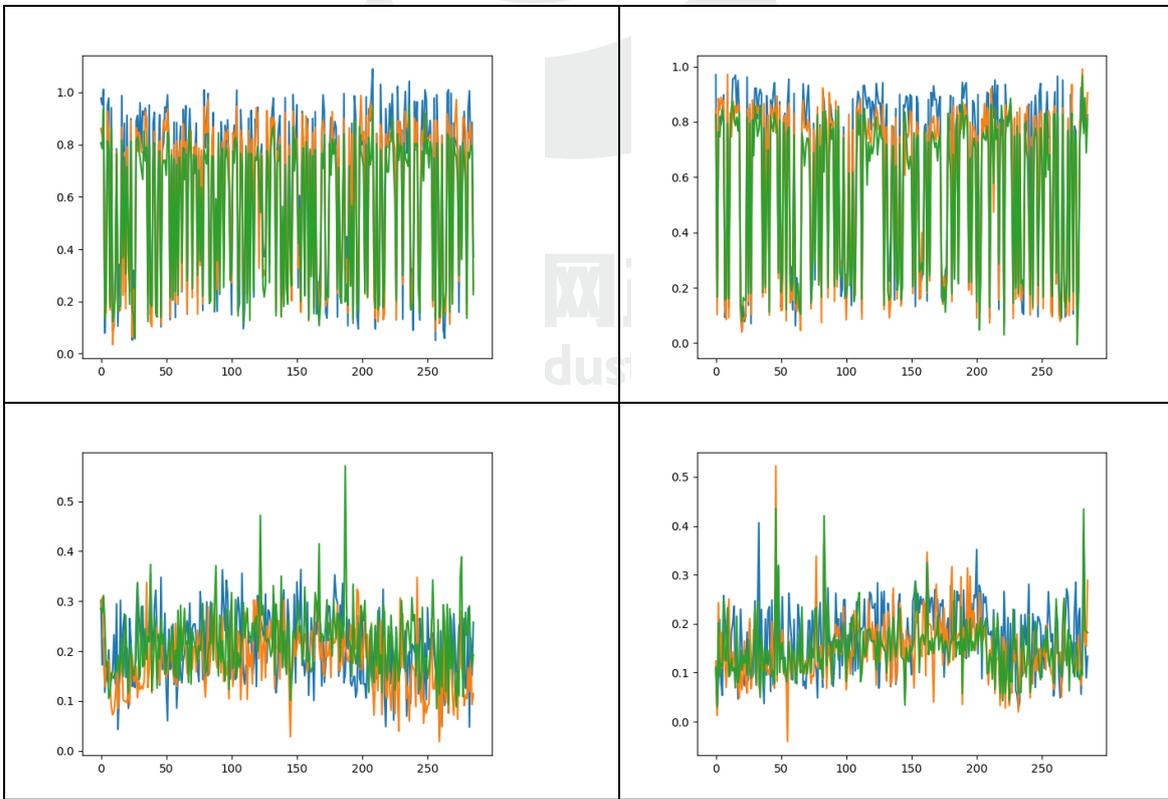


图 2-3-30 预测



根据图 6 中的预测结果进行拟合, 计算模型融合结果。利用结果按照大小排序, 越靠近 1, 说明越接近转子松动故障发生。

6. 结果分析与经验总结

在本次竞赛过程中, 我们查阅资料了解转子脱落的振动特征, 将竞赛目标明确为 0-1 之间预测的回归问题。从分析原始数据出发, 逐个文件的查看数据情况, 有针对性的对数据进行了清洗。根据振动信号处理的经验, 选用时频域方法提取振动特征。

本文提出的方案还有很多可以改进的地方, 例如特征选取计算维度可能不够, 需要继续挖掘更多的特征信息; 此外, 可以选用 Autoencoder 等方法进行模型训练, 计算重构后与原输入相比得到的误差, 作为判断标准, 后续工作可以针对这些问题进行展开。

7. 参考文献

- [1] 贺园玲, 阮志强. 机油泵转子脱落问题的研究与分析 [J]. 内燃机与配件, 2014.
- [2] 童小忠, 应光耀, 吴文健, 刘淑莲. 汽轮机转动部件脱落故障的识别方法 [J]. 振动、测试与诊断, 2012.10.
- [3] 范春生. 300MW 机组低压转子叶片断裂的故障诊断及振动分析 [J]. 动力工程学报, 2010.
- [4] 李卫军, 童小忠, 吴文健. 600MW 机组 LP 转子叶片叶冠脱落分析 [J]. 汽轮机技术, 2008.
- [5] 晋风华, 李录平, 张建东, 汽轮机叶片脱落故障定位方法的研究 [J]. 汽轮机技术, 2006.
- [6] 王秉仁, 姜小丽, 张蕾. 汽轮机叶片故障分析及诊断方法研究 [J]. 煤矿机械, 2005.
- [7] 万书亭, 詹长庚, 豆龙江. 旋转机构转子部件脱落的幅值谱研究与变幅信号谱的简单分析 [J]. 科学技术与工程, 2013.
- [8] 晋风华. 汽轮机叶片脱落故障诊断方法的研究 [J]. 热力透平, 2007.

（六）基于变分模态分解与时间 - 全谱分析的旋转机械转子部件脱落故障预测

1. 团队介绍

团队名称：“我在华中大”

| 成员姓名 | 团队角色 | 职位 |
|------|------|----------------------|
| 崔晓龙 | 队长 | 华中科技大学电气与电子工程学院博士研究生 |
| 季天泽 | 队员 | 华中科技大学电气与电子工程学院硕士研究生 |

华中科技大学，简称“华中大”，因此我们团队命名“我在华中大”。团队由华中科技大学电气与电子工程学院2名研究生组成。华中科技大学电气与电子工程学院实力雄厚，教育部历次学一级科评估中，电气工程学科均名列前三，是国家首批“双一流”建设学科。学院浓厚的科研氛围，是我们团队开展研究的基础。崔晓龙，博士研究生，主要研究方向是大型电力设备状态监测与故障诊断，本次主要负责方案设计、算法实现与成果整理。季天泽，硕士研究生，主要研究方向机械信号处理，本次主要负责数据清洗与信号处理。

2. 背景简介与文献调研

大型旋转机组，如压缩机、蒸汽汽轮机、燃气轮机等是流程工业如能源、化工、发电等行业的核心装备。因设备高速旋转、动能巨大，转子部件脱落故障给设备安全运行带来巨大威胁。由于部件脱落而导致的机组多级动静叶片 / 叶轮损伤的维修成本高、耗时长，因此而造成企业经济效益的重大损失。转子部件脱落的早期征兆难以捕捉，是故障预测的世界性难题。如果能通过大数据方法，实现此故障征兆的早期发现和程度预测，将带来显著的安全价值和经济效益。

转子部件脱落的前兆有可能是部件的松动，结构部分出现裂纹，或者由于碰摩等原因引起冲击振动导致部件连接疲劳等，导致的原因可能是多方面的。旋转机械转子系统的故障诊断与预测研究由来已久，一直以来是研究和实践的热点领域。美国内华达·本特利公司在本特利带领下自上世纪就开始专注于旋转机械的监测与故障诊断。他们开创性的提出了全谱分析的方法^[1, 2]，利用旋转机械轴径向上两只相互垂直的振动传感器信号频谱数据的融合，求

得转子正进动与反进动分量，以此可以判别转子进动方向和旋转轨迹，基于此可以开展转子不平衡，不对中，油膜涡动等多种故障诊断^[3-7]。国内在这方面研究也取得了很多有代表性的成果，例如华中科技大学机械学院杨叔子院士团队很早就开始了旋转机械故障诊断方面的研究^[8]。西安交通大学屈梁生院士和他的团队提出了全息谱理论和方法^[9, 10]。郑州大学的韩捷等提出了全矢谱分析方法并应用与多种故障诊断^[11]。上述方法从旋转机械机理出发结合信号处理与同源信息融合技术对转子振动信号进行描述和表征。近年来，随着信息技术尤其是人工智能与大数据技术的飞速发展，基于数据驱动的故障诊断与预测方法也得到应用和发展。例如美国辛辛那提大学李杰团队提出了设备故障预测与健康管理体系^[12]，还提出了构建设备网络空间与物理空间相映射的理念^[13]。加拿大 Jardine, Andrew K S 和他的团队也专注于基于数据驱动的机械设备故障诊断与状态检修^[14]。在这样的背景下，基于各类智能算法的诊断与预测方法不断涌现。例如基于先进信号处理的方法有小波^[15]，变分模态分解^[16]，经验模态分解与希尔伯特黄变换^[17]等。基于先进智能算法的方法也十分众多，例如支持向量机^[18]，深度学习^[19]等。综合上述这些方法，更多集中在故障诊断，或某特点故障的征兆增强或识别。鲜有专门针对转子部件脱落故障预测的报道。

前述丰富的诊断方法为本赛题的问题提供了全面的参考和启发。转子部件脱落在故障发生后由于质量不均匀，转子会出现严重不平衡。因此可以假设在脱落前，故障发展过程中可能出现平衡状态的变化。而且这种变化可能是渐进的。基于这样的假设，我们从检测转子系统轻微不平衡入手开展研究。经过反复试验，我们总结提出了基于变分模态分解和全时谱融合分析的方法。考虑到振动信号的多分量耦合特性，VMD 作为一种最新提出的具有鲁棒性和噪声稳定性的信号分解方法。我们将其引入对转子径向两只垂直传感器信号分别进行分解，得到振动信号在各个频带内的信号分量。将两只传感器的对应分量采用最新提出的时 - 全谱分析方法进行融合，得到对应断面的时变瞬时轴心轨迹信息。接下来对轴联端和非联端两个断面的时变轨迹信息进行融合，定义了轴心轨迹比例系数，并以此为主要依据判别机组的振动变化和趋势。我们还分析了故障发展与不同阶次轴心轨迹的变化关系，分析了故障发展与轴心轨迹离心率、转子进动方向等特征的关系。我们将提出的特征使用 SVM, KNN 等智能分类算法进行了分类试验。试验结果显示所提出的轨迹面积比例系数与故障的发展有着较强的相关性。

3. 数据解析

本次比赛任务是依据 5 台 (M1~M5) 已知状态的机组数据预测剩余 13 台 (M6~M18) 机的状态和故障趋势。虽然同属高速旋转机械,但是机组类型,额定转速,工况,工作环境等等都存在明显差异。振动信号数据的数量级,存在巨大差异,给出数据中不包含机组工况,结构和尺寸等信息进一步增加了难度,要从中找到相似的规律可谓非常不易。

此外,给出的数据来自工业现场,存在大量的不可用数据,需要进行清洗。例如明显的偏离一贯工况的毛刺。不同测量通道数据时标不对齐等。具体情况将在后续章节举例说明。

不同类型和不同转速机组的振动数据相互之间差异巨大,如何找到其中可以进行直接比较的特征是解决问题的关键。根据相关标准,不同类型的旋转机械在不同的额定转速下有相应的振动参考值,但这只是振动幅值的报警阈值。相同类型甚至相同型号的机组之间振动状态也存在非常大的差别。因此不同机组的振动状态的变化或者不同无法确认是发生部件脱落故障的征兆。

因此寻找不同测点振动状态之间的相互关系并予以描述,从这种相互关系的变化中发现其与故障发展之间的联系和规律是我们的指导思路。

4. 方法

4.1 算法理论

变分模态分解 (Variational Mode Decomposition, VMD) ^[20, 21]

考虑到题目中所提供振动信号有多分量组成,为了实现信号组分的分离,我们选用了在信号自适应分解方面有着卓越性能的变分模态分解,关于变分模态分解的方法细节参见文献^[20]。

时间 - 全谱分析方法

本特利在 1999 年提出了旋转机械全谱分析的理论和技术^[1]。全谱技术通过将两只安装在不同方向上的轴振动传感器输出信号进行信息融合,从而实现对旋转机械轴心轨迹运动的直观描述。使用频率坐标上的分量判别轴的进动方向以及轴心轨迹的形状。全谱实际上是轴心轨迹的谱。在全频谱的基础上,又发展出了全息谱^[22]和全矢谱^[23]。但是这些方法都是基

于傅里叶变换的，由于傅里叶变换的平均效应，这些方法只适用于平稳的振动过程。本次比赛中的振动信号采集时是固定转速，理论上应为平稳信号，然而，从时域波形却发现并非理想平稳信号。因此采用上述平稳信号方法可能不利于信号分析。我们提出了时间 - 全频谱的新方法用于分析非平稳的轴心轨迹信号。

转子系统振动的可描述为简谐运动。

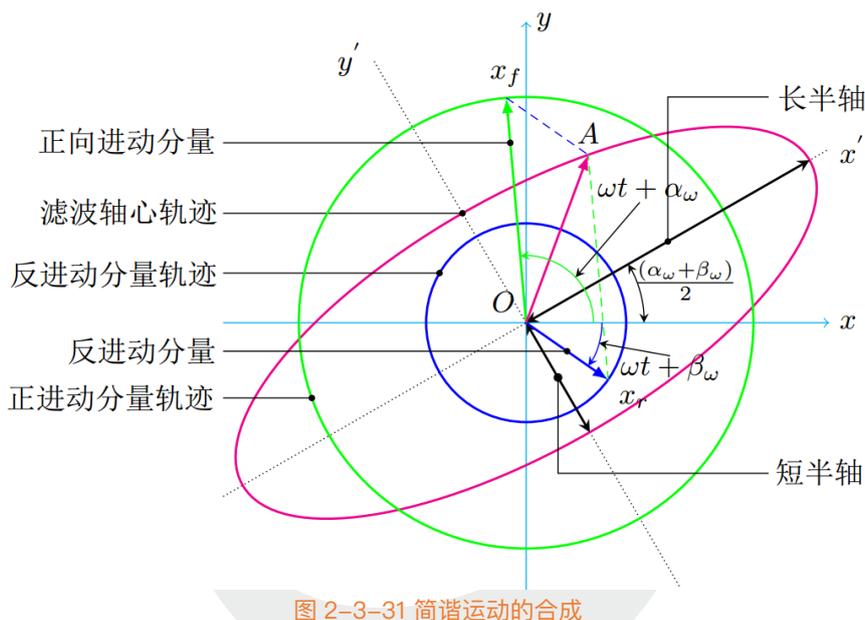


图 2-3-31 简谐运动的合成

首先关注工频振动，在 x, y 方向的运动上可以描述为

$$\begin{cases} x = x_0 \cos(\omega t + \varphi_x) \\ y = y_0 \sin(\omega t + \varphi_y) \end{cases} \quad (1)$$

其中 x_0, y_0 为转子中心在 x, y 方向的运动幅值； φ_x, φ_y 为初始相位角； ω 为转子运动的角速度； t 为时间。

椭圆上的点离椭圆心的距离 R 可以表示为

$$R = \sqrt{x^2 + y^2} = \sqrt{(x_0 \cos(\omega t + \varphi_x))^2 + (y_0 \sin(\omega t + \varphi_y))^2}$$

当旋转至长轴端点时， R 取得最大值，短轴端点时取最小值。由于 x, y 以相同的角速度 ω 变化。因此，求出 R 在长轴或短轴时的 x, y 相位值即可获得获得椭圆长轴端点坐标 (x_l, y_l) 和短轴端点坐标 (x_s, y_s) 。

转为求 R 的极值问题。令

$$f(\gamma) = R^2 = x^2 + y^2 = (x_0 \cos(\gamma + \varphi_x))^2 + (y_0 \sin(\gamma + \varphi_y))^2$$

推导得到以下关系：

$$\frac{\sin(2\gamma)}{\cos(2\gamma)} = \tan(2\gamma) = \frac{M \times \sin(2\varphi_y) - \sin(2\varphi_x)}{\cos(2\varphi_x) - M \times \cos(2\varphi_y)} \quad (2)$$

因此，确定了信号 x 与 y 的初始相位即可求得 γ 。

特别的，当 $y_0 = x_0$ 即 $M=1$ 时，有

$$4\gamma + 2\varphi_x + 2\varphi_y = k\pi, k = 1, 3, 5 \dots$$

$$\gamma + \varphi_x = \frac{k\pi}{2} - (\gamma + \varphi_y), k = 1, 3, 5 \dots$$

