

# 中国科学技术大学

# 工程博士学位论文



## 基于多维时序数据分析的锡膏 印刷异常预警方法研究

作者姓名： 刘斌琨  
学科专业： 电子信息  
校内导师： 赵云波 教授  
实践导师： 朱英 正高级工程师  
完成时间： 二〇二五年五月二十九日



University of Science and Technology of China

A dissertation for doctor's degree



# **Research on the Warning Method of Solder Paste Printing Anomaly based on Multi-Dimensional Time Series Data Analysis**

Author: Liu Binkun

Speciality: Electronic Information

Supervisor: Prof. Zhao Yunbo

Practice supervisor: PSE. Zhu Ying

Completion date: May 29, 2025



## 中国科学技术大学学位论文原创性声明

本人声明所呈交的学位论文，是本人在导师指导下进行研究工作所取得的成果。除已特别加以标注和致谢的地方外，论文中不包含任何他人已经发表或撰写过的研究成果。与我一同工作的同志对本研究所做的贡献均已在论文中作了明确的说明。

作者签名： 刘斌琨

签字日期： 2025年5月29日

## 中国科学技术大学学位论文授权使用声明

作为申请学位的条件之一，学位论文著作权拥有者授权中国科学技术大学拥有学位论文的部分使用权，即：学校有权按有关规定向国家有关部门或机构送交论文的复印件和电子版，允许论文被查阅和借阅，可以将学位论文编入《中国学位论文全文数据库》等有关数据库进行检索，可以采用影印、缩印或扫描等复制手段保存、汇编学位论文。本人提交的电子文档的内容和纸质论文的内容相一致。

控阅的学位论文在解密后也遵守此规定。

公开  控阅（\_\_\_年）

作者签名： 刘斌琨

导师签名： 高云林

签字日期： 2025年5月29日

签字日期： 2025年5月29日



## 创新性及应用性说明

本文围绕基于多维时序数据分析的锡膏印刷异常预警开展锡膏印刷关键部件早期故障预警、锡膏印刷关键部件剩余使用寿命预测、以及锡膏印刷参数不当预警的研究，与已有方法相比显著提高了异常预警性能，可以为锡膏印刷的维护提供更有价值的决策依据。

### 1. 创新性方面：

- (1) 提出一种基于多传感器双重对比的锡膏印刷关键部件早期故障预警算法，相较于基于重构的主流工作，设计了新颖的基于对比的时频对比模块和相关性对比模块，从两个层面抑制了噪声的不利影响并挖掘健康状态下的通用表示，有效解决了难以根据含有高噪声的健康样本准确刻画健康模式的挑战，可以显著提高了关键部件早期故障的预警性能。
- (2) 提出一种基于多传感器交替对比的锡膏印刷关键部件剩余使用寿命预测算法，相较于基于退化阶段差异性的自监督工作，设计了一种新颖的基于跨传感器相似度的交替对比过程，从大量无标签的退化数据中挖掘高区分度的退化特征，有效解决了标签样本难获取以及不同退化阶段间状态监测数据比较相似导致退化特征区分度不足的难点，显著提高了关键部件剩余使用寿命的预测性能。
- (3) 提出了一种基于 PCB 布局图卷积的锡膏印刷参数预警算法，相较于基于时序模式的工作，首次将 PCB 焊盘分布转换成图，有效建模了 PCB 焊盘分布对锡膏印刷质量的重要影响，从而显著提高了印刷参数不当的预警性能。

### 2. 应用性方面：

- (1) 所提关键部件早期故障预警算法已试点应用，可以准确判断关键部件的健康状态，为锡膏印刷机的维护决策提供有效的依据。
- (2) 所提剩余使用寿命预测算法虽然尚未投入实际应用，但很贴合工厂中缺乏标签样本的场景且预测性能更加优异，有力的推动了剩余使用寿命预测算法的工程实际应用。
- (3) 所提锡膏印刷参数预警算法已试点应用，虽然性能尚未满足实际需求，但仍可为调整锡膏印刷参数提供重要的依据，有力推动了锡膏印刷参数不当预警算法的工程实际应用。

## 摘要

锡膏印刷是印刷电路板 (Printed Circuit Board, PCB) 加工的核心工序之一。由于锡膏印刷机故障和锡膏印刷参数不当, 约有 60%至 70%的残次品以及 13%的生产线故障与锡膏印刷相关。而锡膏印刷异常预警可以为锡膏印刷的维护提供有效的决策依据, 从而避免锡膏印刷异常, 因此具有重要的意义。

工业界主要围绕锡膏印刷机中关键部件早期故障预警、关键部件剩余使用寿命预测以及锡膏印刷参数不当预警来开展锡膏印刷异常预警。目前存在以下挑战。首先, 对于锡膏印刷机中关键部件早期故障预警, 存在健康样本含有高噪声的挑战, 已有方法难以准确刻画部件健康模式。其次, 对于锡膏印刷机中关键部件剩余使用寿命预测, 存在标签样本难获取、不同退化阶段间状态监测数据比较相似的挑战, 已有方法难以准确刻画退化模式。最后, 对于锡膏印刷参数不当预警, 已有方法未考虑 PCB 焊盘分布对锡膏印刷质量的重要影响, 导致不能准确预警锡膏印刷参数不当。

针对上述挑战, 利用多维锡膏印刷质量数据以及锡膏印刷机多传感器状态监测数据, 开展基于多维时序数据分析的锡膏印刷异常预警方法研究, 与已有方法相比可以为锡膏印刷的维护提供更有价值的决策依据, 从而提高锡膏印刷质量, 降低返修成本。具体研究工作如下:

- (1) 针对健康样本存在高噪声的挑战, 提出了一种基于多传感器双重对比的锡膏印刷关键部件早期故障预警算法, 设计了时频对比模块和相关性对比模块, 从两个层面抑制了噪声的不利影响并挖掘健康状态下的通用表示, 从而实现了最佳的早期故障预警效果。具体而言, 在时频信息层面, 设计了时频对比模块, 利用 Kullback-Leibler (KL) 散度对比健康状态下时频信息, 从而挖掘健康状态下时频信息的通用表示。随后, 在多传感器相关性层面, 设计了相关性对比模块, 利用 KL 散度对健康状态下多传感器 Pearson 相关性进行对比, 从而有效挖掘健康多传感器相关性的通用表示。结合时频对比模块和相关性对比模块可以提取关键部件健康状态的通用表示, 有效抑制健康样本中高噪声。以私有的锡膏印刷机减震器数据集、公开的轴承、齿轮数据集为例验证所提算法。实验结果表明, 所提算法取得了最佳的预警性能。
- (2) 针对标签样本难获取、不同退化阶段间状态监测数据比较相似的挑战, 提出了一种基于多传感器交替对比的锡膏印刷关键部件剩余使用寿命预测算法, 设计了一种交替对比过程, 可以利用跨传感器相似度从丰富的无标签多传感器数据中挖掘跨传感器不变特征来提高不同退化阶段的特征区

分度，从而实现了最佳的剩余使用寿命预测效果。该算法具体来说，使用 Resnet18 将不同传感器的特征映射到共现空间。然后，在共现空间中进行基于跨传感器相似度的交替对比，从而获得了大量无标签数据的跨传感器不变特征。最后，利用少量带标签的多传感器数据微调模型，以实现少量标签数据下的关键部件剩余使用寿命预测。以公开的轴承、齿轮数据集为例验证所提算法，结果表明，所提算法取得了最佳的剩余使用寿命预测性能。

- (3) 考虑到 PCB 焊盘分布对锡膏印刷质量的重要影响，提出了一种基于 PCB 布局图卷积的锡膏印刷参数预警算法，首次将 PCB 上焊盘的分布建模成图，以捕获 PCB 上焊盘分布对锡膏印刷质量的影响，从而实现了最佳的锡膏印刷参数不当预警效果。具体来说，由于锡膏印刷质量与 PCB 上焊盘的分布有关，根据锡膏印刷质量的 Pearson 相关性将焊盘分布转换为图，然后用相关性阈值修剪图的边，以模拟焊盘的分布。然后为了对时变的锡膏物理化学性质进行建模，设计基于生产时间的注意力，并重构锡膏印刷质量时序特征。接下来，由于锡膏印刷质量异常的稀缺性，设计了加权损失来提高对锡膏印刷质量异常关注。最后，将预测的锡膏印刷质量与锡膏印刷质量标准进行比较，以预警锡膏印刷参数不当。以私有的锡膏印刷机无故障情况下 6 天 11365 条锡膏印刷数据为例验证所提算法，所提算法取得了最佳的锡膏印刷参数不当预警性能。

**关键词：** 锡膏印刷机故障， 故障预警， 剩余使用寿命预测， 锡膏印刷质量， 锡膏印刷参数

## ABSTRACT

Solder paste printing is one of the core processes in printed circuit board (PCB) processing. About 60% to 70% of the defective products and 13% of the production line failures are related to solder paste printing due to the failure of the solder paste printing machine and inappropriate solder paste printing parameters. Warning of solder paste printing anomaly is important because it can provide an effective decision basis for the maintenance of solder paste printing to avoid solder paste printing anomalies.

The industry currently focuses on solder paste printing anomaly warning around early warning of key component failure in solder paste printing machines, remaining useful life prediction of key components, and warning of improper solder paste printing parameters. The following challenges exist. First, for early warning of key component failure in solder paste printing machines, there is the challenge of high noise in health data, and existing methods are difficult to portray component health patterns accurately. Second, for the remaining useful life prediction of key components in the solder paste printing machine, it is difficult to accurately portray the degradation pattern due to the samples' scarcity and the similarity of the condition monitoring data at different degradation stages. Finally, for the warning of improper solder paste printing parameters, the existing methods do not consider the important impact of PCB pad distribution on the quality of solder paste printing, resulting in the inability to accurately warning of improper solder paste printing parameters.

Aiming at the above challenges, this dissertation utilizes multi-dimensional solder paste printing quality data as well as multi-sensor condition monitoring data of solder paste printing machine to research on the warning method for solder paste printing anomalies based on multi-dimensional time series data analysis. Compared to existing methods, this method can provide more valuable decision-making support for the maintenance of solder paste printing, thereby improving the quality of solder paste printing and reducing rework costs. The specific research efforts are described below.

- (1) To address the difficulty of high noise in the health samples, this dissertation proposes a multi-sensor double-contrast based fault early warning algorithm for the key component of solder paste printing. A time-frequency contrast module and a correlation contrast module are designed to suppress the detrimental effects of noise at two levels and to exploit the generalized representation of the health state, thus achieving optimal fault warning results. Specifically, at the time-frequency

information level, a time-frequency contrast module is designed to contrast the time-frequency matrix in the healthy state using the Kullback-Leibler (KL) divergence, thereby mining the universal representation of the time-frequency information in the healthy state. Subsequently, at the multi-sensor correlation level, a correlation contrast module is designed to contrast the multi-sensor Pearson correlation in the health state using the KL divergence, to mine the universal representation of the health multi-sensor correlation effectively. The proposed algorithm is demonstrated on the proprietary solder paste printing machine shock absorber dataset, the publicly available bearing and gear dataset. Experimental results show that the proposed algorithm achieves the best warning performance.

- (2) To address the challenges of scarce samples and more similar monitoring data in different degradation stages, this dissertation proposes a multi-sensor alternate contrast-based algorithm for predicting the remaining useful life of the solder paste printing key component. An alternating contrast process is designed, which can utilize cross-sensor similarity to mine cross-sensor invariant features from rich unlabeled multi-sensor data to improve feature discrimination between different degradation stages, thus achieving the best remaining useful life prediction. Specifically, ResNet18 is employed to map the features from various sensors into a co-occurrence space. Then, alternate contrast based on cross-sensor similarity is performed in the co-occurrence space, resulting in a cross-sensor invariant representation of a large amount of unlabeled data. Finally, the model is finetuned using a small amount of labeled data to achieve the prediction of the remaining useful life of key components under scarce labeled data. The proposed algorithm is validated with the publicly available bearing and gear dataset, and the results show that the proposed algorithm achieves the best remaining useful life prediction performance.
- (3) Considering the influence of PCB pad distribution on solder paste printing quality, this dissertation proposes a warning algorithm for solder paste printing parameters based on PCB layout graph convolution. The algorithm can model the PCB pad distribution as a graph to capture the influence of pad distribution on solder paste printing quality, thereby achieving optimal warning of improper solder paste printing parameters. Specifically, because solder paste printing quality is related to the PCB pad distribution, the pad distribution is converted to a graph based on the Pearson correlation of the solder paste printing quality, and then the edges of the graph are trimmed with a correlation threshold to simulate the dis-

tribution of pads. Then, to model the time-varying physicochemical properties of the solder paste, the production time is normalized, the production time-based attention is computed, and the solder paste printing quality temporal features are reconstructed from the temporal attention. Next, due to the scarcity of defects, weighted losses are designed to increase the attention to solder paste printing quality anomalies. Finally, the predicted solder paste printing quality is compared with the solder paste printing quality standards to warn of improper solder paste printing parameters. The proposed algorithm is demonstrated with the proprietary 11365 solder paste printing data in 6 days without mechanical failure, and achieves the best warning performance for improper solder paste printing parameters.

**KEY WORDS:** Solder Paste Printing Machine Fault, Fault Early Warning, Remaining Useful Life Prediction, Solder Paste Printing Quality, Solder Paste Printing Parameters

## 目录

<b>第 1 章 绪论 .....</b>	<b>1</b>
1.1 研究背景和意义 .....	1
1.2 国内外研究现状 .....	3
1.2.1 关键部件早期故障预警 .....	3
1.2.2 关键部件剩余使用寿命预测 .....	7
1.2.3 锡膏印刷参数预警 .....	11
1.2.4 当前研究存在的问题 .....	13
1.3 本文主要工作和组织结构 .....	14
1.3.1 主要研究内容 .....	14
1.3.2 全文组织结构 .....	16
<b>第 2 章 锡膏印刷异常预警工程应用背景、现状和前景 .....</b>	<b>18</b>
2.1 锡膏印刷异常预警工程应用背景 .....	18
2.1.1 锡膏印刷机组成 .....	18
2.1.2 锡膏印刷参数 .....	20
2.1.3 锡膏印刷步骤 .....	23
2.1.4 锡膏印刷检查 .....	25
2.2 锡膏印刷异常预警工程应用现状 .....	28
2.2.1 关键部件早期故障预警工程应用现状 .....	28
2.2.2 关键部件剩余使用寿命预测工程应用现状 .....	29
2.2.3 锡膏印刷参数不当预警工程应用现状 .....	30
2.3 锡膏印刷异常预警工程应用前景 .....	30
2.3.1 关键部件早期故障预警工程应用前景 .....	30
2.3.2 关键部件剩余使用寿命预测工程应用前景 .....	31
2.3.3 锡膏印刷参数不当预警工程应用前景 .....	31
2.4 本章小结 .....	31
<b>第 3 章 基于多传感器双重对比的锡膏印刷关键部件早期故障预警算法 .....</b>	<b>32</b>
3.1 健康状态下多传感器数据中高噪声影响分析 .....	32
3.2 算法设计 .....	33
3.2.1 数据预处理 .....	34
3.2.2 KL 散度抑制噪声的分析 .....	35
3.2.3 时频对比模块 .....	36

3.2.4	相关性对比模块 .....	38
3.2.5	故障预警标准 .....	38
3.3	实验结果和分析 .....	39
3.3.1	数据集和实验配置 .....	39
3.3.2	实验结果和分析 .....	47
3.3.3	模型性能分析 .....	51
3.3.4	算法应用讨论 .....	59
3.4	本章小结 .....	60
<b>第 4 章</b>	<b>基于多传感器交替对比的锡膏印刷关键部件剩余使用寿命预测算法</b>	<b>61</b>
4.1	不同退化阶段间退化特征区分度分析 .....	61
4.2	算法设计 .....	62
4.2.1	时频转换 .....	63
4.2.2	交替对比 .....	65
4.2.3	跨传感器相似度提高特征区分度的分析 .....	68
4.2.4	微调 .....	69
4.3	实验结果和分析 .....	69
4.3.1	数据集和实验配置 .....	69
4.3.2	实验结果和分析 .....	76
4.3.3	模型性能分析 .....	80
4.3.4	算法应用讨论 .....	84
4.4	本章小结 .....	86
<b>第 5 章</b>	<b>基于 PCB 布局图卷积的锡膏印刷参数预警算法</b>	<b>87</b>
5.1	PCB 布局对锡膏印刷质量的影响分析 .....	87
5.2	算法设计 .....	88
5.2.1	构建 PCB 布局图 .....	89
5.2.2	时间重构 .....	90
5.2.3	时序图特征提取 .....	91
5.2.4	损失函数 .....	92
5.3	实验结果与分析 .....	93
5.3.1	数据集和实验设置 .....	93
5.3.2	实验结果和分析 .....	98
5.3.3	模型性能分析 .....	101
5.3.4	算法时间复杂度分析 .....	105
5.3.5	算法应用讨论 .....	105

5.4 本章小结 .....	106
<b>第 6 章 总结与展望 .....</b>	<b>108</b>
6.1 全文总结 .....	108
6.2 后续研究工作展望 .....	110
<b>参考文献 .....</b>	<b>112</b>
<b>致谢 .....</b>	<b>125</b>
<b>在读期间取得的科研成果 .....</b>	<b>127</b>



## 插图清单

图 1.1	SMT 产线流程 .....	1
图 1.2	论文研究内容 .....	14
图 1.3	论文组织结构 .....	17
图 2.1	锡膏印刷机外观图 .....	18
图 2.2	不同视角下的锡膏印刷机机械结构 .....	19
图 2.3	双刮刀 .....	20
图 2.4	锡膏印刷案例 .....	23
图 2.5	钢网实物图 .....	25
图 2.6	钢网网孔形状 .....	25
图 2.7	合格的锡膏印刷成品 .....	26
图 2.8	锡膏缺陷示意图 .....	28
图 3.1	健康状态下多传感器相关性噪声 .....	33
图 3.2	不同状态间减震器 X 方向加速度时频矩阵的 KL 散度 .....	33
图 3.3	基于多传感器双重对比的锡膏印刷关键部件早期故障预警算法框图	34
图 3.4	不同状态下减震器各个方向加速度的时频矩阵 .....	35
图 3.5	时频对比模块结构图 .....	36
图 3.6	Vision Transformer 流程图 .....	37
图 3.7	减震器位置及机械结构 .....	40
图 3.8	健康状态下减震器监测属性的相关矩阵图 .....	41
图 3.9	故障状态下减震器监测属性的相关矩阵图 .....	42
图 3.10	健康状态下轴承六个不同方向加速度的时频矩阵 .....	44
图 3.11	内圈故障下轴承六个不同方向加速度的时频矩阵 .....	44
图 3.12	t-SNE 降维后, 减震器测试集在特征空间中的特征分布可视化 .....	52
图 3.13	t-SNE 处理后, 轴承测试集在特征空间中的特征分布可视化 .....	53
图 3.14	减震器数据集上不同模型的故障分数分布 .....	53
图 3.15	山东科技大学轴承数据集上不同模型的故障分数分布 .....	54
图 3.16	减震器数据集上消融模型的特征分布 .....	56
图 3.17	减震器数据集上消融模型的故障分数分布 .....	57
图 3.18	训练数据量对模型性能的影响 .....	58
图 3.19	减震器数据集上的超参数分析 .....	58
图 3.20	山东科技大学轴承数据集上的超参数分析 .....	58

图 4.1	轴承不同阶段间多传感器时频矩阵的余弦相似度分布 .....	62
图 4.2	轴承不同阶段间跨传感器相似度的余弦相似度分布 .....	62
图 4.3	基于多传感器交替对比的锡膏印刷关键部件剩余使用寿命预测算法框图 .....	63
图 4.4	轴承不同退化阶段的波形 .....	64
图 4.5	轴承不同退化阶段的时频矩阵 .....	64
图 4.6	捕获跨传感器不变退化特征 .....	65
图 4.7	更新辅传感器特征字典 .....	67
图 4.8	交替机制 .....	68
图 4.9	不同退化阶段间齿轮状态监测数据相似性分布 .....	72
图 4.10	轴承剩余使用寿命预测曲线图 .....	79
图 4.11	t-SNE 降维后轴承 1_3 的特征分布 .....	80
图 4.12	PHM2012 数据集中不同标签数据量下所提算法的指标 .....	84
图 4.13	重庆大学齿轮数据集中不同标签数据量下所提算法的指标 .....	85
图 4.14	PHM2012 数据集中不同字典尺寸下所提算法的指标 .....	85
图 5.1	四个焊盘的锡膏体积、X 方向位置偏移和 Y 方向位置偏移曲线 .....	88
图 5.2	基于 PCB 布局图卷积的锡膏印刷参数预警算法框图 .....	88
图 5.3	将 PCB 转换成图的示意图 .....	89
图 5.4	生产时间间隔分布 .....	90
图 5.5	PCB 元件分布示意图 .....	95
图 5.6	锡膏印刷体积相关性分析 .....	96
图 5.7	锡膏印刷 X 方向偏移相关性分析 .....	97
图 5.8	锡膏印刷 Y 方向偏移相关性分析 .....	98
图 5.9	锡膏印刷参数预警性能可视化 .....	101
图 5.10	锡膏体积预测曲线 .....	102
图 5.11	锡膏 Y 方向偏移预测曲线 .....	102
图 5.12	锡膏 X 方向偏移预测曲线 .....	103
图 5.13	消融实验结果可视化 .....	104
图 5.14	锡膏印刷参数预警的超参数敏感性分析 .....	105

## 附表清单

表 2.1	2022 年 1 月上旬锡膏印刷机故障日志 .....	21
表 2.2	锡膏印刷参数 .....	22
表 2.3	锡膏检查数据 .....	26
表 2.4	SPI 表格数据 .....	27
表 3.1	山东科技大学轴承数据集工况详情 .....	43
表 3.2	实验环境 .....	46
表 3.3	减震器数据集上的实验对比结果 .....	48
表 3.4	山东科技大学轴承数据集上的实验对比结果 .....	50
表 3.5	MCC5-THU 齿轮数据集上的实验对比结果 .....	51
表 3.6	减震器数据集上的消融实验结果 .....	54
表 3.7	山东科技大学轴承数据集上的消融实验结果 .....	55
表 3.8	MCC5-THU 齿轮数据集上的消融实验结果 .....	55
表 4.1	PHM2012 轴承数据集工况详情 .....	71
表 4.2	重庆大学齿轮数据集工况详情 .....	72
表 4.3	PHM2012 轴承数据集实验设置 .....	73
表 4.4	重庆大学齿轮数据集实验设置 .....	74
表 4.5	PHM2012 轴承数据集中所提算法与自监督方法对比实验的 RMSE ..	76
表 4.6	PHM2012 轴承数据集中所提算法与自监督方法对比实验的 MAE ....	77
表 4.7	重庆大学齿轮数据集中所提算法与自监督方法对比实验的 RMSE ...	77
表 4.8	重庆大学齿轮数据集中所提算法与自监督方法对比实验的 MAE .....	78
表 4.9	PHM2012 轴承数据集中所提算法与监督方法对比实验的 RMSE .....	81
表 4.10	PHM2012 轴承数据集中所提算法与监督方法对比实验的 MAE .....	82
表 4.11	重庆大学齿轮数据集中所提算法与监督方法对比实验的 RMSE .....	82
表 4.12	重庆大学齿轮数据集中所提算法与监督方法对比实验的 MAE .....	83
表 4.13	PHM2012 轴承数据集中所提算法消融实验结果 .....	83
表 4.14	重庆大学齿轮数据集中所提算法消融实验结果 .....	84
表 5.1	模型超参数 .....	96
表 5.2	在两个时间尺度下所提算法与基线算法的锡膏印刷参数预警对比结果 100	
表 5.3	在两个时间尺度下所提算法的消融实验结果 .....	103



## 第 1 章 绪论

### 1.1 研究背景和意义

印刷电路板 (Printed Circuit Board, PCB) 是一种用于固定和连接电子元件的基板, 其广泛应用在各种电子设备中, 比如笔记本电脑, 遥控器, 手机等<sup>[1-2]</sup>。目前我国是全球最大的 PCB 生产方, 2023 年约占比全球 PCB 市场的 54%, 市场规模达到了 3000 亿元, 且市场规模保持显著的增长趋势<sup>[3]</sup>。

PCB 主要的加工方式是表面贴装技术 (Surface Mount Technology, SMT)<sup>[4-5]</sup>。SMT 起源于 20 世纪 60 年代, 是一种将电子元件直接贴装在 PCB 表面的技术。SMT 具有高组装密度、可贴装小尺寸元件以及高生产速度的特点。SMT 主要流程如图 1.1 所示, 依次是镭雕, 锡膏印刷, 锡膏检查, 元件贴装, 自动光学检测, 回流炉焊接, 分板, 功能检测。具体介绍如下。



图 1.1 SMT 产线流程

- (1) 镭雕: 利用镭射机在 PCB 上刻二维码, 二维码用于在后续生产流程中追踪 PCB, 传递工单信息。
- (2) 锡膏印刷: 在锡膏印刷机中锡膏被刮刀均匀涂抹在钢网上, 然后锡膏通过钢网的网孔准确地印刷到 PCB 的焊盘上。
- (3) 锡膏检查: 锡膏印刷完成后, 基于激光扫描等方式对锡膏印刷质量进行检查, 包括锡膏的高度, 面积, 体积, 位置等多维属性。
- (4) 元件贴装: 锡膏印刷后, 元件通过自动贴片机被精准贴装到 PCB 上。
- (5) 自动光学检测: 在贴片或者回流炉焊接完成后, 基于工业相机拍照等方式对元件的位置, 形态进行光学检查。
- (6) 回流炉焊接: 在回流炉中, 通过高温将 PCB 焊盘上的锡膏融化, 然后冷却, 完成元件和 PCB 之间的固定和电气连接。
- (7) 分板: 在前序工艺中为了提高生产效率, 通常是同时加工多块 PCB。在回流炉焊接后, 利用裁板机将多块 PCB 裁成单独的 PCB, 以方便后续进行测试。

(8) 功能检测：在 PCB 加工完成后，利用测试机台对 PCB 各项电气功能进行测试。

由此看出，锡膏印刷是 SMT 的基础与前置，其功能是利用锡膏固定 PCB 上的元件和提供电气连接，对 PCB 产品质量起着极为关键的作用<sup>[6-7]</sup>。锡膏印刷是由锡膏印刷机来完成，其由传送系统、刮刀系统、视觉识别定位系统、钢网系统、可调中央平台，控制系统及操作界面等组成。在锡膏印刷时，锡膏印刷机根据控制系统中设定的锡膏印刷参数协调传送系统、刮刀系统、视觉识别定位系统、可调中央平台等各个组成部分，以实现高质量的锡膏印刷。

锡膏印刷异常<sup>[8-11]</sup>主要原因有锡膏印刷机故障、锡膏印刷参数不当。锡膏印刷机故障会出现 PCB 无法传送、传送定位不准、可调中央平台异常抖动等现象，从而造成锡膏印刷出现残次品，甚至无法进行锡膏印刷。锡膏印刷参数不当体现在当锡膏印刷机无硬件故障时，由于外部环境变化，锡膏理化性质变化等因素的影响，锡膏印刷机按照设定的锡膏印刷参数无法生产出满足要求的锡膏印刷产品。

锡膏印刷异常具有时间长、后果严重的特点<sup>[12-17]</sup>。从异常时间而言，根据某大型 SMT 工厂真实数据，在 16 个月中锡膏印刷机累计故障时长为 8868 分钟，占比 SMT 产线总体故障 13%。锡膏印刷机的可调中央平台故障时长为 2031 分钟，占比锡膏印刷机故障 22.9%，其中可调中央平台在上升过程和下降过程中异常震动时长为 1244 分钟，占比锡膏印刷机故障 14.0%。锡膏印刷机的传送系统故障的时长为 1275 分钟，占比锡膏印刷机故障 14.3%。锡膏印刷机的视觉识别定位系统故障时长为 1006 分钟，占比锡膏印刷机故障 11.3%。从异常后果而言，约 60%至 70%的 PCB 残次品与锡膏印刷有关<sup>[18-20]</sup>。

目前工业界对于锡膏印刷异常预警主要围绕预警锡膏印刷机故障和锡膏印刷参数不当来展开。具体而言，对于锡膏印刷机故障预警，主要采用关键部件早期故障预警 (Fault Early Warning, FEW) 与关键部件剩余使用寿命 (Remaining Useful Life, RUL) 预测相结合的策略。这是因为锡膏印刷机故障大多由关键部件故障引起，关键部件是指在锡膏印刷机故障占比较大或在锡膏印刷机中广泛分布的部件。通常在运行初期关键部件的退化趋势不明显，预测剩余使用寿命难度较高，对维护决策的参考价值相对有限。因此工程上大多先分析关键部件是否出现早期故障，出现早期故障后在进行剩余使用寿命预测，预警其完全失效时间，从而为维护决策提供更全面的参考依据。对于锡膏印刷参数不当，由于缺乏直接监测锡膏印刷参数不当的方式，通常工厂利用锡膏印刷质量表征锡膏印刷参数的合理性，绝大多数情况下将锡膏印刷机无硬件故障时的锡膏印刷质量异常等价于锡膏印刷参数不当<sup>[20-22]</sup>。利用锡膏印刷质量异常预测来预警锡膏印刷参数不当，一旦预测到锡膏印刷质量异常，工厂接下来就会结合锡膏印刷质量异

常的程度、类型以及当前的锡膏印刷参数来针对性调整锡膏印刷参数<sup>[23-27]</sup>。

由于锡膏印刷机的状态监测数据大多含有高噪声、故障数据难获取以及影响锡膏印刷质量变化的因素众多，现有的方法难以满足工厂准确预测锡膏印刷异常的实际需求。随着人工智能算法和大数据处理技术的发展，为综合利用高噪声、无标签的多传感器数据以及多维锡膏印刷质量数据来设计锡膏印刷异常预警方法提供了可能。综上所述，本文通过分析锡膏印刷中多维时序数据，构建“关键部件早期故障预警-关键部件剩余使用寿命预测-锡膏印刷参数预警”的锡膏印刷异常预警方法体系，为工厂的锡膏印刷机维护计划制订<sup>[28-30]</sup>以及锡膏印刷参数调整<sup>[23-25]</sup>提供决策依据，有助于实现高质量的锡膏印刷。在锡膏印刷质量提升，返修成本降低，以及 PCB 加工效率提高等方面具有重要的意义。

## 1.2 国内外研究现状

由于锡膏印刷异常主要由锡膏印刷机故障以及锡膏印刷参数不当所造成，因此目前工业界主要通过锡膏印刷机故障预警和锡膏印刷参数预警来实现锡膏印刷异常预警。由于锡膏印刷机故障主要由关键部件所造成，因此工业界通过关键部件早期故障预警和关键部件剩余使用寿命预测相结合的策略来实现锡膏印刷机故障预警，旨在分阶段预警其早期故障和完全失效时间。综上所述，本节围绕以上三个方面开展国内外研究现状介绍。

### 1.2.1 关键部件早期故障预警

关键部件是指在锡膏印刷机故障占比较大或在锡膏印刷机中广泛分布的部件，比如减震器、轴承、齿轮等。减震器作为可调中央平台的核心部件，因减震器导致的锡膏印刷机故障约占锡膏印刷机总故障的 14%。轴承、齿轮则是广泛分布在锡膏印刷机如传送系统的传送装置，刮刀系统中电机驱动刮刀往复式运动等部分，是这些运动系统的重要故障因素<sup>[31]</sup>。虽然锡膏印刷机中钢网、刮刀等部件相较于上述部件更能代表锡膏印刷场景，但是这些部件故障率较低。据合作工厂累计 16 个月的故障记录显示，未见到明确因钢网或者刮刀故障导致的锡膏印刷机故障，因此本节选择以减震器、轴承和齿轮作为锡膏印刷中关键部件进行介绍。

关键部件早期故障预警是指在关键部件完全失效之前，及时发现早期故障，并发出警报。当前文献中尚未见到明确以锡膏印刷为场景的关键部件早期故障预警研究，这可能是因为该场景下的关键部件状态监测数据大多具有保密性质。然而，通用工业场景（如减震器、轴承、齿轮等）下的早期故障预警研究得到了较为广泛的研究，这些研究与锡膏印刷场景下的关键部件早期故障预警存在以

下相似之处。首先, 状态监测数据类型基本一致。这些研究大多基于振动数据分析了通用工业场景下的关键部件退化机制, 而锡膏印刷场景中也往往采用振动传感器监测关键部件的状态。其次, 退化表现相似。这些研究表明振动数据会随着部件退化而波动加大, 这与锡膏印刷场景中关键部件的退化表现是相似的。因此这些研究的结论和方法对锡膏印刷场景下的关键部件早期故障预警具有极大的借鉴和启发价值。鉴于此, 本节选择以减震器、轴承、齿轮等关键部件对象开展通用场景下的早期故障预警介绍。

按照关键部件早期故障预警的发展, 本文将其分为基于过程模型的关键部件早期故障预警、基于信号处理的关键部件早期故障预警和基于深度学习的关键部件早期故障预警。接下来将详细介绍基于过程模型的关键部件早期故障预警、基于信号处理的关键部件早期故障预警和基于深度学习的关键部件早期故障预警。

#### 1.2.1.1 基于过程模型的关键部件早期故障预警

基于过程模型的关键部件早期故障预警通常将部件的实际输出与数学模型的理论输出进行比较, 如果差异超出阈值, 那么就认为存在故障。这类方法通常假定模型的结构和参数是精确已知的。故障可模拟为状态变量的变化。主要的方法包括状态观测器, 参数估计, 奇偶校验方程等。状态观测器是借助观测器从测量结果中重建检测对象的输出, 利用估计误差作为检测故障的指标。Duyun 等人<sup>[32]</sup>针对减震器提出了能够从数据中提取无迟滞阀内参数的物理模型, 将力建模为速度和加速度的函数。Duan 等人<sup>[33]</sup>提出了一种基于参数观测器的新方法, 用于对具有未知扰动的多变量线性系统进行鲁棒故障预警。Termehchy 等人<sup>[34]</sup>面向非最小相位系统提出一种用于故障预警和隔离的未知输入观测器的算法, 即便存在不稳定的不变零点, 依然可以对未知输入进行实时重建。Yang 等人<sup>[35]</sup>讨论了非线性系统基于观测器的故障预警的分析和集成设计。参数估计通常假设系统中某些难以观测的物理参数会因故障出现难以预测的变化, 而这些参数的变化会造成数学模型的参数变化, 因此需要对模型的一些参数进行估计。Gao 等人<sup>[36]</sup>针对系统参数发生异常变化, 提出了一种自适应变化检测和参数识别算法用于具有有限过程和测量噪声的系统故障预警。Hernandez 等人<sup>[37]</sup>则比较了基于状态观测器的减震器故障预警算法和基于参数估计的减震器故障预警算法, 经实验验证在故障早期基于参数估计的减震器故障预警算法更加准确。奇偶校验方程是检查传感器输出和已知输入的奇偶一致性。Chow 等人<sup>[38]</sup>使用奇偶校验关系来生成残差, 从而对系统进行故障预警。

基于过程模型的关键部件早期故障预警的优势在于具备极佳的可解释性, 这主要因为基于过程模型的关键部件早期故障预警通常依赖于数学结构和参数

形式表示的关键部件动态过程模型。但是面对比较复杂的部件，基于过程模型的关键部件早期故障预警大多难以精准建模，从而导致性能不佳。

### 1.2.1.2 基于信号处理的关键部件早期故障预警

基于信号处理的关键部件早期故障预警方法通常在时域、频域或者时频域内对传感器数据进行分解，提取典型故障指标，从而实现故障预警<sup>[39]</sup>。常见的信号处理方法包括经验模态分解<sup>[40]</sup>，傅里叶变换<sup>[41]</sup>、小波变换<sup>[42]</sup>等方式，按照处理思路可以大致分为时域、频域和时频域三种。在时域内<sup>[40,43]</sup>，典型的故障指标包括均值、标准差、均方根值、峰值、脉冲因子、波形因子、峭度和偏度，能够体现传感器数据在时间维度上幅值变化、以及能量分布等特性。例如 Grover 等人<sup>[40]</sup>对于轴承提出了一种仅在时域中使用 Hjorth 参数进行早期故障预警的方案。通过对原始传感器数据进行经验模态分解获得具有代表性的本征模态函数的 Hjorth 参数来计算特征向量，然后使用四个基于规则的分类器进行早期故障预警。而在频域内<sup>[41]</sup>，将时域传感器数据变换到频域主要采用的方式为傅里叶变换，典型的故障指标包括频率的均值、频率重心、均方根频率、标准差频率等，能够体现传感器数据在频域内频率分布，频率变化等特性。例如李心一等人<sup>[41]</sup>引入 Hanning 窗插值快速傅里叶变换对最小熵解卷积和 Teager 能量算子解调进行改进，从而精准的识别轴承故障特征频率。Zhao 等人<sup>[44]</sup>提出了一种基于随机共振的方包络谱负熵轴承故障预警方法。在时频域内<sup>[45-46]</sup>，将时域传感器数据变换到频域主要采用的方式为小波变换、短时傅里叶变换，可以获得传感器数据的频率和时间之间的关系，更加精准的刻画频率随时间的变化以及频率的分布。例如 Shi 等人<sup>[42]</sup>提出了一种基于小波变换和包络谱融合的滚动轴承缺陷预警方法。这种方法能够从谐振频带中充分提取与缺陷相关的特征频率。Rosero 等人<sup>[47]</sup>采用傅里叶快速变换和小波变换对稳态和非稳态工况下轴承损伤进行早期故障预警。Xi 等人<sup>[48]</sup>联合经验模态分解和小波变换设计了一种基于经验小波变换的轴承故障预警方法。Wang 等人<sup>[45]</sup>分析对比了三种时频分析方法对轴承故障预警的敏感性，分别是短时傅里叶变换、伪 Wigner-Ville 分布以及小波变换，并验证了伪 Wigner-Ville 分布的效果最好。

基于信号处理的关键部件早期故障预警方法具有操作简单，可解释性强等优点。但同时故障指标的选取非常依赖专家经验，且基于信号处理的关键部件早期故障预警方法处理大数据的能力较弱，难以有效应对现代工厂中大数据的场景。

### 1.2.1.3 基于深度学习的关键部件早期故障预警

为了处理工厂中大量的传感器数据,基于深度学习的关键部件早期故障预警应运而生<sup>[49-50]</sup>。基于深度学习的关键部件早期故障预警通常是无监督的,这是因为故障数据往往难以收集,通常只有大量健康状态下传感器数据可利用<sup>[51-55]</sup>。基于深度学习的关键部件早期故障预警其核心是假设健康状态数据与故障状态数据服从不同的分布,进而可以从健康状态数据中提取出与故障状态数据有区别的高质量表征,以实现早期故障预警。主流思路是对健康状态的传感器数据进行重建以学习健康状态数据分布,由于健康状态数据与故障状态数据服从不同的分布,那么故障状态数据重建误差会比较大,从而实现早期故障预警。按照具体技术大致可分为基于自编码器的方法和基于生成对抗的方法。

基于自编码器的方法通常由编码器和解码器组成,训练时健康状态的传感器数据作为模型输入,而输出则要求尽可能逼近输入。在编码阶段,编码器将传感器数据作为输入,然后编码压缩至低维特征空间,接着将低维特征由解码器解码至原始的数据空间,最后计算编码器输入和解码器输出之间的差异。例如, Li 等人<sup>[56]</sup>针对轴承故障预警提出一种名为变量累积错误异常检测网络,利用自动编码器进行健康数据重构,并使用时间卷积网络(Temporal Convolution Network, TCN)预测传感器数据。张鸾等人<sup>[57]</sup>针对轴承故障预警问题构建了一种优化的 Swin Transformer 网络,利用 Swin Transformer 重构健康数据的特征。兰杰等人<sup>[58]</sup>为了预警轴承的早期故障,利用基于极限学习机的自编码器对轴承健康状态的样本进行重构。黄宇<sup>[59]</sup>利用 LSTM 搭建自编码器,同时为了克服 LSTM 自编码器训练收敛速度慢的问题,在损失函数中引入了 Kullback-Leibler(KL) 散度,用于优化输入与输出之间的误差。Yu 等人<sup>[60]</sup>提出一种基于异常 Transformer 的无监督故障预警方法,利用卷积神经网络编码轴承的振动信号,然后利用 Transformer 进行解码重建。Batsch 等人<sup>[61]</sup>利用自动编码器深度神经网络架构对齿轮箱振动信号进行重构,成功实现齿轮点蚀故障预警。Wen 等人<sup>[62]</sup>利用 1D-CNN 构造编码器和解码器,然后利用内存模块提取稀疏近似表示,最后用自回归估计器重建信号输入。