则有

$$\cos(\gamma + \varphi_x) = \cos\left(\frac{k\pi}{2} - (\gamma + \varphi_y)\right) = \sin(\gamma + \varphi_y), k = 1, 3, 5 \dots$$

因此当 $\omega t = \gamma$ ，有

$$\frac{y}{x} = \frac{y_0 \sin(\gamma + \varphi_y)}{x_0 \cos(\gamma + \varphi_x)} = \frac{y_0 \sin(\gamma + \varphi_y)}{x_0 \sin(\gamma + \varphi_y)} = 1。$$

设椭圆长轴与 x 轴的夹角为 θ ，则有 $\tan(\theta) = 1$ ；即椭圆与 x 轴的夹角固定为 $\frac{\pi}{4}$ 而与 φ_x 和 φ_y 无关。因此当 x 和 y 方向信号幅值一样时，无论相位关系如何，转子轴心轨迹长轴偏向角都是 45 度或 135 度。

基于上述推导，对于信号 x, y ，假设已知信号任意时刻的瞬时相位为 $\varphi_x(t), \varphi_y(t)$ ，由式 (2) 得 $\gamma(t)$ ，即以当前时刻为起点，以 ω 角速度经过 $\gamma(t)$ 角度后为椭圆的长轴端点。基于此，可以进一步求得椭圆的偏向角 $\theta(t)$ 以及椭圆长轴 $R_a(t)$ 。当 ω 为恒定值时，椭圆是确定的。更一般的，假设角速度 ω 为时变的，记为 $\omega(t)$ 。此时偏向角和长轴都可能是变化的。由前述特殊情况即 $M=1$ 时，无论 $\omega(t)$ 怎么变化， $\theta(t)$ 始终不变。以下给出 t 时刻估计椭圆轨迹的计算方法。

$$R_a(t) = \sqrt{(x_0 \cos(\gamma(t) + \varphi_x(t)))^2 + (y_0 \sin(\gamma(t) + \varphi_y(t)))^2}$$

同理可求得短轴

$$R_b(t) = \sqrt{\left(x_0 \cos\left(\frac{\pi}{2} + \gamma(t) + \varphi_x(t)\right)\right)^2 + \left(y_0 \sin\left(\frac{\pi}{2} + \gamma(t) + \varphi_y(t)\right)\right)^2}$$

相应的可以求得此时的正进动分量与反进动分量：

$$\begin{cases} x_f(t) = \frac{R_a(t) + R_b(t)}{2} \\ x_r(t) = \frac{R_a(t) - R_b(t)}{2} \end{cases}$$

根据全频谱理论，当正进动分量大于反进动分量时，转子为正进动，否则为反进动。进动分量的大小和方向性可以用来表征转子系统的运动状态。这也是我们选用的重要信号特征之一。

(1) 瞬时轨迹

基于上述推导，我们可以根据旋转信号求得任意时刻该信号分量的预计轴心轨迹。换句话说，如果转子保持当前振动状态运行下去，会形成估计的轨迹，我们将其定义为瞬时轨迹，类似于瞬时频率的概念。全谱分析和全息谱分析都是基于一段平稳信号经过 FFT 变换得到，因此其获得的轨迹实际上是转子按照平稳状态至少完成了一个完整周期的运动形成的轨迹。这是一种平均轨迹。然而，实际转子可能往往是不稳定的，某些特定的现象可能仅仅发生在转子旋转到某个角度时出现，如果基于传统的方法则难以判断。由上述方法可以求得转子在任意时刻的瞬时轨迹参数 $(R_a(t), R_b(t))$ ，或者 $(x_f(t), x_r(t))$ 。

(2) 瞬时进动方向

此外，经过推导我们还得到重要结论：

当分析转频分量旋转角速度 ω 一定时，式 $D = \cos(\varphi_y - \varphi_x)$ 表征着转子的进动方向，当 $D > 0$ 时转子正进动，即 X 向 Y，当 $D < 0$ ，Y 向 X。 $D = 0$ 时简化为一条直线的往复运动。我们将 D 定义为进动方向系数。其中 φ_x ， φ_y ，分别表示 X 方向 Y 方向测得信号的初始相位角。

基于上述论，可以不进行傅里叶变换，直接由两个时域信号的相位关系即可判别转子进动方向。另外，由于实际测量信号中 X，Y 方向信号的相位差可能是变换，这正好印证了，

轴心轨迹的进动方向也是变化的事实。轴系轨迹的进动方向是旋转机械转子多种故障的重要指示。本次比赛数据中，转子进动方向也是故障发展阶段中发生变化的重要指标参数。

(3) 仿真与实验

不妨构造如下信号模拟旋转机械开机过程的振动信号。信号幅值随着转速上升而增加。仿真结果如图 2-3-32 和图 2-3-33 所示。由图中可以发现，所述方法可以实现复杂振动过程的直观描述。

```

Fs = 1024; % 采样率
freq1 = 16; % 基频
w1 = 2 * pi * freq1; % 角速度
t = 0 : 1/Fs : 4; % 时间
AMx = 0.1 + 0.1 * t + 0.001 * t.^2; %x 方向信号幅值
AMy = 0.1 + 0.25 * t + 0.0015 * t.^2 ; %y 方向振动信号幅值
omiga1 = (0.2 + 0.001 * t)* w1; %x 方向信号相位
omiga2 = (0.2 + 0.001 * t)* w1; %y 方向信号相位
x = AMx .* cos(omiga1 .*t ); %x 方向信号
y = AMy .* sin(omiga2 .*t + pi*3/8); %y 方向信号
  
```

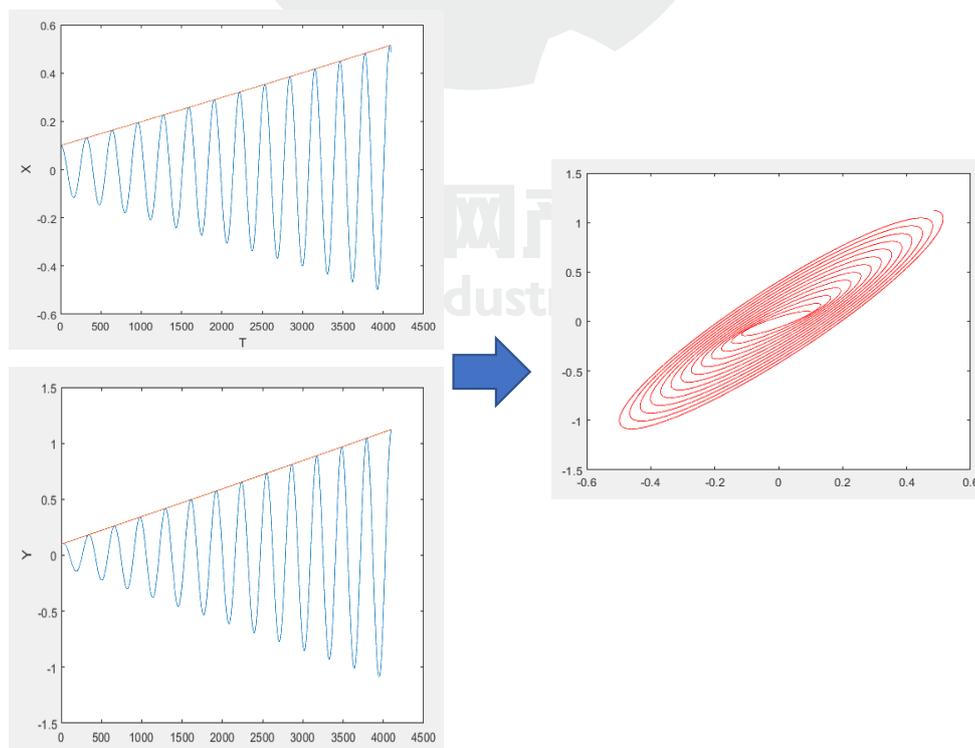


图 2-3-32 模拟旋转机械开机加速过程的轴心轨迹变化

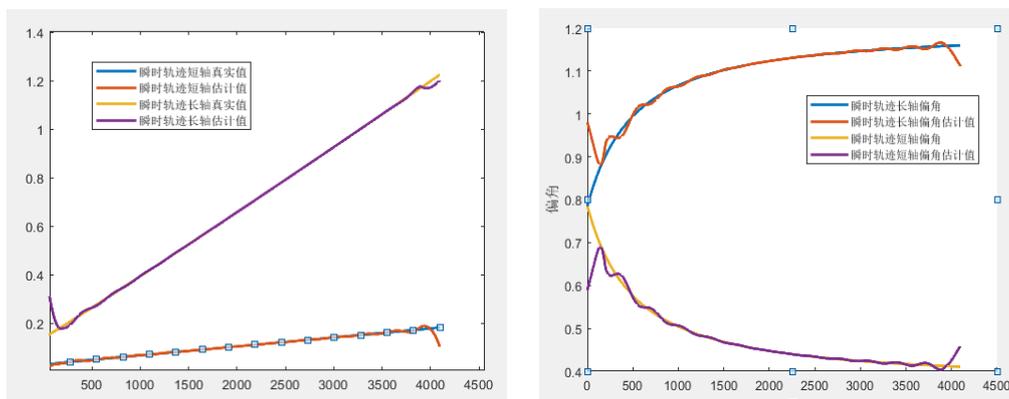


图 2-3-33 基于时 - 全谱分析的瞬时轨迹长短轴以及椭圆轨迹偏向角估计结果

如图 2-3-34 所示给出了选自本次赛题中某机组的一段振动数据，提取出其中的转频分量，两通道信号合成图中所示的轨迹，便于表达，将其绘制在添加时间轴的三维图上。图中红色椭圆线表示了对应时刻的瞬时轨迹。图 2-3-35 为 M9 不同阶段的 1X 瞬时轨迹估计长短轴关系图。从图中不难发现，当为平稳振动时，瞬时轴几乎为一条直线。时间关系，时 - 全谱分析的其他仿真和实验过程不再详细介绍。

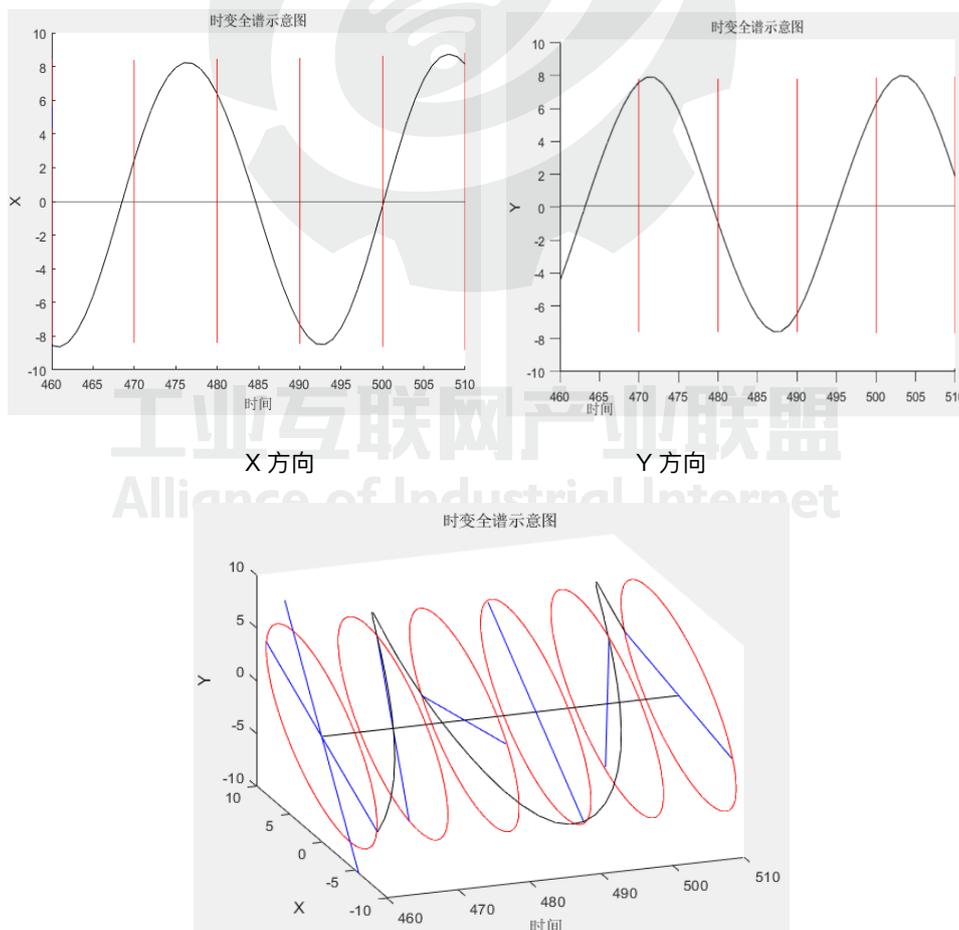


图 2-3-34 振动信号时变全谱分析示

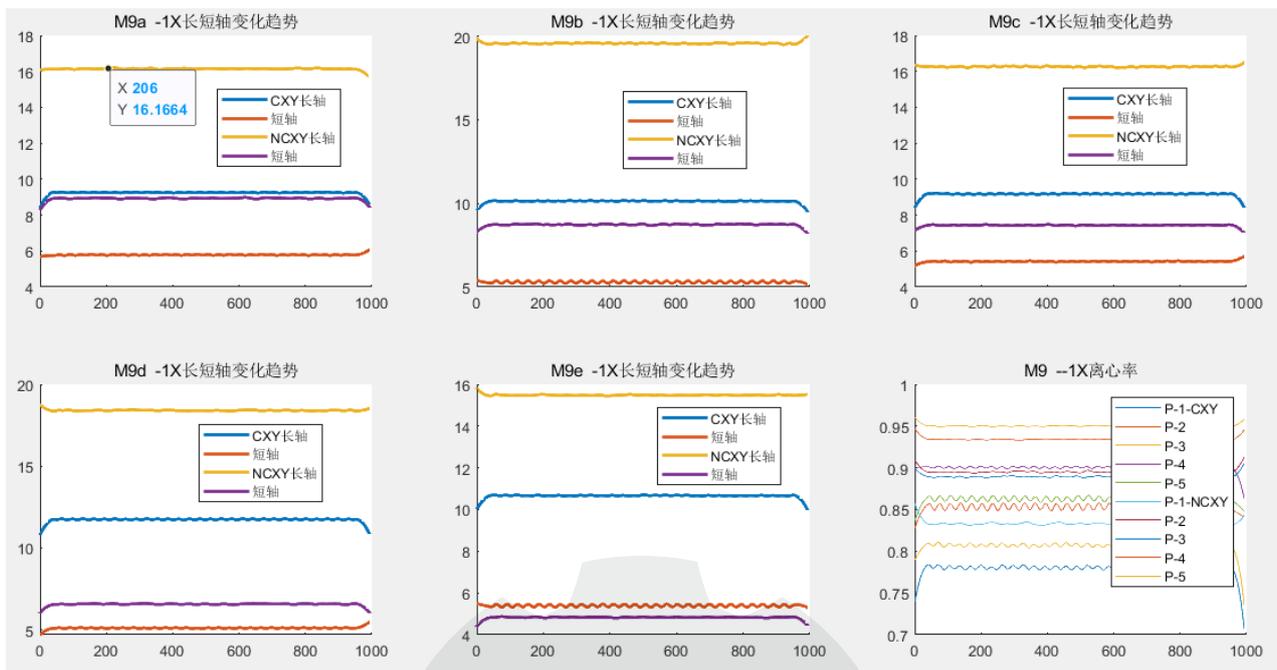


图 2-3-35 M9a-e 各阶段信号的瞬时轨迹长短轴关系图

4.2 解题思路

· 数据清洗

数据处理中我们发现提供的数据中存在测点不对齐，和明显的转速奇异点。前述方法中通道数据的融合方法实现的前提是四个通道数据来自相同的时刻。因此必须是时间对齐的。

例如图所示为 M2_b 中的转速数据。其中红点标识可能为切换工况时的数据。应进行分离或剔除，避免对训练结果引起误判。奇异点检测和与数据对齐算法，不是比赛关键，在此不作详细介绍。仅举例说明。

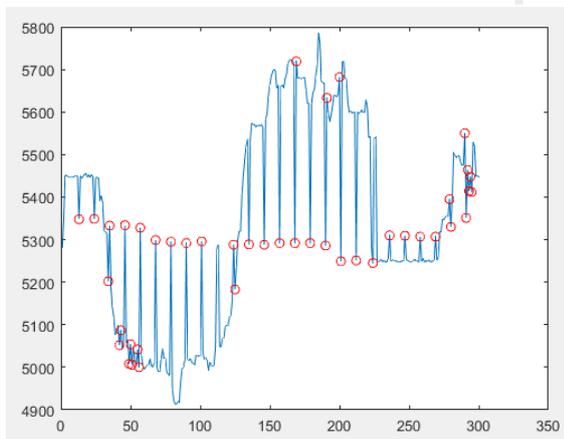


图 2-3-36 M2_b 中转速突变奇异点示意图

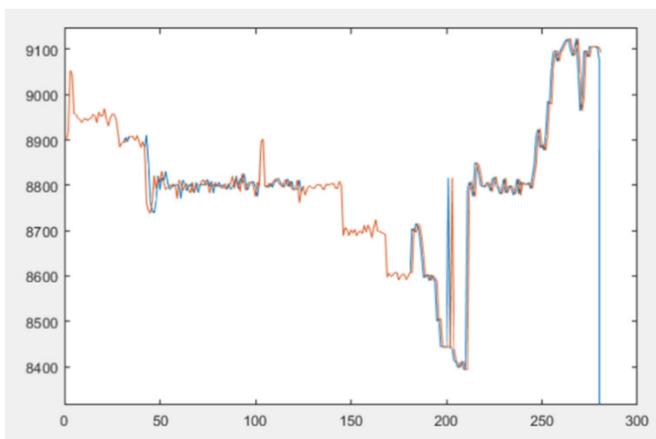


图 2-3-37 M7_a 中数据不对齐问题

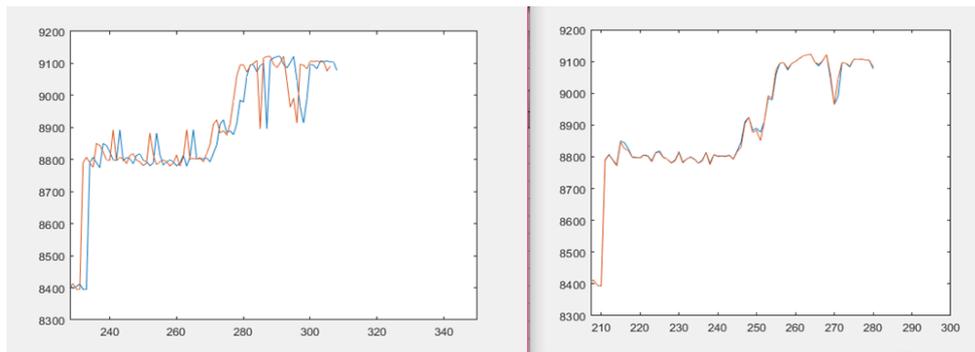


图 2-3-38 M7_a 中数据错位问题处理前后对比

·特征提取

我们尝试了从振动信号中提取多种特征信息用于表征振动，例如时域的峰峰值，均方根值。频域的频谱，时频谱等等。虽然这些特征能很好的描述机组的振动情况，同一台机组的变化也能明显区分。但是某一台机组的特征变化规律无法用以套用在另一台机组上。例如 M1 非联端振动信号主频幅值随着靠近故障的发生有增大趋势，而 M2 却不是这样的规律。因此我们发现对信号进行融合之后使用相对值可以发现一定的规律。因为，无论什么类型的智能算法，都是基于有效的输入特征数据。对于无效的特征数据无论什么样的算法也无法实现准确辨识。

如图 2-3-39 所示给出我们从信号中提取相对特征信息的流程图。我们对比了不同分量振动信号合成轴心轨迹的相互关系。我们惊奇的发现，随着机组靠近振动发生时间，两个端面测得的轴心轨迹的相互关系在不同机组上有着一致的变化规律。即其中一个端面轨迹面积增大，另一个端面不变或者减小。更准确的说，两个端面轴心轨迹的面积比值越接近故障发生值越大。从物理上也可以得到解释，假设可能脱落的部件位置靠近机组非联端，则随着不平衡的发展，非联端的振动轨迹可能逐渐增大，而联端轨迹甚至有可能因为振型的变化减小。但可以确定的是两个端面轴心轨迹的面积之比增大了。这种变化的大小跟不平衡变化的程度有关，也与机组初始的固有不平衡有关。有可能是非常轻微的，也有可能是变化巨大的。这种变化的差别有赖于大量的案例数据进行积累。

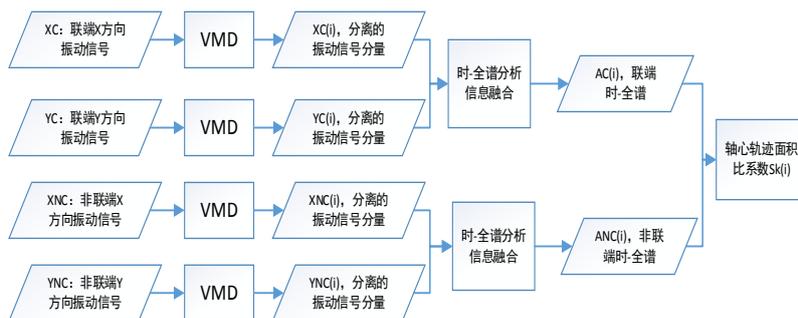


图 2-3-39 特征提取流程图

由前述方法已经求得了椭圆轨迹的两个半轴值 a, b 。根据椭圆面积计算公式 $S = \pi ab$ 。分别求得联端和分联端的轨迹面积 S_c, S_{nc} 。我们定义轨迹面积比例系数 $E_s = \frac{|S_c \square S_{nc}|}{S_c + S_{nc}}$ 。

E_s 越小表示两个端面轨迹面积差别越小，越靠近于 1 表示 差别越大。如图 2-3-40 所示为已知故障发展过程的 M2 的轨迹面积比例系数变化规律。可以发现，基本趋势是越靠近故障发生 E_s 值越大。同样经过初赛确认的 M9 也有着相同的变化规律。我们将 M9 不同阶段 1X 信号分量合成轨迹进行对比，印证了上述规律。从合成轨迹我们发现，故障的发展与某通道的振动幅值没有绝对的一致关系。

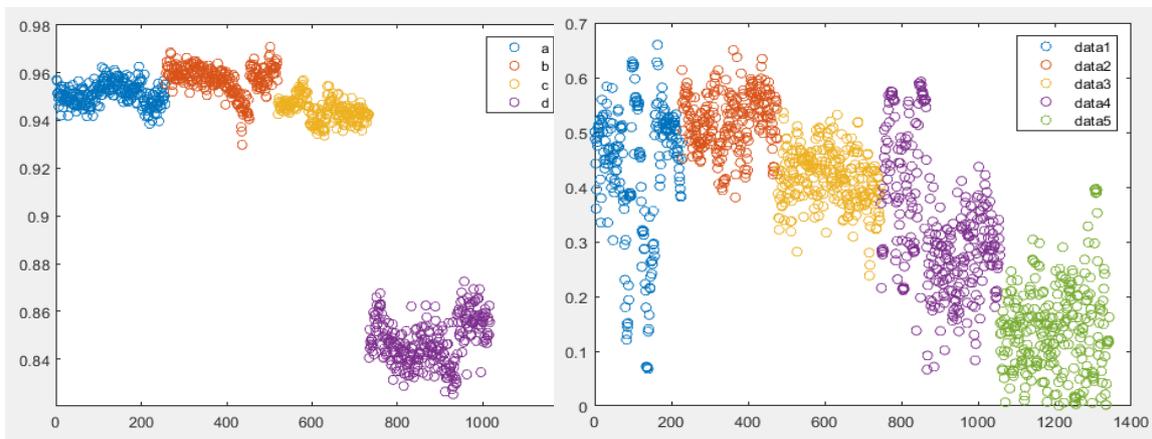


图 2-3-40 M2 M9 轨迹面积比例系数随着阶段的变化趋势

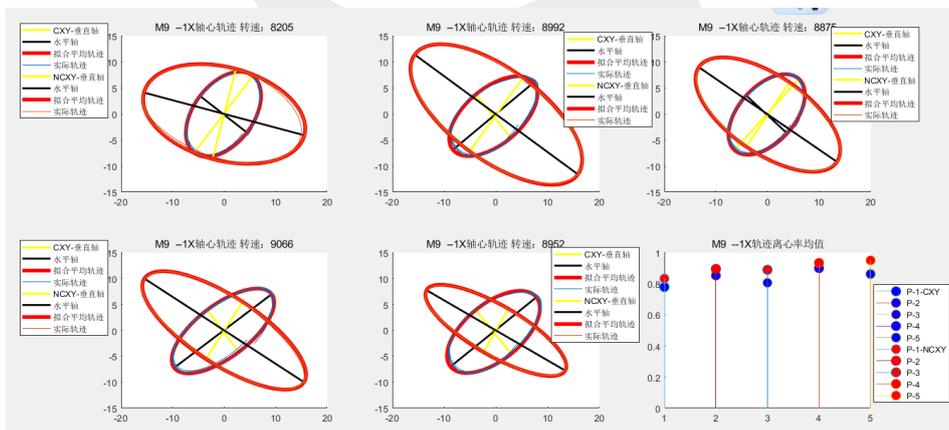


图 2-3-41 M9 不同阶段两个端面 1X 轴心轨迹的相对变化关系依次为 a-e

基于上述考虑我们拟选择如下特征作为预测和训练的指标集。列表 如下：

| 符号 | 特征名称 | 取值范围 | 说明 |
|----------|------------|-------------|--------|
| E_s | 轨迹面积比例系数 | $0 \sim 1$ | 参照前文定义 |
| ec | 联端轴心轨迹离心率 | $0 \sim 1$ | |
| enc | 非联端轴心轨迹离心率 | $0 \sim 1$ | |
| D_c | 联端进动方向系数 | $-1 \sim 1$ | 参照前文定义 |
| D_{nc} | 非联端进动方向系数 | $-1 \sim 1$ | 参照前文定义 |

·趋势预测

由于给出的数据为非连续，因此抽象为分类问题进行求解。我们尝试了支持向量机、KNN 等方法。初始我们选定各阶次的谐波幅值作为输入特征进行分类，若以单台机作为训练和测试对象，用于测试的大多数分类器都可以呈现很好的区分性能。说明故障机组故障发展阶段是可分的。所选特征可以反映机组的故障程度。而非故障机组虽然也可以实现阶段分离，但是准确性明显降低，说明可分离性很低。但是遗憾的是使用训练得到的模型对未知机组开展预测时，效果十分不理想。分类精度和效果与所选算法关系不是太密切，与所选特征关系更密切。分析中我们发现，1X 分量信号为主要依据。

考虑到可能是各台机组振动幅值绝对值由于转速因素存在巨大差异。我们尝试将得到的幅值除以国际标准给定的该转速的报警限定值。折算得到相对振幅。

对应转速下的振动报警值计算公式由下式给出：
$$St = \frac{4800}{\sqrt{S}}$$

其中 S 表示对应转速，St 为对应转速下的振动报警参考值。折算为相对值之后，特征值的幅值处在相同数量级，但是不同机组之间差异仍然巨大，无法实现迁移学习。因此我们认为，学习算法不是本赛题的关键，关键还是找到能进行横向比对的关键性特征。

从已知数据和初赛数据来看，阶段聚类性越强，故障概率越大，这与通过面积比例系数判别的结果十分接近。

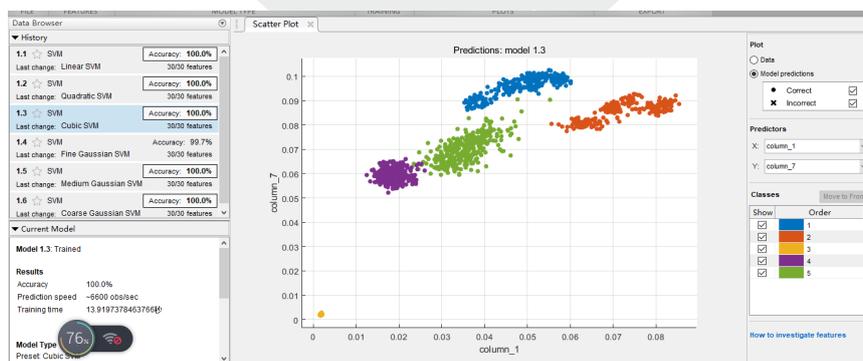


图 2-3-42 M1 分类效果 – 聚类性好，准确度 100%

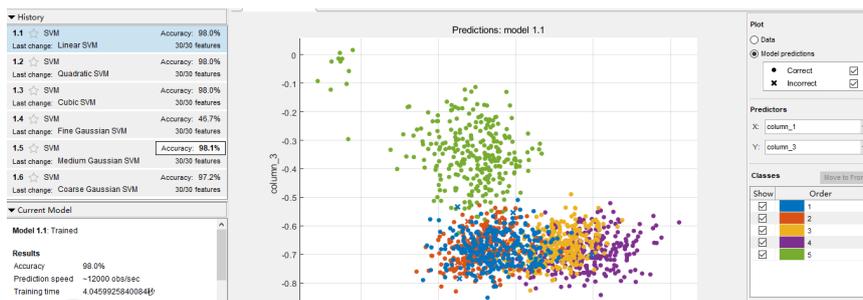


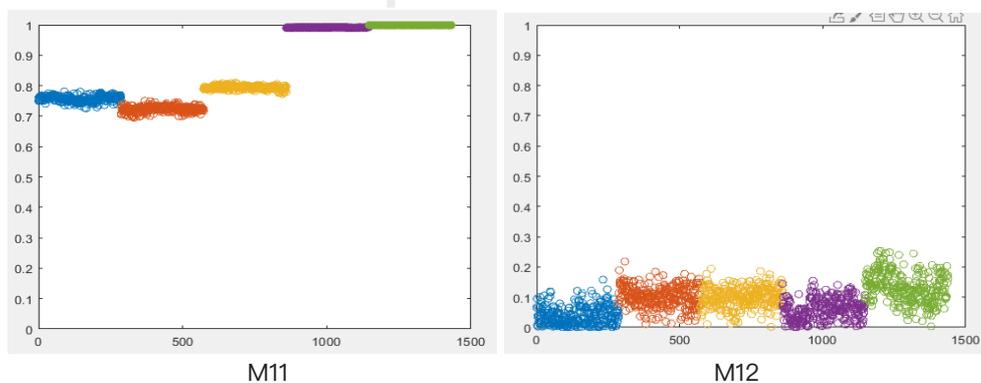
图 2-3-43 M3 分类效果 – 聚类性差，准确度相对低

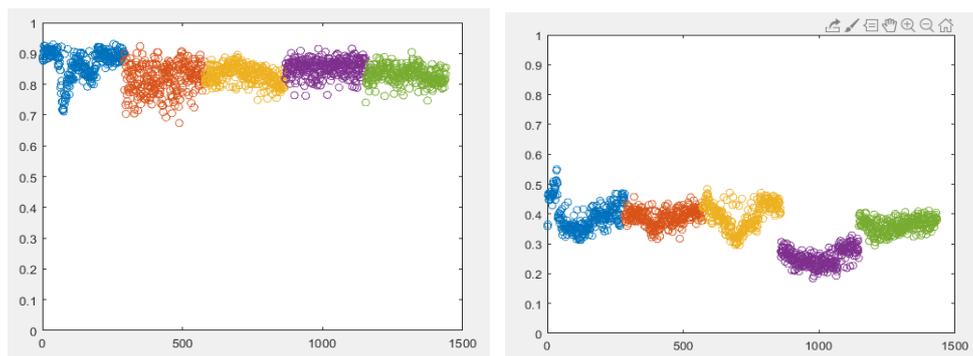
表格 1 以单台机特征进行分类训练准确性结果对比

| 机组号 | 单台机特征训练准确性 | 故障 |
|-----|------------|----|
| M1 | 100% | Y |
| M2 | 100% | Y |
| M3 | 98% | N |
| M4 | 98% | N |
| M5 | 74% | N |
| M6 | 90% | N |
| M7 | 100% | Y |
| M8 | 97% | N |
| M9 | 100% | Y |
| M10 | 99.9% | Y |
| M11 | 100% | ? |
| M12 | 83% | |
| M13 | 95% | |
| M14 | 97% | |
| M15 | 99% | ? |
| M16 | 97% | ? |
| M17 | 99.8% | ? |
| M18 | 90% | ? |