基于生成对抗的方法则是采用生成器-判别器架构。生成器的结构与编码器-解码器结构类似,将原始输入的传感器数据压缩至低维特征空间,再从低维特征空间中还原输入的传感器数据。而判别器则是将生成器的输出和原始的传感器数据一同作为输入,判断生成器的输出和原始的传感器数据哪个才是真实数据。生成器力求生成与真实的传感器数据服从相似分布的数据,而判别器则力求能准确判断哪个才是真实的传感器数据,二者互相博弈,直至生成器能成功欺骗判别器。例如 Wu 等人<sup>[63]</sup>考虑到训练数据中仅包含健康数据,提出了一

种故障注意力生成概率对抗自动编码器，将高维空间中传感器数据嵌入到低维空间中，然后利用低维特征和重构误差的分布概率，构造故障注意力异常状态指标。Liu 等人<sup>[64]</sup>提出分类对抗自动编码器用于滚动轴承的无监督早期故障预警，通过对抗性训练过程训练自动编码器。Shao 等人<sup>[65]</sup>提出一个基于辅助分类器生成对抗网络的框架，以从机械传感器数据中学习并生成真实的一维原始数据，从而实现故障预警。Dai 等人<sup>[66]</sup>利用自编码器设计一种用于机械健康监测的无监督生成对抗网络 (Generative adversarial network, GAN)，仅使用轴承健康状态下的数据样本训练模型。总的来说判别器的引入可以有效提高模型的健康数据重建能力，但是基于生成对抗的方法存在难以训练，可能出现不稳定、崩溃等问题。

除基于重构的主流方法外，还包括基于距离度量和基于时序预测等方法。基于距离度量的方法通过计算监测数据与健康基准状态的偏离程度实现故障预警。例如 Wang 等人<sup>[67]</sup>提出了一种基于图神经网络和集成学习的轴承早期故障预警方法，利用图生成模块提取轴承健康状态下的特征，然后测试时利用 KNN 等集成学习算法度量测试样本与健康样本特征间的距离，从而实现故障预警。Siavash-Abkenari 等人<sup>[68]</sup>利用健康样本特征与测试样本特征间的马氏平方距离作为健康指数，进而通过度量马氏平方距离来实现轴承早期故障预警。基于时序预测的方法则利用历史监测数据建立预测模型，通过分析预测误差进行早期故障预警。例如 Zhang 等人<sup>[69]</sup>利用 LSTM 预测未来的轴承振动信号，然后根据预测误差进行早期故障预警。

然而，由于工厂采集的健康状态监测数据经常受到高噪声的干扰，导致健康数据的分布发生偏移，难以满足健康状态与故障状态数据服从不同分布的基本假设，使得上述研究难以从受污染的健康状态数据中准确刻画关键部件的健康模式。

### 1.2.2 关键部件剩余使用寿命预测

关键部件剩余使用寿命预测旨在预警其完全失效时间<sup>[70-71]</sup>。与 1.2.1 节类似，目前在公开文献未见到明确的锡膏印刷场景下关键部件剩余使用寿命预测研究。现有研究集中在通用工业场景下的关键部件剩余使用寿命预测，与锡膏印刷场景下的关键部件剩余使用寿命预测存在以下相似之处。首先，部件的状态监测数据类型基本一致。在通用工业场景下，部件大多采用振动传感器进行状态监测，这与锡膏印刷场景基本一致。其次，状态监测数据与剩余使用寿命之间的关联比较相似。在通用工业场景与锡膏印刷场景下部件在退化初期大多运行平稳，然后振动加剧，直至完全失效。因此现有研究的结论和方法对于锡膏印刷场景下的关键部件剩余使用寿命预测具有重要的迁移价值与启发意义。鉴于

此，本节开展通用场景下的关键部件剩余使用寿命预测的工作介绍。

按照关键部件剩余使用寿命预测的发展，可分为基于机理模型的关键部件剩余使用寿命预测、基于随机过程的关键部件剩余使用寿命预测和基于深度学习的关键部件剩余使用寿命预测<sup>[72-75]</sup>。下面将详细介绍基于机理模型的关键部件剩余使用寿命预测、基于随机过程的关键部件剩余使用寿命预测以及以基于深度学习的关键部件剩余使用寿命预测。

### 1.2.2.1 基于机理模型的关键部件剩余使用寿命预测

基于机理模型的关键部件剩余使用寿命预测方法通常是根据关键部件的故障机理建立参数化的退化模型，然后依据采样数据或者专家经验对退化模型的参数进行辨识或者求解，从而实现关键部件的剩余使用寿命预测。典型的机理模型<sup>[76]</sup>包括 Paris 模型<sup>[77-78]</sup>、Forman 模型<sup>[79]</sup>等，以刻画部件疲劳裂纹拓展速率为主。Paris 模型假设疲劳裂纹拓展速率与应力强度因子呈幂函数关系<sup>[80-82]</sup>。例如，Li 等人<sup>[80]</sup>基于 Paris 模型，建立了疲劳裂纹拓展速率与材料特性之间的随机缺陷传播模型。陈龙等人<sup>[82]</sup>使用比例型 Paris 模型来刻画裂纹的拓展速率，并利用逆高斯随机过程来建立单样本疲劳裂纹扩展随机模型。Forman 模型则进一步的引入了断裂韧度和应力比的影响<sup>[83-84]</sup>。例如，Oppenheimer 等人<sup>[83]</sup>使用基于故障组合物理模型的滤波器根据测量的物理特征来描述退化状态，然后使用基于线性弹性断裂力学 Forman 裂纹扩展定律的剩余使用寿命预测模型根据机器状态预估对应的寿命。杨冰等人<sup>[84]</sup>提出了一种基于 Forman 模型的随机疲劳长裂纹扩展概率模型及其参数测定方法。

基于机理模型的关键部件剩余使用寿命预测方法通常具有很高的可解释性，但是这类方法对于领域知识有大量的需求，且对复杂的关键部件建模比较困难。

### 1.2.2.2 基于随机过程的关键部件剩余使用寿命预测

基于随机过程的关键部件剩余使用寿命预测方法通常利用随机过程对收集的关键部件状态监测数据进行处理，描述退化变量的演化过程，最终以概率分布的形式建立退化模型。典型的随机过程包括 Wiener 过程、Gamma 过程、Markov 链等方法。Wiener 过程是一种独立增量过程模型，用于刻画部件的性能关于时间非单调退化的场景<sup>[85-89]</sup>。例如，Huang 等人<sup>[86]</sup>提出了一种具有自适应漂移的非线性非均质 Wiener 过程模型来描述退化轨迹。裴洪等人<sup>[87]</sup>提出一种考虑不完美维护影响的性能退化模型与维护决策模型，首先基于 Wiener 过程输出剩余使用寿命的概率分布；然后根据剩余使用寿命、检测间隔和预防性维护阈值来构建维护决策模型。Cai 等人<sup>[88]</sup>使用非线性 Wiener 过程建立了对偶非线性隐式退化模型。Gamma 过程是一种独立非负增量的随机过程，适合描述单调退化，

比如裂纹的增长<sup>[90-92]</sup>。例如, Tan 等人<sup>[90]</sup>研究了连续检查下 Gamma 退化的部件维护模型, 利用 Gamma 分布对部件材料的退化过程进行建模, 然后分析在不完善维护措施的情况下可靠性的变化。李玲等人<sup>[91]</sup>针对部件退化速度随使用时间以及维修次数的增加而越来越快的场景, 联合 Gamma 过程与几何过程提出一种加速退化模型。Xu 等人<sup>[92]</sup>将自适应 Gamma 过程用于描述条件指标的恶化性质。Markov 链主要是将部件的退化状态划分为若干个退化等级, 退化过程为从一个退化等级转移到另一个退化等级<sup>[93-95]</sup>。例如, 李巍华等人<sup>[93]</sup>提取传感器数据的频带能量作为退化特征; 然后将正常样本的特征作为模型观测值从而训练连续隐半 Markov 模型; 从而建立轴承性能退化模型。Xiang 等人<sup>[94]</sup>假设部件受 Markov 操作环境的影响, 部件的瞬时退化率取决于环境的状态, 因此使用 Weibull 分布来近似该部件的首次失效时间分布。Ghasemi<sup>[95]</sup>基于隐半 Markov 理论, 提出了一种基于观测序列预测和状态识别的剩余寿命预测模型。

基于随机过程的剩余使用寿命预测方法优点在于可以给出剩余使用寿命的概率分布, 这对于维护决策有着重大意义, 同时模型的可解释性也比较强, 但是缺点在于对大量的低质量数据的处理能力非常有限。面对以大数据为主要特点的现代工业, 基于随机过程的剩余使用寿命预测方法存在一定的局限性。

### 1.2.2.3 基于深度学习的部件剩余使用寿命预测

基于深度学习的部件剩余使用寿命预测方法通常是监督式学习, 主要利用深度学习模型建立部件状态监测数据与剩余使用寿命标签之间的潜在关系。典型的深度学习方法有卷积神经网络 (Convolution Neural Network, CNN), 循环神经网络 (Recurrent Neural Network, RNN) 及其变体, 图神经网络 (Graph Neural Network, GNN) 和 Transformer 等。CNN 利用卷积来捕获时域中相邻时间步传感器采样数据的相关性或者时频域中时频信息的演变关系<sup>[96-98]</sup>。例如, Zhu 等人<sup>[96]</sup>提出了一种多尺度卷积神经网络用于提取轴承非稳态下的时频退化特征, 从而实现剩余使用寿命的预测。Cao 等人<sup>[97]</sup>提出一种 TCN-Transformer 模型, 将概率预测和区间预测纳入轴承剩余使用寿命预测中, 以提高模型的可靠性。Qin 等人<sup>[98]</sup>设计了一种多尺度综合统计特征, 然后作为门控卷积单元和 TCN 的输入, 从而增强了模型的特征提取能力。RNN 及其变体则侧重于在时域内捕获传感器数据的时序关联性<sup>[99-101]</sup>。例如, Wen 等人<sup>[99]</sup>提出一种 GRU-AE-Wiener 的混合模型, 首先利用离散小波变换将原始数据转换至时频域并将其分解为 5 个频段的能量信号以进行能量密度信号累积变换, 然后将累积变换能量特征作为双向 GRU 与 Wiener 过程的输入, 从而构建健康指数。Lu 等人<sup>[100]</sup>提出了一种物理引导的 LSTM 网络, 选择轴承退化过程中具有单调性的时频域特征指标作为模型输入, 其最终的剩余使用寿命预测更符合物理规律。Zhu 等人<sup>[101]</sup>提出一种时间

相关对比学习 LSTM 模型,使用时间相关对比学习在频域内提取退化特征,然后使用退化特征训练 LSTM,从而实现轴承剩余使用寿命预测。Qin 等人<sup>[102]</sup>提出一种具有宏观-微观注意力的 LSTM 模型,以典型的时域和频域统计特征作为模型输入,以实现齿轮的剩余使用寿命预测。而 GNN 则侧重于捕获传感器或者样本之间的关联<sup>[103-105]</sup>。例如, Ye 等人<sup>[103]</sup>集成多自适应图神经网络与 TCN,利用多自适应图直接建模原始传感器数据间复杂的相互依赖关系,然后利用 TCN 建模原始传感器数据退化模式。Wu 等人<sup>[104]</sup>将轴承的状态监测数据融合成多分辨率超图,以刻画状态检测数据的内在关联;然后设计了超图注意力网络来挖掘超图数据节点之间的高阶关系。Zhou 等人<sup>[105]</sup>将不同时间尺度下的多传感器数据建模多尺度图,然后利用物理引导的多尺度时空图提取退化特征,从而有效避免延迟预测。Transformer 的核心是注意力机制,其侧重于提取全局不同时刻的传感器数据的关联性或者特征重要性。例如, Zhang 等人<sup>[106]</sup>着重考虑了时间特征的价值是可变的,因此提出一种加权时间嵌入 Transformer,可以自动向不同的时间特征赋予不同的权重。Wei 等人<sup>[107]</sup>则提出一种条件变分 Transformer 架构,可自动从状态监测数据中提取一个最重要的退化特征。此外,还有很多人尝试将 CNN, RNN 及其变体等进行组合,以获取更强大的退化特征提取能力。例如, Ma 等人<sup>[108]</sup>提出一种基于多尺度高效通道注意力卷积神经网络和双向门控循环单元的混合架构,将一维振动信号转换为二维图像,然后利用多尺度卷积神经网络提取多尺度退化特征以及双向门控循环单元刻画时间演变模式。

基于深度学习的剩余使用寿命预测方法的优点在于具有强大的退化特征提取能力,能够有效处理海量和复杂的结构化数据,并减少对领域知识的需求,缺点在于比较依赖剩余使用寿命标签数据,这意味关键部件通常需要运行到完全失效才能获取到对应的剩余使用寿命标签。这在工厂中几乎是不允许的。这种标签稀缺性严重制约了深度学习模型在实际工程中的应用。

目前,在少量标签样本下进行剩余使用寿命预测的工作相对较少<sup>[109-112]</sup>,主要是基于退化阶段差异性的自监督方法。这些工作通常假设相隔越远的退化阶段,其状态监测数据差异越大,然后设计相应的预训练任务从大量无标签传感器数据中提取退化特征,最后使用少量带标签的传感器数据建立退化特征到剩余使用寿命的映射。例如 Krokotsch 等人<sup>[110]</sup>和 Kong 等人<sup>[112]</sup>在预训练阶段通过对比任意两段状态监测数据,根据其差异来估计其时间间隔。Akrim 等人<sup>[111]</sup>使用编码器-解码器架构,在预训练阶段基于当前退化阶段的状态监测数据预测未来状态监测数据。

然而,在工厂中由于噪声、部件运行不稳定等因素,不同退化阶段间状态监测数据较为相似,造成上述基于退化阶段差异性的自监督方法难以提取到关于剩余使用寿命的高区分度退化特征。

### 1.2.3 锡膏印刷参数预警

锡膏印刷参数不当是指锡膏印刷机无硬件故障时按照设定的锡膏印刷参数无法生产出符合要求的 PCB 锡膏印刷产品。对于锡膏印刷参数不当，目前缺乏有效的直接监测方式，工厂通常利用锡膏印刷质量反映锡膏印刷参数的合理性，绝大多数情况下将锡膏印刷机无硬件故障时锡膏印刷质量异常等价于锡膏印刷参数不当。因此当前的锡膏印刷参数预警方法通常是预测锡膏印刷机无硬件故障时的印刷质量，然后将其与生产标准进行比较，以判断是否出现锡膏印刷参数不当<sup>[113]</sup>。根据不同的应用场景可以分为投产前锡膏印刷参数预警和投产后锡膏印刷参数预警。投产前锡膏印刷参数预警目标是在生产开始前准确判断所设定的锡膏印刷参数是否合理，是否会导致印刷质量异常。投产后锡膏印刷参数预警目标是在生产开始后预测印刷质量异常，如果不存在锡膏印刷机故障，那么可以认为是锡膏印刷参数不当，从而尝试调整锡膏印刷参数，以避免生产残次品。

#### 1.2.3.1 投产前锡膏印刷参数预警

投产前锡膏印刷参数预警通常是根椐工艺参数，如锡膏印刷参数、PCB 型号、锡膏类型等，进行锡膏印刷质量预测，判断拟定的锡膏印刷参数在投产后是否会造成锡膏印刷异常，即能否稳定的生产合格品。工厂的现状是在 PCB 投产前锡膏印刷工艺工程师需要根据自身丰富的经验设定一组印刷参数，然后试产，根据试产的效果调整印刷参数，以确保最终大批量投产不会出现问题。这个过程会消耗大量的时间以及物力成本，从而造成生产效率降低。因此需要设计一种模型能够根据印刷参数、PCB 型号、锡膏类型准确预估投产后是否会出现印刷质量异常，从而大大缩短印刷参数调整周期以及减少试产成本。早期的研究<sup>[114-116]</sup>侧重于探索典型工艺参数与印刷质量之间的关系，比如钢网厚度、元件间距、开孔面积、刮刀速度、刮刀压力、锡膏粘度和锡膏粒度等因素。例如，Yang 等人<sup>[114]</sup>利用全连接神经网络来拟合上述工艺参数和锡膏印刷体积之间的关联。Tsai 等人<sup>[115]</sup>则提出了一种回归残差控制图来监控锡膏印刷过程。使用线性回归函数来拟合锡膏印刷的上述工艺参数与锡膏体积之间的关系。然而，仅使用线性回归函数很难准确模拟工艺参数与印刷质量之间复杂的非线性效应。Tsai 等人<sup>[116]</sup>利用田口模糊法来评估上述工艺参数在细间距场景下对锡膏印刷性能的影响。由于发现孔径-面积比对细间距元件的锡膏印刷质量有重大影响，后续工作<sup>[24,117]</sup>尝试将孔径-面积比和其他新参数纳入分析锡膏印刷质量的范围。例如，Lu 等人<sup>[117]</sup>引入了更多以前的工作中没有采用的印刷参数，如清洁周期和面积比。基于不同焊盘尺寸、清洁周期和打印机参数的在线学习技术被用来估算锡膏体积。Khader 等人<sup>[24]</sup>提出了一种基于混合整数非线性编程的优化模型，用于寻找不同焊盘的锡膏印刷工艺参数的最佳设置。这种高度非线性的优

化模型能在符合锡膏印刷标准的同时显著减少锡膏体积的分布方差。此外，其他研究<sup>[118-119]</sup>还尝试利用工艺参数同时预测锡膏印刷质量的多个属性。例如，Liukkonen 等人<sup>[118]</sup>将工艺参数作为多层感知器的输入，将锡膏印刷缺陷类型作为输出，在七种缺陷类型中取得了较好的结果。Oliver 等人<sup>[119]</sup>利用 Levenberg-Marquardt 训练算法来训练人工神经网络，在考虑印刷速度、钢网孔径面积比和无铅焊膏类型的情况下，探索锡膏的高度和面积以及相应的转移效率。Martinek 等人<sup>[120]</sup>根据印刷速度、孔径面积比、锡膏粒度的几何平均数和几何偏差建立了一个数据集，用于预测沉积锡膏的面积、厚度和体积。Chen 等人<sup>[121]</sup>基于响应面方法建立了锡膏印刷工艺参数对印刷锡膏高度、面积和体积的预测方程。

这些研究通常以静态方式模拟工艺参数和印刷质量之间复杂的非线性关系，以获得最佳工艺参数。然而，锡膏印刷工艺参数与印刷质量之间的关系在投产后是动态变化的，容易受到环境变化的影响，比如温湿度对锡膏的理化性质有着显著影响。因此，这些方法仍然存在较大局限性，即便在投产初期印刷参数是合适的，能使锡膏印刷稳定有序的执行，但后续随环境变化仍然有可能因锡膏印刷参数不当而导致印刷质量异常。

### 1.2.3.2 投产后锡膏印刷参数预警

投产后锡膏印刷参数预警通常是基于时序模式，将锡膏印刷质量时序数据作为模型的输入，利用锡膏印刷质量的时间临近性进行锡膏印刷质量预测，当出现锡膏印刷质量异常时，就认为是锡膏印刷参数不当。在锡膏印刷中，由于锡膏时变的理化性质和环境变化，按照预先设定的锡膏印刷参数会导致锡膏印刷异常，即锡膏印刷参数不当。工厂希望能及时的预测到锡膏印刷参数不当并施加干预，以避免出现次品。因此，需要对印刷质量的时序模式进行分析，以预警锡膏印刷参数不当。随着高效数据处理算法的发展，投产后锡膏印刷参数预警方法可以利用大量的锡膏印刷质量时序数据，在锡膏印刷过程中实现精细的锡膏印刷质量预测，从而实现锡膏印刷参数预警。投产后锡膏印刷参数预警方法起步较晚，但近年来已进行了广泛的探索。

Lu 等人<sup>[117,122]</sup>提出了一种混合在线优化模型，利用在线学习实时预测锡膏印刷体积，当预测到锡膏印刷质量异常时即认为存在锡膏印刷参数不当，然后利用进化搜索技术来调整锡膏印刷参数，以保证高质量的锡膏印刷。Wang 等人<sup>[123]</sup>提出了一种基于机器学习的锡膏印刷工艺参数优化方法。首先利用 SVR 构建锡膏预测模型，预测未来的锡膏印刷质量。然后当预测到锡膏印刷残次品后利用粒子群算法在锡膏印刷工艺参数的搜索空间中进行优化搜索。Wang 等人<sup>[124-125]</sup>开发一种基于 RNN 的预测模型，利用双树复小波变换从锡膏印刷质量数据中提取合适的特征，然后对未来的锡膏印刷性能进行预测，以判断是否存在

锡膏印刷参数不当。Alelaumi 等人<sup>[126-127]</sup>提出一种基于 CNN 的清洗概况分类模型用于清洗模式这一锡膏印刷参数的选择，将 PCB 锡膏印刷时间序列数据编码为图像，以更好地理解 PCB 锡膏印刷质量趋势和异常，然后确定采用湿洗还是干洗。Alelaumi 等人<sup>[128]</sup>则更关注锡膏印刷质量异常的预测，提出了一种新的多时空智能异常预测框架，以提高 PCB 组装线的一次通过率并降低返工成本。在第一阶段，设计了一个基于随机森林的指数加权移动平均控制图来监控高度自相关的锡膏印刷过程。在第二阶段，根据质量序列数据设计统计特征，通过自适应增强技术提前预测锡膏印刷参数不当。

上述研究通常只考虑锡膏印刷质量的时间临近性，侧重于挖掘锡膏印刷质量的时序特征。然而在工厂中，锡膏印刷质量与 PCB 的焊盘分布是息息相关的，忽略锡膏印刷质量与 PCB 的焊盘分布之间的关系会导致锡膏印刷质量不受 PCB 焊盘分布的约束，从而降低锡膏印刷参数预警的性能。

#### 1.2.4 当前研究存在的问题

- (1) 在关键部件早期故障预警方面：健康样本中含有高噪声。已有的关键部件早期故障预警工作通常是通过对健康样本重构获得一个能拟合健康数据分布的模型，然后在测试阶段重构待测试样本。由于健康状态与故障状态之间数据分布存在差异，如果重构误差较大则认为出现故障。然而上述工作忽略了健康样本中存在高噪声干扰的问题，导致上述工作难以准确刻画关键部件的健康模式。具体而言，以减震器为例，在实际监测中，振动传感器易受温度变化、电磁干扰等因素的影响，存在显著的零漂以及尖峰异常值，造成健康状态下数据分布发生偏移，严重削弱了健康状态与故障状态之间数据分布的差异。
- (2) 在关键部件剩余使用寿命预测方面：标签样本难获取、不同退化阶段间传感器数据表现相似。由于工厂通常不会任由锡膏印刷中关键部件运行至完全失效阶段，因此很难获得部件全周期退化数据，同时也很难获得对应的剩余使用寿命标签。通常只有大量的无标签传感器数据以及少量的带剩余使用寿命标签的传感器数据可用。在少量标签样本条件下，已有的剩余使用寿命预测工作通常利用不同退化阶段间传感器数据的差异来从大量无标签传感器数据中提取退化特征。然而，上述工作忽略了不同退化阶段间多传感器数据表现也很有可能是相似的，导致上述工作提取的退化特征的区分度不足。具体而言，由于噪声、部件运行的不稳定性等因素，在非退化末期传感器数据仍然可能表现为剧烈振动，且幅值较大，这与退化末期时传感器数据表现极为相似。这种现象会造成上述工作提取到的退化特征缺乏区分度，难以准确的将退化特征与退化阶段相关联。

(3) 在锡膏印刷参数预警方面：锡膏印刷质量与 PCB 的焊盘分布存在较强相关性。已有工作通常只利用锡膏印刷质量的时序模式进行印刷参数预警，而忽略了 PCB 的焊盘分布对锡膏印刷质量的重要影响。具体而言，首先由于锡膏是从钢网的网孔沉积到对应的 PCB 焊盘上，因此钢网网孔的孔径、密度等因素会直接影响到锡膏的沉积，从而影响锡膏的印刷质量。钢网上的网孔与 PCB 上焊盘是一一对应关系，因此 PCB 的焊盘分布对锡膏印刷质量存在影响。其次通过数据分析，发现相邻焊盘的锡膏印刷质量是极为相似的，这遵循邻域相似性原理，而且同时印刷多块 PCB 时，在 PCB 中相同位置的焊盘，其锡膏印刷质量往往相似。

### 1.3 本文主要工作和组织结构

针对上述问题，本文依托某大型 SMT 工厂，通过分析该大型 SMT 工厂的锡膏印刷真实生产数据、维护日志，结合锡膏印刷工艺工程师的经验与工厂实际需求，凝练本文主要研究内容。本文主要研究内容以及组织结构具体如下。

#### 1.3.1 主要研究内容

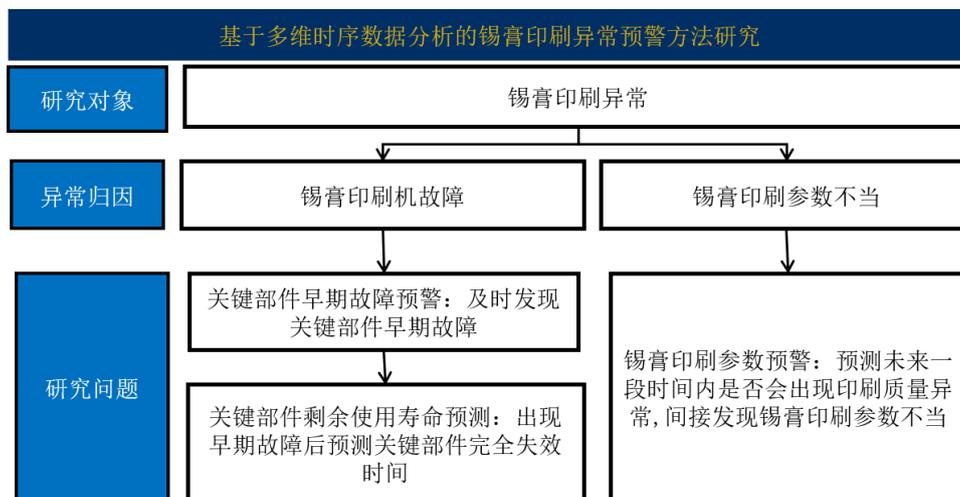


图 1.2 论文研究内容

锡膏印刷异常主要由锡膏印刷机故障和锡膏印刷参数不当这两个因素引起，因此为了实现锡膏印刷异常预警，需要分别对锡膏印刷机故障和锡膏印刷参数不当进行预警。

对于锡膏印刷机故障预警，本文依次具体开展关键部件早期故障预警和关键部件剩余使用寿命预测的研究内容，旨在分阶段的进行故障预警，原因如下。首先，锡膏印刷机作为一个复杂的系统，直接预警整体故障是非常困难的；同时，锡膏印刷机故障主要由若干关键部件造成，因此本文以锡膏印刷机关键部件为切入点，进行锡膏印刷机故障预警。其次，由于关键部件在运行初期退化趋势

不明显,直接预警完全失效时间是非常困难的,对维护决策的参考价值也相对有限。因此在实际生产中,工厂为了制定最优的锡膏印刷机硬件维护决策,通常在关键部件运行初期重点关注其早期故障,在发现关键部件早期故障的基础上进一步预警关键部件的完全失效时间。通过分阶段的故障预警,为锡膏印刷机硬件维护提供更有效更丰富的决策依据,从而尽可能的避免锡膏印刷异常。

锡膏印刷参数不当是指锡膏印刷机无硬件故障时按照设定的锡膏印刷参数无法生产出符合要求的 PCB 锡膏印刷产品。对于锡膏印刷参数不当预警,本文开展通过预测锡膏印刷机无硬件故障下的锡膏印刷质量异常来间接预警锡膏印刷参数不当的研究内容,原因如下。目前缺乏直接监测锡膏印刷参数不当的有效方式,由于除了锡膏印刷机故障之外,锡膏印刷参数不当是最主要的锡膏印刷异常因素,因此工厂通常利用锡膏印刷质量来表征印刷参数的合理性。在实际生产中,工厂绝大多数情况下将锡膏印刷机无硬件故障下锡膏印刷质量异常等价于锡膏印刷参数不当,因此可通过预测锡膏印刷机无硬件故障下的锡膏印刷质量异常来间接实现预警锡膏印刷参数不当。

综上所述,本文分析了造成锡膏印刷异常的因素,结合当前研究存在的问题以及工程现状,利用锡膏印刷机的多传感器状态监测数据以及多维锡膏印刷质量数据,开展基于多维时序数据分析的锡膏印刷异常预警方法研究。面向锡膏印刷异常的两大因素:锡膏印刷机故障、锡膏印刷参数不当,分别开展关键部件早期故障预警、关键部件剩余使用寿命预测以及锡膏印刷参数预警的研究。关键部件早期故障预警、关键部件剩余使用寿命预测以及锡膏印刷参数预警分别对应 1.2.4 节中的三个研究难点。具体阐述如下。

- (1) 基于多传感器双重对比的锡膏印刷关键部件早期故障预警算法:针对锡膏印刷关键部件早期故障预警中健康状态下传感器数据含有高噪声的难点,提出了一种基于多传感器双重对比的锡膏印刷关键部件早期故障预警算法,利用对比的方式分别提取健康状态下多传感器时频信息和多传感器相关性两个层面的通用表示,从而全面抑制高噪声的不良影响。具体而言,在时频信息层面,设计了时频对比模块,利用 KL 散度对健康时频特征进行对比,最小化健康状态下多传感器时频特征的 KL 散度,从而挖掘健康状态下多传感时频信息的通用表征。随后,在相关性层面,设计了相关性对比模块,利用 KL 散度对健康多传感器 Pearson 相关性进行对比,最小化健康状态下多传感器相关性的 KL 散度,从而有效挖掘健康状态下多传感器相关性的通用表示。结合时频对比模块和相关性对比模块可以提取部件健康状态的通用特征,从而克服健康状态下传感器数据含有高噪声的难点。
- (2) 基于多传感器交替对比的锡膏印刷关键部件剩余使用寿命预测算法:针对剩余使用寿命预测中标签样本难获取、不同退化阶段间传感器数据表现相

似的难点，提出了一种基于多传感器交替对比的锡膏印刷关键部件剩余使用寿命预测算法，该方法在共现空间中利用跨传感器相似度从大量的无标签传感器数据中挖掘跨传感器不变特征，从而提高不同退化阶段间特征的区分度。具体来说，在预训练阶段使用 Resnet18 将不同传感器的特征映射到一个共现空间。然后，通过在共现空间中进行基于跨传感器相似度的交替对比，从大量无标签多传感器数据中提取到代表部件退化状态的跨传感器不变特征，这可以显著提高退化特征关于剩余使用寿命的区分度。最后，利用少量带标签的多传感器数据微调预训练模型，以实现少量标签数据下的剩余使用寿命预测。

- (3) 基于 PCB 布局图卷积的锡膏印刷参数预警算法：针对锡膏印刷质量与 PCB 上焊盘的分布存在较强相关性的特点，提出了一种基于 PCB 布局图卷积的锡膏印刷参数预警算法，该方法将 PCB 中焊盘的分布建模成图，以捕获 PCB 上焊盘的分布对锡膏印刷质量的影响。具体来说，由于锡膏印刷质量与焊盘的空间分布有关，因此根据印刷质量的 Pearson 相关性将 PCB 转换为图，然后用相关性阈值修剪图的边，以模拟焊盘的空间分布。然后对锡膏的时变理化性质进行建模，将生产时间归一化，计算基于生产时间的注意力，并根据注意力重构锡膏印刷质量。然后，由于锡膏印刷质量异常的稀缺性，设计了加权损失来提高对锡膏印刷质量异常的关注。最后，将预测的锡膏印刷质量与生产质量标准进行比较，从而发现是否存在锡膏印刷参数不当。

### 1.3.2 全文组织结构

本文章节组织安排如图 1.3。

第一章，绪论。具体介绍研究背景与意义、国内外研究现状、论文的研究难点、主要内容以及论文的组织结构。

第二章，锡膏印刷异常预警应用背景、现状与前景。主要介绍本文研究内容所涉及的背景、应用案例以及发展前景，具体包括锡膏印刷的工程介绍，关键部件早期故障预警、关键部件剩余使用寿命预测、锡膏印刷参数预警这三个研究内容在工程中的具体案例，并总结应用前景。

第三章，基于多传感器双重对比的锡膏印刷关键部件早期故障预警算法。具体包括所提基于多传感器双重对比的关键部件早期故障预警算法的详细介绍以及所提方法与基线方法的性能比较和分析。

第四章，基于多传感器交替对比的锡膏印刷关键部件剩余使用寿命预测算法。具体包括所提基于多传感器交替对比的锡膏印刷关键部件剩余使用寿命预测算法的详细介绍以及所提方法与基线方法的性能比较和分析。

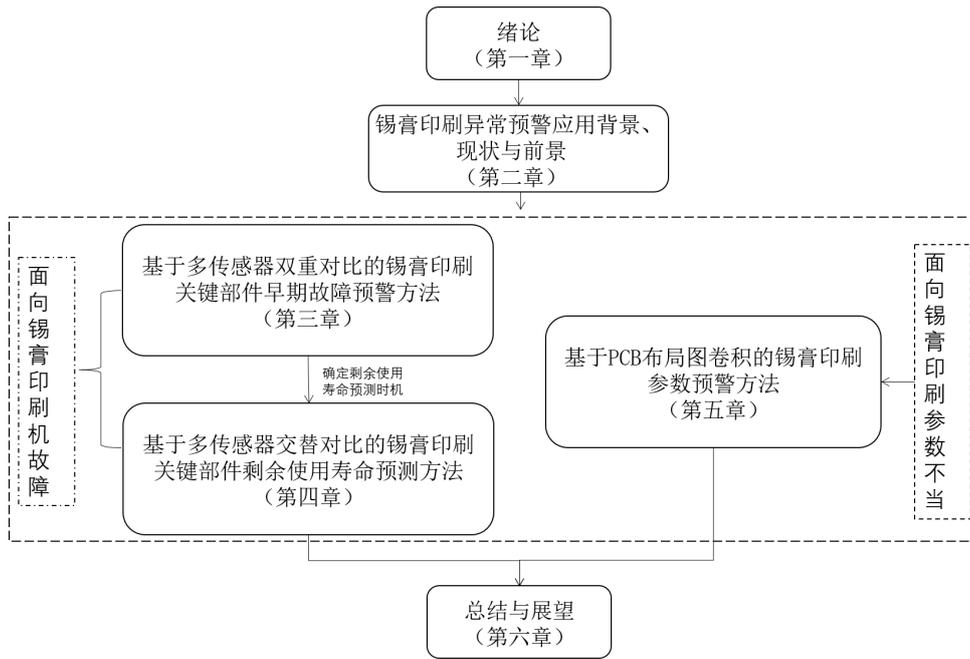


图 1.3 论文组织结构

第五章，基于 PCB 布局图卷积的锡膏印刷参数预警算法。具体包括所提基于 PCB 布局图卷积的锡膏印刷参数预警算法的详细介绍以及所提方法与基线方法的性能比较和分析。

第六章，总结与展望。总结全文的内容和贡献，阐述论文存在的不足，并给出未来研究工作的展望。

## 第 2 章 锡膏印刷异常预警工程应用背景、现状和前景

本章主要介绍锡膏印刷机及锡膏印刷的工程背景，本文研究内容在锡膏印刷行业的工程应用现状以及发展前景，同时拓展介绍本文研究内容在其他有关行业的工程应用现状。

### 2.1 锡膏印刷异常预警工程应用背景

#### 2.1.1 锡膏印刷机组成

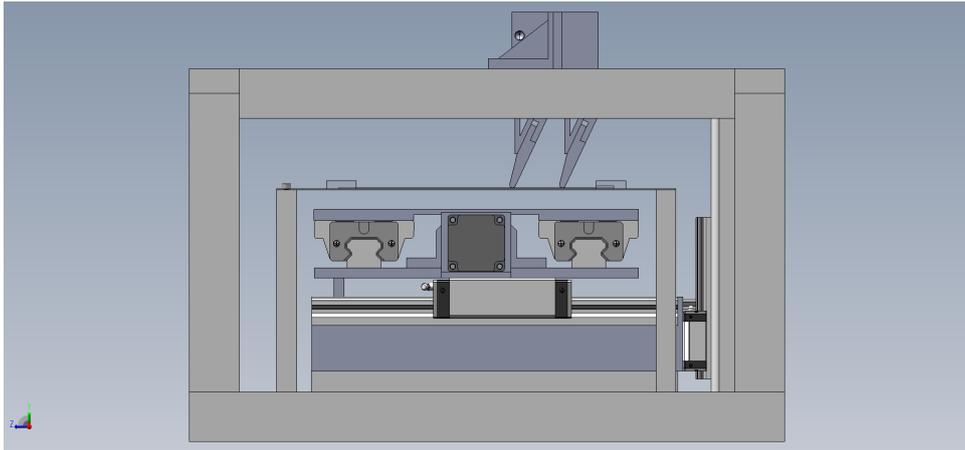


图 2.1 锡膏印刷机外观图

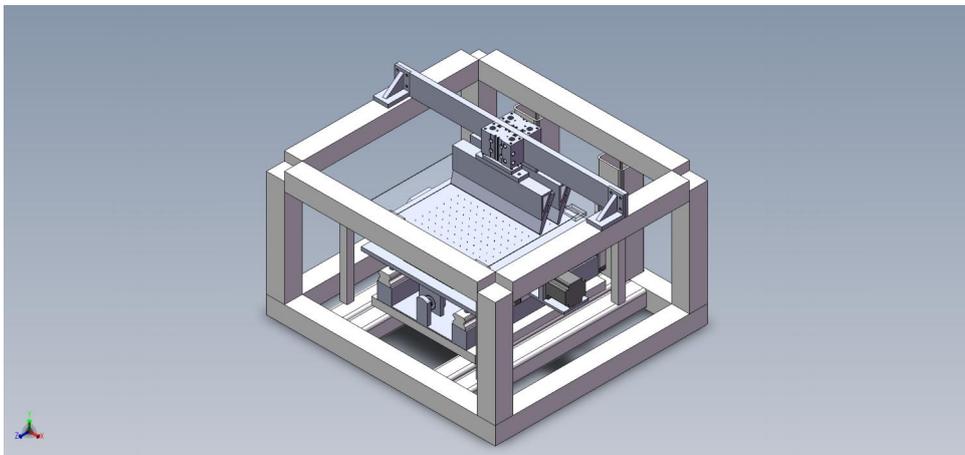
图 2.1 展示了锡膏印刷机的外观，上面有三色报警器，分别对应不同的工作状态，中间有玻璃罩，可以从外面清晰的看到锡膏印刷的整个过程。图 2.2(a)、图 2.2(b)<sup>①</sup> 分别展示了不同视角下锡膏印刷机的机械结构。锡膏印刷机由机架、传送系统、刮刀系统、视觉识别定位系统、钢网系统、可调中央平台、控制系统与操作界面等部分组成。下面将详细介绍。

- (1) 机架：锡膏印刷机的支撑结构，负责支撑锡膏印刷机的重量，保持锡膏印刷机的稳定。锡膏印刷机的机架通常由高强度，耐腐蚀的金属制成，使用寿命非常长。
- (2) 传送系统：传送系统的作用是在锡膏印刷中稳定的传送 PCB，其主要由导轨、皮带传送系统、电机、导轨调宽装置等组成，能够自适应的调整传送系统宽度以传送不同尺寸的 PCB。
- (3) 刮刀系统：图 2.3 展示了双刮刀的示意图。刮刀系统由印刷头，刮刀横梁，刮刀驱动等组成。印刷头集成了刮刀，升降装置等。刮刀驱动的作用是刮刀能够按照预期设定平稳的运行。刮刀系统的作用是均匀的将锡膏涂抹在钢网上，对于锡膏印刷质量有着最直接的影响。在锡膏印刷中刮刀形状和

<sup>①</sup>自 <https://www.jixie5.com/3D/bdfc39c2380861.html> 购买的锡膏印刷机 CAD 图纸



(a) 主视图



(b) 轴测图

图 2.2 不同视角下的锡膏印刷机机械结构

材料的选择也尤为重要，常见的刮刀形状有菱形和拖尾形，常见的刮刀材料有金属材料 and 橡胶材料。

- (4) 视觉识别定位系统：视觉识别定位系统用于在锡膏印刷中精准定位 PCB 的位置，其主要由摄像头、图像处理技术等组成，可以将待印刷的 PCB 和钢网精准对齐。
- (5) 钢网系统：钢网系统由钢网<sup>[129-132]</sup>、固定系统、清洁系统组成。钢网通常是不锈钢材质，负责确定锡膏印刷的具体图案，网孔与待印刷 PCB 上的焊盘一一对应。固定系统负责固定钢网，保证钢网在锡膏印刷中固定不动。固定系统通常由机械夹紧装置和真空吸附装置组成，机械加紧装置采用物理约束将钢网固定在锡膏印刷机内，真空吸附装置则是通过抽真空产生负压来固定钢网。清洁系统负责锡膏印刷后清理钢网上残留的锡膏，以确保钢网的网孔不会被堵塞。清洁时可选择干洗或者湿洗，干洗通过卷纸擦拭钢网表面，湿洗则是先喷洒清洁剂在进行擦拭。干洗存在清洁程度不够的问题，而湿洗则面临频繁使用清洁剂可能会导致锡膏变质的问题。在实际