5. 验证

5.1 轨迹面积比例系数计算结果

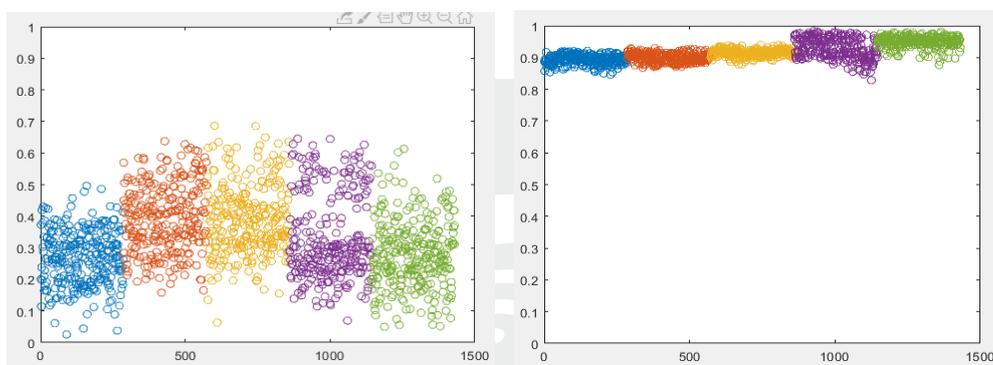




M13

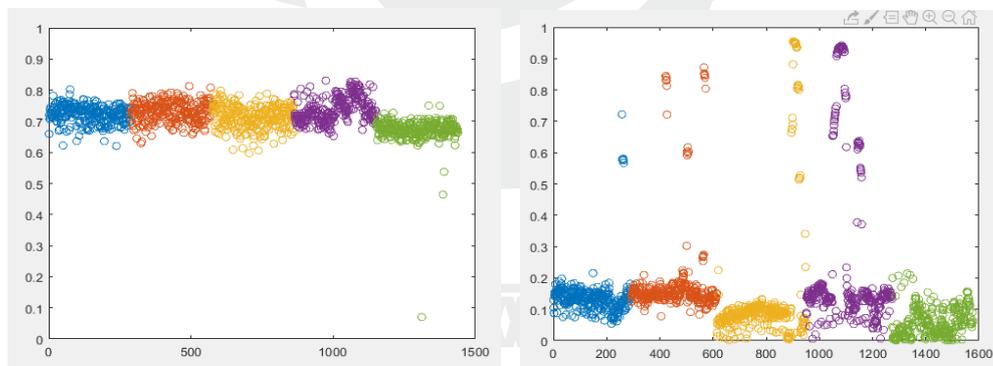
M14

图 2-3-44 M11~M14 不同阶段的面积比例系数变化趋势 (原始顺序 1~5)



M15

M16



M17

M18

图 2-3-45 M15~M18 不同阶段的面积比例系数变化趋势 (原始顺序 1~5)

从上述图示来看。M11, M15, M16, M17, M18 五台机轨迹面积比例系数较高, 存在明显趋势。且波动幅度比较大。认为其发生脱落故障的风险比较大。其余机组虽有一定的变化趋势, 但是波动幅度不大, 趋势也不够明显, 认为发生故障的几率较小。M13 比例系数较高, 说明联端和非联端轨迹面积绝对值差别较大, 存在一定的故障风险, 比例系数存在一定的变化趋势, 由于位置时间顺序, 无法确认是否为劣化过程, 如果为上升趋势, 则同样存在故障风险。M12, M14 整体变化平稳, 发生故障的几率较低。