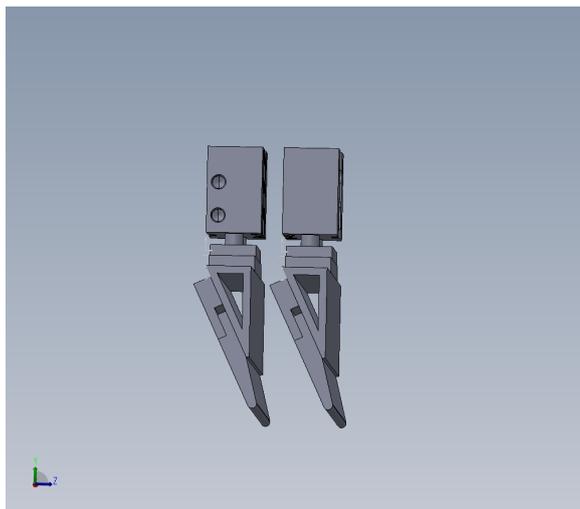


图 2.3 双刮刀

使用中应该采用干洗湿洗相结合的方式。

- (6) 可调中央平台：可调中央平台由 Z 轴升降装置、平台移动装置以及印刷工作台面组成，负责锡膏印刷中 PCB 与钢网的匹配，对准。Z 轴升降装置包括升降底座、升降丝杠、控制电机、升降导轨、减震器等部件。Z 轴升降装置负责在印刷前将 PCB 从低处抬升至高处，与高处的钢网相吻合，同时也负责在印刷完成后将 PCB 从高处降低至低处，与钢网脱模。平台移动装置则包括丝杆、导轨以及步进电机，负责根据预先设定的参数对 PCB 的位置进行微调，从而实现 PCB 与钢网的精准匹配，确保不会出现偏移缺陷。
- (7) 控制系统与操作界面：与前面的组成部分不同，该部分主要是软件，其作用是控制、协调上述系统的运动。为了提升可操作性，会配置一个显示器，通过点击显示器或者按钮，实现对锡膏印刷参数的设置，也可以查看锡膏印刷的日志以及生产数据。

上文介绍了锡膏印刷机的组成，而在实际生产中锡膏印刷机的故障则是由各个部件故障造成的。SMT 工厂面对锡膏印刷机故障是通过锡膏印刷机某个组成单元的异常现象定位至故障的部件。表 2.1 展示了合作的 SMT 工厂的 2022 年 1 月上旬锡膏印刷机故障日志，故障现象对应某个组成单元的异常表现，而故障原因则是对应的故障部件。从中可以看出减震器故障次数以及维修时长占比都要高于其他类型故障。

### 2.1.2 锡膏印刷参数

锡膏印刷机需要设置的印刷参数如表 2.2 所示，属性列为锡膏印刷机中原始的印刷参数名称，中文释义列为对应的中文名称。

锡膏印刷机中印刷参数具体解释如下<sup>[133]</sup>。

- (1) 脱模速度：完成印刷后，PCB 与钢网的分离速度。脱模速度过快可能会导

表 2.1 2022 年 1 月上旬锡膏印刷机故障日志

故障开始时间	维修开始时间	维修结束时间	维修时长(分钟)	故障现象	故障原因	维修措施
01-10 17:10:00	01-10 17:30:00	01-10 19:25:00	115	边夹固定超时	边夹气缸 NG	更换气缸
01-10 15:34:00	01-10 15:35:00	01-10 16:10:00	35	边夹固定超时	固定边翻夹上齿轮定位销断裂	更换定位销
01-09 15:34:00	01-09 15:35:00	01-09 15:55:00	20	工作台下降震动大	下减震器 NG	更换备品
01-07 23:10:00	01-07 23:13:00	01-07 23:40:00	27	基板传输超时	Sensor NG	更换 Sensor
01-07 23:10:00	01-07 23:12:00	01-07 23:38:00	26	基板传输超时	Sensor NG	更换 Sensor
01-05 14:40:00	01-05 14:42:00	01-05 15:02:00	20	工作台制动器上升超时	相机 stop 气缸 NG	更换备品
01-05 02:39:00	01-05 02:40:00	01-05 03:25:00	45	印刷偏移	钢网外扩	调整 X、Y 轴偏移量
01-04 23:39:00	01-04 23:40:00	01-05 01:40:00	120	边夹固定超时	边夹动作阻力大	清洁边夹, 调整固定螺丝松紧
01-04 16:04:00	01-04 16:14:00	01-04 16:58:00	44	工作台下降震动大	下减震器 NG	更换备品
01-04 09:00:00	01-04 09:01:00	01-04 09:16:00	15	开启真空吸附后真空比例阀漏气	真空比例阀破损	更换备品
01-03 05:07:00	01-03 05:08:00	01-03 07:07:00	119	工作台下降震动大	下减震器 NG	更换备品
01-03 02:24:00	01-03 02:25:00	01-03 03:32:00	67	工作台下降震动大	下减震器 NG	更换备品

致锡膏拉尖或者少锡。脱模速度过慢则影响 PCB 锡膏印刷的效率。

- (2) 清洁频率：对钢网的清洁频率，通常设定为每印刷若干块 PCB 后对钢网进行清洁。清洁频率过低可能会导致钢网网孔堵塞，进而造成少锡缺陷。但是如果清洁频率过高，首先会造成锡膏印刷效率降低，减少单位时间内印刷 PCB 的数量，其次清洁剂可能会导致锡膏的成分变化。

表 2.2 锡膏印刷参数

属性名	中文释义
Separate_Speed	脱模速度
X_Offset	X 方向偏移补偿
Clean_Frequency	清洁频率
Y_Offset	Y 方向偏移补偿
Separate_Distance	脱模距离
Theta_Offset	刮刀角度
Table_Height	印刷间距
SPEED	刮刀速度
Print_Distance	印刷距离
Pressure	刮刀压力

- (3) 脱模距离: 是指可调中央平台回到原位前以一定速度安全脱离钢网的距离。锡膏印刷后 PCB 需要小心的与钢网分离, 以保证锡膏能完整的从网孔中分离。当可调中央平台下降至脱模距离后, 再以较高的速度回到原位。脱模距离过大会导致单位时间内印刷的 PCB 数量下降, 脱模距离过小则可能导致锡膏印刷出现残次品。
- (4) 印刷间距: PCB 与钢网之间的距离。印刷间距直接影响锡膏体积, 过大的印刷间距会导致锡膏体积过大, 可能会造成连锡, 塌陷等缺陷, 过小的印刷间距则会导致锡膏体积过小, 可能会造成少锡, 漏印等缺陷。
- (5) 印刷距离: 锡膏印刷时刮刀在钢网上的行进距离。印刷距离过大会导致单位时间内印刷的 PCB 数量下降, 甚至造成刮刀行进距离超限。印刷距离过小可能无法完全覆盖钢网网孔, 造成漏印。
- (6) X 方向偏移补偿: 补偿 PCB 的 X 方向偏移。该值需要精准设置, 过大过小都会导致锡膏在 X 方向偏移超出阈值。
- (7) Y 方向偏移补偿: 补偿 PCB 的 Y 方向偏移。该值同样需要精准设置, 过大过小都会导致锡膏在 Y 方向偏移超出阈值。
- (8) 刮刀角度: 锡膏印刷时刮刀在行进方向与钢网的夹角。刮刀角度大于 80 度会导致锡膏只能滑动前进, 此时向下的分力几乎为零, 锡膏难以被压入钢网网孔。刮刀角度过小会导致向下的分力过大, 同时难以刮净钢网表面的锡膏。通常刮刀角度设定在 45 度至 60 度。
- (9) 刮刀速度: 锡膏印刷时刮刀在钢网上的行进速度。刮刀速度通常要结合刮刀压力、锡膏特性、钢网孔径等其他参数进行设置。刮刀速度影响锡膏的

沉积效率，同时也对钢网清洁频率有着重要影响。

- (10) 刮刀压力：锡膏印刷时刮刀对钢网的向下压力。刮刀压力过大可能会造成钢网变形，甚至损坏。刮刀压力过小可能会造成漏印。

### 2.1.3 锡膏印刷步骤

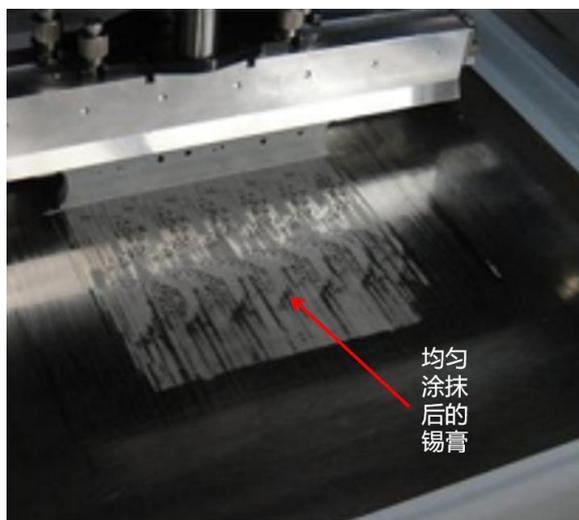


图 2.4 锡膏印刷案例

锡膏印刷如图 2.4 所示，图中展示了锡膏印刷机中均匀涂抹的锡膏，其主要步骤如下。

- (1) PCB 通过输送带传送至锡膏印刷机的可调中央平台。PCB 的位置通过识别 PCB 上的标记点来确定。
- (2) 中央平台向上移动，直到 PCB 紧挨在钢网下方。
- (3) 刮刀在钢网上推动锡膏滚动。锡膏通过钢网上的网孔沉积在 PCB 对应的焊盘上。
- (4) 印刷完成后，可调中央平台向下移动，PCB 与钢网分离。
- (5) 印刷完成后的 PCB 通过输送带传送至下一工序。
- (6) 每印刷一定数量的 PCB 需要对钢网进行清洁以防止网孔堵塞，比如往钢网喷洒清洁剂，然后用纸擦拭干净。

从上述可以看出，锡膏印刷中比较关键的原材料有锡膏和钢网。锡膏起到固定元件以及提供电气通路的作用。钢网则确保锡膏沉积到 PCB 上的指定位置。下面分别介绍。

锡膏通常是一种膏状混合物，起到固定元件以及提供电气通路的作用。锡膏的主要成分包括焊料粉末、助焊剂等。从质量角度，焊料粉末的质量约占锡膏的 90%，从体积角度，焊料粉末的体积约占锡膏的 50%。锡膏最重要的两个理化性质是粘度和熔点。锡膏的粘度则与锡膏印刷的质量密切相关。在印刷时受到刮刀的推力，其粘度下降，当到达钢网的网孔时，粘度达到最低，因此顺利通

过网孔沉积到 PCB 对应的焊盘上。当外力消失，锡膏的粘度又迅速的回升，因此印刷后的锡膏不会出现塌落。

熔点与回流焊环节密切相关，回流焊环节中通过加热将膏状锡膏融化，然后冷却凝固成固体，就形成日常中 PCB 上银色的圆润的锡膏点。低温锡膏的熔点在  $138^{\circ}\text{C}$ ，高温锡膏的熔点在  $217^{\circ}\text{C}$ ，两者的焊料粉末成分存在差异，高温锡膏的焊料粉末主要是锡、银、铜，低温锡膏的焊料粉末主要是锡-铋合金。高温锡膏焊接坚硬牢固；低温锡膏则焊接比较脆，易脱离，但是一些元器件无法承受高温，因此低温锡膏也有其使用场景。由于目前很多是双面 PCB，需要对 PCB 的两个面都进行锡膏印刷，每印刷一面后都要进行回流焊。需要注意的是在第一面的锡膏经过回流焊环节的融化凝固后，锡膏的熔点会上升，从而避免在第二面的锡膏进行回流焊环节时第一面已经凝固的锡膏再次融化，以高温锡膏为例，大概熔点上升约  $10^{\circ}\text{C}$ 。熔点上升的一部分原因是在第一次融化时锡膏中助焊剂加热挥发。

钢网如图 2.5 所示<sup>[134]</sup>，其上有很多网孔，网孔按照一定标准分布。锡膏印刷时要将锡膏放置在钢网上方，PCB 则会放置钢网下方，接着利用刮刀将锡膏均匀涂抹在钢网上方，锡膏受到挤压后沿着网孔沉积在 PCB 的焊盘。钢网由一片轻薄钢片制成，其尺寸要符合锡膏印刷机的要求，通常固定不变。对于钢网制版的方式可分电铸法、化学蚀刻法、激光切割法、混合法。化学蚀刻法首先在不锈钢片上涂抗蚀保护剂，然后用销钉定位感光工具将 PCB 焊盘的形状曝光在不锈钢片两面，接着利用腐蚀性化学溶液将开孔位置的不锈钢腐蚀，从而得到与 PCB 焊盘一一对应的开孔。化学蚀刻法具有加工速度快，一次成型，价格便宜等优点。同时也存在污染严重、化学蚀刻精度不够导致没有完全蚀刻或者蚀刻过度等缺点，因此化学蚀刻法不适合加工细间距钢网。激光切割法则是利用激光在不锈钢片上切割出 PCB 焊盘的形状，切割过程中会产生一些金属熔渣。激光切割法的特点是切割精度高，价格适中，但缺点是相较于化学蚀刻法可同时加工多个钢网，激光切割法需要逐个切割，加工较慢。电铸法工艺非常复杂，利用电镀工艺在预处理的心轴周围生成指定厚度的镍片。电铸钢网的特点是加工精度极高，适合加工超细间距模板，但是工艺复杂，难以控制，加工周期比较长。混合法则是联合化学蚀刻法和激光切割法。

如图 2.6 所示<sup>[134]</sup>，钢网网孔的形状主要有正方形、矩形、圆形、长椭圆形、菱形等形状。钢网网孔的尺寸和形状也会影响锡膏的沉积效率，通常要求网孔面积与网孔侧壁面积的比值大于 0.66，网孔宽度和钢网厚度的比值大于 1.5。

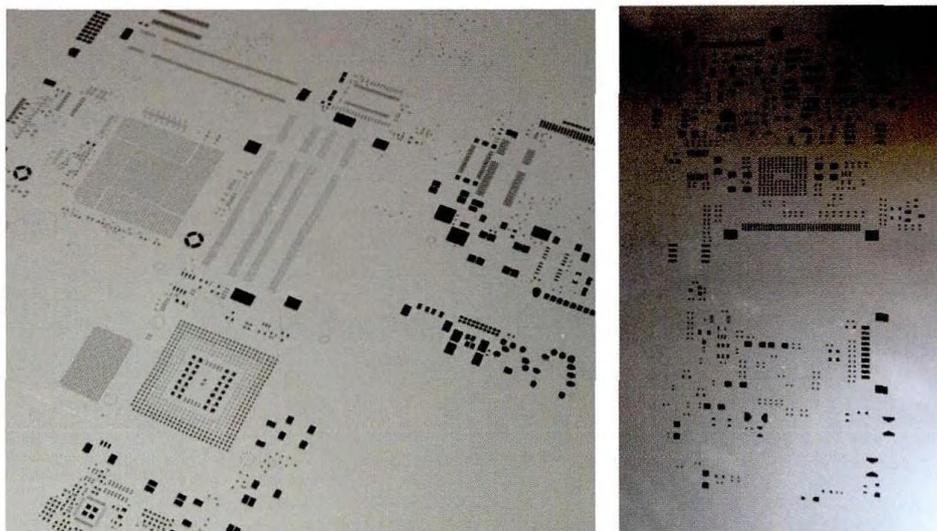


图 2.5 钢网实物图

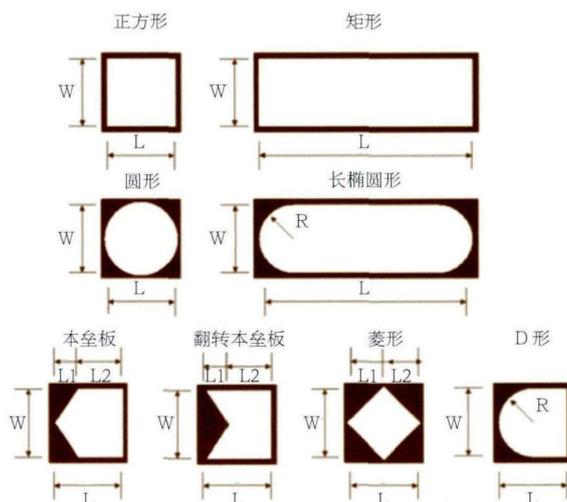


图 2.6 钢网网孔形状

### 2.1.4 锡膏印刷检查

在锡膏印刷完成后，需要进行锡膏检查 (Solder Paste Inspection, SPI)。表 2.3 和表 2.4 共同展示了锡膏检查的内容以及真实数据。首先可以看出，锡膏检查是对每个焊盘都进行检查，只有每个焊盘上的锡膏都符合标准，该块 PCB 才能认为是合格品。其次不同焊盘上锡膏体积差别较大，比如表 2.4 中 PAD ID 为 7 的锡膏体积与 PAD ID 为 19 的锡膏体积存在数量级上的差异，但是与锡膏体积标准值的比值则差别不大，这是因为焊盘的尺寸对锡膏体积有着重要影响，不同焊盘的尺寸存在差异。因此为了方便检查锡膏印刷质量，通常采用与标准值的比作为评价指标，只有该评价指标符合生产标准，该焊盘的检查结果才为合格。

锡膏印刷的常见缺陷有少锡、拉尖、偏移、漏印、凹陷、连锡、塌陷等。图

表 2.3 锡膏检查数据

属性	含义
Height (um)	锡膏高度
Area (um <sup>2</sup> )	锡膏面积
Volume (um <sup>3</sup> )	锡膏体积
Volume (%)	锡膏真实体积与锡膏体积标准值的百分比
Area (%)	锡膏真实面积与锡膏面积标准值的百分比
OffsetX (mm)	锡膏沿 X 方向偏移值
OffsetY (mm)	锡膏沿 Y 方向偏移值
OffsetX (%)	锡膏沿 X 方向偏移值与焊盘 X 方向长度的比值
OffsetY (%)	锡膏沿 X 方向偏移值与焊盘 Y 方向长度的比值
Barcode	PCB 的编号
Component ID	元件的编号
PAD ID	焊盘的编号

2.7 展示了合格的锡膏印刷成品<sup>[18]</sup>。下面对各种锡膏印刷缺陷进行介绍，展示了部分缺陷的示意图，以及分析造成缺陷的原因。

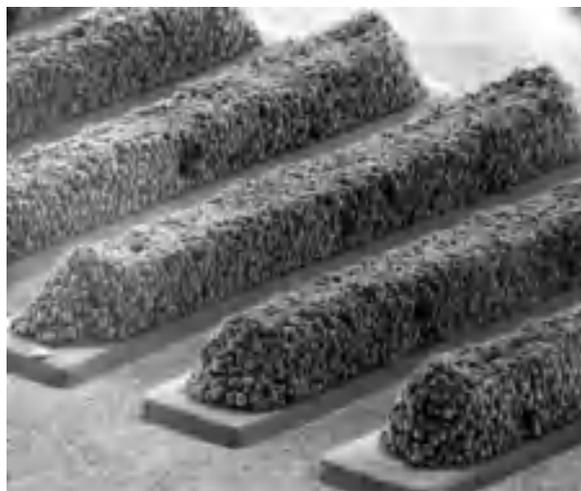


图 2.7 合格的锡膏印刷成品

- (1) 少锡：锡膏高度、体积和面积小于合格品区间的下限。危害是可能导致电气连接断路。造成少锡的常见原因脱模速度、印刷间距，清洁频率等参数设置不合理，有钢网网孔堵塞、钢网网孔较小、锡膏粘度过高等。
- (2) 拉尖：如图 2.8(a) 所示<sup>[18]</sup>，锡膏表面不平整，中间尖峰似突出或者两边尖峰似突出。危害是可能导致虚焊。造成拉尖的常见原因有脱模速度过快、钢网孔壁有毛刺、锡膏过于黏稠、PCB 或者钢网存在形变不平整等。

表 2.4 SPI 表格数据

Barcode	Component ID	PAD ID	Height(um)	Area(um <sup>2</sup> )	Volume(um <sup>3</sup> )	Volume(%)	Area(%)	OffsetX(mm)	OffsetY(mm)	OffsetX(%)	OffsetY(%)
1690097500129	1:2C0303	1	109.076	297814	32484350	115.38	105.779	0.016	-0.017	2.836	-2.963
1690097500129	1:2C0303	2	111.079	300188	33344550	118.435	106.623	0.02	-0.015	3.583	-2.6
1690097500129	1:2C0306	3	117.963	3463006	408506600	123.898	105.031	0.014	-0.011	0.52	-0.828
1690097500129	1:2C0306	4	114.113	3446535	393295800	119.285	104.532	0.013	-0.015	0.463	-1.112
1690097500129	1:2C0503	5	100.443	105791	10625950	96.974	96.546	0.014	-0.028	3.992	-7.446
1690097500129	1:2C0503	6	110.892	109913	12188470	111.233	100.308	0.011	-0.018	3.272	-4.719
1690097500129	1:2C0512	7	100.825	97630	9843558	89.833	89.098	0.03	-0.026	8.078	-7.676
1690097500129	1:2C0512	8	110.074	99995	11006850	100.45	91.256	0.002	-0.024	0.553	-7.008
1690097500129	1:2C0514	9	109.756	100125	10989350	100.29	91.375	0.03	-0.027	7.96	-7.997
1690097500129	1:2C0514	10	127.632	105694	13489960	123.111	96.457	0.021	-0.023	5.754	-6.748
1690097500129	1:2C0515	11	108.289	103408	11198010	102.194	94.372	0.029	-0.022	7.741	-6.542
1690097500129	1:2C0515	12	120.28	108120	13004720	118.682	98.672	0.016	-0.029	4.419	-8.635
1690097500129	1:2C0516	13	101.903	102691	10464440	95.5	93.716	0.028	-0.019	7.431	-5.693
1690097500129	1:2C0516	14	109.85	102826	11295370	103.083	93.84	0.002	-0.015	0.496	-4.433
1690097500129	1:2C0601	15	113.951	292487	33329100	118.38	103.887	0.021	-0.035	3.779	-6.131
1690097500129	1:2C0601	16	114.215	284754	32523050	115.517	101.141	0.024	-0.038	4.279	-6.757
1690097500129	1:2C0602	17	107.317	103455	11102450	101.322	94.414	0.008	-0.037	2.197	-11.006
1690097500129	1:2C0602	18	104.085	103334	10755510	98.156	94.303	0.023	-0.039	6.154	-11.475
1690097500129	1:2C0605	19	125.835	2338426	294255000	134.284	106.715	0.014	-0.019	0.607	-1.846
1690097500129	1:2C0605	20	121.322	2314408	280788700	128.138	105.618	0.015	-0.026	0.644	-2.471
1690097500129	1:2C0607	21	108.913	102770	11193010	102.149	93.789	0.008	-0.039	2.066	-11.526
1690097500129	1:2C0607	22	109.422	102616	11228460	102.472	93.648	0.029	-0.037	7.893	-10.736
1690097500129	1:2D0301	23	124.02	1592844	197543700	134.64	108.564	0.009	-0.013	0.841	-0.786
1690097500129	1:2D0301	24	123.04	1565853	192662200	131.313	106.724	0.015	-0.02	1.422	-1.257

- (3) 偏移：如图 2.8(b) 所示<sup>[18]</sup>，锡膏与焊盘没有完全对齐。危害是可能导致电气连接断路。造成偏移的常见原因有标记点识别出错、PCB 坐标偏移、钢网松动、PCB 停板不稳定。
- (4) 漏印：焊盘上没有锡膏沉积。危害是可能导致电气连接断路。造成漏印的常见原因有钢网网孔过小、刮刀速度过快、锡膏过于黏稠、脱模速度过快等。
- (5) 凹陷：如图 2.8(c) 所示<sup>[18]</sup>，焊盘上的锡膏形状不清晰，中心下凹。危害是易出现虚焊，焊接强度不足。造成凹陷的常见原因有刮刀压力过大或者脱模速度过大、钢网网孔不洁。
- (6) 连锡：如图 2.8(d) 所示<sup>[18]</sup>，两个焊盘上的锡膏相连。危害是导致电气连接短路。造成连锡的原因有钢网过厚导致锡膏过多、钢网与 PCB 间隙过大、刮刀压力过小、锡膏粘度过低。
- (7) 塌陷：焊盘上的锡膏形状不稳定，流向焊盘两侧。危害是回流焊后极可能电气短路。造成塌陷的常见原因有刮刀压力过大、锡膏粘度过低、锡粉颗粒过小等。

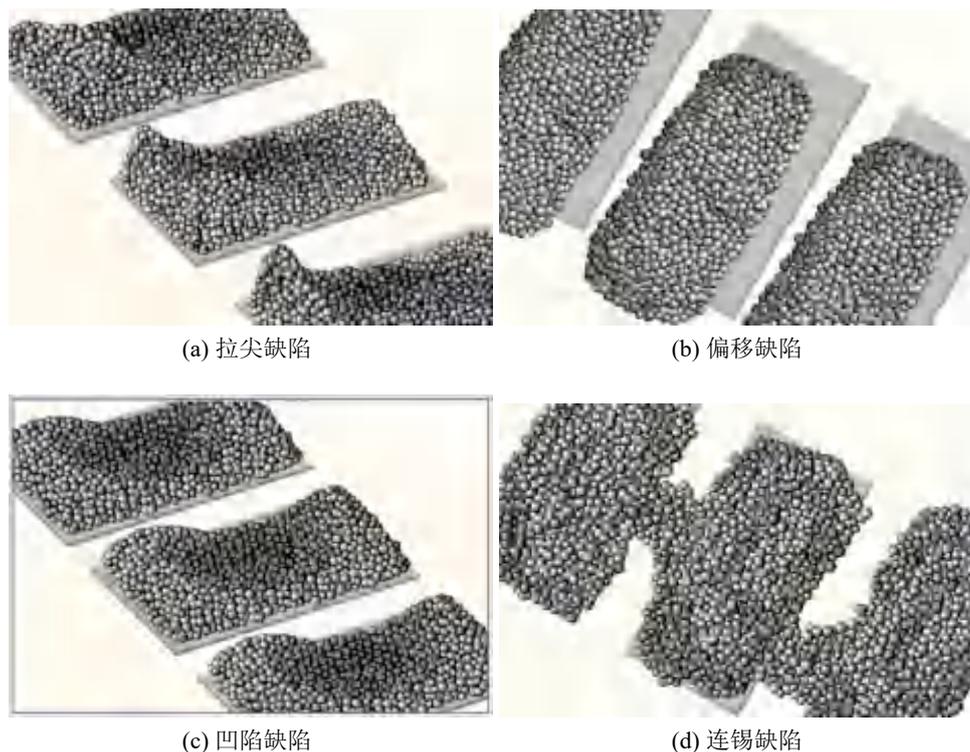


图 2.8 锡膏缺陷示意图

## 2.2 锡膏印刷异常预警工程应用现状

### 2.2.1 关键部件早期故障预警工程应用现状

在锡膏印刷行业中，锡膏印刷关键部件早期故障预警方法主要采用传统的超限法和专家经验法。超限法是指利用传感器对锡膏印刷中关键部件进行状态监测，然后设置故障阈值，当监测的状态超过故障阈值时，就进行故障预警。这种方法具有操作简单，成本低廉的优点，但同时也存在故障阈值设置十分依赖专家经验、由于工厂生产环境中干扰因素导致误报警较多等不足。专家经验法主要是指工程师依靠自身经验以及锡膏印刷残次品的类型，根据故障维护手册对锡膏印刷机进行逐步的故障分析，确定具体故障部件，然后进行早期故障预警。专家经验法具有可解释性强等优点，但是存在以下不足：

- (1) 早期故障预警较迟。工程师对锡膏印刷机进行早期故障预警通常发生在锡膏印刷机出现功能性故障后，此时已经导致 PCB 良率下降以及生产效率下降。
- (2) 耗时较长。锡膏印刷机出现故障时，由于锡膏印刷机是复杂设备，工程师通常难以快速判断故障位置，需要逐步排查。

为了实现在工程中能够快速准确的对锡膏印刷机进行早期故障预警，一些大型 SMT 工厂开发了一种基于人工智能的早期故障预警算法并进行试点应用<sup>[135]</sup>。首先采集大量的真实故障数据，然后利用 KNN 算法对关键部件进行早

期故障预警，从而取得了良好的效果。这种基于人工智能的早期故障预警算法具有故障预警性能优异的优点，但存在算法开发成本高，难以全面推广的不足。这是因为需要牺牲 PCB 生产良率和 SMT 生产效率，来获得足够的故障样本。

在其它行业中，关键部件早期故障预警也有非常广泛的应用。比如在煤炭行业中煤炭需要通过皮带输送机向外传送。皮带运输机的托辊会出现悬空、转动异响、卡死等故障，如不及时处理，可能会造成皮带机传输带断裂、物料堆积等停机事故。中国中煤开发了一种基于声纹识别的人工智能算法实现对托辊的故障预警，其将声纹传感器安装在皮带机下方钢板结构上，然后利用故障样本对人工智能算法进行监督式训练，最终实现 7\*24 小时远程实时故障预警<sup>[136]</sup>。华为开发了因联 iPHM 设备健康智能维护云平台，在水泥公司进行了应用，故障预警准确率超过 90%，非计划停机时间下降 40%，降低 5%-10%的设备总维护成本，并提升 10%-20%的设备正常运转时间<sup>[137]</sup>。

由于成本低，操作简单，目前关键部件早期故障预警在工程应用中主要采用以超限法和专家经验法为代表的传统方法，而以人工智能为代表的先进算法由于需要采集足够的故障样本、开发成本高，更多的是以试点的形式小范围内应用。因此开发一种无需故障样本，且能高效预警关键部件故障的算法是当下迫切的需求。

### 2.2.2 关键部件剩余使用寿命预测工程应用现状

在锡膏印刷行业中，目前采用对锡膏印刷机进行定期维护的策略，而不是预估剩余使用寿命。定期维护包括对设备整体进行清洁；钢网、刮刀等部件进行清洗和检查；对传动系统、可调中央平台等运动系统等运动部件进行清洁和润滑；对易损件根据维护手册进行更换等。

目前锡膏印刷行业暂时没有关键部件剩余使用寿命预测方面的应用，这是因为难以收集到带剩余使用寿命标签的退化数据，导致难以建立有效的剩余使用寿命预测模型。从锡膏印刷机 16 个月总故障时长 8868 分钟可以看出，当前的定期维护策略无法完全避免故障的发生，仍有大量的故障发生在维护的间歇时间。同时定期维护会造成过度维护，导致高昂的不必要的维护成本。因此锡膏印刷机关键部件剩余使用寿命预测对于提高维护效率、降低维护成本和停机时间仍然是非常必要的。

在其它行业中，比如某个汽车制造公司，他们对生产线上的机械设备采集振动、温度、压力等进行状态监测数据，然后利用人工智能开发剩余使用寿命预测模型，从而能够准确的提前预测机械设备故障<sup>[138]</sup>。容知日新对青岛特钢进行全面的产线监测，采集振动、温度、电机电流、电压等状态监测数据，可有效预测联轴器磨损、保持架断裂、轴承辊道剥落等故障。每年能够降低设备抢修费用

约 393.6 万元，减少因抢修而导致的产量、效益损失约 358.1 万元<sup>[139]</sup>。

综上所述，剩余使用寿命预测在锡膏印刷行业还处于起步阶段，但是在其它行业已经有了较多的应用，并成功节省了大量的企业维护成本，降低了企业效益损失。因此结合锡膏印刷行业难以获得带剩余使用寿命标签的退化数据的特点，开发一种仅需少量带剩余使用寿命标签的退化数据即可有效预测剩余使用寿命的算法是当下迫切的需求。

### 2.2.3 锡膏印刷参数不当预警工程应用现状

据工厂实地调研，出现锡膏印刷参数不当时，产品良率可能会下降至 70%，会产生高昂的返修成本，因此工厂对于锡膏印刷参数不当预警有强烈的现实需求。工厂希望能通过锡膏印刷参数不当预警-印刷参数优化这一思路来避免生产出锡膏印刷残次品<sup>[140-143]</sup>。锡膏印刷参数不当预警作为前沿研究，准确性距离大规模商用仍有一定距离。目前仅有一些大型 SMT 工厂进行试点应用。主要是根据锡膏印刷质量中的偏移属性预测未来每个焊盘的锡膏印刷偏移程度，当预测到偏移超限时就预警偏移补偿参数不当，从而及时的调用锡膏印刷参数调整模型，动态地调整锡膏印刷参数中 X 方向位置偏移补偿和 Y 方向位置偏移补偿，然后避免生产出锡膏印刷残次品。

相较于锡膏印刷参数不当预警，在工厂中更多的是利用 3 维锡膏检测仪对锡膏印刷产品进行异常检测，从而发现锡膏印刷参数不当，其技术更加成熟，检测性能十分优越。3 维锡膏检测仪采用激光三角测量或结构光投影技术，获取锡膏的三维形貌（高度、体积、平整度）。激光三角测量是利用激光线扫描锡膏表面，通过反射光角度计算高度数据。而结构光投影则是投射光栅图案，根据形变图像重建 3D 模型。目前 3 维锡膏检测仪的准确率高达 99%<sup>[144]</sup>。

综上所述，虽然锡膏印刷参数不当预警有着强烈的现实需求，受限于技术发展，目前仍没有规模化的工程应用。因此开发一种高性能的锡膏印刷参数不当预警算法是当下迫切的需求。

## 2.3 锡膏印刷异常预警工程应用前景

### 2.3.1 关键部件早期故障预警工程应用前景

关键部件早期故障预警具有很好的工程应用前景。对于锡膏印刷行业而言，目前锡膏印刷机故障时间占比 SMT 产线故障时间约 13%。锡膏印刷机故障每年产生大量的停机成本、返修成本。因此对于锡膏印刷机中关键部件进行早期故障预警，及时的发现关键部件早期故障，可以有效地降低停机成本、返修成本。对于其他行业而言，本文开发的关键部件早期故障预警算法具有一定的通用性，

可以供其他行业在开发关键部件早期故障预警算法时借鉴思路，减少算法开发成本，缩短算法开发周期。

### 2.3.2 关键部件剩余使用寿命预测工程应用前景

关键部件剩余使用寿命预测具有非常远大的工程应用前景。在锡膏印刷行业中，目前缺乏成熟的剩余使用寿命预测方案。在全球范围内，目前仍有 80% 以上的设备还没采用有效的剩余使用寿命预测方案。从已有的剩余使用寿命预测案例中可以看出，剩余使用寿命预测可以有效避免设备故障所造成的损失，还可以降低企业维护成本。因此剩余使用寿命预测具有极其广阔的市场。

### 2.3.3 锡膏印刷参数不当预警工程应用前景

据工厂实地调研，出现锡膏印刷参数不当时，产品良率可能会下降至 70%，持续时长约两到三小时。而高性能的锡膏印刷参数不当预警算法与锡膏印刷参数优化模型相结合，可以显著的提高锡膏印刷的产品良率，有效避免因锡膏印刷参数不当所导致的锡膏印刷异常。这可以极大的降低锡膏印刷的返修成本，显著提高工厂的市场竞争力。

## 2.4 本章小结

本章针对锡膏印刷异常预警，详细介绍了其工程背景、应用现状以及应用前景。首先为了清晰的呈现锡膏印刷异常预警的工程背景，本章详细介绍了锡膏印刷机的组成结构、锡膏印刷参数的类型、锡膏印刷的步骤以及锡膏印刷检查的具体内容，并列举了合作 SMT 工厂的故障记录以说明关键部件故障的危害。其次为了全面的介绍锡膏印刷异常预警的工程应用现状，围绕锡膏印刷异常预警的三个子任务分别介绍了关键部件早期故障预警、关键部件剩余使用寿命预测以及锡膏印刷参数不当预警的工程应用现状。可以看出当前关键部件早期故障预警和锡膏印刷参数不当预警都存在一些试点应用，尤其是关键部件早期故障预警在其他行业已有一些初步的商业化推广，而关键部件剩余使用寿命预测虽然在其它行业有了一些应用，但是在锡膏印刷行业仍然处于未探索的状态。最后详细介绍了锡膏印刷参数不当预警的工程应用前景，结合锡膏印刷参数不当预警的工程应用现状，可以看出锡膏印刷参数不当预警有着极大的潜在工程价值以及必要性。

## 第3章 基于多传感器双重对比的锡膏印刷关键部件早期故障预警算法

锡膏印刷机故障是引起锡膏印刷异常的两种主要因素之一。由于锡膏印刷机故障通常体现为关键部件故障，因此为了预警锡膏印刷机故障，本章研究仅利用大量健康状态下的传感器监测数据实现高性能的关键部件早期故障预警，旨在及时地发现关键部件早期故障。考虑到在工厂中健康状态下多传感器数据会被高噪声干扰，本章提出了一种基于多传感器双重对比的锡膏印刷关键部件早期故障预警算法，其核心是利用时频对比模块和相关性对比模块分别最小化健康状态下多传感器时频信息的差异和多传感器相关性的差异，从而能显著提高早期故障预警性能。然后，在实验设计部分，本章在公开的山东科技大学轴承数据集、MCC5-THU 齿轮数据集以及私有的锡膏印刷机减震器数据集上验证了所提算法的故障预警性能，分析了所提算法各个模块的有效性，分别探索了健康状态数据量和超参数对模型性能的影响。

本章结构安排如下：3.1 节分析了健康状态下多传感器数据中高噪声的影响；3.2 节介绍了本章提出的基于多传感器双重对比的锡膏印刷关键部件早期故障预警算法；3.3 节介绍了上述算法的实验结果与分析；最后 3.4 节总结本章内容。

### 3.1 健康状态下多传感器数据中高噪声影响分析

以锡膏印刷关键部件减震器为例，首先，图 3.1 显示了健康状态下多传感器高噪声中的多传感器相关性噪声。减震器的振动数据收集自锡膏印刷机生产过程。利用减震器的 X 和 Y 方向上的加速度样本计算 Pearson 相关性。绿色曲线表示不同方向之间加速度的相关性，蓝色曲线表示相关性的趋势。健康状态下的多传感器相关异常用红星标记。相关性趋势表明，健康状态下的相关性不同于故障状态下的相关性。然而，可以发现在健康状态下存在许多相关性异常值，这使得基于重构的早期故障预警方法难以准确刻画关键部件的健康模式。

其次，图 3.2 展示了不同状态间减震器 X 方向加速度时频矩阵的 KL 散度，可以发现两个健康状态下的时频矩阵 KL 散度约为 0.5，分布比较相似。这说明正常状态下，健康样本通常服从相似分布。但是部分健康样本由于电磁干扰、人类活动等影响包含了较大的噪声，从而导致这些样本的分布出现偏移，健康状态下的时频矩阵与健康状态下含有高噪声的时频矩阵的 KL 散度显著变大，说明其分布差异也在变大，这使得基于重构的早期故障预警方法难以从健康样本中