5.2 1X 分量轴心轨迹对比图

附几台机不同阶段 1X 轴心轨迹对比图。

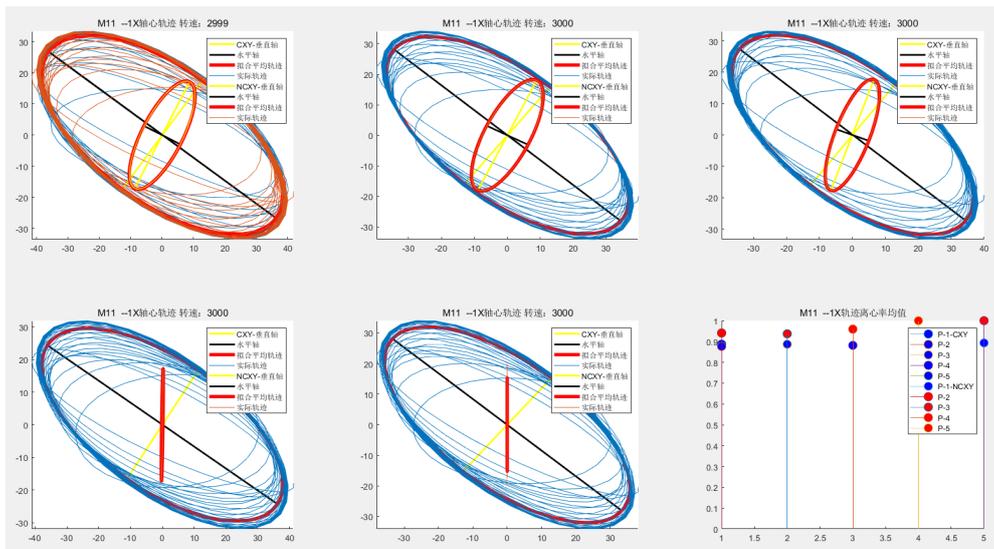


图 2-3-46 M11 不同阶段 1X 轴心轨迹对比图

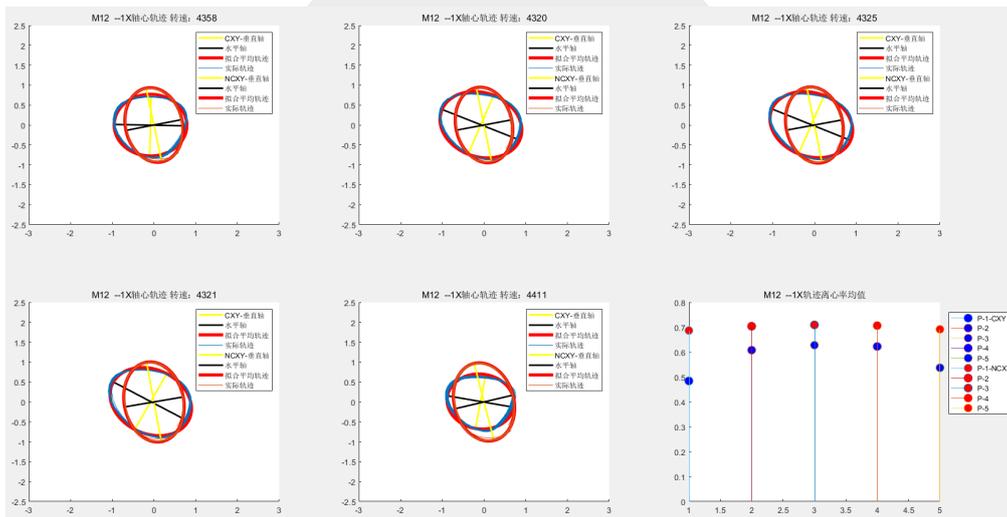


图 2-3-47 M12 不同阶段 1X 轴心轨迹对比图

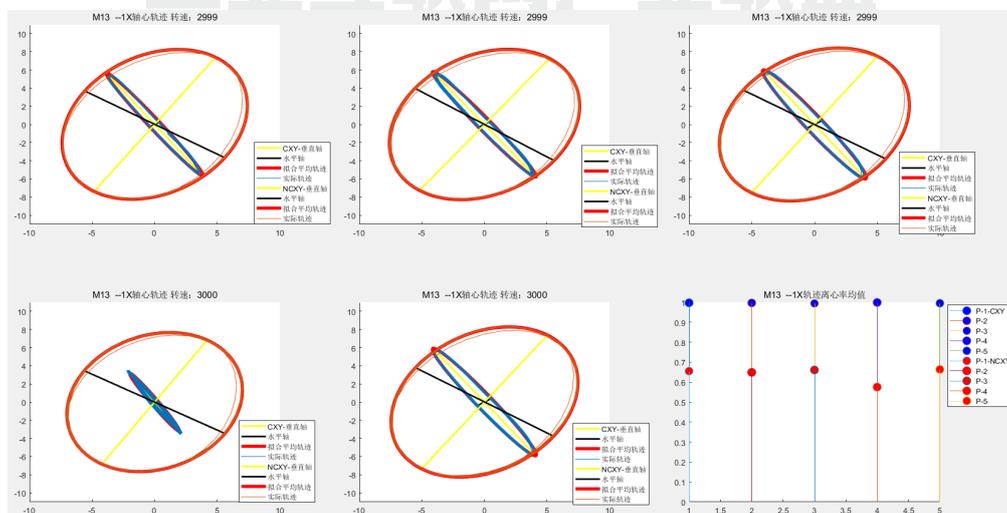


图 2-3-48 M13 不同阶段 1X 轴心轨迹对比图

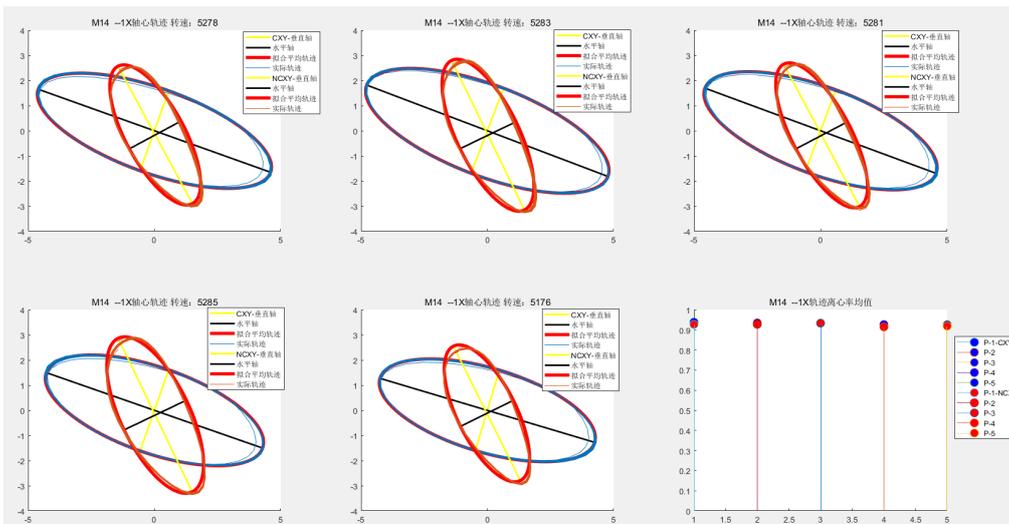


图 2-3-49 M14 不同阶段 1X 轴心轨迹对比图

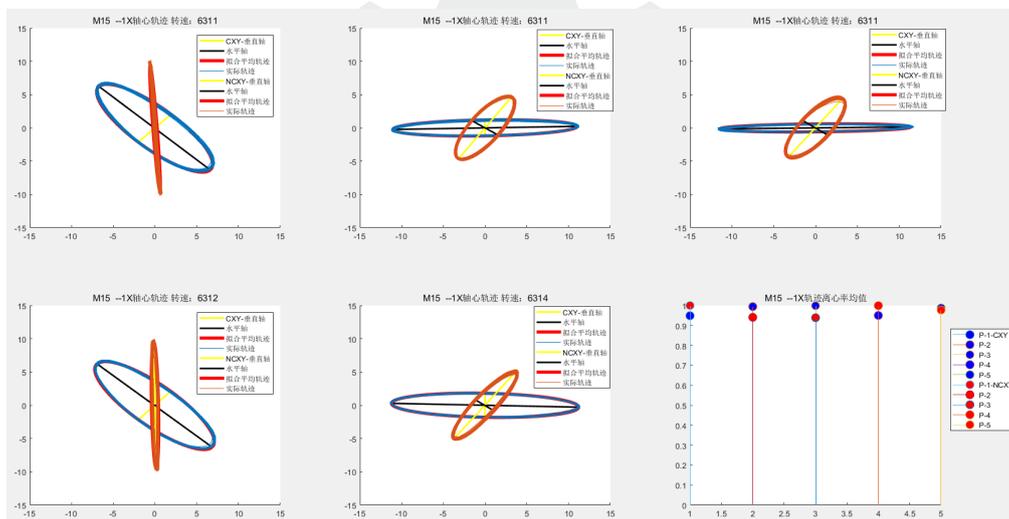


图 2-3-50 M15 不同阶段 1X 轴心轨迹对比图

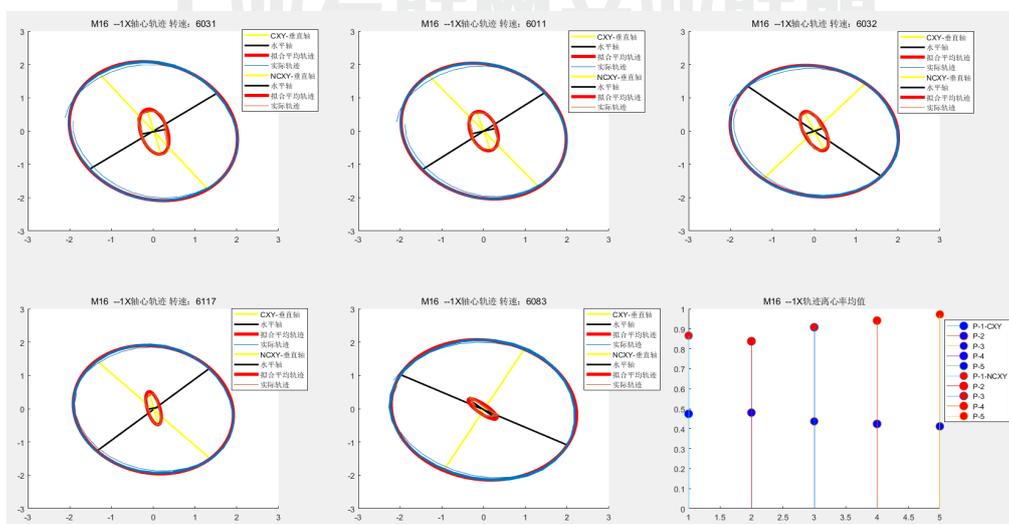


图 2-3-51 M16 不同阶段 1X 轴心轨迹对比图

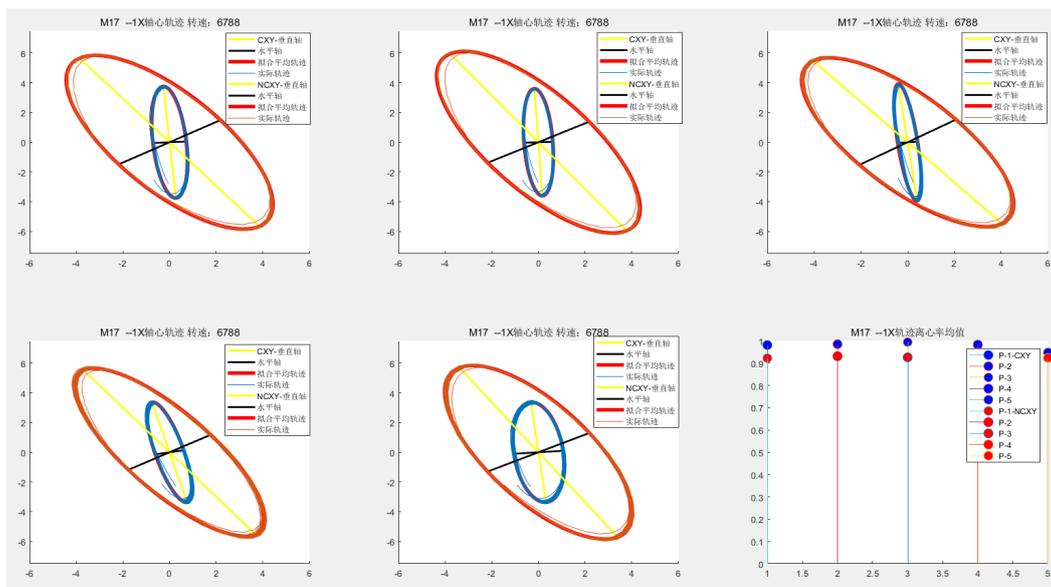


图 2-3-52 M17 不同阶段 1X 轴心轨迹对比图

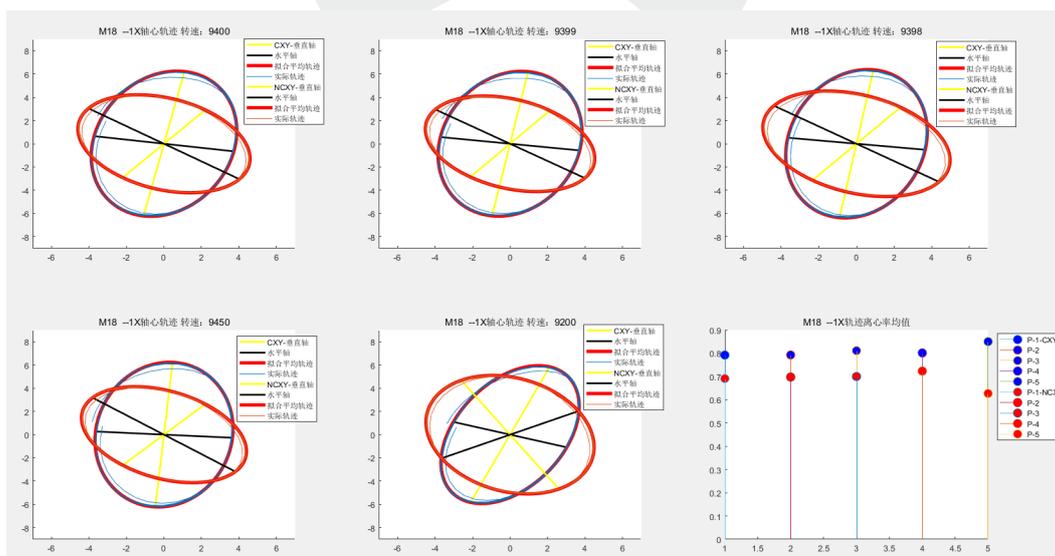


图 2-3-53 M18 不同阶段 1X 轴心轨迹对比图

5.3 2X 及其他合成轨迹对比分析

除了重点分析 1X 轨迹变化以外，我们还对 2X 及高阶合轨迹进行了对比分析。分析中我们也发现故障机组不同阶段下轨迹形状变化明显，差异巨大。如图 2-3-54 为 M2 各个阶段的不同频段轨迹的合成图。从图中我们不难发现除了轨迹面积变化以外，轨迹的形状也有着明显的变化。时间关系，我们还未未来得及分析这种变化的量化表示。如果能进行量化描述，对于预测故障发展应该是很有帮助的。同样我们也给出了 M6 非故障机组的合成轨迹变化，见图 2-3-56。从图中我们可以看出不同阶段轨迹未有特别明显的变化。

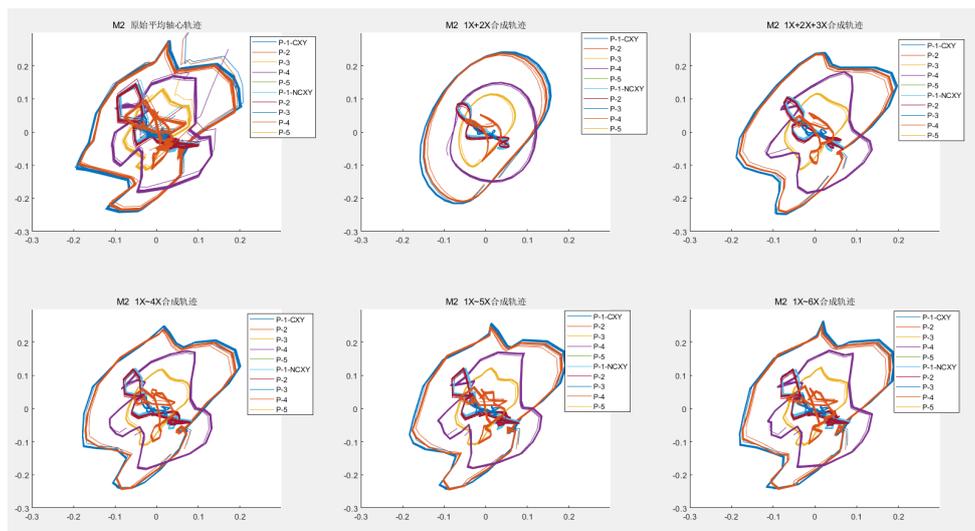


图 2-3-54 M2 不同阶段合成轨迹的变化关系

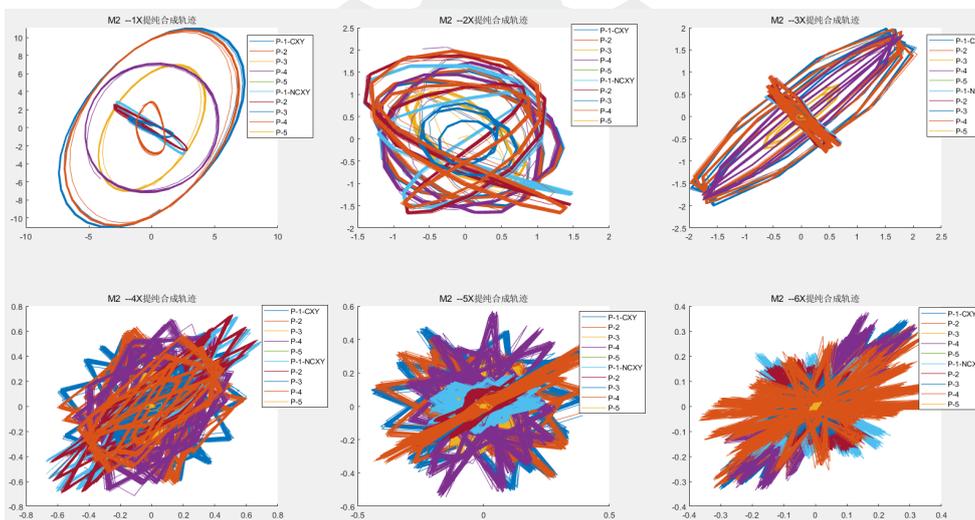


图 2-3-55 M2 不同阶段 1~6X 合成轨迹变化图

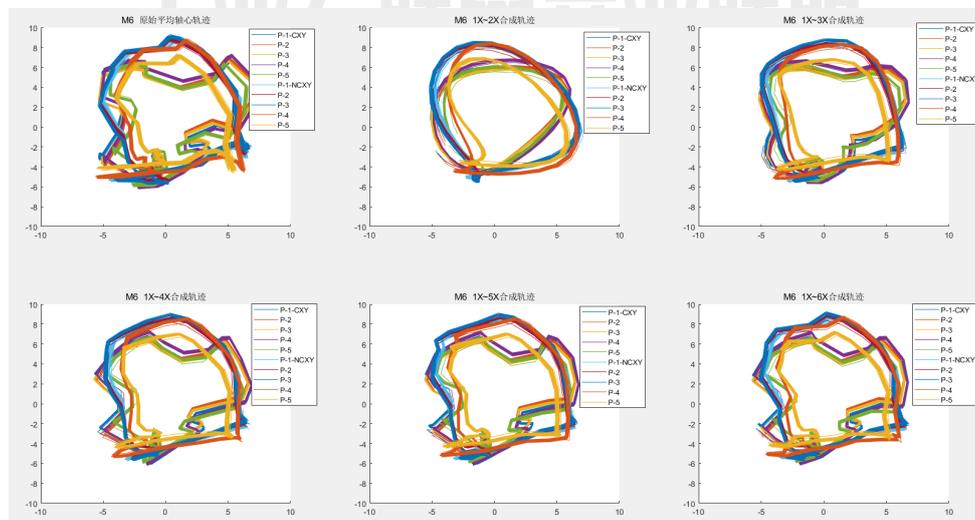


图 2-3-56 M6 不同阶段各阶合成轨迹的变化关系

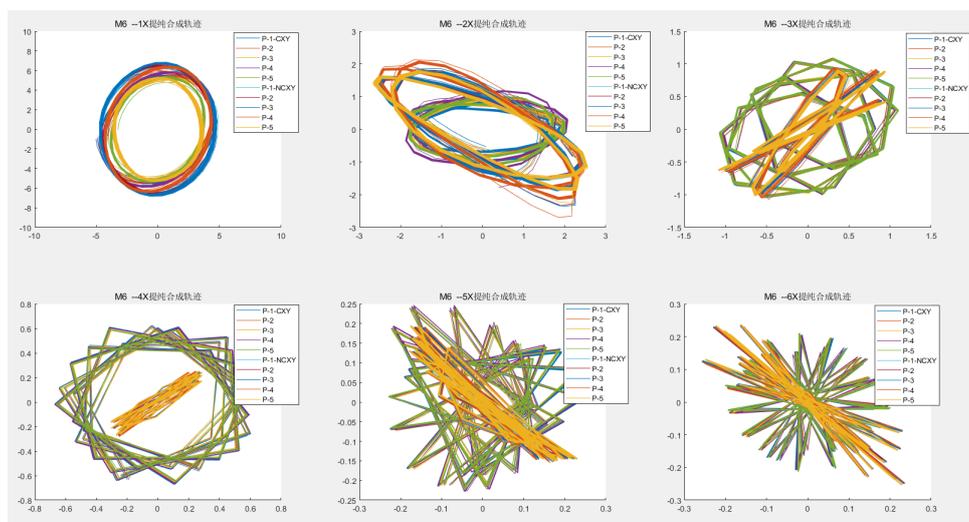


图 2-3-57 M6 不同阶段 1~6X 轨迹图

6. 结果分析与经验总结

旋转机械部件脱落故障征兆可能表现为轻微不平衡或机组平衡状态的变化。

最为明显且直接的征兆为两断面 1X 轴心轨迹相对关系的变化，且差别越大，发生概率越大。如果发生突变则发生几率的概率更大。轨迹面积比例系数还可以作为机组振动健康状况评价的一项非常有用的量化指标。

我们提出了时间 - 全谱分析的方法，提出并定义了瞬时轨迹概念。提出了旋转机械进动方向判别指标和方法。这对于分析旋转机械转子部件脱落乃至其他类型故障都拓展了思路。

分析故障机组发现，2X，3X 及高次谐波轨迹随着故障的发展也存在一定的规律，例如形状，大小等。但是还未能实现规律的完全总结。尚难以作为判别依据。

综合判断 M11，M15，M16，M17，M18 五台机发生故障概率更高 M13 比例系数较高，说明联端和非联端轨迹面积绝对值差别较大，存在一定的故障风险，比例系数存在一定的变化趋势，由于位置时间顺序，无法确认是否为劣化过程，如果为上升趋势，则同样存在故障风险。

M12，M14 整体变化相对平稳，发生故障的几率较低。M18 机组工况切换比较多，且面积比例系数较低，存在较大的不确定性。M14 不同阶段参数存在跳变，但是没有十分明显的劣化趋势，同样存在不确定性。如果能配合相关工况数据，应能有更好的判断结果。

结合比赛中数据的处理，下一步需要研究如何利用这些趋势和特征训练自动预测模型。目前挑选出来的特征进行横向对比和迁移学习时的效果仍然不佳，有必要进行进一步的特征空间转换，将不同机组数据投影到相同空间，以便达到更好的预测结果。

从最终公布结果来看，发生部件脱落故障的机组为 M11，M13，M15。M17，M18 发生其他类型故障。与所提方法判别结果接近。所提方法提取出的指标可作为大型旋转机械机组故障综合预警指标。也可作为基于机器学习方法的训练特征。

所提方法基于转子系统振动机理，算法简单，对计算硬件要求不高，且具有较好的解释性，对数据依赖度也不高，有一定的工业应用价值。此外，所提方法特别适用于经常处于非平稳工况下的旋转机械的故障诊断。

7. 参考文献

- [1] GOLDMAN P M A. Application of full spectrum to rotating machinery diagnostics [J]. Orbit, 1999,20 (1): 17–21.
- [2] BENTLY DONALDE., HATCH CHARLEST. 旋转机械诊断技术 [M]. 机械工业出版社, 2014.
- [3] MONTE M, VERBELEN F, VERVISCH B. The use of orbitals and full spectra to identify misalignment[M]//Springer, 2014:215–222.
- [4] FULL SPECTRUM ANALYSISIN JOURNAL BEARING DIAGNOSTICS [J].
- [5] PATEL T H, DARPE A K. Use of full spectrum cascade for rotor rub identification[J]. Advances in Vibration Engineering, 2009,8(2): 139–151.
- [6] FENGQI W, MENG G. Compound rub malfunctions feature extraction based on full-spectrum cascade analysis and SVM[J]. Mechanical Systems and Signal Processing, 2006,20(8): 2007–2021.
- [7] SHRAVANKUMAR C, TIWARI R. Detection of a fatigue crack in a rotor system using full-spectrum based estimation[J]. Sadhana, 2016,41(2): 239–251.

- [8] 李晓峰. 基于动力学的转子系统主要故障特征的研究[D]. 华中科技大学机械制造, 2001.
- [9] 屈梁生, 邱海, 徐光华. 全息动平衡技术: 原理与实践[J]. 中国机械工程, 1998,9(1): 60-63.
- [10] 屈梁生, 史东锋. 全息谱十年: 回顾与展望[J]. 振动. 测试与诊断, 1998(04): 3-10.
- [11] 韩捷, 关惠玲, 梁川, 等. 矢谱——一种实用的旋转机械故障诊断分析方法[J]. 机械强度, 1998(03): 54-57.
- [12] LEE J, WU F, ZHAO W, et al. Prognostics and health management design for rotary machinery systems—Reviews, methodology and applications[J]. Mechanical Systems and Signal Processing, 2014,42(1): 314-334.
- [13] LEE J, DAVARI H, SINGH J, et al. Industrial Artificial Intelligence for industry 4.0-based manufacturing systems[J]. Manufacturing Letters, 2018,18: 20-23.
- [14] JARDINE A K S, LIN D, BANJEVIC D. A review on machinery diagnostics and prognostics implementing condition-based maintenance[J]. Mechanical Systems and Signal Processing, 2006,20(7): 1483-1510.
- [15] YAN R, GAO R X, CHEN X. Wavelets for fault diagnosis of rotary machines: A review with applications[J]. Signal Processing, 2014,96(5): 1-15.
- [16] WANG Y, MARKERT R, XIANG J, et al. Research on variational mode decomposition and its application in detecting rub-impact fault of the rotor system[J]. Mechanical Systems and Signal Processing, 2015,60-61: 243-251.
- [17] YU D, CHENG J, YANG Y. Application of EMD method and Hilbert spectrum to the fault diagnosis of roller bearings[J]. Mechanical Systems and Signal Processing, 2005,19(2): 259-270.
- [18] WIDODO A, YANG B S. Support vector machine in machine condition monitoring and fault diagnosis[J]. Mechanical Systems & Signal Processing,

2008,21(6): 2560–2574.