提取到与故障样本有区别的高质量表征。

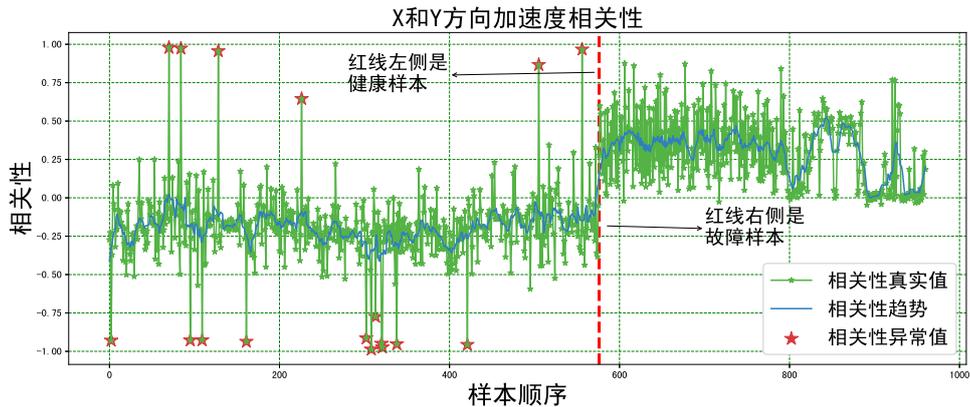


图 3.1 健康状态下多传感器相关性噪声

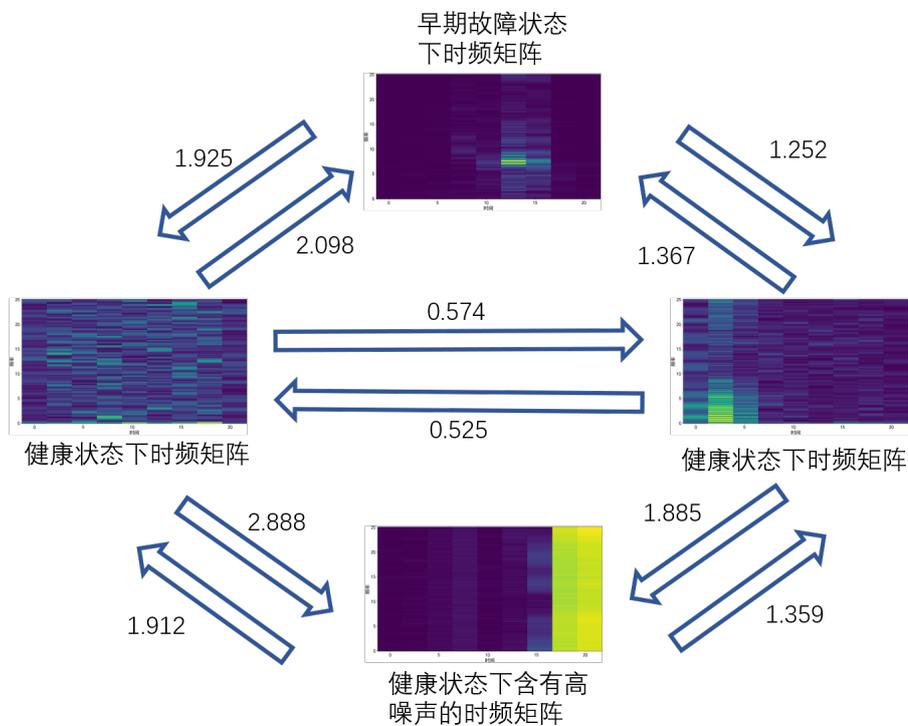


图 3.2 不同状态间减震器 X 方向加速度时频矩阵的 KL 散度

### 3.2 算法设计

在锡膏印刷场景中，由于锡膏印刷设备关键部件长期处于健康运行状态，工厂通常会积累大量的健康状态多传感器监测数据。尽管存在一定程度的工况差异，但同类型关键部件在相同运行状态下仍表现出相对一致的性能退化特征。基于此，通过深入分析这些多传感器监测数据，可以提取该类型关键部件的普适性退化规律，从而实现有效的早期故障预警。本章研究任务是针对特定类型关键部件的早期故障预警问题，首先，基于多个同类型关键部件在健康状态下的大

量多传感器数据，构建早期故障预警模型；其次，基于目标关键部件从历史至当前一段时间内的多传感器数据，利用所构建的早期故障预警模型实现其早期故障状态的识别。

所构建的早期故障预警模型图 3.3 所示，其大致可分为三个步骤，即数据预处理、时频对比和相关性对比。数据预处理旨在将多传感器数据从时域转换到时频域，以便在后续步骤中准确识别故障。时频对比通过 KL 散度最小化健康状态下多传感器时频特征的差异来挖掘健康状态下的通用时频表示。相关性对比通过 KL 散度最小化健康状态下多传感器相关性的差异，以挖掘健康状态下的通用相关性表示。

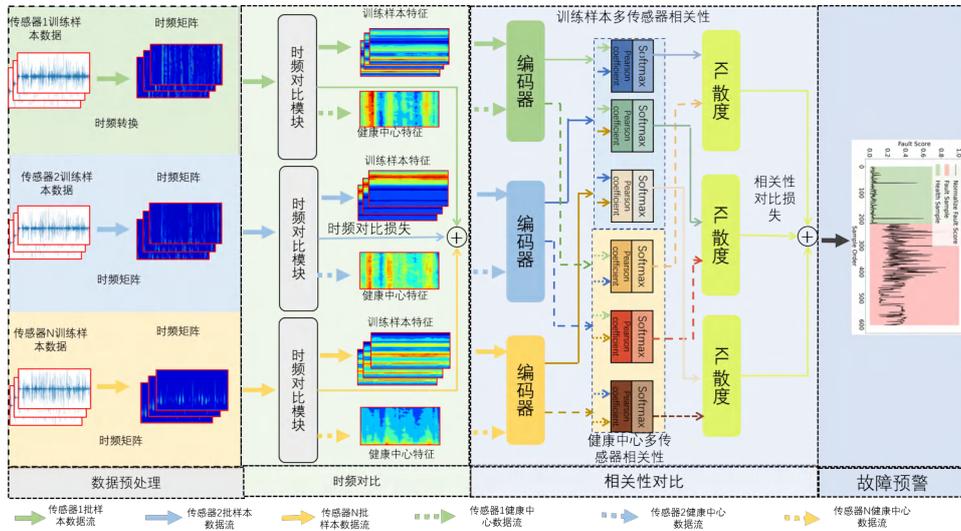


图 3.3 基于多传感器双重对比的锡膏印刷关键部件早期故障预警算法框图

### 3.2.1 数据预处理

首先，利用短时傅里叶变换 (Short-Time Fourier Transform, STFT) 将训练样本从时域变换到时频域，从而揭示更多的故障指标。如公式 (3.1) 所示：

$$TF_i^j = \text{STFT}(x_i^j), \quad (3.1)$$

其中  $x_i^j$  表示第  $i$  个传感器数据经过滑动窗口后得到的第  $j$  个训练样本， $TF_i^j$  表示相应的时频矩阵。

以锡膏印刷关键部件减震器为例，图 3.4 展示了不同状态下去除传感器零漂后减震器 X、Y 和 Z 方向加速度的时频矩阵。可以看出，在健康状态下，减震器各方向加速度的频率分布较为分散。这是因为在 X 和 Y 方向减震器本身没有振动，监测的振动信号体现出随机性，因此频率分布比较分散。而 Z 方向存在径向往复运动，减震器在 Z 方向加速度也非恒定，具体与锡膏印刷工艺参数中脱模距离和脱模速度有关，结合振动信号随机性后呈现出如图 3.4(e) 所示的频率分

量主要集中在低频段，少部分在高频段的状态。出现故障后，X和Y方向加速度的时频矩阵与健康状态相比存在差异。首先是频率分量关于时间的分布存在明显的周期性，这是因为减震器在健康状态下只有垂直运动，而在出现故障后存在轻微摇晃，从而导致X和Y方向的频谱变化。其次频率分量的分布更为集中，这与故障后故障频率分量占比更高有关。

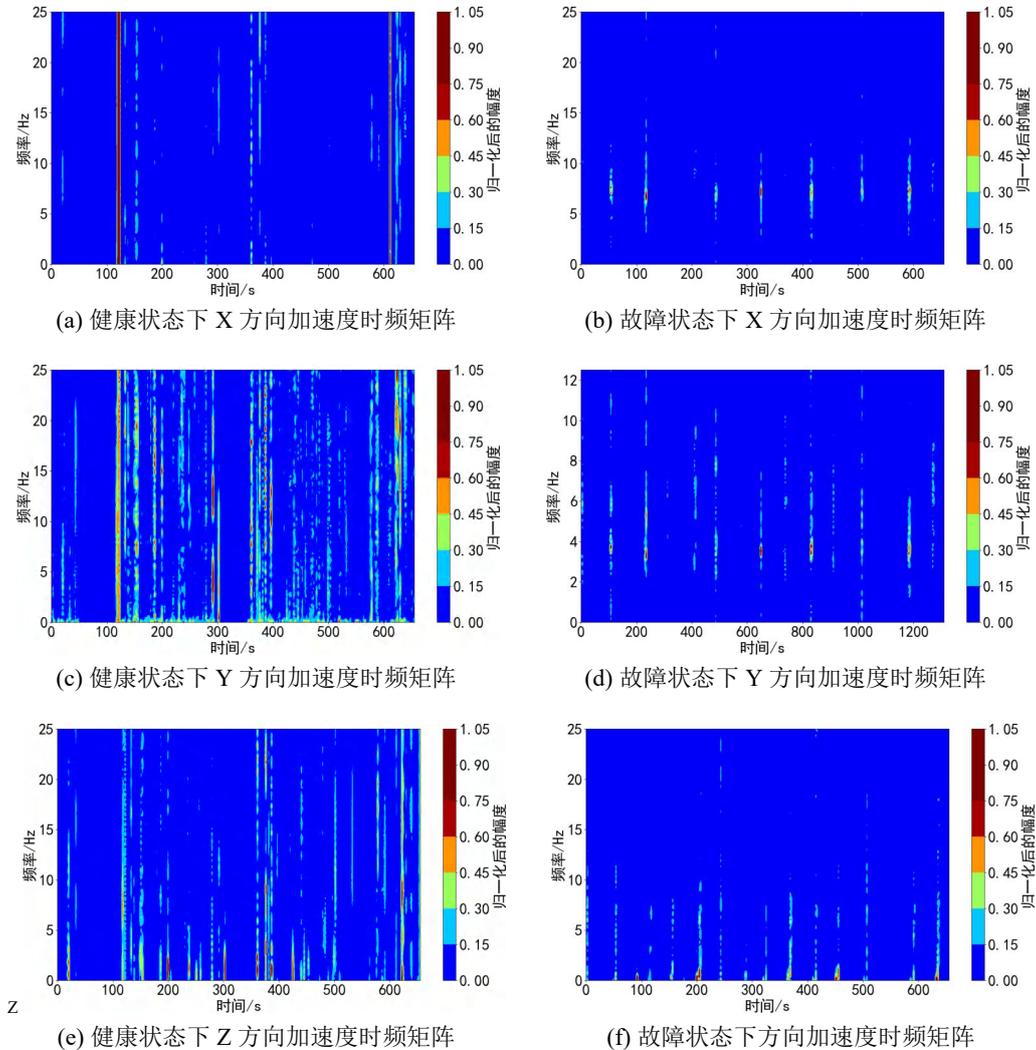


图 3.4 不同状态下减震器各个方向加速度的时频矩阵

### 3.2.2 KL 散度抑制噪声的分析

利用 KL 散度抑制噪声和挖掘健康状态通用表示的核心依据是 KL 散度能够量化不同状态下传感器数据的分布差异，差异越大则 KL 散度越大；差异越小则 KL 散度越小。首先，近期研究表明<sup>[145-146]</sup>，KL 散度可通过度量特征空间内变量分布的差异，然后通过优化损失函数从而对齐多个变量间的分布，从而挖掘变量间的通用表示。其次，在本研究中健康样本通常服从相似分布，但是健康样本被噪声污染后会出现分布偏移。而在特征空间中可以通过 KL 散度量健康样本间的分布差异，然后特征空间中健康样本的分布差异作为优化目标，通过梯

度下降的方式最小化特征空间中健康样本的分布差异，从而尽可能抑制噪声的影响，逼近健康样本的真实分布。基于上述操作，所有健康样本都将服从相似分布，从而实现挖掘健康状态通用表示。基于此，本章设计了如下的时频对比模块和相关性对比模块。

### 3.2.3 时频对比模块

在锡膏印刷关键部件退化过程中，多传感器时频会慢慢偏离健康中心。因此，本章设计了如图 3.5 所示的时频对比模块，对比健康中心和当前多传感器的时频特征，来判定关键部件的故障。

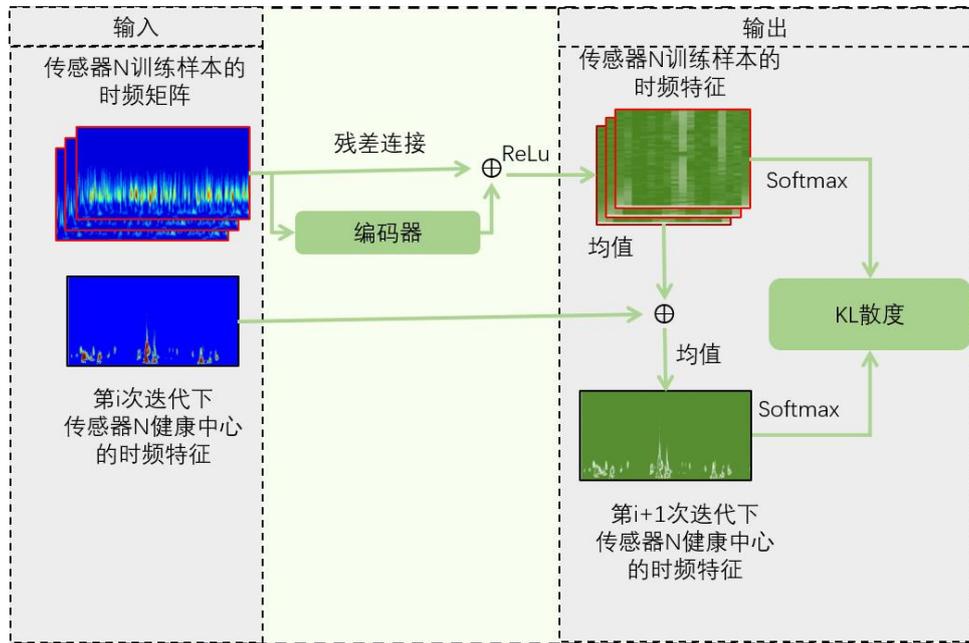


图 3.5 时频对比模块结构图

#### 3.2.3.1 健康中心构建

首先，如公式 (3.2) 所示，提取第  $j$  个训练样本  $TF_i^{j,f}$  的时频特征  $TF_i^j$ 。具体来说，为每个传感器建立一个编码器 Encoder，对第  $j$  个样本的时频矩阵进行编码。同时，为了减少时频信息的损失以及避免梯度的消失，采用残差结构进一步提高特征提取效果。

$$TF_i^{j,f} = \text{ReLu}(\text{Encoder}(TF_i^j) + TF_i^j), \quad (3.2)$$

其中 ReLu 是非线性激活函数。

编码器 Encoder 采用 Vision Transformer 架构<sup>[147]</sup>，如图 3.6 所示，主要分为以下三步。

- (1) 将输入的时频矩阵输入划分成若干个子区域，然后将每个子区域拉平成一维向量。将一维向量作为线性映射的输入以进行编码。

- (2) 将每个子区域的位置进行编码并与子区域的编码相融合。
- (3) 将上述融合结果作为 Transformer 的输入，从而实现时频矩阵的特征提取。

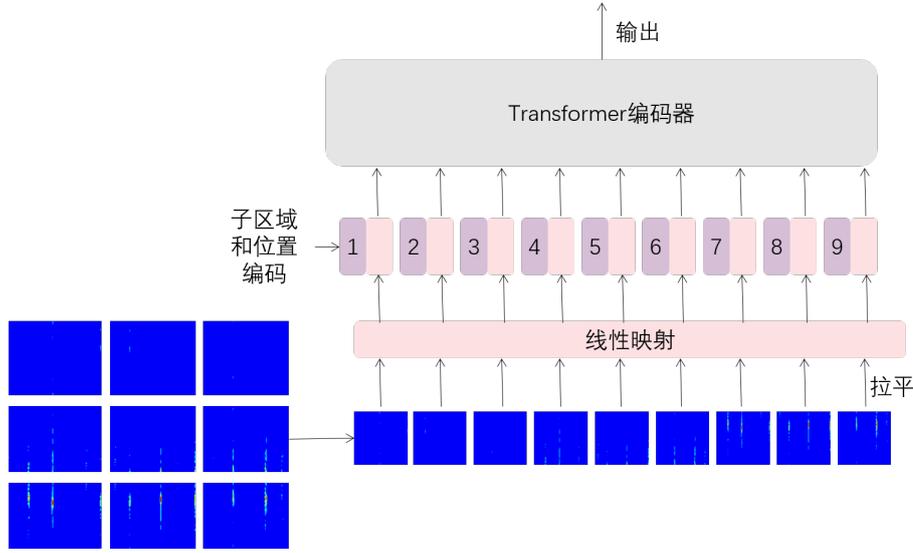


图 3.6 Vision Transformer 流程图

然后，如公式 (3.3) 所示，在训练阶段，针对每批次  $B$  个时频样本，计算第  $i$  个传感器的局部健康中心  $TF_i^{lc,f}$ ,

$$TF_i^{lc,f} = \frac{\sum_{j=1}^B (TF_i^{j,f})}{B}. \quad (3.3)$$

接下来，通过迭代不断逼近第  $i$  个传感器的全局健康中心  $TF_i^{c,f}$ ,

$$TF_{i \text{ iter}+1}^{c,f} = \frac{TF_{i \text{ iter}}^{c,f} + TF_i^{lc,f}}{2}, \quad (3.4)$$

其中  $\text{iter}$  为迭代次数， $\text{iter} = 0$  时， $TF_i^{c,f}$  为随机初始化。

请注意，上述操作仅在训练阶段执行，而在测试阶段，第  $i$  个传感器的全局健康中心是固定的。

### 3.2.3.2 时频对比

为了测量训练样本的特征和健康中心的特征之间的差异，采用 KL 散度作为度量。具体地，使用 Softmax 变换时频特征矩阵以获得特征概率分布。因为 KL 散度是不对称的，所以需要交叉计算。为了防止模型在训练过程中崩溃，引入了 Stop 机制，这意味着在计算 KL 散度时忽略该项的梯度。

通过以上操作，实现了测量健康中心和训练样本之间的差异。对所有训练样本进行迭代产生总差异度量，即时频对比损失  $\mathcal{L}_{cs}$ 。

$$\begin{aligned} \mathcal{L}_{cs} = & \sum_{i=1}^m \sum_{j=1}^B \frac{\text{KL}(\text{Stop}(\sigma(TF_i^{j,f})), \sigma(TF_i^{c,f}))}{Bm} \\ & + \sum_{i=1}^m \sum_{j=1}^B \frac{\text{KL}(\text{Stop}(\sigma(TF_i^{c,f})), \sigma(TF_i^{j,f}))}{Bm}, \end{aligned} \quad (3.5)$$

其中  $B$  为训练批次大小,  $m$  为传感器数量,  $\sigma$  为非线性激活函数 Softmax。

### 3.2.4 相关性对比模块

如公式 (3.6) 所示, 首先提取时频特征, 然后计算第  $i$  个传感器的健康中心特征  $\text{Encoder}(\text{TF}_i^{c,f})$  与第  $n$  个传感器的健康中心特征  $\text{Encoder}(\text{TF}_n^{c,f})$  之间的相关性  $P_{i,n}^c$ 。同样计算第  $i$  个传感器和第  $n$  个传感器的训练样本之间的特征相关性  $P_{i,n}^j$ 。

$$P_{i,n}^c = \text{Pearson}(\text{Encoder}(\text{TF}_i^{c,f}), \text{Encoder}(\text{TF}_n^{c,f})), \quad (3.6)$$

$$P_{i,n}^j = \text{Pearson}(\text{Encoder}(\text{TF}_i^{j,e}), \text{Encoder}(\text{TF}_n^{j,e})). \quad (3.7)$$

接下来, 测量健康中心的相关性  $P_{i,n}^c$  和训练样本的相关性  $P_{i,n}^j$  之间的差异, 即计算健康中心和训练样本的多传感器相关性之间的 KL 散度。对于  $m$  个传感器, 需要计算总共  $Bm(m-1)$  组 KL 散度, 虽然较为复杂, 但是关键部件的传感器数量通常不会太多, 因此仍是可接受的。

多传感器相关性对比损失  $\mathcal{L}_{cp}$  的形式化如下。

$$\begin{aligned} \mathcal{L}_{cp} &= \sum_{i=2}^m \sum_{n=1}^{i-1} \sum_{j=1}^B \frac{\text{KL}(\text{Stop}(\sigma(P_{i,n}^j)), \sigma(P_{i,n}^c))}{Bm(m-1)} \\ &+ \sum_{i=2}^m \sum_{n=1}^{i-1} \sum_{j=1}^B \frac{\text{KL}(\text{Stop}(\sigma(P_{i,n}^c)), \sigma(P_{i,n}^j))}{Bm(m-1)}, \end{aligned} \quad (3.8)$$

其中  $B$  为训练批次大小,  $m$  为传感器数量,  $\sigma$  为非线性激活函数 Softmax。

训练总损失如下所示:

$$\mathcal{L}_{total} = \alpha \mathcal{L}_{cs} + \beta \mathcal{L}_{cp} + \gamma \|\theta\|_2, \quad (3.9)$$

其中  $\alpha$ 、 $\beta$  和  $\gamma$  为超参数,  $\|\theta\|_2$  表示正则化损失。

### 3.2.5 故障预警标准

由于故障样本和健康中心存在较大差异, 因此, 最终的故障得分定义为

$$\text{FaultScore} = \alpha \mathcal{L}_{cs} + \beta \mathcal{L}_{cp}, \quad (3.10)$$

这是通过双重对比得到的故障得分, 故障样本的得分高于健康样本。设置故障阈值  $\delta$ , 当故障得分超过故障阈值时, 就可以判断关键部件出现故障。

$$\text{Result} = \begin{cases} \text{Health} & \text{FaultScore} < \delta \\ \text{Fault} & \text{FaultScore} \geq \delta. \end{cases} \quad (3.11)$$

基于多传感器双重对比的锡膏印刷关键部件早期故障预警算法的算法优化过程如算法 3.1 所示。

**算法 3.1 基于多传感器双重对比的锡膏印刷关键部件早期故障预警算法**


---

**Input:**  $C$  个传感器的无故障的历史时序数据  $x_1, x_2, \dots, x_C$ , 滑动窗口为  $W$ , 历史时序数据长度为  $T$ .

**Output:** 关键部件是否存在早期故障, 早期故障预警模型  $M$

```

/* 构建无故障标签数据集 */
1  $X \leftarrow \emptyset$ 
2 for  $t \in [0, 1, \dots, T - W]$  do
3   | 选择起始时刻为  $t$ , 长度为  $W$  的序列  $(x_1(t), x_2(t), \dots, x_C(t))$ 
4   |  $X \leftarrow X \cup (x_1(t), x_2(t), \dots, x_C(t))$ 
5 end
/* 数据处理 */
/*  $N$  为样本总数 */
6 for  $i \in [0, 1, \dots, N]$  do
7   | 选择数据集中第  $i$  个样本  $X^i$ 
8   | 根据公式 (3.1) 进行时频转换
9 end
10 while 网络收敛 do
11   | 根据公式 (3.2) 至公式 (3.4) 迭代获取  $C$  个传感器的健康中心
12   | 根据公式 (3.5) 计算时频对比损失
13   | 根据公式 (3.6) 至公式 (3.8) 计算相关性对比损失
14   | 联合公式 (3.5) 和公式 (3.8) 更新早期故障预警模型  $M$  的参数
15 end
/* 故障预警 */
16 根据公式 (3.10) 和公式 (3.11) 进行早期故障预警

```

---

### 3.3 实验结果和分析

#### 3.3.1 数据集和实验配置

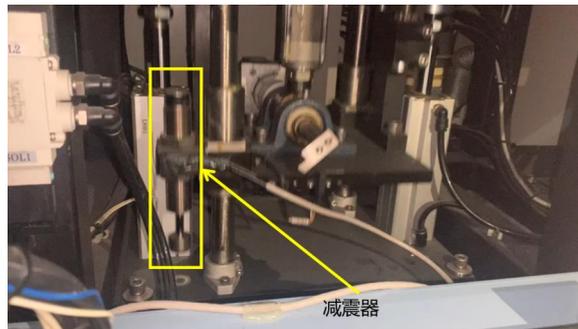
##### 3.3.1.1 数据集

由于商业机密保护及数据采集成本等因素的限制, 目前学术界和工业界均缺乏公开的锡膏印刷场景下关键部件状态监测数据集。尽管通过合作企业获取了部分关键部件的状态监测数据, 但在数据规模和多样性方面仍存在不足。基于此, 本研究选取恰当的通用场景下关键部件公开数据集, 再结合私有的锡膏印刷机减震器数据集, 通过系统化的对比实验设计, 对所提出算法的有效性进行多维度验证。

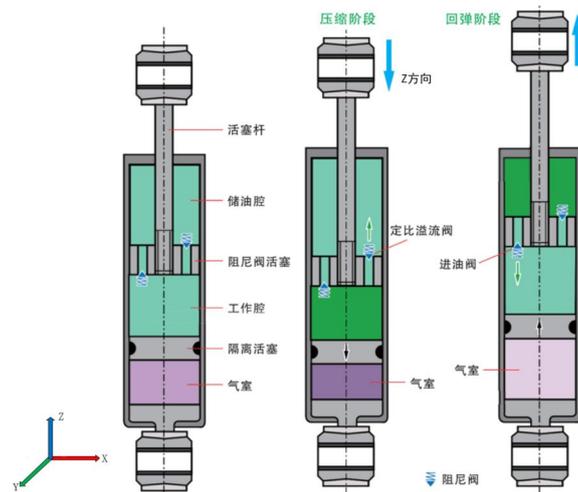
轴承和齿轮是锡膏印刷机中广泛存在的运动部件, 是传送系统、刮刀系统等运动系统故障的重要因素, 因此以轴承和齿轮为对象进行早期故障预警有着现实的工程需求和应用价值。由于目前缺乏可用的锡膏印刷机轴承和齿轮的状态监测数据, 因此本章选择恰当的公开的轴承和齿轮数据集进行算法验证, 具有一定的合理性。

## (1) 减震器数据集

减震器引起的故障约占锡膏印刷机总故障时间 14%，是常见的故障之一，因此以减震器为例研究关键部件早期故障预警。减震器数据集是从一家大型 SMT 生产线工厂中锡膏印刷机上实时采集的，具有较高的噪声。图 3.7(a) 展示了减震器在锡膏印刷机中的安装位置，减震器负责锡膏印刷机可调中央平台的升降。当 PCB 进入锡膏印刷机时，可调中央平台处于低处，然后可调中央平台升高至与钢网结合的适当高度，接下来开始印刷。图 3.7(b)<sup>[148]</sup> 展示了减震器的工作原理，即沿着垂直方向（Z 方向）做往复运动，而在水平面的两个正交方向（X 方向和 Y 方向）上，理想状态下不发生运动。减震器由加速度传感器监测 X、Y 和 Z 方向的加速度。数据收集时间约为两天，采样间隔约为 20ms。采样采用滑动窗口法，滑动步长为 2048，窗口大小为 2048。总共获得了 961 个样本，包括 385 个早期故障样本和 576 个健康样本。训练集包含 359 个健康样本，测试集包含 217 个健康样本和 385 个早期故障样本。



(a) 减震器在锡膏印刷机中的安装位置



(b) 减震器的机械结构

图 3.7 减震器位置及机械结构

图 3.8 和图 3.9 展示了不同状态下减震器监测属性的相关矩阵图。从图 3.8 首先可以看出各个方向加速度间相关性较弱。其次 X、Y、Z 三个方向的加速度处于一个固定的集中的位置，这意味着多传感器间的关联是固定的，即健康状态

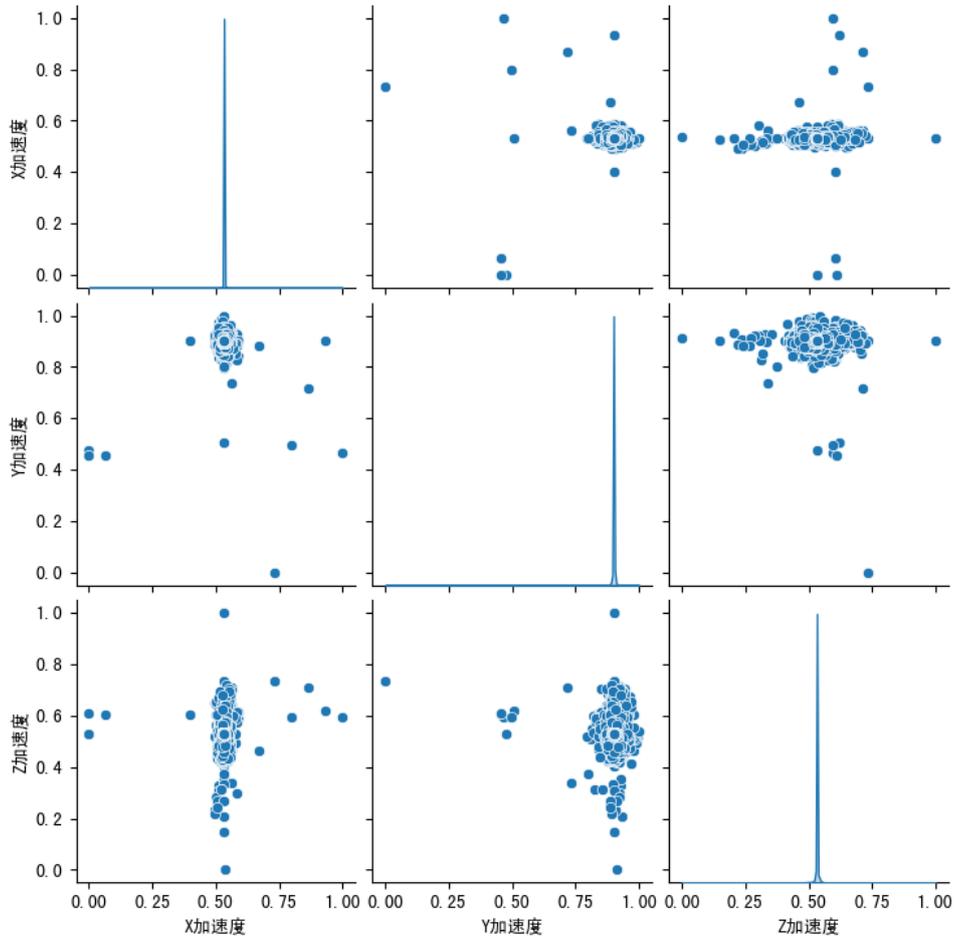


图 3.8 健康状态下减震器监测属性的相关矩阵图

下 Z 方向加速度较大，X 和 Y 方向加速度较小。然后可以发现 X-Y 方向加速度相关矩阵图要远比 X-Z 方向加速度相关矩阵图和 Y-Z 方向加速度相关矩阵图更加集中，这说明 Z 方向作为轴向，加速度是动态变化，而 X 和 Y 方向的加速度则比较固定。从图 3.9 首先可以看出 X-Y 方向加速度相比健康状态下更加具有相关性。这是因为减震器出现故障，当 Y 方向加速度变大时，X 方向加速度也会随之变大。其次健康状态下的监测属性相关矩阵图和故障状态下的监测属性相关矩阵图呈现出差异，这说明多传感器间的关联发生了变化，这也是可以实现无监督早期故障预警的基础。

#### (2) 山东科技大学轴承数据集<sup>[149-152]</sup>

目前公开的轴承故障数据集比较多，比如凯斯西储轴承数据集<sup>[153]</sup>、德国帕德博恩轴承数据集<sup>[154]</sup>、江南大学轴承数据集<sup>[155]</sup>以及山东科技大学轴承数据集等。最终选择以山东科技大学轴承数据集为例进行算法验证，原因如下：

- (1.) 工况：由于锡膏印刷机中轴承的位置不同以及锡膏印刷周期较长（15 至 20 秒），轴承的工况比较多且大多数情况下转速较低。据调研，目前江南大学轴承数据集、德国帕德博恩轴承数据集以及山东科技大学轴承数据集包含

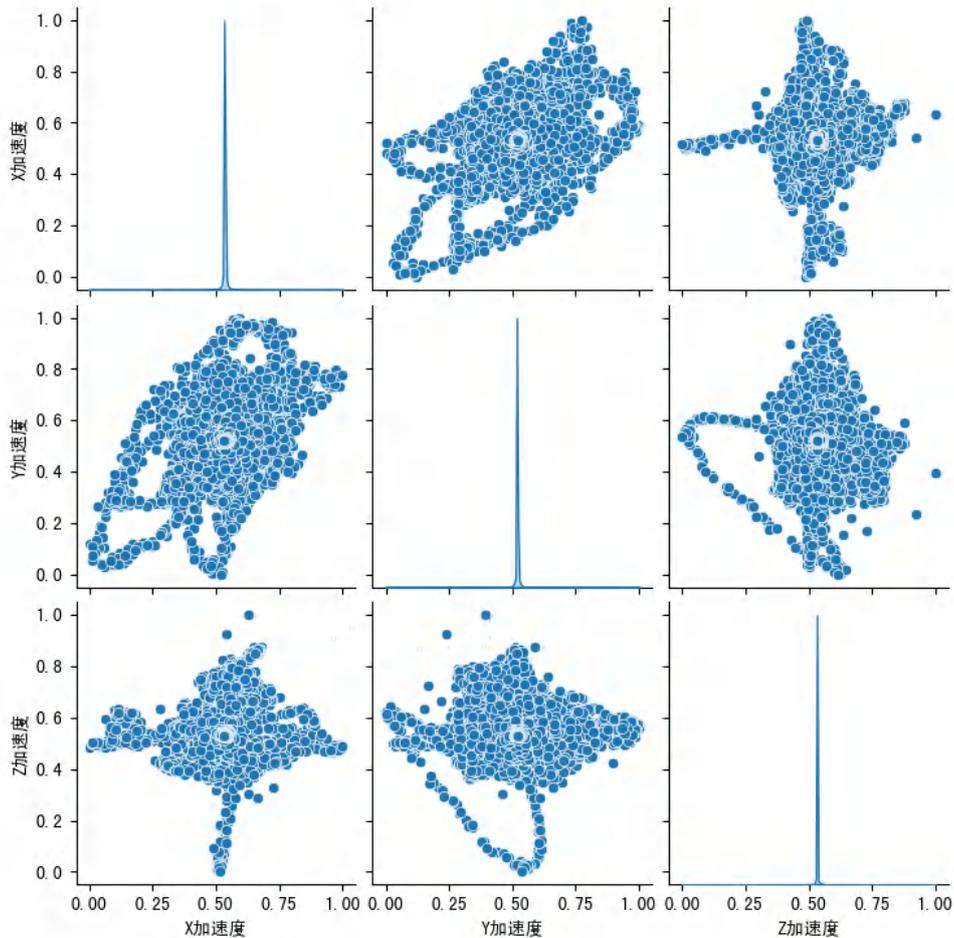


图 3.9 故障状态下减震器监测属性的相关矩阵图

转速相对较低情况下的轴承状态监测数据，相对接近锡膏印刷机中轴承的转速。而山东科技大学轴承数据集有 24 种恒定工况，江南大学轴承数据集有 3 种恒定工况，德国帕德博恩轴承数据集有 4 种恒定工况，从工况的数量而言山东科技大学轴承数据集具有显著优势。

- (2.) 故障类型：本章的目标是及时发现早期故障，因此需要尽可能包含不同位置以及不同尺寸故障的轴承数据集，这更有利于本章的研究。据调研，目前凯斯西储轴承数据集、德国帕德博恩轴承数据集以及山东科技大学轴承数据集比较符合条件。凯斯西储轴承数据集包含 3 种不同位置的故障，4 种故障尺寸；德国帕德博恩轴承数据集包含 3 种不同位置的故障，5 种故障尺寸；山东科技大学轴承数据集则包含 3 种不同位置的故障，3 种故障尺寸。
- (3.) 轴承规格：据调研，锡膏印刷机中部分轴承规格与山东科技大学轴承数据集所用轴承的规格比较接近。

综上所述，从轴承工况、规格以及故障类型的角度，分别比较了公开的轴承数据集与锡膏印刷机中轴承的相似性，山东科技大学轴承故障数据集是能找到

的最接近的数据集。因此能以山东科技大学发布的轴承故障数据集为例分析轴承早期故障表现，在大量的工况下对多种故障类型进行广泛的算法性能验证，以证明所提算法的有效性和泛化性。

山东科技大学轴承数据集有如表 3.1 所示的 24 种恒定工况。故障类型包括内圈故障，外圈故障，滚珠故障，每种故障包含 3 个不同尺寸，按照故障程度逐渐演变，分别是 0.2mm, 0.4mm, 0.6mm。两个三向压电加速度传感器安装在轴承座，每次采样时长 40s，采样频率为 25.6kHz。样本使用滑动窗口法生成，滑动步长为 2048，窗口大小为 2048。为了更全面的验证所提算法的泛化性能，在构建数据集时不仅仅囊括了转速相对较低情况下状态监测数据，还引入其他转速情况下状态监测数据。训练集包含健康状态下 24 种工况共 6144 个样本，每种工况 256 个样本。测试集包含另外的健康状态下 24 种工况共 6144 个样本，每种工况 256 个样本；24 种工况下 5400 个早期故障样本，每种工况下 3 个故障类型，每个故障类型有 75 个样本。

表 3.1 山东科技大学轴承数据集工况详情

转速 (rpm)	负载 (N)	转速 (rpm)	负载 (N)	转速 (rpm)	负载 (N)
1000	0	1500	0	1800	0
	20		20		20
	40		40		40
	60		60		60
2000	0	2500	0	3000	0
	20		20		20
	40		40		40
	60		60		60

图 3.10 和图 3.11 显示了轴承在健康状态和故障状态下各个方向加速度的时频矩阵。首先健康状态下，轴承 X 方向的加速度时频矩阵要比 Y 和 Z 方向的更加离散，这与监测的轴向振动有关，轴承主要是在垂直与水平两个方向上做规律振动，轴向振动比较轻微，因此 X 方向加速度的频率分量体现出更强的随机性，而 Y 和 Z 方向则相对集中。其次相较于健康状态，故障状态下轴承各个方向加速度的频率分量都明显更加集中。

### (3) MCC5-THU 齿轮数据集<sup>[156]</sup>

据调研，MCC5-THU 齿轮数据集是唯一包含不同故障程度，适用于早期故障预警的齿轮数据集。该数据集与锡膏印刷场景下的齿轮相似之处正在二者的转速均比较低，工况较为接近，因此退化模式较相似。该数据集的工况是动态变

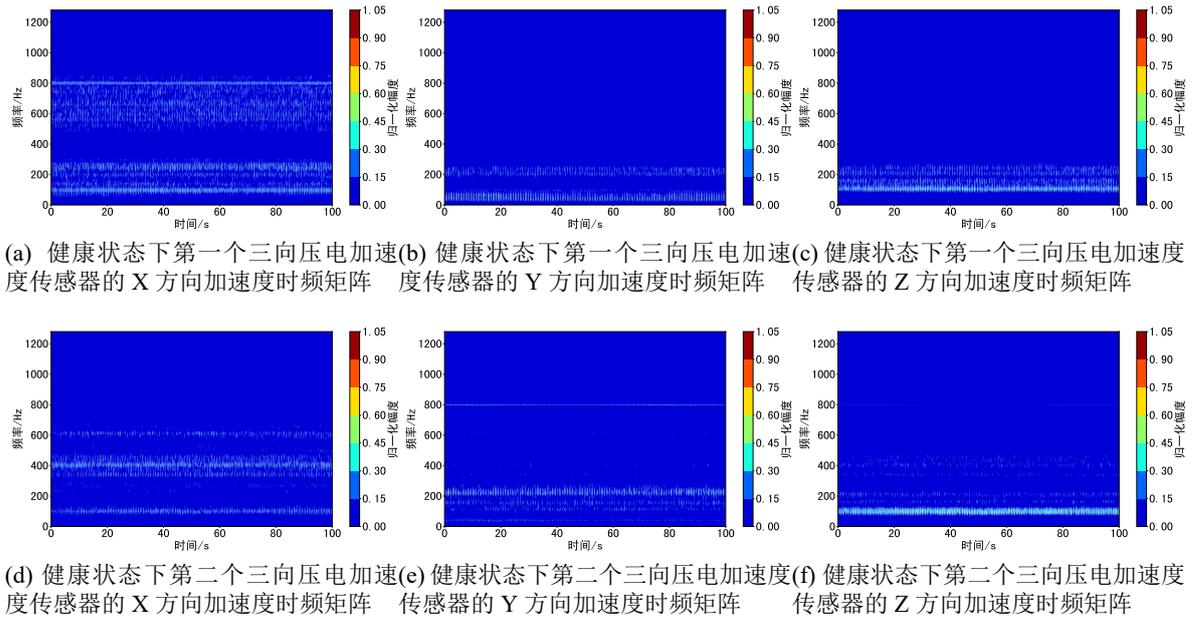


图 3.10 健康状态下轴承六个不同方向加速度的时频矩阵

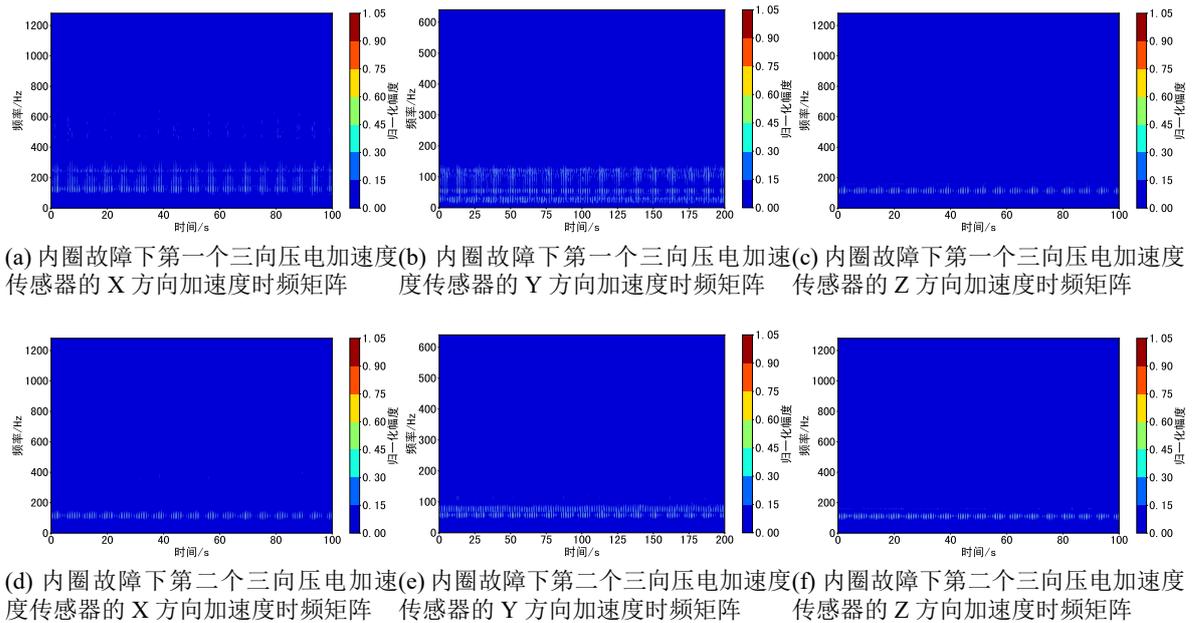


图 3.11 内圈故障下轴承六个不同方向加速度的时频矩阵

化的，更贴合工厂的真实场景。

该数据集包含齿轮磨损、齿轮点蚀、齿轮裂纹、断齿四种单一故障类型，包含轻微，中度，重度三种故障程度，六个振动加速度传感器，以及时变速度和时变负载两大工况类型。采样频率为 12.8kHz，采样时长为 60s。样本使用滑动窗口法生成，滑动步长为 2048，窗口大小为 2048。训练集包含健康状态下 2244 个样本。测试集包含另外的健康状态下 2244 个样本；早期故障状态下 864 个样本，每种单一故障类型有 216 个样本。

### 3.3.1.2 超参数设定

正则化系数  $\gamma$  为 0.001。批次大小为 128，学习率为 0.001。训练周期设置为 200。在减震器数据集中，损失函数  $\mathcal{L}_{cs}$  的系数  $\alpha$  为 1，损失函数  $\mathcal{L}_{cp}$  的系数  $\beta$  为 1。在山东科技大学轴承数据集中，损失函数  $\mathcal{L}_{cs}$  的系数  $\alpha$  为 1000，损失函数  $\mathcal{L}_{cp}$  的系数  $\beta$  为 1。在 MCC5-THU 数据集中，损失函数  $\mathcal{L}_{cs}$  的系数  $\alpha$  为 10，损失函数  $\mathcal{L}_{cp}$  的系数  $\beta$  为 10000。

### 3.3.1.3 实验指标

选择 F1 分数 (F1 Score)、准确率 (Accuracy)、召回率 (Recall) 和精准率 (Precision) 作为评价模型性能的指标。将早期故障样本视为正样本。为了计算 F1 分数，引入了真阳性 (TP)、真阴性 (TN)、假阳性 (FP) 和假阴性 (FN)。有关 TP、TN、FP 和 FN 的详细信息如下。

- (1) TP: 准确判别的早期故障样本数量。
- (2) TN: 准确判别的健康样本数量。
- (3) FP: 错误判别为早期故障的健康样本数量。
- (4) FN: 被错误判别为健康的早期故障样本数量。

召回率和精准率可通过公式 (3.12) 和公式 (3.13) 计算得出。F1 分数是召回率和精准率的组合。

$$\text{Recall} = \frac{\text{TP}}{\text{TP} + \text{FN}}, \quad (3.12)$$

$$\text{Precision} = \frac{\text{TP}}{\text{TP} + \text{FP}}, \quad (3.13)$$

$$\text{F1} = \frac{2 \cdot \text{Recall} \cdot \text{Precision}}{\text{Recall} + \text{Precision}}. \quad (3.14)$$

### 3.3.1.4 实验环境

本章所提出的模型在一台高性能 GPU 服务器上运行，并使用 Pytorch 框架搭建模型，具体的实验环境配置见表 3.2。

### 3.3.1.5 基线方法

为证明所提算法的有效性，从丰富对比方法类型的角度选择了 12 个方法进行比较。具体原因如下：

- (1) 基于重构的方法：基于重构的方法是当前最主流的早期故障预警方法。选择了 LSTM-VAE<sup>[157]</sup>、FGPAA<sup>[63]</sup>、TimesNet<sup>[158]</sup>、ATF-UAD<sup>[159]</sup>、TranAD<sup>[160]</sup>、MRRAE<sup>[62]</sup>、SAT<sup>[60]</sup> 作为对比方法。LSTM-VAE 采用最经典

表 3.2 实验环境

实验配置	版本型号
操作系统	Ubuntu 20.04.4 LTS
内存	32GiB
CPU 型号	Intel(R) Core(TM) i7-11700K @3.60GHz ×16
GPU 型号	GeForce GTX 3090Ti
GPU 数量	2
CUDA 版本	10.1.243
Pytorch 版本	2.5.1

的自编码器架构，被广泛采纳为对比方法。TimesNet 是性能优越的时序基础模型，也可以应用在早期故障预警领域。ATF-UAD 是联合时域和频域进行早期故障预警的前沿研究。TranAD、MRRAE、SAT 是时域内进行重构的前沿研究。

- (2) 其他类型的方法：选择了 IF<sup>[161]</sup>、OCSVM<sup>[162]</sup>、MOCN<sup>[163]</sup>、GDN<sup>[164]</sup>、和 CPC<sup>[165]</sup>。IF 是最经典的基于密度的故障预警算法，被广泛采纳为对比方法。OCSVM 和 MOCN 都是基于边界的方法，OCSVM 是其中最经典的代表，MOCN 与其思想相似但是具有更强大的特征提取能力。GDN 是基于预测的方法，着重考虑了不同传感器之间的关联性，很适合本章的多传感器场景。CPC 则是首个基于对比的方法。

以下是对比方法的具体介绍。

- (1) **OCSVM<sup>[162]</sup>**: SVM 的一个分类变体，使用超平面来区分健康和早期故障样本。由于传感器采样频率较高，难以将一段时间内全部的传感器数据直接用于 OCSVM 的训练，因此训练时只输入一段时间内传感器数据的均值和方差。采用 RBF 核函数。
- (2) **IF<sup>[161]</sup>**: 一种基于集合分区的无监督早期故障预警算法，用于隔离数据集中的异常点，而不是分析正常点。
- (3) **LSTM-VAE<sup>[157]</sup>**: 基于 LSTM 的变分自动编码器，重建健康数据的预期分布。
- (4) **FGPAA<sup>[63]</sup>**: 一种基于故障注意力的生成概率对抗自动编码器算法，能自动发现嵌入在高维数据空间中的低维流形。利用自编码器降低特征提取中的数据信息丢失。然后，利用低维特征的分布概率和重建误差构建故障注意力异常状态指示器。
- (5) **MOCN<sup>[163]</sup>**: 多尺度单类分类网络，只依赖于健康状态下的传感器数据。

该模型由多尺度特征表示学习模块和单分类器训练模块组成。多尺度特征表示学习模块从原始振动信号中提取部件的状态特征，然后单分类器训练模块将所有的健康状态下的部件状态特征包裹在一个最小半径的超球体内。

- (6) **TimesNet**<sup>[158]</sup>: 通过频率分解解耦时间序列的周期性，将一维时间序列数据扩展到二维空间，然后建模复杂的时间变化模式，从而实现早期故障预警。
- (7) **MRRAE**<sup>[62]</sup>: 利用 1D-CNN 构造编码器和解码器，然后利用内存模块提取稀疏近似表示，最后用自回归估计器重建信号输入。
- (8) **SAT**<sup>[60]</sup>: 一种基于异常 Transformer 的无监督早期故障预警方法。该方法将振动数据输入卷积神经网络进行编码，然后由 Transformer 进行解码重建。
- (9) **GDN**<sup>[164]</sup>: 图偏差网络，利用图卷积建立多传感器相关性模型，可用于多传感器早期故障预警。
- (10) **TranAD**<sup>[160]</sup>: 基于深度 Transformer 网络的异常预警模型，利用基于注意力的序列编码器，可以快速执行异常预警，并为数据中更广泛的时间趋势建模。
- (11) **ATF-UAD**<sup>[159]</sup>: 用于时间异常预警的对抗时频重构网络，包括一个时间重构器、一个频率重构器和一个双视角对抗学习机制。时间重构器利用注意力机制和图卷积网络将特征关系密切的点结合在一起。频率重构器提取频率之间的关系来重构异常频段。双视角对抗学习机制旨在最大限度地提高重建序列中的正常值，突出异常点并帮助其在数据中定位。
- (12) **CPC**<sup>[165]</sup>: 一种基于对比学习的无监督早期故障预警方法，利用对比学习区分数据样本和其增强样本，从而实现从振动信号中挖掘健康状态数据的内在表征，然后利用单分类器进行早期故障预警。

### 3.3.2 实验结果和分析

#### 3.3.2.1 对比结果分析

所提算法和基线方法在真实减震器数据集的实验结果见表 3.3。最优结果用黑体标出。所提算法在减震器数据集上的准确率为 0.992，F1 分数为 0.994，召回率为 0.997，精准率为 0.990。基线模型在减震器数据集上的最高准确率为 0.942 (ATF-UAD)，最高 F1 分数为 0.957 (ATF-UAD)，召回率为 1.000 (TranAD, ATF-UAD)，精准率为 1.000 (SAT)。在真实的减震器数据集上，与最佳的基线结果相比，所提算法在准确率、F1 分数上都有显著提高，准确率提高了 0.050，F1 分数提高了 0.037。虽然所提算法的召回率和精准率没有达到最佳的 1.000，但它的召回率和精准率是次优的，达到了 0.997 和 0.990。综上所述所提算法超越了基

于重构的主流方法、基于密度的方法、基于边界的方法、基于预测的方法以及基于对比的方法，具体原因分析如下。首先，以 LSTM-VAE 这个典型的基于重构的方法为例，其重构时会先建模健康样本的分布，再从中采样作为解码器的输入。而建模健康样本的分布时会忠实的保留噪声的影响，因此面对被高噪声污染的减震器数据时性能不佳。这也是基于重构的方法所面临的共性问题，在重建时可能会重建噪声，从而降低了早期故障预警性能。这说明了所提算法抑制噪声的必要性。其中值得注意的是 TimesNet 这种先进的时序模型将根据频率分布划分振动数据，而在面对不同方向加速度的频率分布不同时，按照相同的频率分布划分多传感器数据会破坏振动数据的演变模式，从而降低了早期故障预警的性能。与 TimesNet 相比，所提算法的优势在与着重考虑了不同方向加速度间的关联，利用编码器分别提取不同方向的加速度特征，然后利用所设计相关性对比模块挖掘不同方向加速度在健康状态下的关联性。OCSVM 和 IF 分别是基于边界和基于密度方法的典型代表，由于是传统的机器学习模型，特征提取能力相对较弱，因此性能较为保守。基于对比的 CPC 则试图在频域中利用对比挖掘健康状态下的频域通用表示，而所提算法则进一步的在多传感器相关性层面利用相关性对比模块挖掘健康状态下的多传感器相关性通用表示，从而提高早期故障预警性能。

表 3.3 减震器数据集上的实验对比结果

方法	Accuracy	F1 Score	Recall	Precision
OCSVM	0.720	0.820	0.997	0.696
IF	0.560	0.713	0.855	0.612
LSTM-VAE	0.555	0.509	0.361	0.860
FGPAA	0.797	0.843	0.859	0.828
MOCN	0.762	0.803	0.756	0.856
TimesNet	0.782	0.851	0.974	0.756
MRRAE	0.593	0.563	0.410	0.898
SAT	0.809	0.824	0.701	<b>1.000</b>
GDN	0.917	0.939	0.997	0.887
TranAD	0.929	0.947	<b>1.000</b>	0.900
ATF-UAD	0.942	0.957	<b>1.000</b>	0.917
CPC	0.914	0.935	0.971	0.901
所提算法	<b>0.992</b>	<b>0.994</b>	0.997	0.990

所提算法和基线方法在山东科技大学轴承数据集的实验结果见表 3.4。在

山东科技大学轴承数据集上, 所提算法的准确率为 0.978, F1 分数为 0.976, 召回率为 0.970, 精准率为 0.982。基线模型在山东科技大学轴承数据集上的最高准确率为 0.946 (CPC), 最高 F1 分数为 0.940 (CPC), 召回率为 1.000 (OCSVM, FGPA, GDN, TranAD), 精准率为 0.987(TimesNet)。在山东科技大学轴承数据集上, 与最佳的基线结果相比, 所提算法在准确率、F1 分数上都有提高, 准确率提高了 0.032, F1 分数提高了 0.036。虽然所提算法的召回率和精准率并不是特别优异, 一方面所提算法的召回率和精准率是次优的, 另一方面召回率需要和精准率综合考虑。因为只需要将所有样本都判断为故障样本就可以使召回率达到 1.000, 即发现了所有的故障样本, 如 OCSVM 的召回率达到 1.000, 但是精准率只有 0.487, 几乎将所有样本都判断为故障, 准确率只有 0.487。与之相反, 只需要识别出最有可能故障的样本, 那么精准率也可以达到 1.000。因此所提算法的召回率和精准率均保持在较高的水平, 综合来看所提算法的性能是最优的。下面将详细分析基线方法和所提算法的性能表现。首先, 仍以典型的基于重构的方法 LSTM-VAE 为例, 该模型在山东科技大学轴承数据集上的早期故障预警性能显著优于减震器数据集。这种性能差异主要源于山东科技大学轴承数据集相对减震器数据集包含的噪声较少, LSTM-VAE 在建模健康样本的分布时受到噪声的影响会变弱。这证明了噪声对模型性能有显著的影响以及所提算法抑制噪声的必要性。其次, 相较于减震器数据集上的表现, 除了 LSTM-VAE、TimesNet、MRRAE 和 SAT 之外, 其余方法都出现一定程度的性能下降, CPC 则几乎持平, 这主要源于山东科技大学轴承数据集具有大量的工况, 极大增加了早期故障预警的难度。最后, 虽然 CPC 在减震器数据集和山东科技大学轴承数据集均取得了较为优异的性能, 但仍然整体上略逊于所提算法, 这主要源于所提算法在 CPC 的基础上进一步挖掘健康状态下多传感器的关联, 构建了相关性通用表示。

所提算法和基线方法在 MCC5-THU 齿轮数据集的实验结果见表 3.5。在 MCC5-THU 齿轮数据集上, 所提算法的准确率为 0.875, F1 分数为 0.804, 召回率为 0.922, 精准率为 0.712。基线模型在 MCC5-THU 齿轮数据集上的最高准确率为 0.842 (CPC), 最高 F1 分数为 0.773 (CPC), 召回率为 1.000 (IF, FGPA, GDN), 精准率为 0.705(TranAD)。在 MCC5-THU 齿轮数据集上, 与最佳的基线结果相比, 所提算法在准确率、F1 分数、精准率上都有提高, 准确率提高了 0.033, F1 分数提高了 0.032, 精准率提高了 0.007。相较于前两个数据集, 在 MCC5-THU 齿轮数据集上所有算法的性能普遍下降。这主要是因为 MCC5-THU 齿轮数据集是可变工况, 健康与故障状态多传感器数据的分布是动态变化的, 因此难以实现高性能的早期故障预警。

图 3.12 展示了经过 t-SNE 降维后, 所提算法在减震器数据集上特征空间中

表 3.4 山东科技大学轴承数据集上的实验对比结果

方法	Accuracy	F1 Score	Recall	Precision
OCSVM	0.487	0.655	<b>1.000</b>	0.487
IF	0.294	0.454	0.603	0.364
LSTM-VAE	0.808	0.769	0.657	0.929
FGPAA	0.487	0.655	<b>1.000</b>	0.487
MOCN	0.777	0.755	0.733	0.778
MRRAE	0.889	0.867	0.774	0.985
SAT	0.896	0.877	0.790	0.986
TimesNet	0.909	0.893	0.815	<b>0.987</b>
GDN	0.616	0.709	<b>1.000</b>	0.546
TranAD	0.916	0.917	<b>1.000</b>	0.847
ATF-UAD	0.826	0.776	0.646	0.974
CPC	0.946	0.940	0.904	0.980
所提算法	<b>0.978</b>	<b>0.976</b>	0.970	0.982

特征分布的可视化。所提算法的特征分布不仅呈现出清晰的健康和故障特征边界，而且呈现出明显的簇状。首先不同状态下减震器的特征在潜在空间中表现出了极佳的可分性，这表明所提算法对于判断减震器状态具有出色的性能。其次不同状态下的减震器特征呈现出近似圆形的良好簇状，表明所提算法能保证相同状态下减震器特征是相似的，证明了所提算法能够有效提取不同状态下减震器的固有特征。

图 3.13 展示了经过 t-SNE 降维后，所提算法在山东科技大学轴承数据集上特征空间中特征分布的可视化。首先，健康状态下的特征与故障状态下的特征表现出良好的可分离性，仅仅在中间偏上的区域存在少量重叠，这证明了所提算法出色的性能。其次，可以看出在山东科技大学轴承数据集上所提算法的特征分布没有减震器数据集上那么理想，这主要是由于轴承的工况有 24 种，故障的类型和尺寸则有 9 种，远比减震器的工况要多，因此没有呈现良好的簇状，但是不同工况内部仍然有一定的聚集性。这表明工况对于早期故障预警是有影响的。所提算法虽然难以提取到相同状态下不同工况的通用特征，但仍然能在整体上对故障与健康进行区分。

图 3.14 展示了所提算法和 CPC 在减震器测试样本上的故障分数。绿色区域为健康样本，红色区域为故障样本，黑色曲线为故障得分曲线。与 CPC 相比，整体上所提算法在健康状态下的故障分数更小更平滑，故障样本上的故障分数与

表 3.5 MCC5-THU 齿轮数据集上的实验对比结果

方法	Accuracy	F1 Score	Recall	Precision
OCSVM	0.154	0.153	0.274	0.106
IF	0.342	0.458	<b>1.000</b>	0.297
LSTM-VAE	0.279	0.435	0.999	0.278
FGPAA	0.482	0.518	<b>1.000</b>	0.349
MOCN	0.596	0.522	0.793	0.389
TimesNet	0.817	0.683	0.708	0.659
MRRAE	0.307	0.445	0.998	0.286
SAT	0.645	0.454	0.530	0.397
GDN	0.632	0.602	<b>1.000</b>	0.430
TranAD	0.838	0.712	0.720	0.705
ATF-UAD	0.849	0.746	0.794	0.703
CPC	0.842	0.773	0.966	0.644
所提算法	<b>0.875</b>	<b>0.804</b>	0.922	<b>0.712</b>

健康样本上的故障分数也存在显著差异。这表明，所提算法挖掘了健康状态下减震器的固有特性，对健康样本的判定更加稳定。

图 3.15 展示了所提算法和 CPC 在山东科技大学轴承数据集测试样本上的故障分数。首先可以看出对于不同的故障尺寸，所提算法都能较为准确的预警，即便是 0.2mm 这种较为微小的故障。这说明所提算法对于轴承这种关键部件能实现早期故障预警。其次可以看出故障分数存在显著的峰和谷，这是不同工况和不同故障尺寸综合导致的，这说明工况的差异会导致故障分数的变化。然后，所提算法在轴承健康状态下的故障分数要比 CPC 的故障分数更加平稳、更加低，这说明所提算法可以更加敏锐的捕获到轴承在健康状态下的通用表示。最后虽然故障状态下，CPC 的故障分数明显要高于本章所提算法，但是 CPC 在健康状态下的故障分数也要高于本章所提算法，因此事实上 CPC 的早期故障预警性能还是略逊于本章所提算法。

### 3.3.3 模型性能分析

#### 3.3.3.1 消融实验

为了分析模型中不同组件对故障预警性能的影响，五种消融变体模型被设计，具体如下：

- (1) **Variante- $N\mathcal{L}_{cs}$** : 为了分析时频对比损失对早期故障预警的影响，删除了训

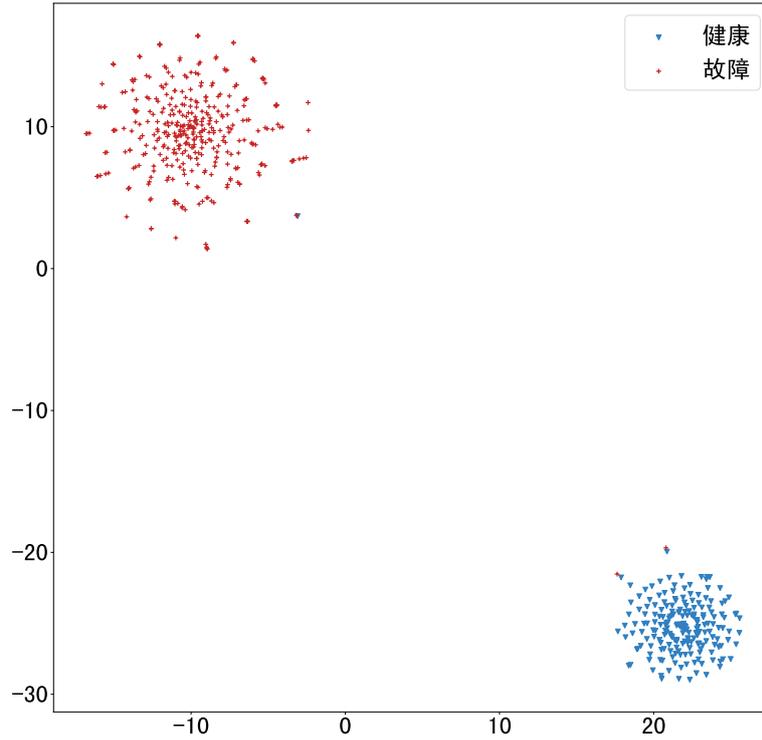


图 3.12 t-SNE 降维后，减震器测试集在特征空间中的特征分布可视化

训练损失  $\mathcal{L}_{cs}$  并保持其他部分不变。

- (2) **Variant-NCSC:** 为了分析时频对比模块对早期故障预警的影响，不仅删除了时频对比损失，还删除了整个时频对比模块。
- (3) **Variant- $N\mathcal{L}_{cp}$ :** 为了分析相关性对比损失对早期故障预警的影响，删除了训练损失  $\mathcal{L}_{cp}$  而保持其他部分不变。
- (4) **Variant-CP:** 为了验证相关性对比的有效性，根据公式 (3.15)、公式 (3.16) 和公式 (3.17) 修改了多传感器相关性对比模块。对比不同传感器的特征而非对比健康中心的多传感器相关性和样本的多传感器相关性，目的是提取多传感器间的共性特征，其余部分保持不变。
- (5) **Variant-RCenter:** 为了验证健康中心对早期故障预警的有效性，随机选择了一个健康样本作为健康中心，其他部分保持不变。

$$f_i^{j,e} = \text{Encoder}(\text{TF}_i^{j,e}), \quad (3.15)$$

$$f_n^{j,e} = \text{Encoder}(\text{TF}_n^{j,e}), \quad (3.16)$$

$$\begin{aligned} \bar{\mathcal{L}}_{cp} &= \sum_{i=2}^m \sum_{n=1}^{i-1} \sum_{j=1}^B \frac{\text{KL}(\text{Stop}(\sigma(f_i^{j,e})), \sigma(f_n^{j,e}))}{Bm(m-1)} \\ &+ \sum_{i=2}^m \sum_{n=1}^{i-1} \sum_{j=1}^B \frac{\text{KL}(\text{Stop}(\sigma(f_n^{j,e})), \sigma(f_i^{j,e}))}{Bm(m-1)}. \end{aligned} \quad (3.17)$$

表 3.6、表 3.7 和表 3.8 显示了所提算法在减震器数据集、山东科技大学轴承数据集、MCC5-THU 齿轮数据集上与五个消融变体模型之间的比较结果。所提算法框架取得了最佳性能，可见，所提算法的架构是最合理的。删除时频对比损

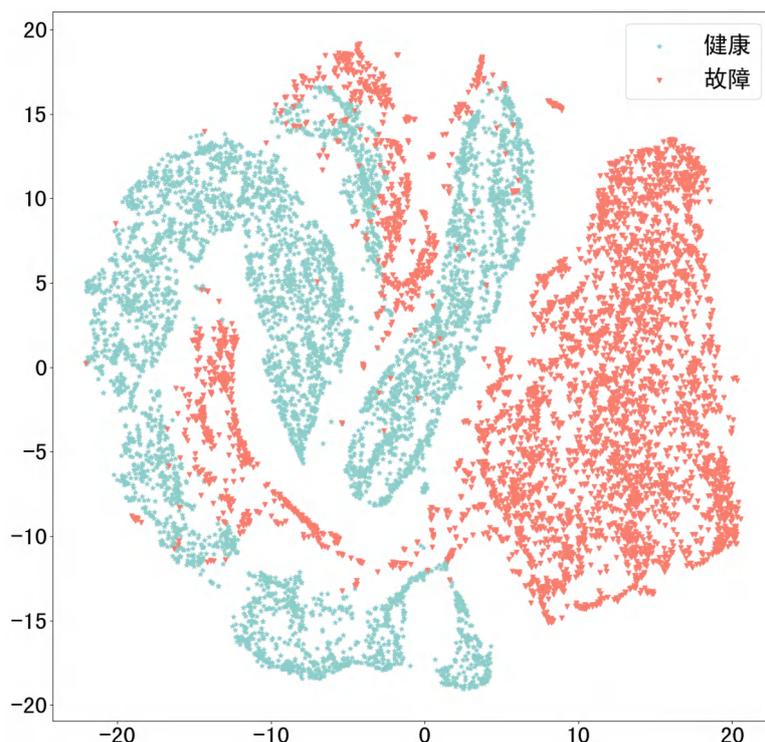


图 3.13 t-SNE 处理后，轴承测试集在特征空间中的特征分布可视化

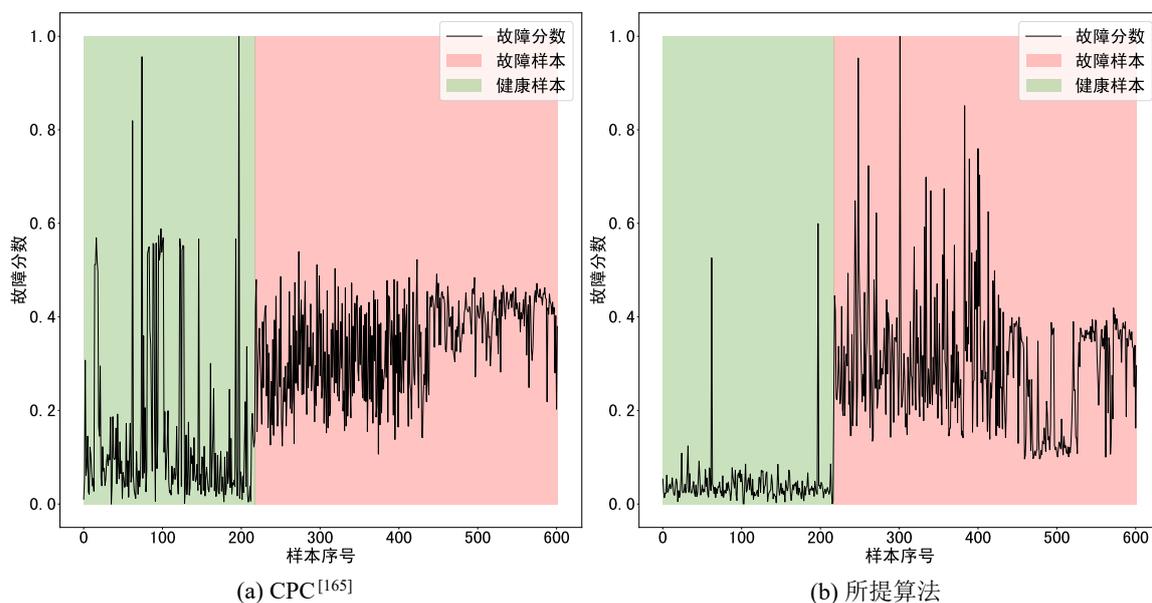


图 3.14 减震器数据集上不同模型的故障分数分布

失后， $\text{Variant-}N\mathcal{L}_{CS}$  在减震器数据集上相比所提算法在准确率下降了 0.040，F1 分数下降了 0.030，精准率下降了 0.058；在山东科技大学轴承数据集中准确率下降了 0.070，F1 分数下降了 0.07，召回率下降了 0.070，精准率下降了 0.080；在 MCC5-THU 齿轮数据集中准确率下降了 0.002，F1 分数下降了 0.002，精准率下降了 0.004。这证明了时频对比损失在所提算法的框架中扮演着重要的角色，其可以有效抑制时频噪声，从而提高关键部件早期故障预警性能。删除相关性对

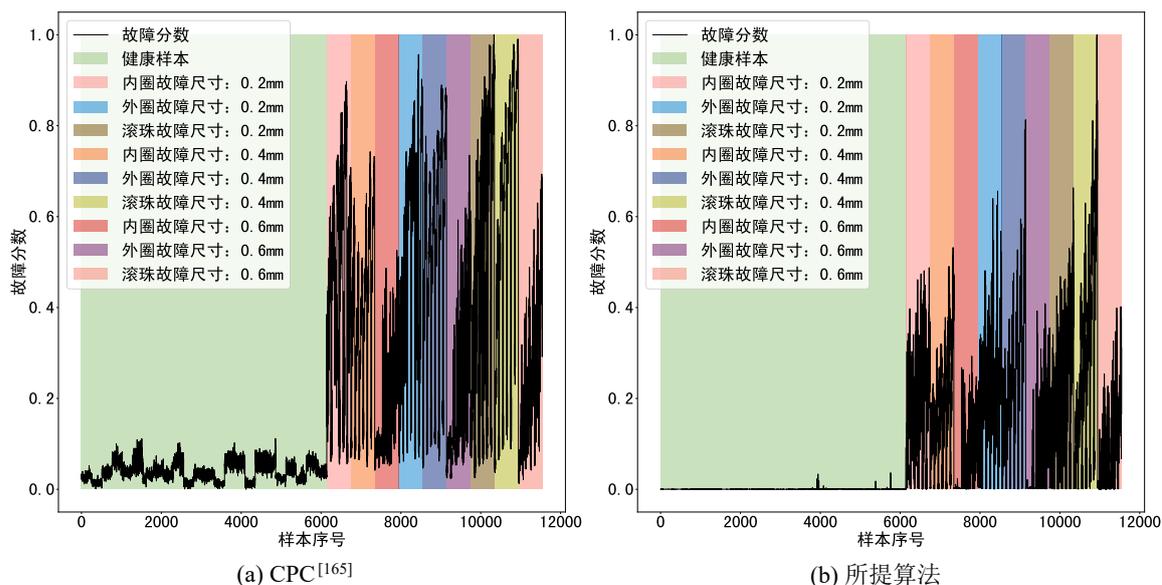


图 3.15 山东科技大学轴承数据集上不同模型的故障分数分布

表 3.6 减震器数据集上的消融实验结果

方法	Accuracy	F1 Score	Recall	Precision
Variant- $N\mathcal{L}_{cs}$	0.952	0.964	0.997	0.932
Variant-NCSC	0.640	0.780	0.997	0.640
Variant- $N\mathcal{L}_{cp}$	0.691	0.804	0.992	0.676
Variant-CP	0.829	0.882	0.997	0.790
Variant-RCenter	0.922	0.942	0.992	0.897
所提算法	<b>0.992</b>	<b>0.994</b>	<b>0.997</b>	<b>0.990</b>

比损失后, Variant- $N\mathcal{L}_{cp}$  在减震器数据集上相比所提算法在准确率下降了 0.301, F1 分数下降了 0.190, 精准率下降了 0.314; 在山东科技大学轴承数据集中准确率下降了 0.084, F1 分数下降了 0.095, 召回率下降了 0.129, 精准率下降了 0.057; 在 MCC5-THU 齿轮数据集中准确率下降了 0.107, F1 分数下降了 0.290, 召回率下降了 0.480, 精准率下降了 0.097。这证明了相关性对比损失在所提算法的框架中同样扮演着重要的角色, 其可以有效抑制相关性噪声, 从而提高关键部件早期故障预警性能。除此之外可以发现, 删除相关性对比损失要比删除时频对比损失造成的后果更为严重, 这说明相关性对比损失在所提算法框架中扮演着更加重要的角色。

Variant-NCSC 是所有变体中最差的, 在减震器数据集上相比所提算法在准确率下降了 0.352, F1 分数下降了 0.214, 精准率下降了 0.350; 在轴承数据集中准确率下降了 0.422, F1 分数下降了 0.322, 召回率下降了 0.072, 精准率下降了

表 3.7 山东科技大学轴承数据集上的消融实验结果

方法	Accuracy	F1 Score	Recall	Precision
Variant- $N\mathcal{L}_{cs}$	0.971	0.969	0.963	0.974
Variant-NCSC	0.556	0.654	0.898	0.515
Variant- $N\mathcal{L}_{cp}$	0.894	0.881	0.841	0.925
Variant-CP	0.893	0.875	0.800	0.966
Variant-RCenter	0.930	0.926	0.933	0.919
所提算法	<b>0.978</b>	<b>0.976</b>	<b>0.970</b>	<b>0.982</b>

表 3.8 MCC5-THU 齿轮数据集上的消融实验结果

方法	Accuracy	F1 Score	Recall	Precision
Variant- $N\mathcal{L}_{cs}$	0.873	0.802	0.925	0.708
Variant-NCSC	0.400	0.472	<b>0.964</b>	0.312
Variant- $N\mathcal{L}_{cp}$	0.768	0.514	0.442	0.615
Variant-CP	0.730	0.605	0.742	0.510
Variant-RCenter	0.783	0.659	0.751	0.586
所提算法	<b>0.875</b>	<b>0.804</b>	0.922	<b>0.712</b>

0.467；在 MCC5-THU 齿轮数据集中准确率下降了 0.475，F1 分数下降了 0.322，精准率下降了 0.400。因为它不仅移除了时频对比损失，还删除了一个编码器层，导致特征提取器的性能进一步下降。在 Variant-CP 中，修改了相关性对比模块，并发现对比相关性对比多传感器特征更加有效。这是因为多传感器相关性更多地反映在多传感器协同关系中。在 Variant-RCenter 中，验证了健康中心的重要性。随机选择健康样本难以有效表征健康状态下的工作特性。

图 3.16 展示了四个消融变体模型在减震器测试样本的潜在空间中的特征分布。在图 3.16(a) 中，Variant- $N\mathcal{L}_{cs}$  提取的相同状态下的特征呈现近似椭圆形，具备一定的聚集性，同时展示出了最好的健康特征和故障特征间的可分离性。其次图 3.16(d) 中，不同状态的特征分布边界相对比较模糊。健康特征主要集中在左上角，故障特征占据了图 3.16(d) 的右半部分，分布边界比较模糊但仍然可以观察到。而图 3.16(b), 图 3.16(c) 中不同状态下的特征分布非常离散，缺乏聚集性，同时也没有清晰的分类边界。这四个消融变体模型的特征分布表现与四个消融变体模型的实验指标排名刚好是一一对应的。

图 3.17 展示了四个消融变体模型在减震器测试样本上的故障分数分布。首先可以看出图 3.17(a) 和图 3.17(d) 健康状态和故障状态下故障分数具备一定的可

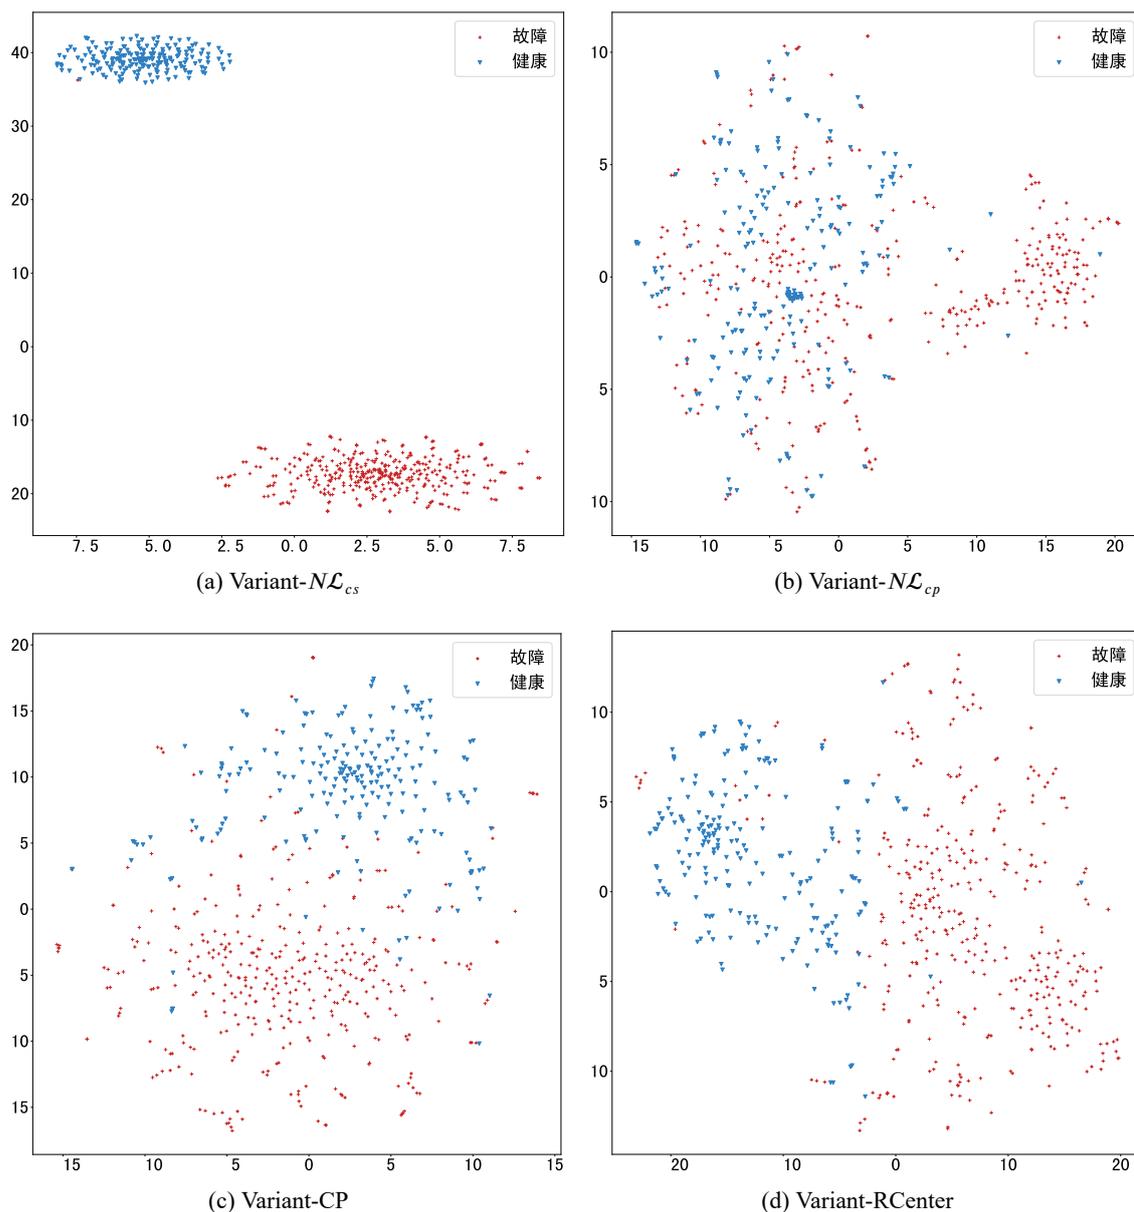


图 3.16 减震器数据集上消融模型的特征分布

分离性。这印证了 Variant- $N\mathcal{L}_{cs}$  和 Variant-RCenter 两个变体模型的高性能，也说明了时频对比损失  $\mathcal{L}_{cs}$  和健康中心对于模型性能有一定影响，但不是特别显著。观察图 3.17(b) 和图 3.17(c)，在不同健康状态下 Variant- $N\mathcal{L}_{cp}$  和 Variant-CP 两个变体模型的故障分数是难以区分的。其共同原因是 Variant- $N\mathcal{L}_{cp}$  和 Variant-CP 都没有从多传感器相关性的角度刻画减震器的健康状态。

### 3.3.3.2 训练数据量对模型性能的影响

图 3.18 显示了模型在减震器数据集和轴承数据集中不同训练数据量下的结果。本章选择了 5%，40%，60%，70%，100%，五个不同的训练数据百分比，其中 100% 是指使用训练集中的所有健康样本。首先可以看出，训练数据越多，模