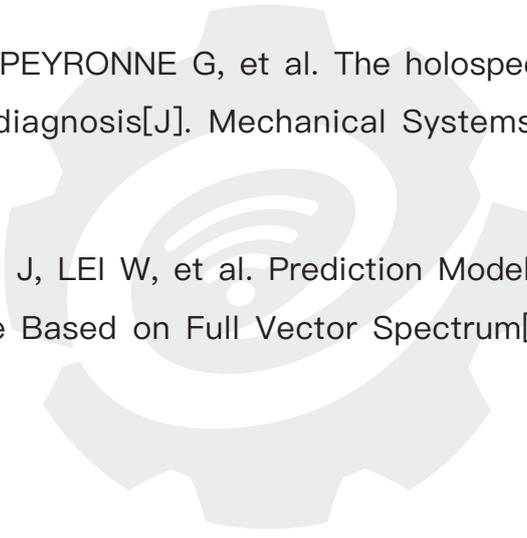
[19] ZHAO R, YAN R, CHEN Z, et al. Deep learning and its applications to machine health monitoring[J]. Mechanical Systems and Signal Processing, 2019,115: 213–237.

[20] DRAGOMIRETSKIY K, ZOSSO D. Variational Mode Decomposition[J]. IEEE Transactions on Signal Processing, 2014,62(3): 531–544.

[21] XU B, ZHOU F, LI H, et al. Early fault feature extraction of bearings based on Teager energy operator and optimal VMD[J]. ISA Trans, 2019,86: 249–265.

[22] QU L, LIU X, PEYRONNE G, et al. The holospectrum: A new method for rotor surveillance and diagnosis[J]. Mechanical Systems and Signal Processing, 1989,3(3): 255–267.

[23] CHEN L, HAN J, LEI W, et al. Prediction Model of Vibration Feature for Equipment Maintenance Based on Full Vector Spectrum[J]. Shock and Vibration, 2017,2017: 1–8.



工业互联网产业联盟
Alliance of Industrial Internet

(七) 基于多传感器信号变化分析的转子系统异常检测

1. 团队介绍

团队名称: Tea

| 成员姓名 | 团队角色 | 职位 |
|--------------|------|-----------------|
| Myungyon Kim | 队长 | 韩国首尔国立大学, 博士研究生 |
| Jongmin Park | 队员 | 韩国首尔国立大学, 博士研究生 |
| Yongjin Shin | 队员 | 韩国首尔国立大学, 博士研究生 |

Kim Myungyon, Jongmin Park 和 Yongjin Shin 是韩国首尔国立大学的博士研究生, 跟随 Byeng D. Youn 教授在实验室从事系统健康和风险管理的研究。

2. 背景简介与文献调研

该项目的目标是对喷射中使用的转子进行预测, 因而主要任务是捕获转子故障的早期症状。主要任务分为两个部分: 第一部分是识别目标故障单元; 第二部分是根据故障强度对时间序列进行排序。

所用数据来自汽轮机和压缩机, 其传感器类型是涡流位移传感器, 每个单元有 5 个测量集, 每个测量包含 6~7 个传感器数据; 联轴器 X, Y (2), 非联轴器 X, Y (2), 轴向位移 (2~3)。

评分规则如下: R 计算为 R_1 和 R_2 的乘积。在步骤 1 中, R_1 是正确分类数与总数之比, 步骤 2 中, R_2 是正确的连续故障序列的长度与故障序列的总长度之比。

$$R = R_1 \times R_2$$

(R_1 : 用于正确分类, R_2 : 用于正确排序)

$$R_1 = \frac{c}{n}$$

(c : 正确分类的单位数)

$$R_2 = \frac{S_1 + S_2 + \dots + S_m}{m}$$

(m : 故障单元数, S_i : 第 i 个故障单元)

表 1 正确的连续序列比例

| 正确和连续序列的数量 | 1 | 2 | 3 | 4 | 5 |
|------------|-----|-----|-----|-----|---|
| | 0.2 | 0.4 | 0.6 | 0.8 | 1 |

3. 数据解析

如果转子零件飞驰中有故障，则在获得的信号中应显示出明显的变化。离目标故障越近，所获得信号的变化越大^[1]。我们可以确认信号本身，X & Y 之间，耦合与非耦合之间 3 个部分的变化。

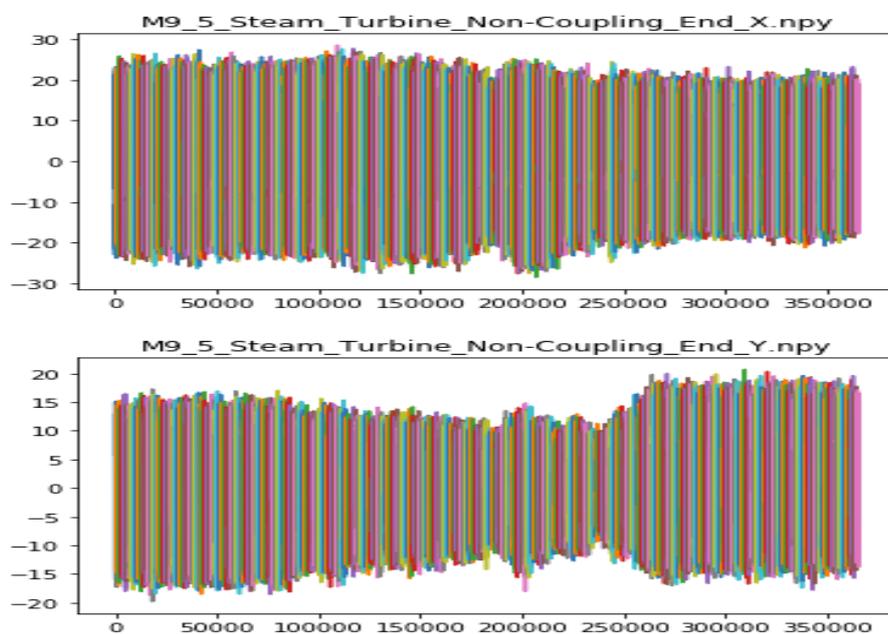


图 2-3-58 信号本身的变化

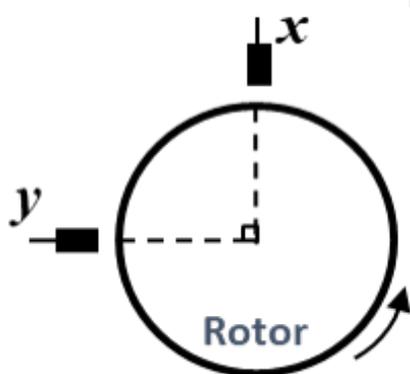


图 2-3-59 X & Y 之间的差异

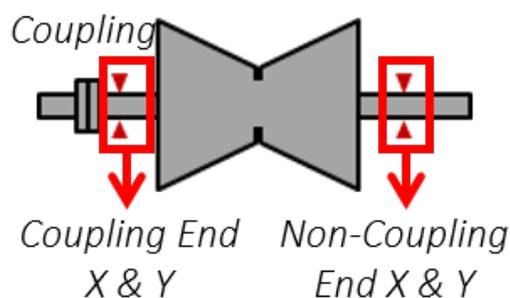


图 2-3-60 耦合和非耦合之间的变化

系统的类型和规格可能不同，进而导致我们无法获悉故障发生在何处。因此，我们使用多种数据分析方法基于多个传感器的数据开展分析研究。通过与其他单元进行比较，变化较大的单元被认定为故障单元。

表 2 详细展示了我们所使用的每种技术特征和特性，在第一步中，我们使用整波趋势、轨道分析、时域分析和特征 2D 图来检测故障单元^[2-3]。在第二步中，我们使用时域分析、特征比率趋势和特征差异对时间序列进行了排序^[4]。

表 2 使用的分析方法

| | 分析方法 | 特征参数 | 特性 |
|----|-------------|------------------------|-------------------|
| 0 | 速度曲线 | 各系统转速 | |
| 1 | 整体趋势 | 数据变化 | |
| 2 | 轨道分析 | 轨道 / 平均信号轨道 | |
| 3 | 时域分析 | 均方根值, 峰值, 平均值, 均方根值方差等 | |
| 4 | 2D 图 | 均方根值, 一倍频, 归一化的均方根值 | 耦合 / 非耦合 x, y 特征图 |
| 5 | 比率趋势 / 2D 图 | X 与 Y 的均方根比 // 传感器 | 或倒数 |
| 6 | 特征差异 | X 与 Y 的均方根差 // 传感器 | 或反过来 |
| 7 | 频率 | | |
| 8 | 倒谱 | 质素 | |
| 9 | 平均分析 | 角域平均 | 同步信号之间的均值 |
| 10 | 残差 | 同步信号之差 | |

第一步：检测故障单元

- 1) 全波趋势
- 2) 轨道分析
- 3) 时域分析
- 4) 二维特征图

第二步：排序时间序列

- 1) 时域分析
- 2) 特征比率趋势
- 3) 特征差异

图 2-3-61 整个步骤的路线图

4. 方法

对于本次比赛，任务有两种：（1）确定出现目标故障的单元；（2）根据故障的强度对时间顺序进行排序。为解决这两个任务，我们提出了一种两步式的问题解决方法。

对于第一个任务，要检测或识别具有目标故障的单元，我们使用了第3节中介绍的几种数据分析方法。首先，如图5所示，我们可以使用整个波动趋势图来区分正常系统和故障系统。如背景部分所述，越接近目标故障，所获得的信号变化越大。图2-3-62 (a)是正常情况，显示信号内的变化很小。相反，对于图2-3-62 (b)所示的故障情况，可以看出信号的变化相对较大。

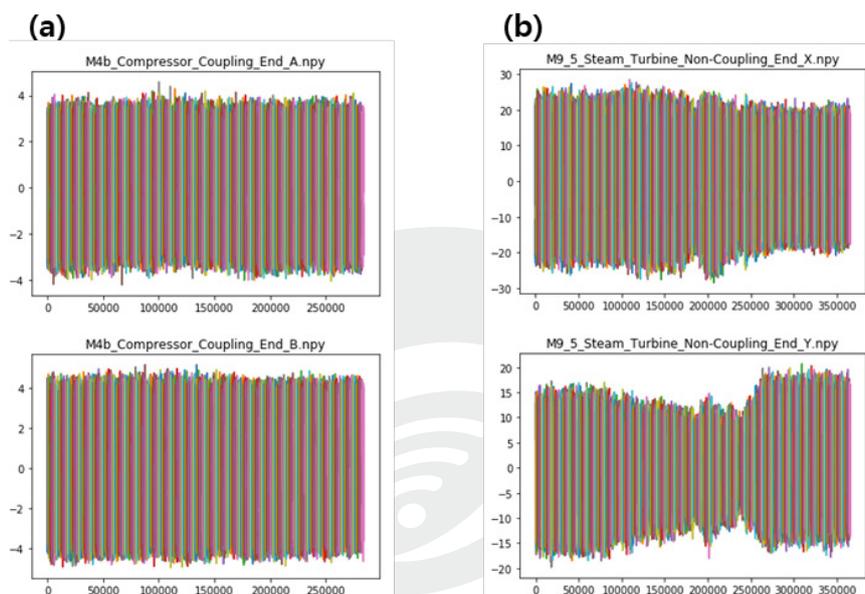


图 2-3-62 (a) 正常和 (b) 故障信号的全波趋势图

另外，使用轨道分析来解决任务1。如图2-3-63 (a)所示，对于正常情况，我们能够确认轨道图变化很小，但是，对于图2-3-63 (b)中的故障情况，轨道随时间变化很大，且形状非常失真。

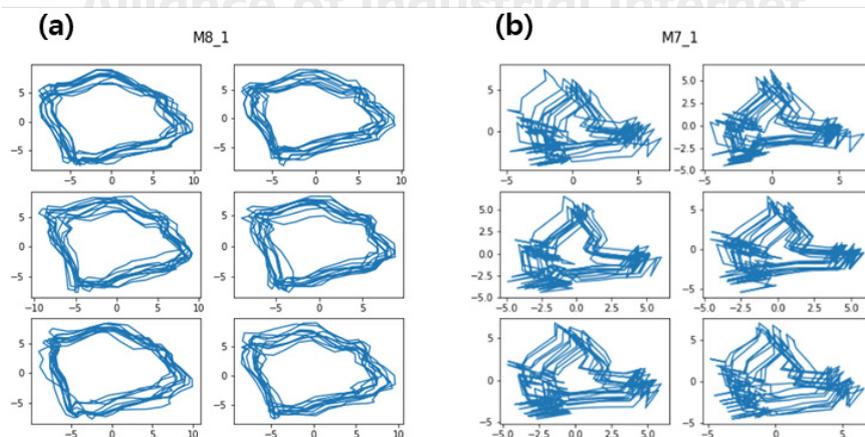


图 2-3-63 (a) 正常和 (b) 故障信号的轨道分析图。

接下来，为进行更多的定量分析，使用了时域分析方法。图 2-3-64 显示了非耦合信号的 RMS 图，这是我们使用的时域特征之一。在此图中，彩色部分代表故障系统。我们可以看到，故障系统和正常系统是明显可区分的。

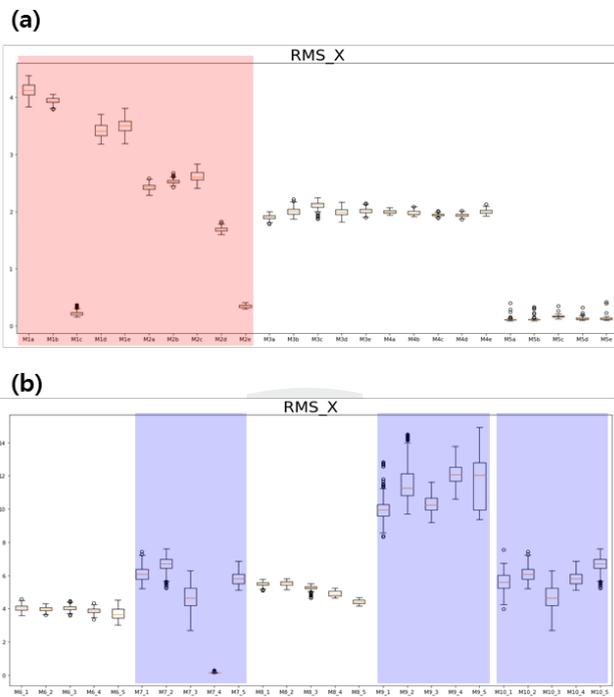


图 2-3-64 时域分析 –(a) 训练集和 (b) 测试集的 RMS 图。

之后分析时域特征内的方差，以图 2-3-65 中所提供的 RMS 特征的方差为例，可以看到，基于 RMS 方差可以轻松针对训练集 (a) 和测试集 (b) 识别故障系统和正常系统。

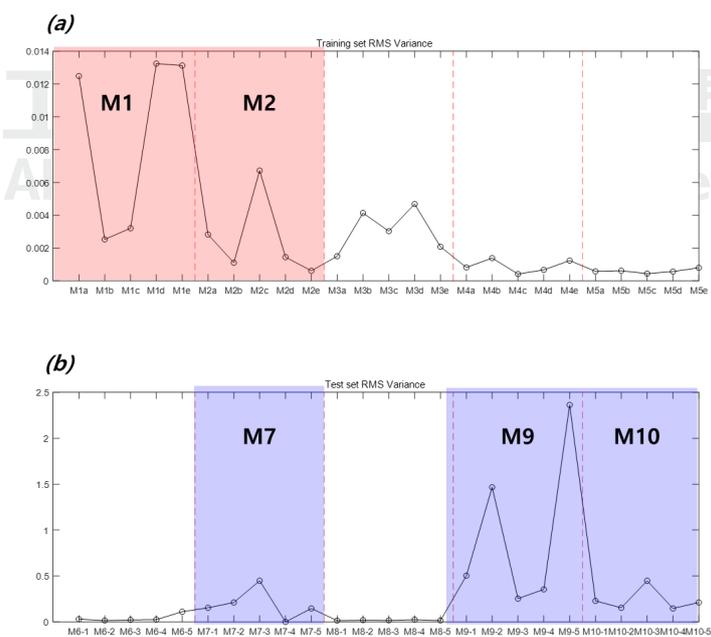


图 2-3-65 (a) 训练集和 (b) 测试集的 RMS 方差图。

步骤1中的最后一步分析方法是基于x和y传感器的时域特征的二维图。如图2-3-66(a)所示，它是x和y传感器的RMS二维图，我们可以看到，正常信号的不同时间序列之间存在重叠。可以看出，在正常系统数据的情况下，数据随时间的变化很小，这意味着没有明显的变化，例如转子飞越故障。相反，对于故障系统数据，如图2-3-66(b)所示，可以看出数据随时间存在一些变化，这可能是由于目标系统中出现多个故障状态而导致的。