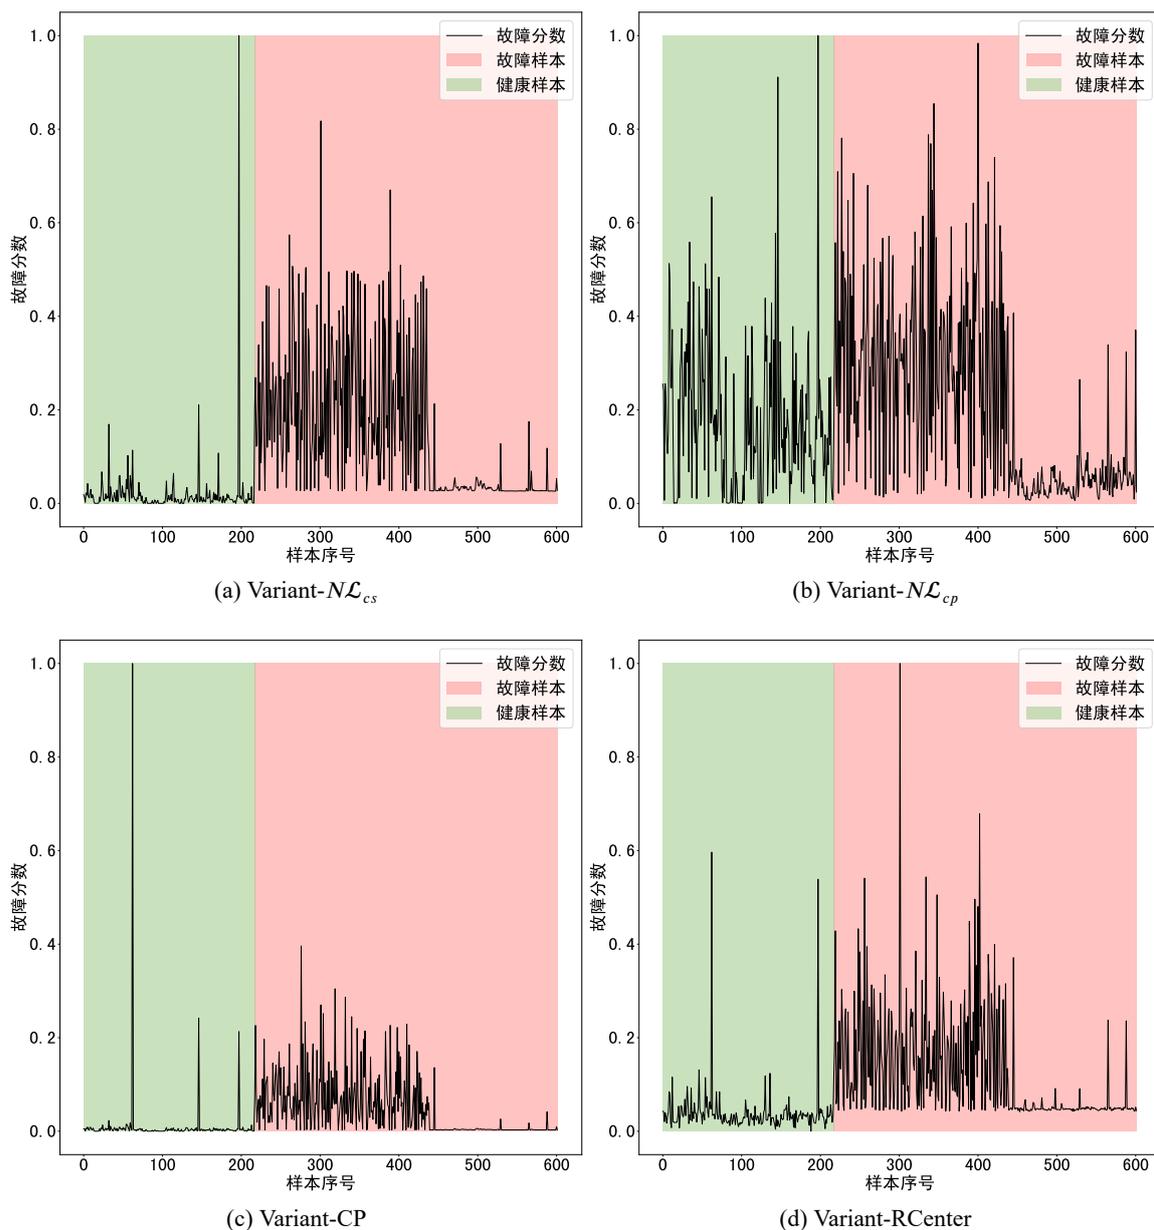


图 3.17 减震器数据集上消融模型的故障分数分布

型在两个数据集上的 F1 分数以及准确率就越高，这说明模型的性能随着训练数据量的增加而增强，原因在于数据量越多模型越能学习到更加准确的关键部件健康状态下的多传感器数据分布，有利于刻画关键部件状态。其次，当训练数据量从 70% 增加到 100% 时，在减震器数据集上模型性能上升微乎其微，而在山东科技大学轴承数据集上仍有较大的性能提高。这主要源于减震器的工况相对较少，仅需不太多的数据就能精准刻画减震器的健康模式，而轴承则恰恰相反。

### 3.3.3.3 超参数敏感性分析

为了分析超参数对模型性能的影响，本章进行了超参数敏感性实验，其中两个典型的超参数被选择：损失函数  $\mathcal{L}_{cs}$  的系数  $\alpha$  和损失函数  $\mathcal{L}_{cp}$  的系数  $\beta$ 。

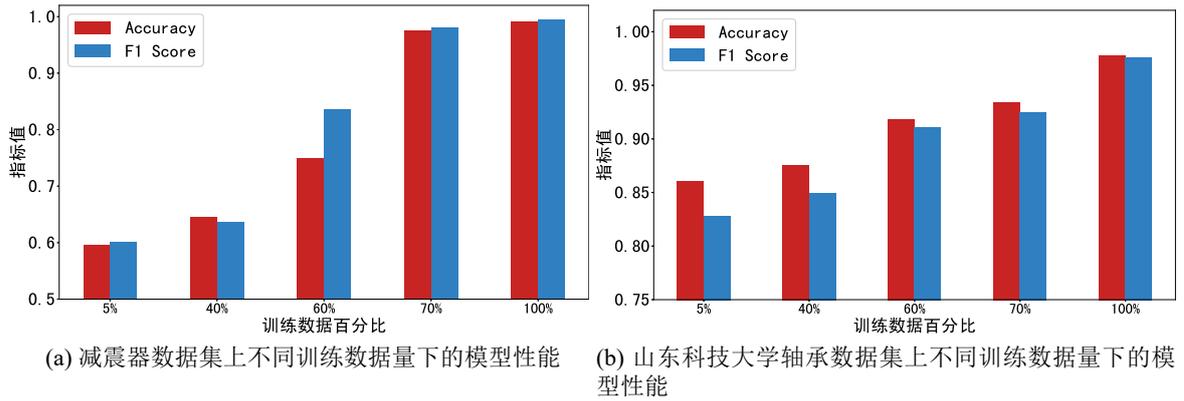


图 3.18 训练数据量对模型性能的影响

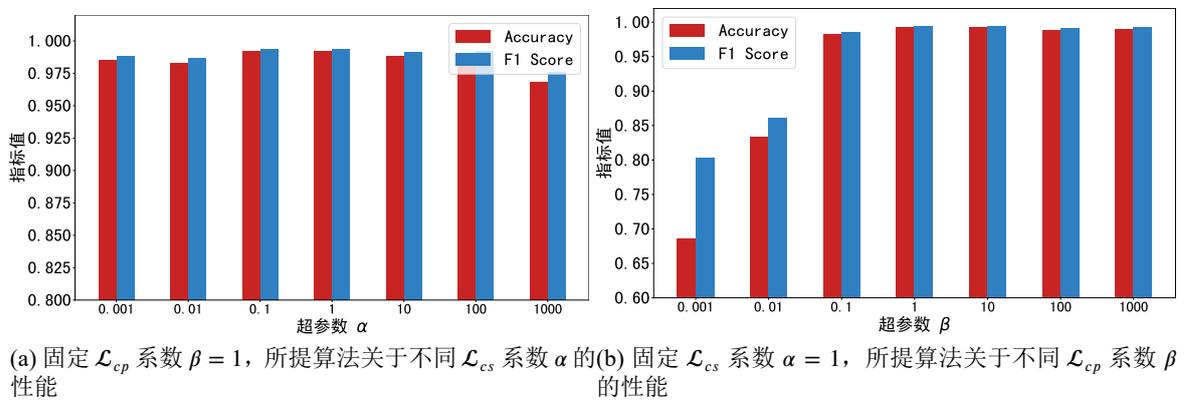


图 3.19 减震器数据集上的超参数分析

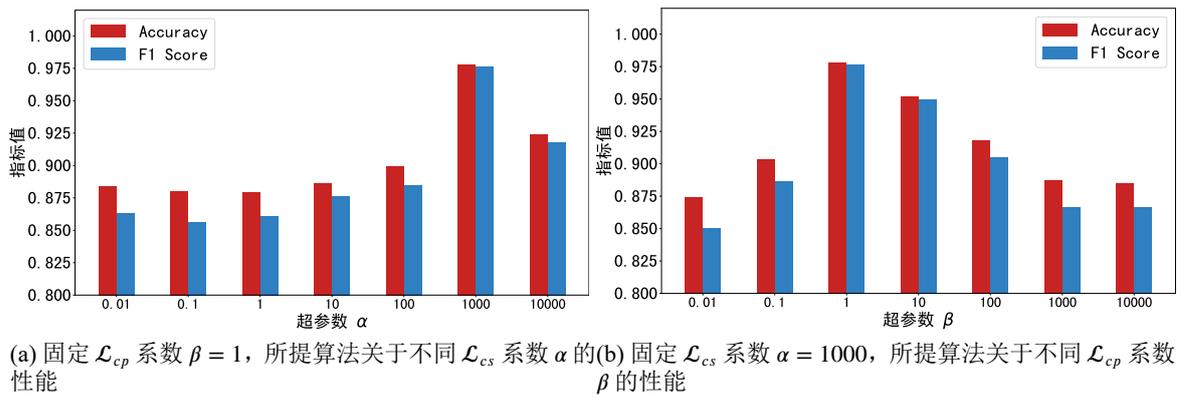


图 3.20 山东科技大学轴承数据集上的超参数分析

图 3.19 展示了所提算法在减震器数据集上的超参数敏感性分析实验结果。首先观察图 3.19(a), 可以发现, 如果固定超参数  $\beta$ , 在真实减震器数据集上, 模型性能会随着超参数  $\alpha$  的变化而略有波动。这说明在实际减震器数据集上, 模型对超参数  $\alpha$  并不敏感。其次观察图 3.19(b), 在真实减震器数据集上固定超参数  $\alpha$  的情况下, 模型性能随超参数  $\beta$  的变化而出现较大波动。这说明在实际减震器数据集上, 模型对超参数  $\beta$  要比超参数  $\alpha$  敏感。

图 3.20 展示了所提算法在山东科技大学轴承数据集上的超参数敏感性分析实验结果。从图 3.20(a) 可以发现, 如果固定超参数  $\beta$ , 在山东科技大学轴承数据集上则前期变化较小, 仅在  $\alpha = 1000$  模型性能剧烈上升。这说明在山东科技大学轴承数据集上模型对超参数  $\alpha$  全局表现出不敏感, 因为模型性能随  $\alpha$  的变化仅略有波动, 但是模型的最佳性能依赖合适的超参数  $\alpha$ 。其次观察图 3.20(b), 在山东科技大学轴承数据集上固定超参数  $\alpha$  的情况下, 模型性能随超参数  $\beta$  的变化而呈现明显的上升趋势。这说明在山东科技大学轴承数据集上, 模型对超参数  $\beta$  要比超参数  $\alpha$  敏感。

综上所述, 首先, 损失函数  $\mathcal{L}_{cs}$  的系数  $\alpha$  和损失函数  $\mathcal{L}_{cp}$  的系数  $\beta$  在减震器数据集和山东科技大学轴承数据集上的表现存在较大差异, 这可能是因为减震器数据是单工况的, 且只有一种故障类型, 而山东科技大学轴承数据集不仅仅有 24 种工况, 而且还有 9 种故障类型, 同时传感器数量也存在较大差异, 因此超参数  $\alpha$  和  $\beta$  相对会更难调控模型性能。其次, 在设计模型架构中, 由于模型对超参数  $\beta$  要比超参数  $\alpha$  更加敏感, 因此损失函数  $\mathcal{L}_{cp}$  比  $\mathcal{L}_{cs}$  对模型性能的影响更大。

#### 3.3.3.4 算法时间复杂度分析

出于应用的实时性需求, 需要分析算法的时间复杂度。与传统算法的时间复杂度分析不同, 基于深度学习的早期故障预警算法的时间复杂度不仅与输入样本的数量有关, 还与输入样本的尺寸, 模型的层数, 特征通道数等等有关, 因此通常以浮点运算次数 (Floating Point Operations, FLOPs) 来表示。在减震器数据集中, 所提算法的 FLOPs 约为 7.79M, 在山东科技大学轴承数据集和 MCC5-THU 齿轮数据集中所提算法的 FLOPs 约为 16.64M。可以看出, 所提算法的时间复杂度随传感器数量数量的增加而增加。这主要源于两个方面, 第一, 所提算法针对每个传感器都设计了相应的编码器, 当传感器数量增加时, 编码器的数量也会增加, 进而引起时间复杂度的上升。第二, 在相关性对比模块中, 所提算法会计算任意两个传感器时频特征间的相关性, 从而造成算法时间复杂度随传感器数量数量的增加而增加。在工厂中, 关键部件的传感器数量通常不会过多, 因此所提算法的时间复杂度仍然是可接受的。

#### 3.3.4 算法应用讨论

本章所提算法分别在真实的锡膏印刷机减震器数据集、山东科技大学轴承数据集和 MCC5-THU 齿轮数据集上进行了充分的验证, 表现出非常优越的预警性能。对于锡膏印刷机中减震器, 所提算法可以在一定程度上满足工厂对锡膏印刷机减震器早期故障预警的需求, 具有显著的工程应用价值。对于锡膏印刷

机中轴承和齿轮，公开的轴承、齿轮数据集和锡膏印刷机中轴承、齿轮在真实情况下存在客观差异，比如转速、负载等不完全一致，这些因素导致所提算法在锡膏印刷场景中可能会性能下降，但是仍然具备一定的工程应用价值，原因如下。首先，在实际应用中，如果所提算法的早期故障预警性能下降，那么可调节所提算法的故障分数阈值。虽然可能会增大故障误报率，但是可以减少故障漏报率。基于此，所制定的维护决策会偏向保守，但依旧具有一定的工程应用价值；其次，所提算法分析了工厂实际情况，在多个数据集多种工况下进行了充分的实验验证，证明了所提算法具有合理性以及良好的泛化性能，这可以为后续的工程应用算法研发提供有价值的借鉴。

### 3.4 本章小结

本章针对仅使用健康样本下的锡膏印刷关键部件早期故障预警问题，提出了一种基于多传感器双重对比的锡膏印刷关键部件早期故障预警算法。相较于以 LSTM-VAE、ATF-UAD 等基于重构的主流方法，所提算法利用时频对比模块和相关性对比模块，从两个层面共同抑制了噪声的不利影响并挖掘健康状态下的通用表示，可以有效解决健康样本含有高噪声的难点。相较于以 CPC 为代表的基于对比的方法，所提算法中在挖掘健康状态下时频通用表示的基础上，进一步挖掘了健康状态下多传感器相关性的通用表示，有效提升了早期故障预警精度。首先，基于迭代获得健康中心。然后，设计了一个时频对比模块来提取健康状态下多传感器时频信息的通用表示。使用 KL 散度来对比训练样本特征与健康中心特征，并最小化 KL 散度，从而获取健康状态下多传感器时频信息的通用表示。接下来，设计了一个相关性对比模块，以提取健康状态下相关性的通用表示。使用 KL 散度对比训练样本和健康中心之间的多传感器相关性，有效提取健康状态下相关性的通用表示。最后，在私有的锡膏印刷机减震器数据集、公开的山东科技大学轴承数据集和 MCC5-THU 齿轮数据集上验证了所提算法，其显著优于最先进的基线方法，能有效判别关键部件的当前状态，证明了所提算法的优越性和普适性。本章构建了仅使用健康样本下的关键部件早期故障预警模型，实现了对关键部件健康状态的准确刻画，解决了健康状态下多传感器数据中包含大量噪声导致关键部件健康状态刻画出现偏差的关键问题。

## 第4章 基于多传感器交替对比的锡膏印刷关键部件剩余使用寿命预测算法

上一章研究了锡膏印刷关键部件早期故障预警算法，针对锡膏印刷机故障预警，在发现锡膏印刷关键部件早期故障后，需要进一步地预警其完全失效时间，为制定维护计划提供更全面的决策依据，以及时阻止锡膏印刷异常。因此本章结合产线实际情况，针对锡膏印刷关键部件，研究利用大量无剩余使用寿命标签的传感器数据辅助仅有少量带剩余使用寿命标签的数据实现高性能剩余使用寿命预测，旨在准确预警锡膏印刷关键部件的完全失效时间。考虑到直接从无标签传感器数据提取锡膏印刷关键部件退化特征存在区分度不足的挑战，本章提出了一种基于多传感器交替对比的锡膏印刷关键部件剩余使用寿命预测算法，其核心是利用交替对比提取跨传感器不变特征，能够显著提高不同退化阶段间退化特征的区分度，从而准确预测关键部件的剩余使用寿命。在实验设计部分，本章在 PHM2012 轴承数据集和重庆大学齿轮数据集上验证了所提算法的剩余使用寿命预测精度，分析了所提算法中各个模块的有效性，探索了标签数据量对模型性能的影响。

本章结构安排如下：4.1 节分析了不同退化阶段间退化特征区分度；4.2 节介绍了本章提出的基于多传感器交替对比的锡膏印刷关键部件剩余使用寿命预测算法，4.3 节介绍了上述算法的实验结果与分析；最后 4.4 节总结本章内容。

### 4.1 不同退化阶段间退化特征区分度分析

以锡膏印刷机关键传动部件轴承为例，本研究通过计算不同退化阶段间多传感器数据的余弦相似度矩阵（结果如图 4.1 所示），发现矩阵中存在显著的高相似度区域（图中红色区域）。相似度越高，说明区分度越低。这一现象表明，轴承在不同退化阶段采集的多传感器数据具有较高的相似性，直接从多传感器数据中提取退化特征会面临区分度不足的挑战。深入分析其成因，主要可归结为部件运行的不稳定性以及多传感器监测系统中的电磁噪声等因素。这些因素共同作用，使得不同退化阶段间传感器数据在特征空间中的区分度降低。

图 4.2 则展示了不同退化阶段间跨传感器相似度的余弦相似度分布。与图 4.1 相比，不同退化阶段间跨传感器相似度的余弦相似度显然比较低，这说明不同退化阶段间的跨传感器相似度具有更高的区分度，因此基于跨传感器相似度可以提取到更有区分度的退化特征。

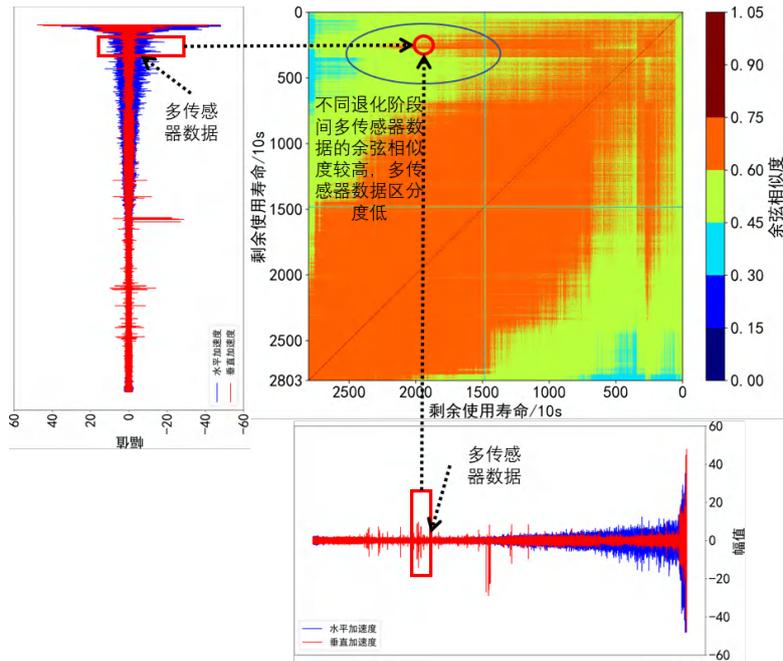


图 4.1 轴承不同阶段间多传感器时频矩阵的余弦相似度分布

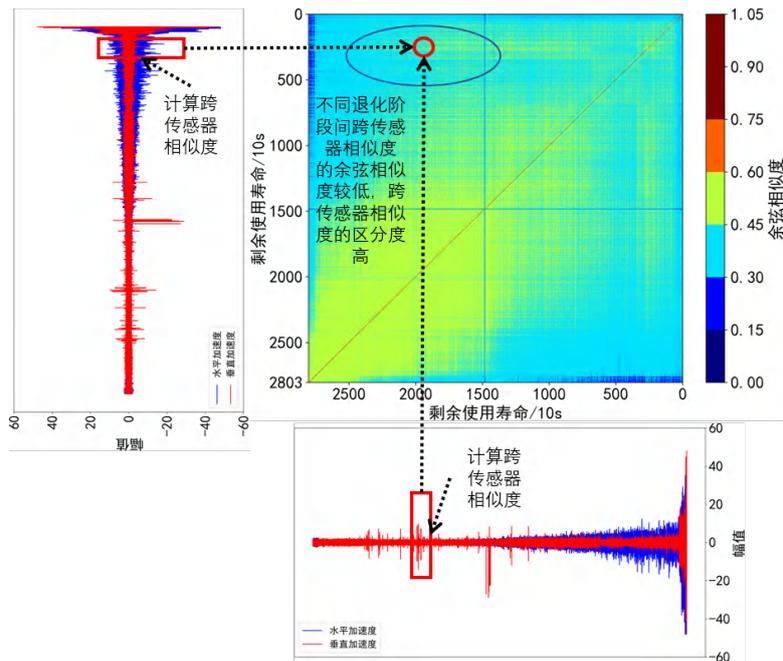


图 4.2 轴承不同阶段间跨传感器相似度的余弦相似度分布

## 4.2 算法设计

在工厂中，尽管存在一定程度的工况差异，但同类型关键部件的退化模式仍表现出一定相似性。基于此，可通过深入分析这些多传感器监测数据，提取该类型关键部件的普适性退化规律，从而实现有效的剩余使用寿命预测。然而，出于安全和经济的考量，工厂大多不会允许关键部件退化至完全失效，因此通常仅有少量的带剩余使用寿命标签的多传感器数据以及大量的无标签多传感器数据可

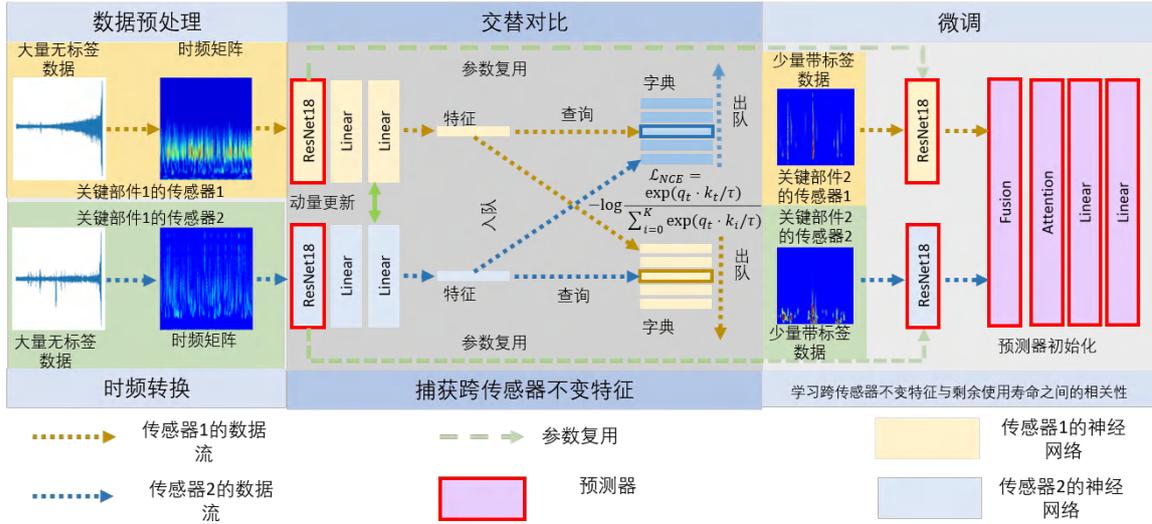


图 4.3 基于多传感器交替对比的锡膏印刷关键部件剩余使用寿命预测算法框图

用。因此本章任务为针对特定类型关键部件剩余使用寿命问题，首先，基于多个同类型关键部件大量无标签多传感器数据和少量带标签的多传感器数据构建剩余使用寿命预测模型。然后，基于目标关键部件从过去至现在一段时间内的多传感器数据，所构建的剩余使用寿命预测模型即可实现其剩余使用寿命预测。

所构建的剩余使用寿命预测模型如图 4.3 所示。主要包括三个部分：时频转换、交替对比和微调。时频转换通过短时傅里叶变换将原始信号转换为时频域，同时提取时域和频域的特征。交替对比由特征提取器和特征对比组成。特征提取器从大量无标签的时频数据中提取特征并映射到共现空间，以学习跨传感器不变特征。在特征对比中，一个传感器被视为主传感器，另一个被视为辅传感器。辅传感器特征提取器采用动量更新确保特征的一致性。然后，在共现空间中计算主传感器特征和辅传感器特征之间的相似度，并通过优化对比损失使不同传感器在同一时刻的特征具有最大相似度。重复上述过程，直到每个传感器都作为主传感器，以获得跨传感器不变特征。微调时初始化预测器并利用少量标签数据微调模型参数以实现剩余使用寿命的预测。

### 4.2.1 时频转换

考虑到在关键部件退化过程中，传感器信号不仅振幅会逐渐改变，而且频率也会逐渐改变，因此通过数据预处理将频率和时间变化暴露出来。采用短时傅里叶变换将传感器数据从时域变换到时频域，公式如下：

$$I_{i,t} = \text{STFT}(x_i(t)), \quad (4.1)$$

在公式 (4.1) 中  $x_i(t)$  代表第  $i$  个传感器的原始数据，其中  $t$  是起始时间， $t + N$  是终止时间。通过短时傅里叶变换，传感器原始数据  $x_i(t)$  转换为一个时频矩阵  $I_{i,t}$ 。

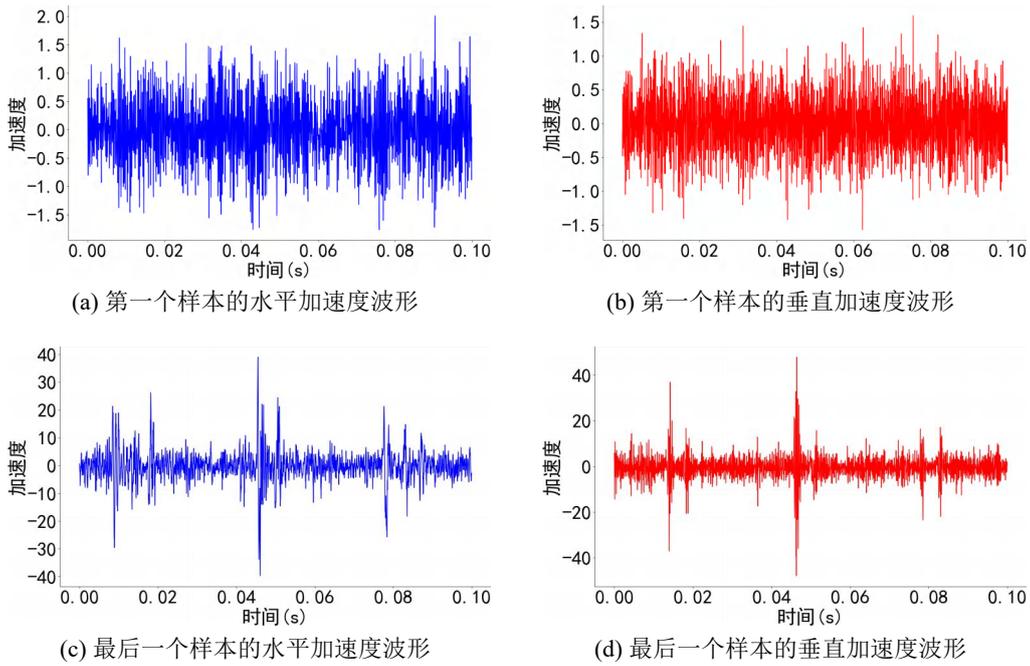


图 4.4 轴承不同退化阶段的波形

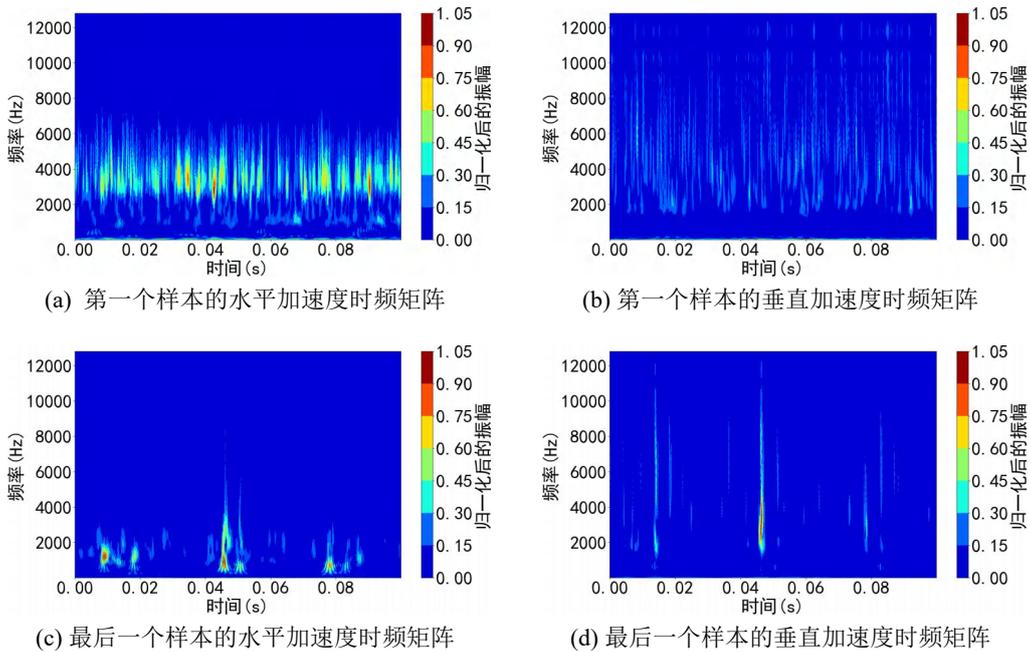


图 4.5 轴承不同退化阶段的时频矩阵

图 4.4 展示了在不同健康状态下轴承 1\_1 的水平 and 垂直加速度波形。可以看出健康和故障状态之间存在明显差异，但由于波形的杂乱，很难发现水平和垂直加速度之间的差异。图 4.5 显示了在不同健康状态下轴承 1\_1 的水平 and 垂直加速度的时频矩阵。不仅揭露了健康和故障状态之间的差异，还展示了水平和垂直加速度之间的差异。这是因为短时傅里叶变换暴露了波形中隐藏的频域信息，使显示的信息更加丰富。

然后采用双线性插值  $\varphi(\cdot)$  减少了时频矩阵  $I_{i,t}$  的维度，以加快特征提取的速度。

$$\bar{I}_{i,t} = \varphi(I_{i,t}), \quad (4.2)$$

$\bar{I}_{i,t}$  是第  $i$  个传感器原始信号经短时傅里叶变换和降维处理后的时频矩阵，其中  $t$  为起始时间， $t + N$  为结束时间。

#### 4.2.2 交替对比

在交替对比中，只有大量无标签的传感器数据可用，因此需要使用传感器数据本身的特征作为训练标签。对于多传感器监测的关键部件，虽然传感器监测的物理量不一样，但是不同的传感器监测数据应该反映相同健康状态，因此一个良好的健康状态应该是跨传感器不变的。为了建模这种良好的健康状态，本章试图提取跨传感器不变特征。具体地，采用跨传感器相似度进行交替对比，以最大化同一时刻的多传感器特征的相似度，同时抑制不同时刻的多传感器特征的相似度，从而获得具有高度区分度的跨传感器不变特征。如图 4.6 所示，给出了提取跨传感器不变特征的图解说明。

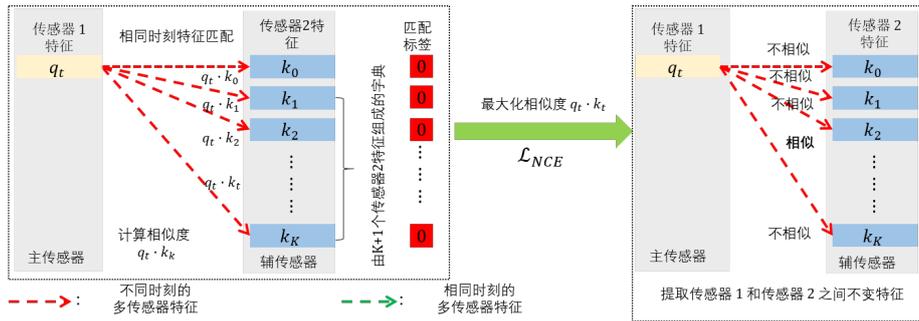


图 4.6 捕获跨传感器不变退化特征

##### (1) 选择主传感器

构建一个多分支网络以提取每个传感器的特征并映射到一个共现空间。在本章中，使用 ResNet18 骨干网络  $E$  作为特征提取器和全连接层  $FC$  来构建一个多分支网络。选择第  $i$  个传感器  $V_i$  作为主传感器  $V_m$ ，相应的骨干网络  $f_i$  被标记为  $f_m$ ，而时频矩阵  $\bar{I}_{i,t}$  被记为  $\bar{I}_{m,t}$ 。其他传感器  $V_j$ ， $i \neq j$  被视为辅传感器  $V_{a_j}$ ，相应的骨干网络  $f_j$  被记为  $f_{a_j}$ ，而时频矩阵  $\bar{I}_{j,t}$  被记为  $\bar{I}_{a_j,t}$ 。

##### (2) 特征字典

主传感器的特征  $q_t$  是主传感器在时刻  $t$  记录的关键部件健康状态。特征字典  $D_j$  包含第  $j$  个辅传感器的特征  $\{k_{j,0}, k_{j,1}, \dots, k_{j,K}\}$ 。  $D_j$  的含义是第  $j$  个辅传感器在  $K + 1$  个不同时刻记录的部件健康状态。其公式如下：

$$q_t = f_m(\bar{I}_{m,t}) = FC_m(E_m(\bar{I}_{m,t})), \quad (4.3)$$

**算法 4.1 交替对比算法**


---

**Input:**  $C$  个传感器的历史时序数据  $x_1, x_2, \dots, x_C$ , 滑动窗口为  $N$ , 历史时序数据长度为  $T$ .

**Output:**  $C$  个传感器的对应的特征提取器  $E$

```

/* 构建无剩余使用寿命标签数据集 */
1  $X^u \leftarrow \emptyset$ 
2 for  $t \in [0, 1, \dots, T - N]$  do
3     选择起始时刻为  $t$ , 长度为  $N$  的序列  $(x_1(t), x_2(t), \dots, x_C(t))$ 
4      $X^u \leftarrow X^u \cup (x_1(t), x_2(t), \dots, x_C(t))$ 
5 end
/* 数据处理 */
6 for  $i \in [0, 1, \dots, N^u]$  do
7     选择数据集中第  $i$  个样本  $X^{u,i}$ 
8     根据公式 (4.1) 进行时频转换
9     根据公式 (4.2) 进行插值
10 end
11 for  $c \in [0, 1, \dots, C]$  do
12     随机初始化第  $c$  个传感器对应的特征提取器  $E_c$  和全连接层  $FC_c$ 
13     选择第  $c$  个传感器作为主传感器, 其他传感器作为辅传感器
14     根据公式 (4.3) 提取主传感器特征
15     根据公式 (4.4) 提取辅传感器特征
16     基于点积计算主传感器特征和辅传感器特征间的相似度
17     根据公式 (4.6) 优化主传感器特征提取器  $E_c$  和全连接层  $FC_c$  的参数
18     更新特征字典
19     根据公式 (4.7) 更新辅传感器的网络参数
20 end
    
```

---

$$k_{j,k} = f_{a_j}(\bar{I}_{a_j,k}) = FC_{s_j}(E_{a_j}(\bar{I}_{a_j,k})). \quad (4.4)$$

## (3) 特征相似度计算

首先, 给出主传感器在时刻  $t$  时的退化特征  $q_t$ , 以及与第  $j$  个辅传感器对应的特征字典  $D_j = \{k_{j,0}, k_{j,1}, \dots, k_{j,K}\}$ 。

然后, 在字典  $D_j$  中主传感器特征  $q_t$  与时刻  $k$  的退化特征  $k_{j,k}$  之间的相似度  $Sim_{t,k}^j$  如下所示,

$$Sim_{t,k}^j = q_t \cdot k_{j,k} = \sum_{n=1}^N q_t^n k_{j,k}^n, \quad (4.5)$$

其中  $Sim_{t,k}^j$  表示主传感器在  $t$  时刻的退化特征与第  $j$  个辅传感器在  $k$  时刻的退化特征之间的相似度,  $\cdot$  表示点积。 $N$  表示退化特征  $q_t$  和  $k_{j,k}$  中的元素个数,  $n$  表示第  $n$  个元素。 $q_t^n k_{j,k}^n$  表示退化特征  $q_t$  中的  $n$  个元素与退化特征  $k_{j,k}$  中的  $n$  个元素相乘。

最后, 按照上述步骤, 计算主传感器退化特征  $q_t$  与特征字典  $D_j$  中所有退化特征  $k_{j,0}, k_{j,1}, \dots, k_{j,K}$  之间的相似度  $\{Sim_{t,0}^j, Sim_{t,1}^j, \dots, Sim_{t,K}^j\}$ 。

(4) 对比损失

多个时刻的特征相似度使用 Softmax 进行归一化。令多传感器特征相似度  $Sim_{t,t}^j$  在相同时刻的匹配标签为 1，不同时刻的多传感器特征匹配标签为 0。然后将归一化后的特征相似度输入到交叉熵函数。交叉熵旨在最大化相同时刻的多传感器特征相似度，同时抑制不同时刻的传感器特征的相似度。总之，为了最大化相同时刻的传感器特征的相似度，以获得跨传感器不变的退化特征，对比损失函数  $\mathcal{L}_{NCE}$  如下构建：

$$\mathcal{L}_{NCE} = - \sum_j \log \frac{\exp\left(\frac{Sim_{t,t}^j}{\tau}\right)}{\exp\left(\frac{Sim_{t,t}^j}{\tau}\right) + \sum_{k=0, k \neq t}^K \exp\left(\frac{Sim_{t,k}^j}{\tau}\right)} + \mu_c \|\theta_m\|_2, \quad (4.6)$$

其中  $\tau$  是温度超参数， $\mu_c$  是正则化权重， $\|\theta_m\|_2$  表示主传感器网络  $f_m$  的 L2 正则化。主传感器的特征  $q_t$  在辅传感器的  $K + 1$  个样本中寻找最相似的样本，这个过程类似于对特征  $q_t$  进行  $K + 1$  分类。

(5) 更新特征字典

因为主传感器的特征  $q_t$  在训练过程中不断变化，所以需要动态维护特征字典。由于特征字典的长度远大于批量大小，每次重新计算特征字典中的所有特征是不切实际的。因此，采用如图 4.7 所示的先进先出的队列更新，一次更新一个批次的特征。在每个批次中，将辅传感器特征入队到相应的特征字典中，并出队最早的辅传感器特征。