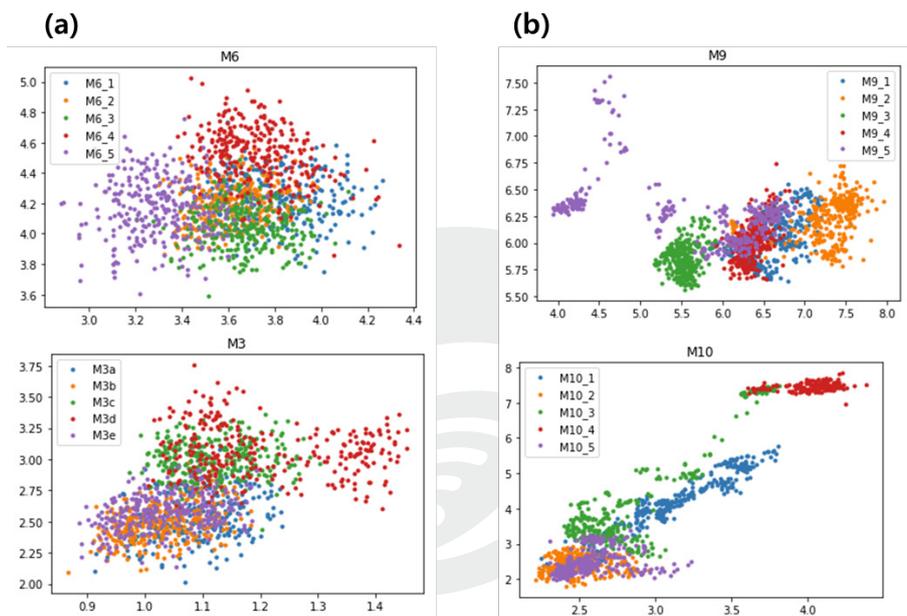


图 2-3-66 (a) 正常信号和 (b) 故障信号的 RMS 二维图

对于第二项任务，根据故障强度对时间序列进行排序，我们开发了分析不同信号之间变化的方法。如背景部分所述，当发生诸如转子部件飞散之类的故障时，可以检测到所获得信号的显著变化：

- (1) 信号自身内；
- (2) x 和 y 传感器之间；
- (3) 传感器安装在不同的位置。

对于步骤1，上面提到的分析方法主要集中在信号本身内捕获的变化。在此步骤中，为了检测安装在垂直位置的两个传感器之间的变化，我们分析了这两个传感器信号的时域特征之间的差异和比率。

例如，图2-3-67显示了来自两个传感器x和y的RMS值之间的比率，用于初始阶段的训练数据集。我们可以看到，RMS值的变化取决于健康状态或时间。

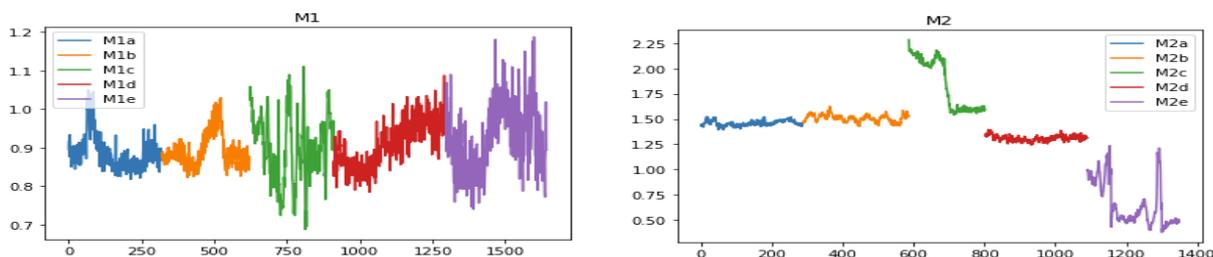


图 2-3-67 训练数据集故障信号的 RMS 比率图

对于初步阶段的数据集测试，我们还可以基于 RMS 比率和差异分析，根据故障的强度正确排序时间顺序。图 2-3-68 显示了测试数据集故障信号的 RMS 比率图。基于 RMS 比率 / 差异的趋势，我们能够正确排序序列。

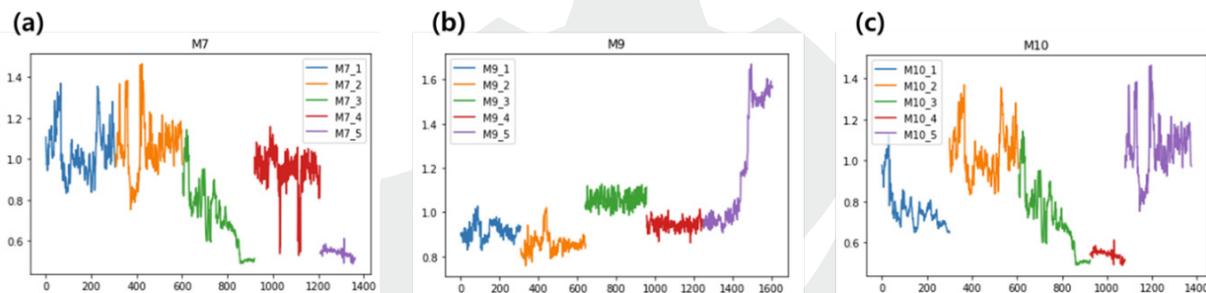


图 2-3-68 测试数据集故障信号的 RMS 比率图：(a)M7,(b)M9 和 (c)M10

5. 验证

正如我们在初期阶段所做的那样，我们进行了变分分析以检测和预测故障。我们使用沿 x 和 y 轴在耦合和非耦合部分获得的振动信号。当我们分析信号时，根据表 3 中的系统分离了数据集。

工业互联网产业联盟

表 3. 系统类型

| 系统 | 数据集 |
|-----|-----------------|
| 汽轮机 | M11,M12,M17,M18 |
| 压缩机 | M13,M14,M15,M16 |

首先，我们提取每个数据的 RMS 并进行分析。在图 2-3-69 中，对于汽轮机数据，M11，M13 数据的 RMS 值大于其他数据集，尤其是在非耦合信号中。对于压缩器，在耦合和非耦合信号方面，M15 的 RMS 值都比其他数据集大。

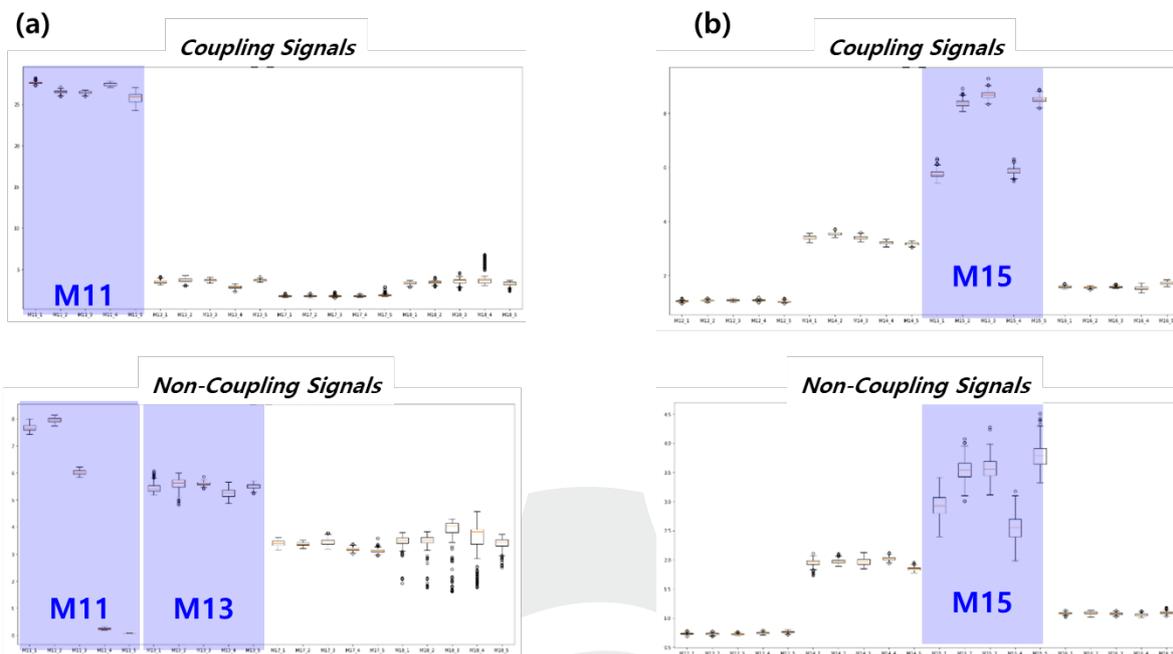


图 2-3-69(a) 汽轮机 (b) 压缩机在 x 轴上的 RMS 箱形图

为了更深入地分析，我们从每个数据集的 RMS 中提取方差，并绘制为图 2-3-70。M11、13、15、18 显示出更高的 RMS 值方差。考虑到 RMS 值的大小和方差，在 M18 情况下，方差异常大。但是 M13、13、15 在 RMS 值的大小和方差上均显示出故障特征。

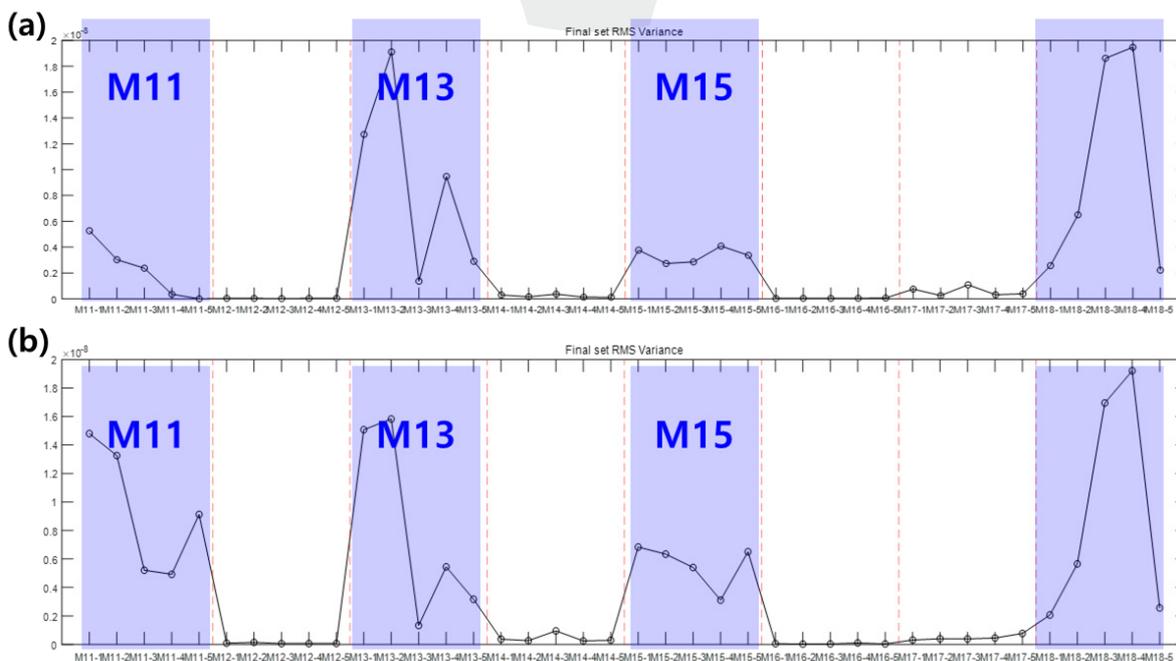


图 2-3-70 沿 (a)x 轴, (b)y 轴的非耦合 RMS 的方差

为了更准确地确定，我们还进行了图 2-3-71 的轨道分析。对于 M11、13，轨道没有显示出圆形。它们呈椭圆形，在耦合和非耦合情况下，它们的主轴分别逆时针和顺时针旋转。特别是，在 M13 中耦合信号的情况表明，轨道在接近直线的地方变形了。因此，我们确定 M11、13、15 个数据集已包含故障数据。

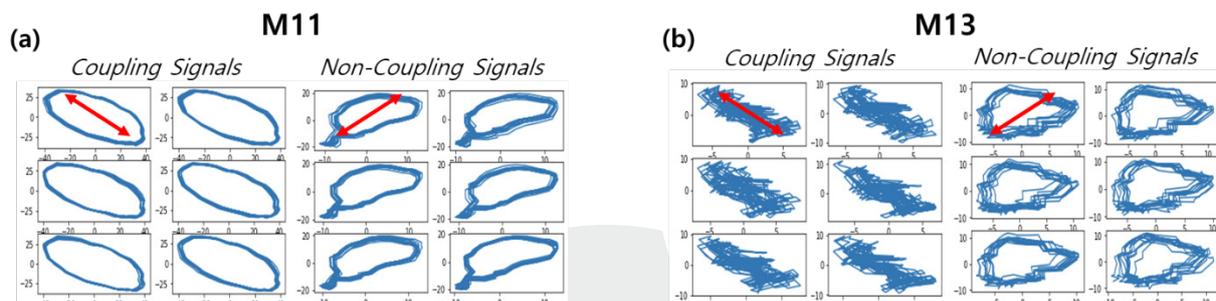


图 2-3-71 M11、13 的耦合和非耦合信号的轨道分析

确定要设置故障的数据集后，我们必须确定哪个数据更接近或远离故障时间。因此，我们还使用每个数据的 RMS 值的比率和差异对数据进行了变异分析。

首先，我们在图 2-3-72 中观察到耦合和非耦合信号中 RMS 的差异。在 M11 中，我们可以通过 RMS 的差异来区分 M11_1、11_2、11_3 和 M11_4、11_5。因此，我们可以得出结论，(1,2,3) 集或 (4,5) 集更接近失效时间。

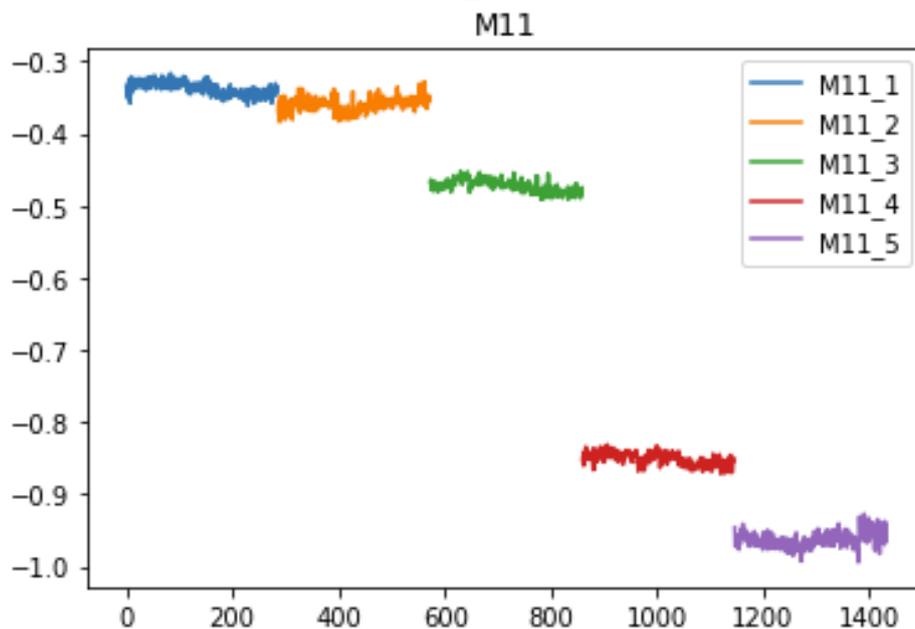


图 2-3-72 M11 数据集在非耦合中的 RMS 差异

接下来，我们在图 2-3-73 中观察到耦合和非耦合信号中 RMS 的比率。在 M15 情况下，非耦合显示 RMS 比率值的差异，我们可以分为 (1,4) 数据集和 (2,3,5) 数据集。在 M13 情况下，耦合率的 RMS 比值没有明显显示，但其方差显示出不同。M13_2 和 13_4 显示较大的方差，而 13_1、13_3 和 13_5 显示较小的方差。因此，我们可以将 M13 数据集分为 (2,4) 和 (1,3,5)。综上所述，我们能够将故障数据集分为两组，如表 4 所示，并且能够找到距故障时间更近或更远的数据。