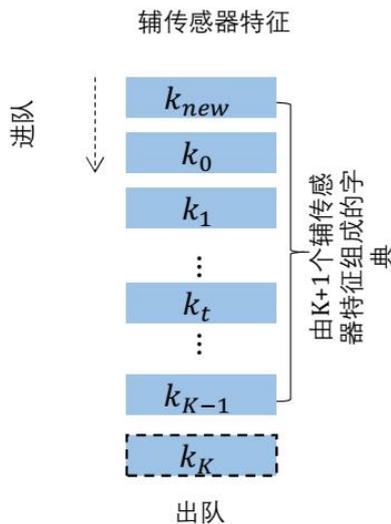


图 4.7 更新辅传感器特征字典

(6) 更新辅传感器网络参数

因为辅传感器主干网络也在更新，这些最早的特征对应的参数可能与当前参数明显不同。通过上述操作，实现了特征字典的缓慢的动态更新，同时确保字

典长度可以远大于批量大小。由于辅传感器网络参数的快速变化会降低字典中特征的一致性。因此，辅传感器网络的梯度被忽略，并使用动量更新进行参数更新<sup>[166]</sup>。

$$\theta_j \leftarrow m\theta_j + (1 - m)\theta_m, \quad (4.7)$$

在这里  $m$  是动量更新因子， $\theta_m$  是主传感器网络参数， $\theta_j$  是第  $j$  个辅传感器网络参数。

(7) 交替机制

如图 4.8 所示，以上过程每  $F_{ex}$  个周期交替一次，直到每个传感器都担任过主传感器为止，以确保每个传感器的网络都能学习到良好的表示。交替对比的

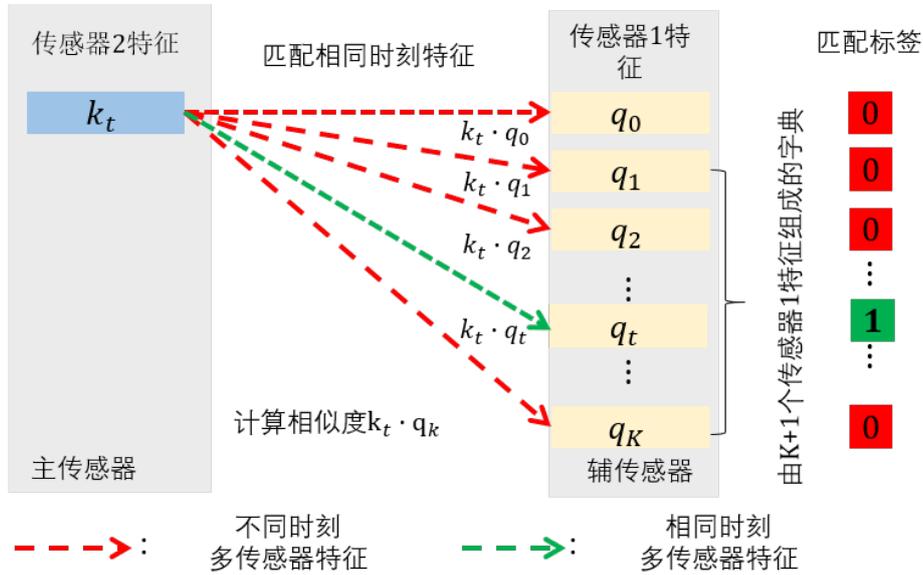


图 4.8 交替机制

算法优化过程如算法 4.1 所示。

4.2.3 跨传感器相似度提高特征区分度的分析

不同退化阶段间多传感器数据相似度较高的原因在于部件运行的不稳定性以及多传感器监测系统中的电磁噪声等因素。值得注意的是，由于各传感器在监测位置和类型上的差异性，这些干扰因素可被归纳为两类：传感器特异性干扰和系统共性干扰。由于跨传感器相似度可量化相同时刻多传感器特征间的距离关系，因此可利用跨传感器相似度挖掘跨传感器不变特征。这类特征反映了多个传感器共同监测的退化信息。与已有的自监督预训练方法相比，虽然跨传感器不变特征无法完全消除系统共性干扰的影响，但其抑制了传感器特异性干扰，从而相对提升了退化特征在剩余使用寿命预测中的区分度。

#### 4.2.4 微调

在交替对比中，模型提取了跨传感器不变特征。为了建立跨传感器不变特征与剩余使用寿命的关联，使用少量带有剩余使用寿命标签的传感器数据对模型进行微调。特征提取器的参数被复用，而预测器  $P_F$  则被初始化。

##### (1) 特征融合

来自不同传感器的特征被融合。融合方法选择拼接，其公式如下：

$$F_t = \text{Cat}([E_1(\bar{I}_{1,t}), E_2(\bar{I}_{2,t}), \dots, E_i(\bar{I}_{i,t})]), \quad (4.8)$$

其中  $\text{Cat}$  是拼接符号，将上述特征沿着最后一维拼接。

##### (2) 注意力机制

空间注意力被设计用于调整特征权重。

$$\alpha_s = \text{Tanh}(W_s F_t + b_s), \quad (4.9)$$

$$a_s = \text{Softmax}(W_i \alpha_s + b_i), \quad (4.10)$$

$W_s$  和  $W_i$  是可训练的权重参数，而  $b_s$  和  $b_i$  是可训练的偏置参数。

$$\bar{F}_t = a_s \cdot F_t, \quad (4.11)$$

在这里乘号  $\cdot$  表示逐元素相乘。 $\bar{F}_t$  是经过注意力重构后的特征。

##### (3) 剩余使用寿命预测

预测器  $P_F$  对重构后的特征  $\bar{F}_t$  进行回归预测。

$$RUL_p = P_F(\bar{F}_t), \quad (4.12)$$

其中  $RUL_p \in \mathbb{R}^+$  是模型预测的剩余使用寿命，而微调的损失函数  $\mathcal{L}_F$  则定义如下：

$$\mathcal{L}_F = (RUL_p - y_t)^2 + \mu_f \|\theta\|_2, \quad (4.13)$$

其中  $y_t$  是对应的剩余使用寿命标签， $\|\theta\|_2$  代表 L2 正则化， $\mu_f$  是正则化系数。

微调的算法优化过程如算法 4.2 所示。

### 4.3 实验结果和分析

#### 4.3.1 数据集和实验配置

##### 4.3.1.1 数据集介绍

在前文中，以减震器、轴承和齿轮为对象验证了故障预警算法。由于采集自锡膏印刷场景下的减震器数据缺乏完全失效的时间记录，同时目前也缺乏公

**算法 4.2 微调算法**


---

**Input:**  $C$  个传感器的历史时序数据  $x_1, x_2, \dots, x_C$ , 滑动窗口为  $N$ , 历史时序数据长度为  $T_l$ .

**Output:** 剩余使用寿命预测值  $RUL_p$

/\* 构建有剩余使用寿命标签数据集 \*/

- 1  $X^l \leftarrow \emptyset$
- 2 **for**  $t \in [0, 1, \dots, T_l - N]$  **do**
- 3     选择起始时刻为  $t$ , 长度为  $N$  的序列  $(x_1(t), x_2(t), \dots, x_C(t))$
- 4      $X^l \leftarrow X^l \cup (x_1(t), x_2(t), \dots, x_C(t))$
- 5 **end**
- /\* 数据处理 \*/
- /\*  $N^l$  为样本总数 \*/
- 6 **for**  $i \in [0, 1, \dots, N^l]$  **do**
- 7     选择数据集中第  $i$  个样本  $X^{l,i}$
- 8     根据公式 (4.1) 进行时频转换
- 9     根据公式 (4.2) 进行插值
- 10 **end**
- 11 **for**  $c \in [0, 1, \dots, C]$  **do**
- 12     获取算法 4.1 中第  $c$  个传感器对应的特征提取器  $E_c$
- 13 **end**
- 14 随机初始化预测器  $P_F$
- 15 **while** 网络收敛 **do**
- 16     根据公式 (4.8) 拼接  $C$  个传感器的特征
- 17     根据公式 (4.9) 至公式 (4.11) 计算加权后的退化特征
- 18     根据公式 (4.12) 利用预测器预测  $RUL_p$
- 19     根据公式 (4.13) 优化特征提取器和预测器的参数
- 20 **end**

---

开的减震器剩余使用寿命数据集, 因此无法以减震器为对象验证所提算法的有效性。考虑到研究对象的连贯性和充分性, 本章在以轴承和齿轮为研究对象以验证所提算法有效性。

轴承和齿轮作为锡膏印刷机传动系统的关键机械部件, 其性能退化是导致传动系统故障的主要因素之一, 因此开展针对这两类关键部件的剩余使用寿命预测研究具有重要的工程实践价值。然而, 本研究面临以下数据获取的挑战: 其一, 由于商业保密, 目前缺乏公开的锡膏印刷场景下轴承和齿轮性能退化数据集; 其二, 基于生产安全性和经济性考量, 合作企业缺乏关键部件全周期退化数据。这些因素导致难以获取特定于锡膏印刷场景的部件退化数据用于算法验证。为解决这一问题, 本研究系统分析了通用工业场景下公开可获取的轴承和齿轮退化数据集与锡膏印刷场景的相似性, 选取恰当的公开数据集通过充分的多角度的实验设计来验证算法的有效性和合理性。

### (1) PHM2012 轴承数据集

目前轴承公开的剩余使用寿命数据集有 IMS 轴承数据集<sup>[167]</sup>、XJTU-SY 滚动轴承加速寿命实验数据集<sup>[168]</sup>和 PHM2012 轴承数据集<sup>[169]</sup>等。最终选择以 PHM2012 轴承数据集为例进行算法验证，原因如下：

- (1) 工况：锡膏印刷机中轴承具有多工况、低转速的特点。据调研，IMS 数据集仅有一种工况，XJTU-SY 滚动轴承加速寿命实验数据集和 PHM2012 轴承数据集则都有三种工况，因此 XJTU-SY 滚动轴承加速寿命实验数据集和 PHM2012 轴承数据集占据一定优势。同时 PHM2012 轴承数据集中转速较低，相对更接近锡膏印刷机中轴承的真实工况。
- (2) 轴承数量：IMS 轴承数据集有 3 个轴承，XJTU-SY 滚动轴承加速寿命实验数据集包含 15 个轴承的退化数据，而 PHM2012 轴承数据集则包含 17 个轴承的退化数据。更多的轴承意味着可以更充分验证所提算法的泛化性和有效性，因此 PHM2012 轴承数据集具有更大的优势。
- (3) 轴承规格：据调研，锡膏印刷机中部分轴承规格与 PHM2012 轴承数据集中的轴承规格比较相似。

综上所述，从轴承工况、规格以及数量的角度，分别比较了公开轴承数据集与锡膏印刷机中轴承的相似性以及优势，确定 PHM2012 轴承数据集为最合适的数据集。因此本章以 PHM2012 轴承数据集为例分析轴承的退化模式，在多种工况下进行充分的实验验证，可有效证明所提算法的有效性和泛化性。

PHM2012 轴承数据集是从 PRONOSTIA 实验平台获得的轴承加速退化数据。使用采样频率为 25.6 kHz 的垂直和水平加速度传感器记录了轴承的工作状态，每 10 秒记录一次。每次采样持续 0.1 秒。该数据集包含了如表 4.1 所示的三种工况下的 17 个轴承退化数据集。

表 4.1 PHM2012 轴承数据集工况详情

工况	转速 (rpm)	负载 (N)	轴承
工况 1	1800	4000	轴承 1_1、轴承 1_2、轴承 1_3、轴承 1_4、 轴承 1_5、轴承 1_6、轴承 1_7
工况 2	1650	4200	轴承 2_1、轴承 2_2、轴承 2_3、轴承 2_4、 轴承 2_5、轴承 2_6、轴承 2_7
工况 3	1500	5000	轴承 3_1、轴承 3_2、轴承 3_3

### (2) 重庆大学齿轮数据集

据调研，目前公开可用的齿轮剩余使用寿命数据集仅有重庆大学齿轮数据集<sup>[102]</sup>。该数据集与锡膏印刷场景下的齿轮相似之处正在二者的转速均比较低，

因此退化模式较为接近，能以重庆大学齿轮数据集为例分析齿轮的退化模式。通过在多种工况下进行充分的实验验证，以证明所提算法的有效性和泛化性。

重庆大学齿轮数据集包含如表 4.2 所示 3 种工况，一共 4 个齿轮，采样频率为 25kHz，分别监测齿轮的垂直和水平加速度，每 1 分钟记录一次。每次采样持续 10 秒。从图可以看出不同退化阶段间，齿轮的状态监测数据同样具有较高的相似性。这也说明了不同退化阶段间状态监测数据具有较高相似性是一种较常见的现象。

表 4.2 重庆大学齿轮数据集工况详情

	转速 (rpm)	负载 (N)	齿轮
工况 1	1100	4400	齿轮 1
工况 2	800	4070	齿轮 2, 齿轮 3
工况 3	800	3750	齿轮 4

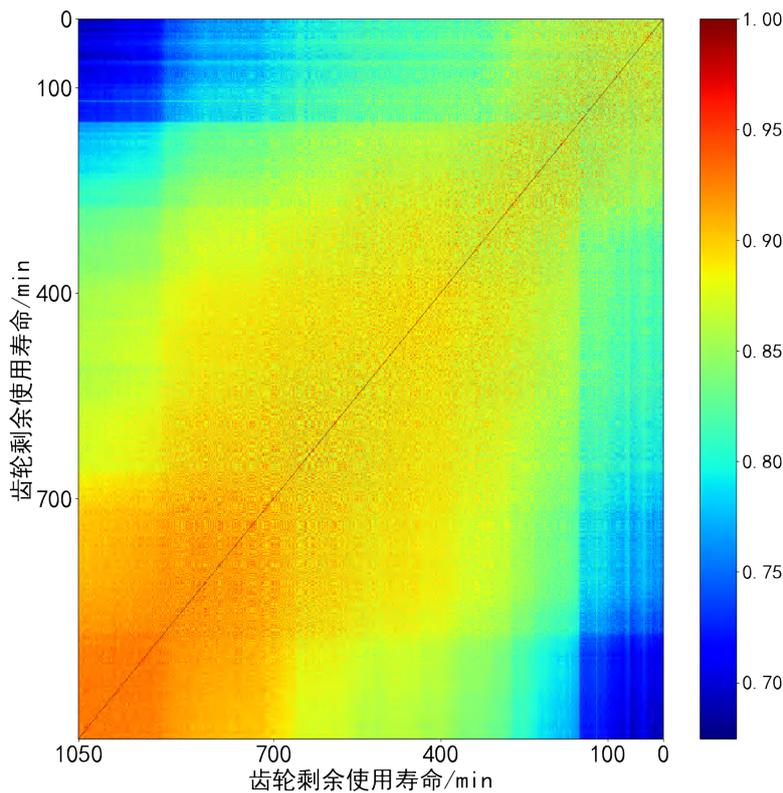


图 4.9 不同退化阶段间齿轮状态监测数据相似性分布

#### 4.3.1.2 数据集设置

由于高昂的采集成本和其他原因，只能收集到少量带剩余使用寿命标签的数据以及大量无标签的退化数据。由于这种情况下对剩余使用寿命预测的研究有限，目前缺乏适用于此情景的数据集。为了进行研究并与基线方法进行比较，

本章对原始的 PHM2012 轴承数据集和重庆大学齿轮数据集进行了合理修改。对数据集的修改尽可能符合工厂实际情况，可以作为后续类似研究的参考。

交替对比和微调所用的训练数据如表 4.3 和表 4.4 所示。无标签的数据集是使用大量无标签数据构建的，用于交替对比的训练，而带有剩余使用寿命标签的数据集则是使用少量剩余使用寿命数据构建的，用于微调模型。在交替对比中，模型仅使用轴承的振动加速度数据进行预训练。在整个交替对比中，没有任何剩余使用寿命标签参与模型的训练。然后，在微调中，模型使用带有少量剩余使用寿命标签的振动加速度数据进行微调。

以 PHM2012 轴承数据集工况 1 为例，交替对比使用的数据集包括轴承 1\_2、轴承 2\_1、轴承 2\_2、轴承 3\_1、轴承 3\_2 的退化数据。在整个交替对比过程中，没有任何剩余使用寿命标签参与训练。在微调中，模型仅使用轴承 1\_1 的最后 50%带剩余使用寿命标签的振动加速度数据进行微调。轴承 1\_3、轴承 1\_4、轴承 1\_5、轴承 1\_6 和轴承 1\_7 是测试集。

表 4.3 PHM2012 轴承数据集实验设置

工况	交替对比	微调	测试数据
	(无剩余使用寿命标签参与训练)	(有剩余使用寿命标签参与训练)	
工况 1	轴承 1_2、轴承 2_1、 轴承 2_2、轴承 3_1、 轴承 3_2	50% 轴承 1_1 数据	轴承 1_3、轴承 1_4、 轴承 1_5、轴承 1_6、 轴承 1_7
工况 2	轴承 1_1、轴承 1_2、 轴承 2_2、轴承 3_1、 轴承 3_2、	50% 轴承 2_1 数据	轴承 2_3、轴承 2_4、 轴承 2_5、轴承 2_6、 轴承 2_7
工况 3	轴承 1_1、轴承 1_2、 轴承 2_1、轴承 2_2、 轴承 3_2、	50% 轴承 3_1 数据	轴承 3_3

#### 4.3.1.3 超参数

在交替对比中正则化因子  $\mu_c$  为 0.0001，学习率为 0.0001，迭代周期为 800，主传感器每 100 个周期交替一次，选择 SGD 作为优化算法，对应的动量为 0.9。批尺寸为 128，动量更新因子  $m$  为 0.999，温度系数  $\tau$  为 0.07，特征维度为 128。在微调中正则化因子  $\mu_f$  取 0.01，学习率为 0.0001，迭代周期为 200，选择 SGD 作为优化算法，对应的动量为 0.9，批尺寸为 128。

对于 PHM2012 轴承数据集和重庆大学齿轮数据集，字典大小  $K + 1$  分别为 3201 和 1025。

表 4.4 重庆大学齿轮数据集实验设置

交替对比 (无剩余使用寿命标签参与训练)	微调 (有剩余使用寿命标签参与训练)	测试数据
齿轮 2、齿轮 3	50% 齿轮 4 数据	齿轮 1
齿轮 1、齿轮 4	50% 齿轮 3 数据	齿轮 2
齿轮 1、齿轮 4	50% 齿轮 2 数据	齿轮 3
齿轮 2、齿轮 3	50% 齿轮 1 数据	齿轮 4

#### 4.3.1.4 评价指标

评价指标为 RMSE 和 MAE。

$$\text{MAE} = \frac{1}{n} \sum_{i=1}^n |\text{Act}RUL_i - \widehat{RUL}_i|, \quad (4.14)$$

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (\text{Act}RUL_i - \widehat{RUL}_i)^2}, \quad (4.15)$$

其中  $\text{Act}RUL_i$  是第  $i$  个样本的剩余使用寿命真实值， $\widehat{RUL}_i$  是第  $i$  个样本的剩余使用寿命预测值。RMSE 和 MAE 越高，表示模型性能越差。

#### 4.3.1.5 基线模型

由于目标是在少量标签数据下进行剩余使用寿命预测，本章选择了 4 种自监督方法和 6 种监督方法来更好地展示方法的性能。原因如下：

- (1) 自监督方法。目前在少量标签数据下进行剩余使用寿命预测的研究主要采用自监督思路，利用大量的无标签数据辅助少量标签数据进行预测。本章选择 4 个自监督方法作为对比，分别为 SSPCL<sup>[109]</sup>、SSL<sup>[110]</sup>、DeepSSL<sup>[111]</sup>、USL<sup>[112]</sup>。SSPCL 是该领域首个自监督工作，通过数据增强进行对比。SSL 是首次采用估计任意两段状态检测数据时间间隔的自监督工作。USL 则是基于 SSL 的改进工作。DeepSSL 则是首次采用状态检测数据预测的自监督工作。以上四种方法代表了该领域最为经典的三种自监督架构。
- (2) 监督方法。仅通过自监督学习方法的对比实验尚不足以全面评估模型性能。为系统验证所提算法在少量标签数据条件下对剩余使用寿命预测的提升作用，必须引入先进的监督学习方法作为对比。选择 CABLSTM<sup>[170]</sup>、2DLSTM<sup>[171]</sup>、MSGCNN-TR<sup>[172]</sup>、HA-

ConvLSTM<sup>[173]</sup>、CVT-FT<sup>[107]</sup>和 MSECNN-BIGRU<sup>[108]</sup>作为对比方法。其中 CABLSTM、MSECNN-BIGRU、MSGCNN-TR 侧重挖掘时域退化特征，而 2DLSTM、HA-ConvLSTM、CVT-FT 则侧重于挖掘时频退化特征，同时这六种方法又分别代表以 LSTM、CNN、Transformer 为核心的模型设计架构。

下面是四种自监督方法的详细介绍。

- (1) **SSPCL<sup>[109]</sup>**: 一种通过数据增强的对比自监督学习方法。在预训练阶段，在所有的传感器数据的数据增强变体中搜索与当前传感器数据最相似的变体。
- (2) **SSL<sup>[110]</sup>**: 在预训练阶段估计任意两个状态检测数据片段之间的时间间隔，从而学习传感器数据的时间相关性。
- (3) **DeepSSL<sup>[111]</sup>**: 使用 GRU 设计编码和解码架构，在预训练阶段执行传感器数据的时间预测。
- (4) **USL<sup>[112]</sup>**: 利用状态检测数据采样间隔从无标签样本中学习退化信息，同时利用少量带标签的状态检测数据对模型加以约束。

下面是六种监督方法的详细介绍。

- (1) **CABLSTM<sup>[170]</sup>**: 一种基于卷积注意机制的双向长短期记忆网络，用于轴承的端到端寿命预测。首先，输入信号通过 CNN 进行处理以获取特征信息。其次，将获得的特征信息输入带有注意机制的双向 LSTM 网络中。
- (2) **2DLSTM<sup>[171]</sup>**: 一种基于二维 LSTM 的融合网络用于剩余使用寿命预测。2DLSTM 用于逐一提取传感器数据的深度时频特征，使用信息融合单元来融合多传感器特征以预测轴承的剩余使用寿命。
- (3) **MSGCNN-TR<sup>[172]</sup>**: 一种具有多尺度门控 CNN 的 Transformer 预测模型，用于预测滚动轴承的剩余使用寿命。
- (4) **HA-ConvLSTM<sup>[173]</sup>**: 一种基于注意力的混合多小波系数融合方法，用于评估轴承的剩余使用寿命。首先，使用多小波对原始信号进行分解。其次，设计了基于注意力的混合 ConvLSTM 网络，自适应地加权小波系数通道。最后，通过多层感知机利用学习到的特征来评估剩余使用寿命。
- (5) **CVT-FT<sup>[107]</sup>**: 一种用于预测轴承剩余使用寿命的条件变分 Transformer 模型。利用两个 Transformer 生成网络分别提取退化特征，第一个 Transformer 生成网络用于获取与剩余使用寿命最相关的退化特征，并最小化两个 Transformer 生成网络的特征分布差异。在预测时使用第二个 Transformer 生成网络进行预测。
- (6) **MSECNN-BIGRU<sup>[108]</sup>**: 一种用于预测轴承剩余使用寿命的基于多尺度高效通道注意力卷积神经网络和双向门控循环单元的混合架构，利用多尺度

卷积神经网络提取多尺度退化特征，然后利用双向门控循环单元刻画时间演变模式。

#### 4.3.1.6 实验公平性说明

本章问题设置涉及大量无标签的传感器数据和少量的带剩余使用寿命标签的传感器数据。监督方法使用与所提算法在微调中一致的训练数据，而自监督方法在两个阶段都使用与所提算法一致的训练数据。大量无标签的传感器数据对每种方法都是开放的，只是对监督方法而言，有效利用无标签的传感器数据比较困难。此外，在微调中，所提算法使用的标签数据与监督方法中使用的标签数据完全相同。因此，所提算法与监督方法以及自监督方法的所有比较都是公平的。

表 4.5 PHM2012 轴承数据集中所提算法与自监督方法对比实验的 RMSE

轴承	SSL	SSPCL	DeepSSL	USL	所提算法
轴承 1_3	0.326	0.698	0.497	0.552	<b>0.281</b>
轴承 1_4	0.283	0.370	0.288	0.285	<b>0.215</b>
轴承 1_5	0.453	0.512	0.407	0.412	<b>0.332</b>
轴承 1_6	0.449	0.509	0.402	0.377	<b>0.379</b>
轴承 1_7	0.726	0.831	0.639	0.662	<b>0.424</b>
轴承 2_3	<b>0.920</b>	1.018	0.973	0.976	0.988
轴承 2_4	0.569	0.573	0.675	0.449	<b>0.487</b>
轴承 2_5	0.572	0.590	0.683	0.600	<b>0.447</b>
轴承 2_6	0.553	0.598	0.666	0.428	<b>0.368</b>
轴承 2_7	0.888	0.370	0.509	0.437	<b>0.323</b>
轴承 3_3	0.577	<b>0.463</b>	0.503	0.644	0.515
均值	0.574	0.594	0.567	0.529	<b>0.433</b>

#### 4.3.2 实验结果和分析

##### 4.3.2.1 与自监督方法对比

所提算法和 4 个自监督方法在 PHM2012 轴承数据集和重庆大学齿轮数据集上进行了对比验证，在训练时都使用了大量无标签的传感器数据以及少量带标签的传感器数据。实验结果如表 4.5、表 4.6、表 4.7 和表 4.8 所示。所提算法在 PHM2012 轴承数据集和重庆大学齿轮数据集上均实现了最佳的性能。在 PHM2012 轴承数据集中，所提算法的平均 RMSE 和 MAE 分别为 0.433 和 0.369，

表 4.6 PHM2012 轴承数据集中所提算法与自监督方法对比实验的 MAE

轴承	SSL	SSPCL	DeepSSL	USL	所提算法
轴承 1_3	0.280	0.637	0.413	0.469	<b>0.213</b>
轴承 1_4	0.246	0.303	0.250	0.244	<b>0.161</b>
轴承 1_5	0.372	0.429	0.332	0.338	<b>0.283</b>
轴承 1_6	0.368	0.426	0.328	0.309	<b>0.314</b>
轴承 1_7	0.667	0.778	0.570	0.589	<b>0.360</b>
轴承 2_3	<b>0.873</b>	0.968	0.929	0.932	0.945
轴承 2_4	0.490	0.489	0.610	0.368	<b>0.402</b>
轴承 2_5	0.493	0.515	0.618	0.526	<b>0.376</b>
轴承 2_6	0.472	0.517	0.600	0.350	<b>0.302</b>
轴承 2_7	0.839	0.302	0.421	0.357	<b>0.276</b>
轴承 3_3	0.500	<b>0.381</b>	0.534	0.575	0.426
均值	0.509	0.522	0.510	0.460	<b>0.369</b>

表 4.7 重庆大学齿轮数据集中所提算法与自监督方法对比实验的 RMSE

齿轮	SSL	SSPCL	DeepSSL	USL	所提算法
齿轮 1	0.342	0.308	0.357	0.316	<b>0.293</b>
齿轮 2	0.328	0.353	0.316	0.323	<b>0.301</b>
齿轮 3	0.392	0.373	0.427	0.375	<b>0.324</b>
齿轮 4	0.359	0.415	0.340	0.349	<b>0.335</b>
均值	0.355	0.362	0.360	0.341	<b>0.313</b>

而次优的 RMSE 和 MAE 分别为 USL 的 0.529 和 0.460。与次优结果对比, 在 RMSE 上所提算法降低了 0.096, 在 MAE 上所提算法降低了 0.091。在重庆大学齿轮数据集中, 所提算法的平均 RMSE 和 MAE 分别为 0.313 和 0.266, 而次优的 RMSE 和 MAE 分别为 USL 的 0.341 和 0.283。与次优结果对比, 在 RMSE 上所提算法降低了 0.028, 在 MAE 上所提算法降低了 0.017。实验结果表明在相同的数据集设置下, 相较于其他自监督方法的预训练任务, 本章设计的交替对比过程更加有效。交替对比最大化了同一时刻多传感器特征相似度, 提升了退化特征关于剩余使用寿命的区分度。以 SSL、SSPCL、DeepSSL 和 USL 为代表的自监督剩余使用寿命预测算法通常通过堆叠多传感器数据并利用不同退化阶段间传感器数据的差异来构建预训练任务。然而, 当不同退化阶段的传感器数据比较

表 4.8 重庆大学齿轮数据集中所提算法与自监督方法对比实验的 MAE

齿轮	SSL	SSPCL	DeepSSL	USL	所提算法
齿轮 1	0.283	0.262	0.294	0.267	<b>0.253</b>
齿轮 2	0.281	0.289	0.270	0.271	<b>0.258</b>
齿轮 3	0.321	0.304	0.349	0.307	<b>0.272</b>
齿轮 4	0.296	0.339	0.283	0.289	<b>0.279</b>
均值	0.295	0.299	0.299	0.283	<b>0.266</b>

相似时，这些工作可能难以提取到高区分度的退化特征，而所提算法则可以通过交替对比来最大化同一时刻多传感器特征相似度，从而提高退化特征的区分度，最终实现更好性能。

图 4.10 显示了轴承 1\_3、轴承 1\_4、轴承 2\_7 的剩余使用寿命预测情况。图中红色为剩余使用寿命真值，绿色为平滑后的剩余使用寿命预测值。首先从图中可以看出所提算法能大体上跟随剩余使用寿命真值的变化，尤其是图 4.10(b)。这证明了所提算法的有效性，能够利用少量的带剩余使用寿命标签数据即可准确的预测剩余使用寿命。其次可以发现相较于轴承退化的末期，所提算法在轴承退化的早期表现不是特别理想，尤其在图 4.10(a) 和图 4.10(c) 中表现更为明显。这也说明了研究故障预警任务的必要性。图 4.10(a) 中早期的剩余使用寿命预测值近似水平直线。这是因为在训练时只使用了少量的退化末期的带标签数据，导致退化早期的剩余使用寿命预测性能下降。但是从实际应用的角度出发，退化末期的剩余使用寿命预测更具有价值，因此总体来说所提算法还是有效的。

图 4.11 展示了轴承 1\_3 的 t-SNE 降维后的退化特征分布。蓝色和绿色代表退化的早期阶段，黄色和橙色代表退化的中期阶段，红色代表退化的末期阶段。首先可以看出整个退化过程是平滑过渡的，左侧是以蓝绿色为主的早期退化特征，中间是黄色和橙色的中期退化特征，右侧是以红色为主的末期退化特征。这说明所提算法可以有效捕获轴承的退化模式。其次可以看出早期退化特征和末期退化特征在特征空间中存在明显的距离，这说明所提算法可以有效区分退化的早期阶段和末期阶段。

#### 4.3.2.2 与监督方法对比

为了进一步分析利用大量无标签数据的有效性和必要性，所提算法和 6 个监督方法在 PHM2012 轴承数据集和重庆大学齿轮数据集上进行了对比验证。实验设置中所提算法与监督方法使用相同的带标签传感器数据，但是额外引入大量的无标签传感器数据。实验结果如表 4.9、表 4.10、表 4.11 和表 4.12 所示。所提算法在 PHM2012 轴承数据集和重庆大学齿轮数据集上均实现了最佳的性

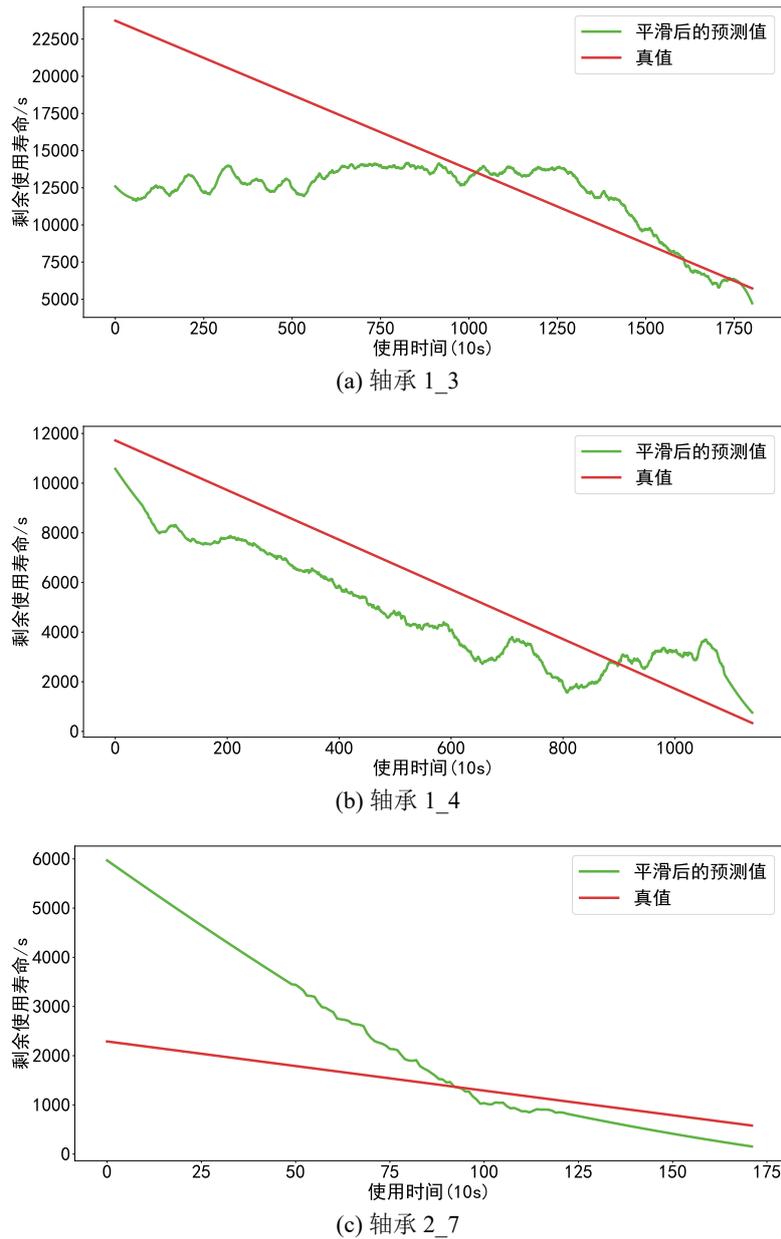


图 4.10 轴承剩余使用寿命预测曲线图

能。在 PHM2012 轴承数据集中，所提算法的平均 RMSE 和 MAE 分别为 0.433 和 0.369，而次优的 RMSE 和 MAE 分别为 MSECNN-BIGRU 的 0.610 和 0.542。与次优结果对比，在 RMSE 上所提算法降低了 0.177，在 MAE 上所提算法降低了 0.173。在重庆大学齿轮数据集中，所提算法的平均 RMSE 和 MAE 分别为 0.313 和 0.266，而次优的 RMSE 和 MAE 分别为 MSECNN-BIGRU 的 0.377 和 0.310。与次优结果对比，在 RMSE 上所提算法降低了 0.064，在 MAE 上所提算法降低了 0.054。首先，上述结果证明利用大量无标签数据可以有效提高模型预测的性能。在相同的带标签数据前提下，相较于以 MSECNN-BIGRU 为代表的监督方法，所提算法利用设计的交替对比过程充分从大量的无标签传感器数据中建模关键部件的退化模式，从而获得一个具有良好退化特征提取能力的预训练模型。

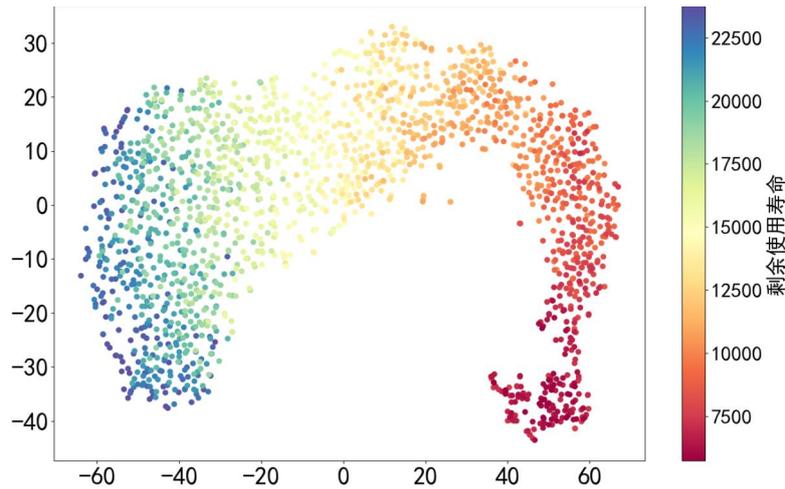


图 4.11 t-SNE 降维后轴承 1\_3 的特征分布

这种训练策略可以有效降低对带标签传感器数据的依赖。其次，充分利用大量无标签数据是非常必要的。自监督方法在 PHM2012 轴承数据集的最差 RMSE 为 0.594，最差 MAE 为 0.522；在重庆大学齿轮数据集上的最差 RMSE 为 0.362，最差 MAE 为 0.299。而监督方法的最佳结果也略逊于上述自监督方法的最差结果。这表明当仅有少量带标签传感器数据时，监督方法的性能相较于自监督方法更加保守。监督方法通常依赖大量带标签的传感器数据来刻画关键部件退化模式，面对有限的带标签的传感器数据时刻画的退化模式会出现较大的偏差，而自监督方法则可通过预训练任务利用大量的无标签传感器数据有效的刻画关键部件退化模式。

### 4.3.3 模型性能分析

#### 4.3.3.1 消融实验

为了更好地解释所提算法的优越性以及分析方法优越性的原因，本章设计了消融实验，构建了以下两种变体。

- (1) **Variant-NP:** 为验证交替对比的有效性，跳过交替对比，直接使用少量带标签的数据训练模型，其余内容保持不变。
- (2) **Variant-Loss:** 为验证对比损失的有效性，将对比损失替换为用于计算同一时刻不同传感器之间特征差异的 MSE 损失，其余内容保持不变。

表 4.13 和表 4.14 展示了所提算法和两种变体在 PHM2012 轴承数据集以及重庆大学齿轮数据集上的 RMSE 和 MAE 来验证所提算法中交替对比和对比损失的有效性。首先为验证交替对比的有效性，所提算法与没有交替对比的 Variant-NP 进行比较。与 Variant-NP 相比，所提算法在所有的齿轮和轴承上均取得了更加的预测效果。在 PHM2012 轴承数据集上所提算法的平均 RMSE 降低了 0.233，平均 MAE 降低了 0.235；在重庆大学齿轮数据集上所提算法的平均 RMSE 下降

表 4.9 PHM2012 轴承数据集中所提算法与监督方法对比实验的 RMSE

轴承	CAB	2D	MSGCNN	HA-Conv	CVT-FT	MSECNN	所提算法
	LSTM	LSTM	-TR	LSTM		-BIGRU	
轴承 1_3	0.542	0.789	0.496	0.853	0.691	0.441	<b>0.281</b>
轴承 1_4	0.278	0.316	0.282	0.582	0.369	0.268	<b>0.215</b>
轴承 1_5	0.411	0.561	0.576	0.628	0.510	0.639	<b>0.332</b>
轴承 1_6	0.405	0.547	0.573	0.622	0.505	0.633	<b>0.379</b>
轴承 1_7	0.645	0.951	0.777	1.028	0.827	0.516	<b>0.424</b>
轴承 2_3	0.966	1.160	1.157	1.017	<b>0.822</b>	1.011	0.988
轴承 2_4	0.783	0.776	0.771	0.518	0.783	0.505	<b>0.487</b>
轴承 2_5	0.606	0.714	0.711	0.633	0.560	0.630	<b>0.447</b>
轴承 2_6	0.781	0.775	0.768	0.499	0.500	0.562	<b>0.368</b>
轴承 2_7	0.888	0.871	0.840	<b>0.291</b>	0.650	0.888	0.323
轴承 3_3	0.789	0.735	0.780	0.601	0.732	0.613	<b>0.515</b>
均值	0.645	0.745	0.703	0.661	0.632	0.610	<b>0.433</b>

了 0.120，平均 MAE 下降了 0.086。这意味着交替对比能够通过捕获跨传感器不变特征从而有效地减少对带标签传感器数据的需求，从而显著提高所提算法的剩余使用寿命预测性能。其次为验证对比损失的有效性，所提算法与使用 MSE 损失函数而不是对比损失函数的 Variant-Loss 进行了比较。与 Variant-Loss 相比，所提算法同样在所有的齿轮和轴承上均取得了更加的预测效果。在 PHM2012 轴承数据集上所提算法 RMSE 降低了 0.200，MAE 降低了 0.198；在重庆大学齿轮数据集上所提算法的平均 RMSE 下降了 0.046，平均 MAE 下降了 0.030。MSE 损失函数通过拉近同一时刻的多传感器退化特征之间的距离来捕获跨传感器不变特征。对比损失函数则借鉴分类的思想，在提取同一时刻多传感器特征相似度的同时抑制不同时刻的多传感器特征相似度，确保提取到跨传感器不变的具有高度区分度的退化特征。进一步可以发现 Variant-Loss 相较于 Variant-NP，整体剩余使用寿命预测性能更高，这证明通过预训练可以有效利用大量的无标签数据，从而提升剩余使用寿命预测性能。

#### 4.3.3.2 不同标签数据量下方法的有效性

本章聚焦于少量标签数据下的剩余使用寿命预测问题。鉴于标签数据的稀缺性对模型性能产生的关键影响，本节将探究标签数据量与预测精度之间的关联。在实验设置中，保持交替对比中无标签数据量不变，然后调整微调中标签数