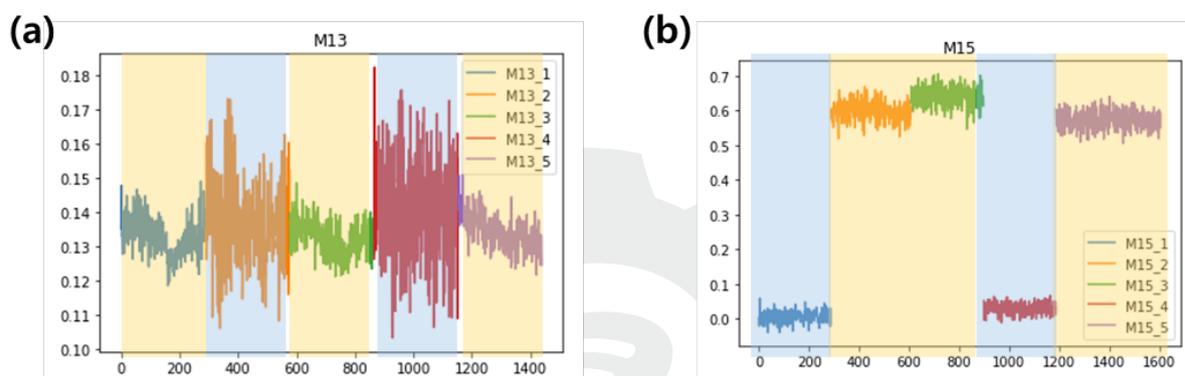


图 2-3-73 (a) 耦合 M13 和 (b) 非耦合 M15 中的 RMS 之比

表 4 分离数据集以预测故障时间的结果

| 故障数据集 | 已分离的数据集 |
|-------|---------------|
| M11 | (1,2,3)&(4,5) |
| M13 | (1,4)&(2,3,5) |
| M15 | (2,4)&(1,3,5) |

工业互联网产业联盟
Alliance of Industrial Internet

我们检测到故障数据集并预测了转子系统的故障时间。我们对这两个部分进行了变异分析。在第一部分中，我们提取 RMS 和 RMS 方差以检测故障数据集并执行轨道分析。为了预测故障时间，我们将数据集分为两部分，以确定哪个数据集更接近或远离故障。

因此，我们可以准确地检测到故障集，但是在时间预测中存在一些错误。由于标签数据的不可信性，我们无法预测发生故障的准确时间。但是我们可以分离和匹配哪个数据集更接近或远离故障。因此，如果我们获得更准确的标记数据，则可以使用相同类型的数据来预测转子系统何时发生故障。

7. 参考文献

[1] BentlyDE, Hatch CT, Grissom B. Fundamentals of Rotating Machinery Diagnostics. ASME Press; 2002.

[2] Jung JH, Jeon BC, Youn BD, Kim M, Kim D, Kim Y. Omnidirectional regeneration (ODR) of proximity sensor signals for robust diagnosis of journal bearing systems. Mech Syst Signal Process 2017;90:189–207. <https://doi.org/10.1016/j.ymssp.2016.12.030>.

[3] Park J, Jeon B, Park J, Cui J, Kim M, Youn BD. Failure prediction of a motor-driven gearbox in a pulverizer under external noise and disturbance. Smart Struct Syst 2018;22. <https://doi.org/10.12989/sss.2018.22.2.185>.

[4] Jeon BC, Jung JH, Youn BD, Kim YW, Bae YC. Datum unit optimization for robustness of a journal bearing diagnosis system. Int J Precis Eng Manuf 2015;16:2411–25. <https://doi.org/10.1007/s12541-015-0311-y>

第三篇章 工业大数据产业创新生态及平台

一、工业大数据产业创新生态

随着新一代信息技术与制造业加速融合，工业互联网、智能制造等正在从概念普及进入实践深耕的发展阶段，在这一进程中，大数据作为一种新的资产、资源和生产要素，技术创新和应用实践日趋活跃，已成为驱动制造业智能化变革的重要动力。而工业数据量激增，软件、网络、装备等各领域间技术频繁发生跨界耦合交融，人工智能等技术创新大幅提升工业大数据的应用潜能，使得工业大数据正处于融合发展和变革创新的重要关口。

美国早在 2008 年起开始探索通过竞赛方式促进大数据、人工智能与制造业融合，针对设备健康状态评估、剩余生命周期预测等问题进行方法研究和测试论证，涉及航空发动机、齿轮箱、风机测风仪、半导体、轨道交通等多个工业场景。GE 也曾经发起过多次数据竞赛，悬赏解决飞行路径规划、医疗大数据等问题，并获得解决实际问题的具体模型算法和专业人才。短短几年内，工业大数据竞赛在全球发展迅速，为企业带来了切实的效益，并且激发了一批有热情、有潜力的开发者参与其中。

为进一步探索工业大数据对工业改革的深远影响，自 2017 年起在工业和信息化部指导下，中国信息通信研究院连续三年主办工业大数据创新竞赛，旨在从吸引人才关注、促进工业智能化、建立工业大数据生态等多个方面推动我国工业大数据产业创新生态发展。近年来通过搭建产业创新平台，对产业生态形成了良好的促进作用。创新平台以打通企业创新供需壁垒为起点，逐步扩展至行业数据资源池建设、研发工具和方法论总结、人才培养、创业孵化等领域，激发工业大数据产业创新活力，促进开发者、制造企业、产业服务机构的良性互动。



图 3-1-1 工业大数据产业创新生态

二、工业大数据产业创新平台

在工业互联网体系架构建设目标的指引下，信通院于 2018 年初筹划并建设了“工业大数据产业创新平台”（以下简称“创新平台”，网址：<http://www.industrial-bigdata.com>）。创新平台是基于工业基础数据库和云应用支撑环境开发的综合性数据分析平台，以推动工业大数据产业创新为使命，为我国工业大数据开发者搭建了学习成长、交流讨论、应用实践的一站式门户，旨在降低大数据创业创新门槛，帮助工业客户加速大数据基础建设，激发更多开发者参与发现工业大数据价值，促进工业大数据的基础技术研究和应用，培育工业大数据产业发展生态。



图 3-2-1 工业大数据产业创新平台

创新平台共包括 4 个对外主频道：数据竞赛、数据集、工业智能、课程学习。

- **数据竞赛**：自首届中国工业大数据创新竞赛起，创新平台承担了工业大数据相关赛务的组织和管理工作。创新平台可授权经认证的合作企业进行赛题发布，并为广大开发者提供了数据下载、竞赛结果上传及线上评分、参赛交流等支持。

- **数据集**：由于工业领域对数据的封闭性，工业数据集一直是工业大数据技术创新过程中的“稀缺资源”。创新平台整理集合了 37 组开源工业数据集，来自全球各大学、研究机构及企业，覆盖基础工业加工、能源电力、轨道车辆、航空航天、电子半导体、通用设备等领域，应用对象从部件级、设备级、产线级到工厂级 4 个层级，建模问题包括健康评估、故障诊断、寿命预测、生产过程分析等，帮助工业大数据开发者解决“无米”之难。

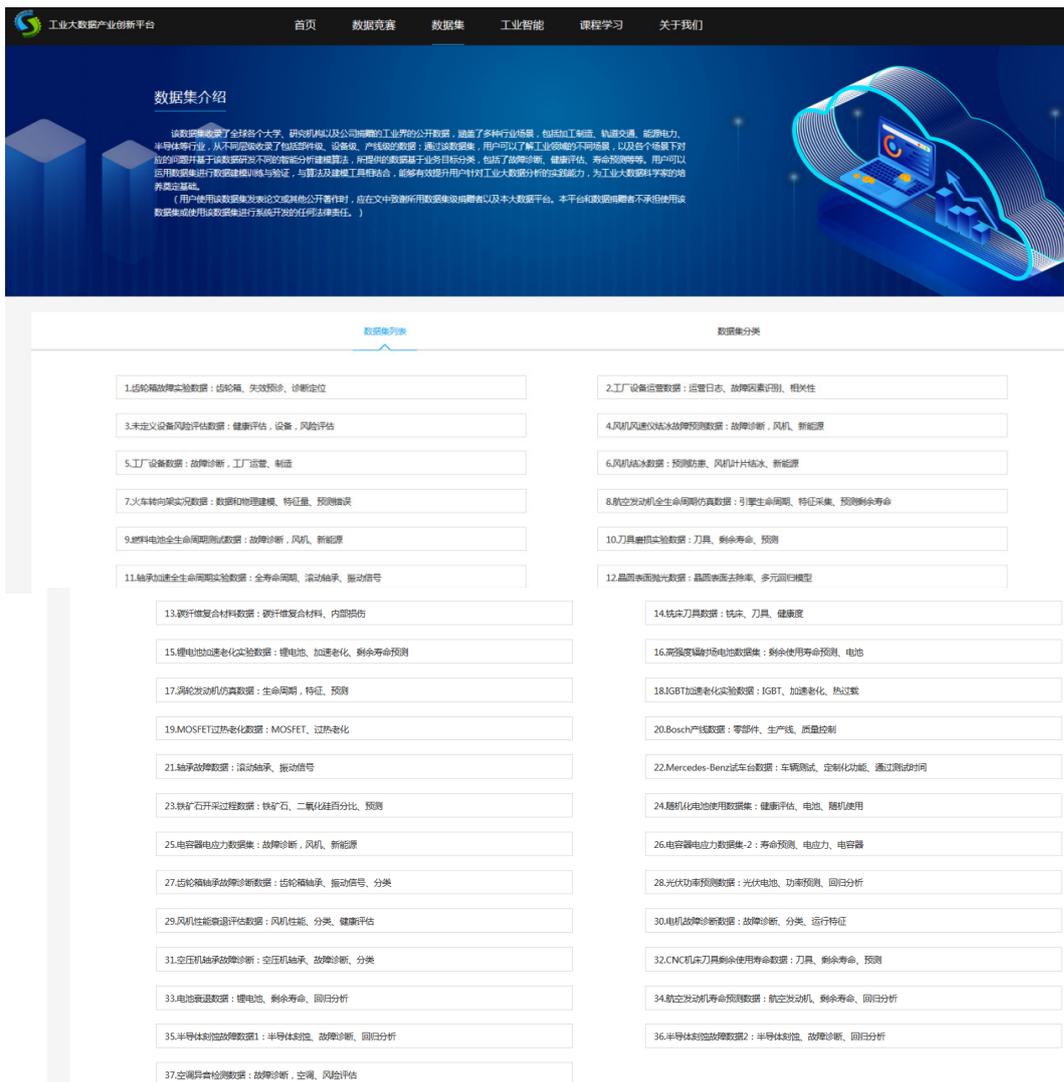


图 3-2-2 数据资源

· **工业智能：**创新平台集成了产业界前沿的工业智能建模工具，包括工业数据在线分析系统和工业智能建模客户端，该工具内置了全套的机理分析和机器学习建模组件，完整覆盖数据预处理、特征工程、模型训练、模型调优、模型评估等建模环节；引入算子市场概念，提供丰富的工业行业建模模板、实例以及 100+ 个算子，为典型行业和工业建模场景提供建模模板，如风机叶片结冰故障预警、轴承故障诊断、数控机床剩余寿命预测、半导体晶圆刻蚀过程异常检测等用例，固化成熟的技术路径，支撑模型快速原型化；提供融入领域知识的行业组件，将工业智能研发成果和成功经验转化为平台建模组件，帮助用户提升建模效果；提供“拖拉拽”画布式建模、数据集成及监控技术，“地图化”的数据存储及权限控制，多语言数据交互式探索，可视化呈现定义及配置数据结果等，专为工业大数据开发者定制，专门解决工业场景数据质量低、领域知识门槛高的两大建模挑战，帮助用户有效挖掘数据规律、快速构建预测模型。



图 3-2-3 工业智能建模工具

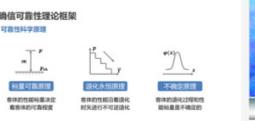
· 课程学习：创新平台提供了丰富的免费学习资源，目前已累计 60 余课时，由产、学、研各界资深专家亲自讲授，由浅入深，覆盖离散和流程行业，内容涵盖技术方法、实操讲解、战略洞察等，提升开发者对智能制造和工业大数据相关技术的理解。



工业大数据创新平台

[首页](#)
[数据竞赛](#)
[数据集](#)
[工业智能](#)
[课程学习](#)
[关于我们](#)

课程目录

| | | | |
|---|--|--|--|
|  流程工业案例 共2节课程 关键词：PHM 工业智能 振动信号 DCS监控信号 |  离散工业案例 共2节课程 关键词：PHM 工业智能 离散工业 带锯机床 能耗优化 |  优化算法 共3节课程 关键词：PHM 工业智能 优化算法 |  健康预测 共3节课程 关键词：PHM 工业智能 健康预测 |
|  振动分析 共5节课程 关键词：信号处理 故障诊断 PHM |  模型评估 共4节课程 关键词：分类 聚类 回归 时间序列 模型评估 |  风险评估 共5节课程 关键词：PHM 工业智能 风险评估 |  矩阵运算与数据预处理 共5节课程 关键词：技术 实战 矩阵 PHM |
|  相关性分析 共2节课程 关键词：技术 实战 相关系数 PHM |  特征工程 共3节课程 关键词：技术 实战 特征工程 PHM |  空调异常检测案例 共7节课程 关键词：技术 实战 检测 PHM |  基于数字孪生的工业大数据智能分析与实践 共2节课程 关键词：数字孪生 赛博物理系统 工业大数据 工业人工智能 |
|  可信可靠性理论框架 可信科学课程 关键词：可靠性科学 退化 不确定性 可靠性模型 |  变工况机械装备的早期和定量化诊断技术 共2节课程 关键词：机械装备 变工况 故障诊断 |  工业数据资产 共2节课程 关键词：工业大数据 数据资产 保值增值 数据资产评估 |  数字化工厂 共2节课程 关键词：数字孪生 |
|  智能制造中的预测性维护技术标准与应用 共2节课程 关键词：智能制造 预测性维护 标准化 |  中国制造智能化转型战略思考 共4节课程 关键词：战略 智能制造 CPS |  PHM算法与智能分析技术 共7节课程 关键词：技术 实战 PHM |  工业智能建模平台使用介绍 共2节课程 关键词：技术 实战 工业智能建模平台 |

课程内容合作伙伴名录

| | | | | |
|--|---|---|--|---|
|  机械工业仪器仪表综合技术经济研究所 |  北京天智睿云科技有限公司 |  西安交通大学 |  清华大学 |  西电电子科技大学 |
|  北京航空航天大学 可靠性与系统工程学院 |  中国信息通信研究院 | | | |

图 3-2-4 课程学习

创新平台得到了多所高校与产业机构的大力支持。未来，信通院将继续依托创新平台为广大工业大数据开发者提供更丰富的资源和支持。



工业大数据创新竞赛

Industrial Big Data Innovation Competition