表 4.10 PHM2012 轴承数据集中所提算法与监督方法对比实验的 MAE

轴承	CAB	2D	MSGCNN	HA-Conv	CVT-FT	MSECNN	所提算法
	LSTM	LSTM	-TR	LSTM		-BIGRU	
轴承 1_3	0.460	0.734	0.416	0.803	0.627	0.358	<b>0.213</b>
轴承 1_4	0.242	0.262	0.242	0.505	0.302	0.222	<b>0.161</b>
轴承 1_5	0.335	0.480	0.475	0.558	0.427	0.570	<b>0.283</b>
轴承 1_6	0.330	0.452	0.464	0.551	0.422	0.563	<b>0.314</b>
轴承 1_7	0.577	0.906	0.639	0.986	0.774	0.432	<b>0.360</b>
轴承 2_3	0.922	1.123	1.120	0.975	<b>0.746</b>	0.970	0.945
轴承 2_4	0.727	0.720	0.714	0.434	0.727	0.421	<b>0.402</b>
轴承 2_5	0.532	0.653	0.650	0.563	0.480	0.559	<b>0.376</b>
轴承 2_6	0.726	0.718	0.712	0.416	0.409	0.486	<b>0.302</b>
轴承 2_7	0.839	0.821	0.788	<b>0.252</b>	0.551	0.839	0.276
轴承 3_3	0.734	0.676	0.724	0.527	0.672	0.542	<b>0.426</b>
均值	0.584	0.686	0.631	0.597	0.558	0.542	<b>0.369</b>

表 4.11 重庆大学齿轮数据集中所提算法与监督方法对比实验的 RMSE

齿轮	CAB	2D	MSGCNN	HA-Conv	CVT-FT	MSECNN	所提算法
	LSTM	LSTM	-TR	LSTM		-BIGRU	
齿轮 1	0.437	0.420	0.336	0.573	0.306	0.359	<b>0.293</b>
齿轮 2	0.394	0.380	0.352	0.564	0.400	0.394	<b>0.301</b>
齿轮 3	0.367	0.506	0.366	0.571	0.404	0.348	<b>0.324</b>
齿轮 4	0.374	0.370	0.415	0.568	0.449	0.408	<b>0.335</b>
均值	0.393	0.419	0.367	0.569	0.390	0.377	<b>0.313</b>

据量, 包括 10%, 30%, 50%, 从而分析标签数据量对模型性能的影响。图 4.12 和图 4.13 展示了不同标签数据量下模型在 PHM2012 轴承数据集和重庆大学齿轮箱数据集上的 RMSE 和 MAE, 多边形所包围的面积越大对应的模型性能越差。首先从图 4.12(a)、图 4.12(b)、图 4.13(a) 和图 4.13(b) 可以看出随着微调阶段标签数据量的下降, 封闭多边形所包围的面积也越来越大, 这说明模型总体性能也越来越差。其次可以看出随着微调阶段标签数据量的下降, 每个轴承和齿轮上的预测指标都在下降, 这说明标签数据量对模型性能有着强烈的且稳定的影响。

表 4.12 重庆大学齿轮数据集中所提算法与监督方法对比实验的 MAE

齿轮	CAB	2D	MSGCNN	HA-Conv	CVT-FT	MSECNN	所提算法
	LSTM	LSTM	-TR	LSTM		-BIGRU	
齿轮 1	0.357	0.342	0.279	0.494	0.259	0.296	<b>0.253</b>
齿轮 2	0.321	0.311	0.291	0.485	0.326	0.322	<b>0.258</b>
齿轮 3	0.302	0.422	0.300	0.492	0.330	0.288	<b>0.272</b>
齿轮 4	0.306	0.303	0.339	0.489	0.369	0.332	<b>0.279</b>
均值	0.322	0.345	0.302	0.490	0.321	0.310	<b>0.266</b>

表 4.13 PHM2012 轴承数据集中所提算法消融实验结果

轴承	RMSE			MAE		
	Variant-NP	Variant-Loss	所提算法	Variant-NP	Variant-Loss	所提算法
轴承 1_3	0.624	0.570	<b>0.281</b>	0.557	0.498	<b>0.213</b>
轴承 1_4	0.308	0.294	<b>0.215</b>	0.262	0.255	<b>0.161</b>
轴承 1_5	0.463	0.422	<b>0.332</b>	0.379	0.342	<b>0.283</b>
轴承 1_6	0.468	0.446	<b>0.379</b>	0.384	0.364	<b>0.314</b>
轴承 1_7	0.747	0.673	<b>0.424</b>	0.685	0.571	<b>0.360</b>
轴承 2_3	1.151	1.135	<b>0.988</b>	1.114	1.097	<b>0.945</b>
轴承 2_4	0.760	0.730	<b>0.487</b>	0.703	0.670	<b>0.402</b>
轴承 2_5	0.701	0.699	<b>0.447</b>	0.639	0.636	<b>0.376</b>
轴承 2_6	0.756	0.723	<b>0.368</b>	0.698	0.662	<b>0.302</b>
轴承 2_7	0.804	0.694	<b>0.323</b>	0.749	0.630	<b>0.276</b>
轴承 3_3	0.545	0.575	<b>0.515</b>	0.479	0.509	<b>0.426</b>
均值	0.666	0.633	<b>0.433</b>	0.604	0.567	<b>0.369</b>

#### 4.3.3.3 超参数敏感性分析

为了进一步分析对模型性能影响的因素，本章进行了模型的超参数敏感性分析，其中字典尺寸作为最关键的超参数被选择。图 4.14 展示了字典尺寸对模型性能的影响。从图 4.14(a) 和图 4.14(b) 可以看出，随着字典尺寸的增加，预测误差逐步减少。这是因为在交替对比中，字典尺寸越大，主传感器特征与相同时刻的辅传感器特征匹配就越困难。更具有挑战性的预训练任务可以增强模型提取跨传感器不变特征的能力。

表 4.14 重庆大学齿轮数据集中所提算法消融实验结果

齿轮	RMSE			MAE		
	Variant-NP	Variant-Loss	所提算法	Variant-NP	Variant-Loss	所提算法
齿轮 1	0.412	0.416	<b>0.293</b>	0.336	0.338	<b>0.253</b>
齿轮 2	0.526	0.353	<b>0.301</b>	0.423	0.289	<b>0.258</b>
齿轮 3	0.414	0.318	<b>0.324</b>	0.338	0.270	<b>0.272</b>
齿轮 4	0.380	0.349	<b>0.335</b>	0.310	0.286	<b>0.279</b>
均值	0.433	0.359	<b>0.313</b>	0.352	0.296	<b>0.266</b>

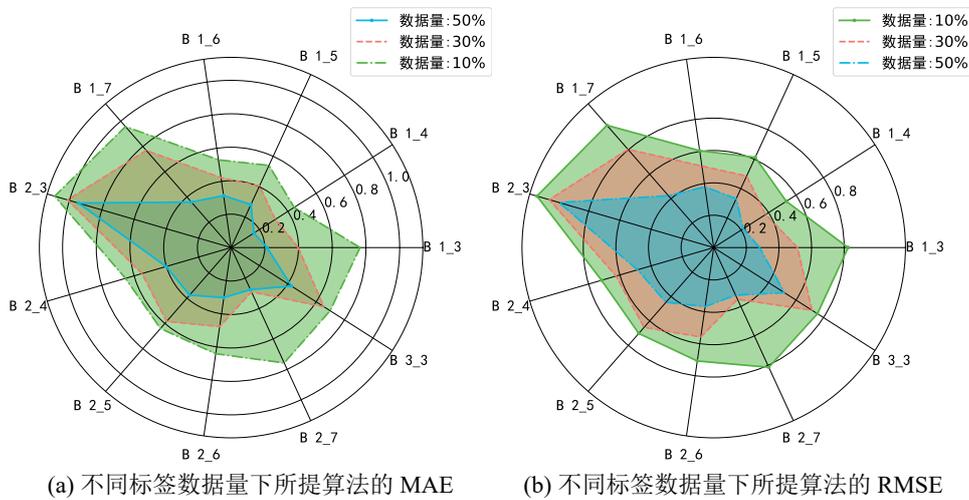


图 4.12 PHM2012 数据集中不同标签数据量下所提算法的指标

#### 4.3.3.4 算法时间复杂度分析

在 PHM2012 轴承数据集和重庆大学齿轮数据集中，所提算法在推理时单个样本的 FLOPs 均为 1.14G。这主要源于这两个数据集均包含两个传感器，因此特征提取器均为双分支，具有相同的模型结构。进一步的，双分支特征提取器的 FLOPs 约为 1.13G。可以看出，所提算法的复杂度主要集中在双分支特征提取器。由于特征提取器的复杂度与分支数量，即多传感器数量，线性相关，因此当传感器数量过多时，可能会存在时间复杂度过高的风险。但是关键部件的传感器数量通常不会太多，因此整体上仍是可接受的。

#### 4.3.4 算法应用讨论

所提算法在 PHM2012 轴承数据集和重庆大学齿轮数据集上验证了有效性和泛化性能。由于 PHM2012 轴承数据集和重庆大学齿轮数据集与锡膏印刷机中轴承、齿轮的真实情况仍旧存在一定差异，因此所提算法在锡膏印刷场景下

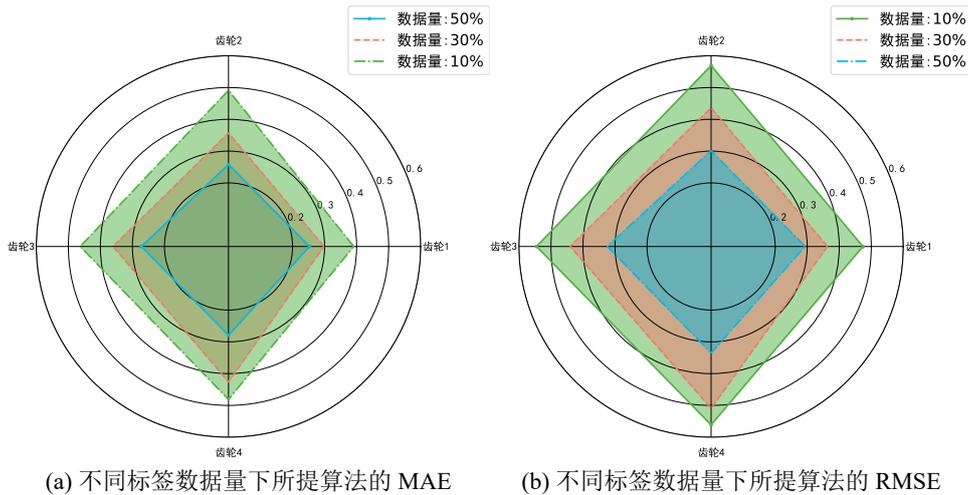


图 4.13 重庆大学齿轮数据集中不同标签数据量下所提算法的指标

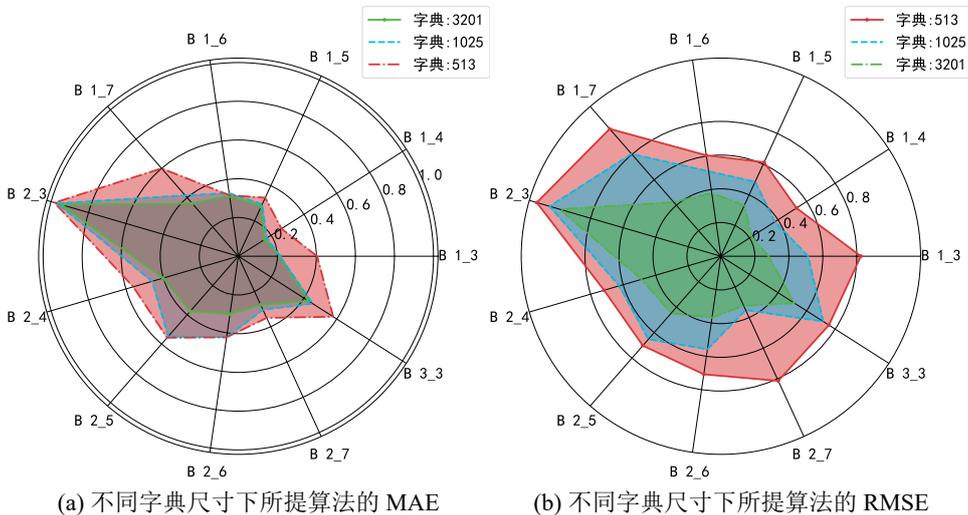


图 4.14 PHM2012 数据集中不同字典尺寸下所提算法的指标

可能会出现性能下降。但是所提算法仍然具备一定的工程应用价值，原因如下。首先，相较于以 CABLSTM、MSGCNN-TR、MSECNN-BIGRU、2DLSTM、HA-ConvLSTM、CVT-FT 等为代表的监督方法，本章研究的场景更贴合真实工厂中标签数据难以获取的场景，所提算法的自监督架构可充分利用大量的无标签数据来建模关键部件的退化模式，相较于监督方法可大幅提高预测性能。其次，相较于以 SSPCL、SSL、DeepSSL、USL 为代表的自监督方法，所设计的交替对比过程利用跨传感器相似度可有效提高退化特征的区分度，从而提高所提算法的适应性。最后，所提算法即便在锡膏印刷机轴承、齿轮上性能有所下降，在实际应用中仍可采用较保守的维护策略来实现所提算法的应用价值，比如相较于所预测的剩余使用寿命，更早的进行维护。综上所述，所提算法在锡膏印刷场景下仍具有一定的有效性和工程应用价值，同时有力推动了剩余使用寿命预测的工

程应用。

#### 4.4 本章小结

本章针对少量标签数据下关键部件剩余使用寿命预测问题,提出了一种基于多传感器交替对比的锡膏印刷关键部件剩余使用寿命预测算法,该方法设计了一种交替对比过程,可以利用大量无标签的传感器数据,辅助少量带有剩余使用寿命标签的传感器数据进行高性能的剩余使用寿命预测。相较于以 CABLSTM、MSGCNN-TR、MSECNN-BIGRU、2DLSTM、HA-ConvLSTM、CVT-FT 等为代表的监督方法,所提算法采用自监督架构,可以从监督学习难以利用的大量无标签数据中建模关键部件的退化模式,从而提高剩余使用寿命预测的性能。相较于以 SSPCL、SSL、DeepSSL、USL 为代表的自监督方法,所提算法中交替对比过程利用跨传感器相似度可以挖掘跨传感器不变特征,从而显著提高退化特征区分度。具体来说,在交替对比过程中,将 ResNet18 的主干网络作为特征提取器,将特征映射到共现空间内。在共现空间中,任意传感器作为主传感器,其余传感器作为辅传感器,然后计算主传感器特征与辅传感器特征之间的相似度,并优化对比损失,使在同一时刻的主传感器特征与辅传感器特征最相似,从而获得主传感器与辅传感器之间的跨传感器不变特征。重复上述过程,直到每个传感器都充当主传感器,从而获得高度判别的退化特征。然后,通过使用少量的带剩余使用寿命标签数据对模型进行微调。最终利用丰富的无标签传感器数据辅助稀缺标签样本实现剩余使用寿命预测。最后,在公开的 PHM2012 轴承数据集和重庆大学齿轮数据集上全面评估了所提算法。在测试数据上,本章提出的算法优于其他最先进的基线模型,这表明本章提出的算法可以利用丰富的无标签传感器数据来辅助少数带有剩余使用寿命标签的传感器数据进行剩余使用寿命预测。同时,剩余使用寿命预测结果图也证明了研究关键部件早期故障预警任务的必要性,即在退化初期关键部件的剩余使用寿命预测存在较大偏差。本章构建了稀缺标签样本下剩余使用寿命预测模型,实现了利用大量无标签数据捕获轴承的退化特征,解决了已有自监督方法利用不同退化阶段间传感器数据差异性来设计预训练任务导致退化特征区分度不足的问题。

## 第5章 基于 PCB 布局图卷积的锡膏印刷参数预警算法

针对锡膏印刷机故障，第三章和第四章分别构建了关键部件早期故障预警以及剩余使用寿命预测算法，分阶段预警其早期故障和完全失效时间，从而实现了锡膏印刷机故障预警。接下来本章面向引起锡膏印刷异常另一主要因素，锡膏印刷参数不当，开展锡膏印刷参数预警研究，旨在通过预测锡膏印刷机无硬件故障状态下的锡膏印刷质量异常来间接预警锡膏印刷参数不当。考虑到锡膏印刷质量受 PCB 布局的影响，本章提出一种基于 PCB 布局图卷积的锡膏印刷参数预警算法，其核心是将 PCB 布局转换成图以建模 PCB 上焊盘分布对锡膏印刷质量的影响，从而实现准确预警锡膏印刷参数不当。在实验设计部分，本章在私有的锡膏印刷机无故障状态下 6 天 11365 条的锡膏印刷质量数据集上验证了所提算法的预测精度，然后分析了所提算法各个模块的有效性。

本章结构安排如下：5.1 节分析了 PCB 布局对锡膏印刷质量的影响；5.2 节介绍了本章提出的基于 PCB 布局图卷积的锡膏印刷参数预警算法；5.3 节介绍了上述算法的实验结果与分析；最后 5.4 节总结本章内容。

### 5.1 PCB 布局对锡膏印刷质量的影响分析

焊盘的位置如图 5.1 所示。可以看出，焊盘 A 与焊盘 B 相邻，而焊盘 D 则远离焊盘 A。焊盘 C 与焊盘 A 具有相同的局部结构。这是因为工厂通常采用 PCB 拼板策略，即同时印刷多个相同的 PCB，然后沿着预定的裁板线进行切割。图中的黑色虚线就是裁板线。由于尺寸和分辨率的限制，这里只显示了 PCB 裁板线两侧的两幅局部图像。需要注意的是，这里的裁板线仅用于说明情况。

PCB 布局对锡膏印刷质量的影响体现在邻域相似性和局部结构依赖性。具体来说，图 5.1(b)、图 5.1(c) 和图 5.1(d) 分别显示了四个焊盘的锡膏印刷体积、X 方向偏移量和 Y 方向偏移量的曲线。可以看出，焊盘 A、B 和 C 在三个锡膏印刷质量属性方面表现出相似的趋势，而焊盘 D 则存在一些差异。这是因为焊盘 A 和 B 相邻，印刷质量变化遵循邻域相似性原则。焊盘 A 和 C 显示出相同的局部结构。元件间距是影响锡膏印刷质量的关键因素。因此，尽管它们相距甚远，即使不在同一块 PCB 上，也能表现出相似的印刷质量。焊盘 D 由于与焊盘 A 的距离以及局部结构不一致而显示出一些差异。

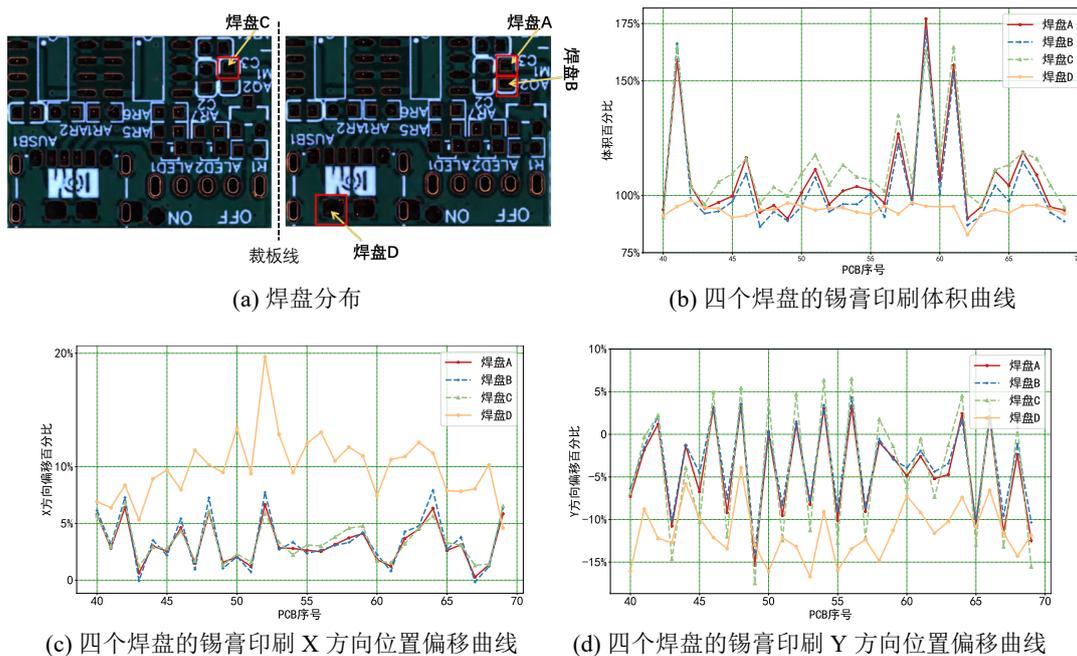


图 5.1 四个焊盘的锡膏体积、X 方向位置偏移和 Y 方向位置偏移曲线

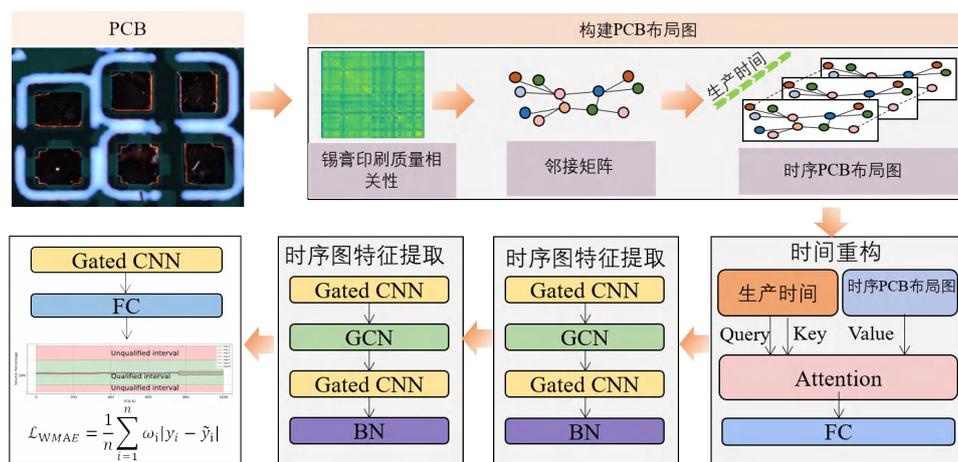


图 5.2 基于 PCB 布局图卷积的锡膏印刷参数预警算法框图

## 5.2 算法设计

由于锡膏印刷参数不当和锡膏印刷机故障是最主要的锡膏印刷异常原因，因此当锡膏印刷机无硬件故障时，如果出现锡膏印刷质量异常，那么就可以认为出现了锡膏印刷参数不当。由于相邻生产的同型号 PCB 锡膏印刷质量具有一定的相似性，因此可以根据过去的锡膏印刷质量预测未来的印刷质量变化。而 SMT 工厂会持续进行锡膏印刷，同时检查每块 PCB 的锡膏印刷质量，因此积累了大量可用的锡膏印刷质量数据。本章任务是为了预测未来  $T$  块同型号 PCB 锡膏印刷质量是否会出现异常以预警是否出现锡膏印刷参数不当，首先，基于大量的同型号 PCB 锡膏印刷质量数据构建锡膏印刷参数预警模型。然后，给定从过

去至现在一段时间内的同型号 PCB 锡膏印刷质量数据，所构建的锡膏印刷参数预警模型即可判断未来  $T$  块同型号 PCB 内是否会出现锡膏印刷参数不当。

图 5.2 展示了基于 PCB 布局图卷积的锡膏印刷参数预警算法的框架。它由构建 PCB 布局图、时间重构和时序图特征提取三部分组成。构建 PCB 布局图是通过锡膏印刷质量相关性将 PCB 的焊盘分布转换为加权图，以模拟 PCB 的焊盘分布，然后将锡膏印刷质量按照生产时间顺序，依次堆叠。时间重构是根据生产时间建立基于生产时间的注意力，模拟锡膏理化性质的时变性，以重构 PCB 时序特征。时序图特征提取则是建模锡膏印刷质量的时间临近性和 PCB 焊盘分布对锡膏印刷质量的影响。下面将详细介绍基于 PCB 布局图卷积的锡膏印刷参数预警算法。

### 5.2.1 构建 PCB 布局图

如图 5.3 所示，红框中的黑色区域为焊盘，在锡膏印刷中，锡膏将印刷到焊盘的位置。在时间  $t$  时，PCB 布局图  $G_t = (V_t, A)$  以图中红色框内的焊盘为节点，以表示印刷质量相关性的绿线为边。 $V_t = [x_t^1, \dots, x_t^M] \in \mathbb{R}^M$ ， $V_t$  是图的节点， $M$  表示焊盘的数量， $x_t^i \in \mathbb{R}$ ， $i = 1, \dots, M$ ， $x_t^i$  表示第  $i$  个焊盘在时刻  $t$  的质量特征。 $A$  是通过边聚合得到的邻接矩阵。

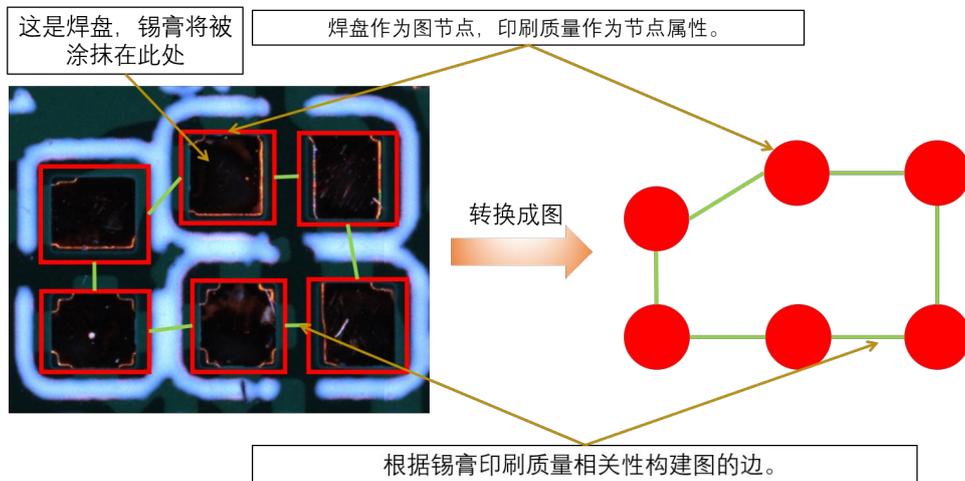


图 5.3 将 PCB 转换成图的示意图

下面将介绍邻接矩阵  $A$  的设计。首先，本章选择 Pearson 相关系数来分析锡膏印刷质量。计算公式如下，

$$c_{i,j} = \frac{\sum_{t=t_1}^{t_N} (x_t^i - \mu_{t_1,t_N}^i) (x_t^j - \mu_{t_1,t_N}^j)}{\sigma_{t_1,t_N}^i \sigma_{t_1,t_N}^j}, \quad (5.1)$$

其中  $X_{t_1,t_N}^i = [x_{t_1}^i, x_{t_1+1}^i, \dots, x_{t_N}^i] \in \mathbb{R}^{N \times 1}$  表示从时刻  $t_1$  到时刻  $t_N$  的第  $i$  个焊盘上锡膏印刷质量的集合。 $\mu_{t_1,t_N}^i$  是  $X_{t_1,t_N}^i$  的均值， $\sigma_{t_1,t_N}^i$  是  $X_{t_1,t_N}^i$  的方差。

然后本章引入一个阈值函数  $T_\lambda(c)$ ，当相关性  $c_{i,j}$  小于  $\lambda$  时，删去图中的对

应边。阈值函数  $T_\lambda(c)$  表示如下。

$$T_\lambda(c_{i,j}) = \begin{cases} c_{i,j} & c_{i,j} \geq \lambda \text{ and } i \neq j \\ 0 & c_{i,j} < \lambda \text{ and } i \neq j \\ 0 & i = j \end{cases} \quad (5.2)$$

由此获得表示 PCB 布局的邻接矩阵  $A$ 。

$$A = \begin{pmatrix} T_\lambda(c_{1,1}) & \cdots & T_\lambda(c_{1,M}) \\ \vdots & \ddots & \vdots \\ T_\lambda(c_{M,1}) & \cdots & T_\lambda(c_{M,M}) \end{pmatrix} \in \mathbb{R}^{M \times M}. \quad (5.3)$$

然后将每个焊盘上的锡膏印刷质量按照生产时间顺序排列最终获得时序 PCB 布局图。

由于拼板策略导致相隔较远的焊盘也存在较高的锡膏印刷质量相似性，而基于焊盘位置构建 PCB 布局图会导致距离越远节点间的相关性越弱，与现状不符，因此本章没有选择基于焊盘位置构建 PCB 布局图。

### 5.2.2 时间重构

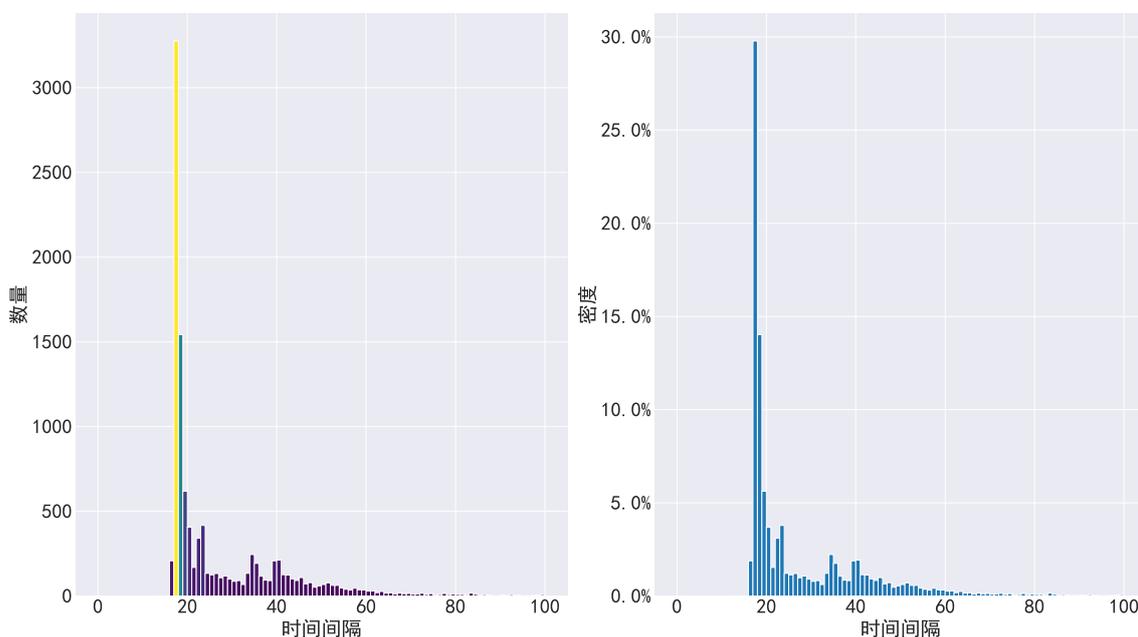


图 5.4 生产时间间隔分布

锡膏是影响印刷质量的主要因素之一，其物理和化学性质会随着时间的推移而逐渐发生变化<sup>[174-175]</sup>。锡膏印刷生产间隔并非恒定不变的，如图 5.4 所示绝大部分的生产时间间隔小于 20s，但是仍然有很多的生产间隔分布离散，且间隔较长。因此，需要考虑时间对印刷质量的影响。让实际生产时间向量  $\mathbf{t} =$

$[t_1, t_2, \dots, t_N] \in \mathbb{R}^{1 \times N}$ , 首先对向量  $\mathbf{t}$  进行归一化, 公式如下,

$$i_i = \frac{t_i - t_1}{t_N - t_1}, i = 1, \dots, N. \quad (5.4)$$

得到归一化生产时间向量  $\mathbf{i} = [i_1, i_2, \dots, i_N] \in \mathbb{R}^{1 \times N}$ 。为了模拟生产时间对锡膏印刷质量的影响, 通过生产时刻计算时间注意力, 并以时间注意力为基础的加权形式重构锡膏印刷质量特征。

编码归一化生产时间向量  $\mathbf{i}$ ,

$$e_k = W_1 \mathbf{i} + b_1 \in \mathbb{R}^{d \times N}, \quad (5.5)$$

$$e_q = W_1' \mathbf{i} + b_1' \in \mathbb{R}^{d \times N}, \quad (5.6)$$

其中,  $W_1 \in \mathbb{R}^{d \times 1}$ ,  $b_1 \in \mathbb{R}^d$ ,  $W_1' \in \mathbb{R}^{d \times 1}$ ,  $b_1' \in \mathbb{R}^d$  为可训练参数,  $d$  表示编码维数。

用下式计算基于生产时间的注意力矩阵  $Att$ 。

$$Att = \text{LeakyRelu}(e_k^T W_k^T) \text{LeakyRelu}(W_q e_q), \quad (5.7)$$

其中  $W_k \in \mathbb{R}^{d \times d}$  和  $W_q \in \mathbb{R}^{d \times d}$  是可训练参数,  $\text{LeakyRelu}$  是非线性激活函数。

然后使用  $\text{Softmax}$  对  $Att$  进行约束, 将锡膏之间的注意力得分转换为  $[0, 1]$  之间的概率分布, 同时突出锡膏之间的关系。

$$Att'_{i,j} = \frac{\exp(Att_{i,j})}{\sum_{j=1}^N \exp(Att_{i,j})}. \quad (5.8)$$

最后, 得到的注意力矩阵  $Att'$  用于重建从时刻  $t_1$  到时刻  $t_N$  的第  $i$  个锡膏的特征  $X_{t_1, t_N}^i$ 。

$$X_{t_1, t_N}^{i'} = Att' X_{t_1, t_N}^i, \quad (5.9)$$

其中,  $X_{t_1, t_N}^{i'} = [x_{t_1}^{i'}, \dots, x_{t_N}^{i'}] \in \mathbb{R}^{N \times 1}$ ,  $X_{t_1, t_N}^{i'}$  表示重建的锡膏印刷特征、将重建的特征构建成图  $G_i' = (V_i', A)$ ,  $V_i' = [x_{t_1}^{i'}, \dots, x_{t_N}^{i'}]$ , 作为时空图卷积的输入。

### 5.2.3 时序图特征提取

为了捕捉锡膏印刷质量时间临近性以及 PCB 焊盘分布对锡膏印刷质量的影响, 构建了一个时序图特征提取模块。如图所示, 每个时序图特征提取模块由两个门控卷积神经网络 (Gated Convolution Neural Network, Gated CNN)、一个图卷积网络和一个批归一化层 (Batch Normalization Layer, BN Layer) 组成。

Gated CNN 在时间维度上学习单个锡膏的印刷质量变化模式, 具体表现如下。

$$y_c^i = (W_{c1} * x_c^i + b_{c1}) \otimes \sigma(W_{c2} * x_c^i + b_{c2}), \quad (5.10)$$

其中  $W_{c1}$  和  $W_{c2}$  是卷积核,  $b_{c1}$  和  $b_{c2}$  是偏置, 它们都是可训练参数,  $\sigma$  是非线性激活函数 Sigmoid,  $\otimes$  是矩阵间元素的乘积,  $x_c^i$  表示第  $i$  层 Gated CNN 的输入,  $y_c^i$  表示第  $i$  层 Gated CNN 的输出。

GCN 建模 PCB 焊盘分布对锡膏印刷质量的影响, 如下式所示。

$$y_g^i = g_\theta *_{\mathcal{G}} x_g^i = g_\theta(L) x_g^i = g_\theta(U \Lambda U^T) x_g^i = U g_\theta(\Lambda) U^T x_g^i, \quad (5.11)$$

其中  $g_\theta$  是核,  $*_{\mathcal{G}}$  是图卷积运算,  $L$  是归一化拉普拉斯矩阵,  $x_g^i$  表示第  $i$  层的 GCN 输入,  $y_g^i$  是第  $i$  层的 GCN 输出。

$$L = I_M - D^{-\frac{1}{2}} A D^{-\frac{1}{2}} = U \Lambda U^T \in \mathbb{R}^{M \times M}, \quad (5.12)$$

其中  $U$  是正则化邻接矩阵  $L$  的特征向量矩阵,  $D_{ii} = \sum_j A_{ij}$ 。由于运算复杂度较高, 需要对上式进行简化。

$$y_g^i = g_\theta *_{\mathcal{G}} x_g^i = g_\theta(L) x_g^i \approx \sum_{k=0}^{K-1} \theta_k T_k(\tilde{L}) x_g^i, \quad (5.13)$$

其中  $T_k(\tilde{L})$  是  $\tilde{L} = \frac{2L}{\lambda_{max}} - I_M$  的  $k$  阶切比雪夫近似值。  $\lambda_{max}$  是  $L$  的最大特征值。进一步假设  $\lambda_{max} \approx 2$ ,

$$y_g^i \approx \theta_0 x_g^i + \theta_1 (L - I_M) x_g^i \approx \theta_0 x_g^i - \theta_1 (D^{-\frac{1}{2}} A D^{-\frac{1}{2}}) x_g^i. \quad (5.14)$$

让  $\theta_0 = -\theta_1$ , 然后

$$y_g^i \approx \theta_0 (I_M + D^{-\frac{1}{2}} A D^{-\frac{1}{2}}) x_g^i \approx \theta_0 \tilde{D}^{-\frac{1}{2}} \tilde{A} \tilde{D}^{-\frac{1}{2}} x_g^i, \quad (5.15)$$

其中  $\tilde{A} = A + I_M$ ,  $\tilde{D}_{ii} = \sum_j \tilde{A}_{ij}$ 。

#### 5.2.4 损失函数

令最后一层 Gated CNN 的输出为  $y_c^5$ , 经过全连接层后得到最终输出。

$$\tilde{g} = \sigma_o(W_f y_c^5 + b_f). \quad (5.16)$$

考虑到锡膏印刷参数不当发生频率较低, 锡膏印刷质量异常样本远少于正常样本, 因此必须增加异常样本的权重以防止虚假的低误差指标, 这里设计了加权平均绝对误差  $\mathcal{L}_{WMAE}$ 。

$$\mathcal{L}_{WMAE} = \frac{1}{TM} \sum_t \sum_i \omega_N (1 - C_i^t) |y_i^t - \tilde{y}_i^t| + \omega_P C_i^t |y_i^t - \tilde{y}_i^t|, \quad (5.17)$$

其中  $C_i^t$  是  $t$  时刻的第  $i$  个锡膏质量类别标签, 异常标签为 1, 正常标签为 0;  $y_i^t$  是  $t$  时刻的第  $i$  个锡膏质量;  $\tilde{y}_i^t$  是相应的预测值;  $\omega_P$  是异常样本的类别权重,  $\omega_N$  是正常样本的类别权重。

总损失函数如下：

$$\mathcal{L} = \mathcal{L}_{WMAE} + \mu \|\theta\|_2, \quad (5.18)$$

其中  $\theta$  是模型的参数， $\mu$  是超参数， $\|\cdot\|_2$  表示正则化。

基于 PCB 布局图卷积的锡膏印刷参数预警算法的优化过程如算法 5.1 所示。

---

**算法 5.1 基于 PCB 布局图卷积的锡膏印刷参数预警算法**


---

**Input:**  $N$  个 PCB 的历史锡膏印刷质量数据  $G_1, G_2, \dots, G_N$ , 滑动窗口为  $W$ , 预测窗口为  $T$ , 滑动步长为 1.

**Output:** 锡膏印刷质量预测值  $\tilde{g}$ , 预测模型  $Model$

```

/* 数据处理：将锡膏印刷质量数据转换成图 */
1 根据公式 (5.1) 计算锡膏印刷质量相关性
2 根据公式 (5.2) 和公式 (5.3) 计算邻接矩阵
/* 构建锡膏印刷质量预测数据集 */
3  $\mathcal{G} \leftarrow \emptyset$ 
4 for  $n \in [0, 1, \dots, N - W - T]$  do
5     选择起始时刻为  $n$ , 长度为  $W + T$  的序列  $(G_n, G_{n+1}, \dots, G_{W-1}, \dots, G_{W+T-1})$ 
6      $\mathcal{G} \leftarrow \mathcal{G} \cup (G_n, G_{n+1}, \dots, G_{W-1}, \dots, G_{W+T-1})$ 
7      $(G_n, G_{n+1}, \dots, G_{W-1})$  是输入,  $(G_W, \dots, G_{W+T-1})$  是标签
8 end
9 随机初始化预测模型  $Model$ 
10 while 网络收敛 do
11     根据公式 (5.4) 到公式 (5.9) 计算基于生产时间的注意力
12     根据公式 (5.10) 到公式 (5.12) 提取锡膏印刷质量时序图的特征
13     根据公式 (5.16) 预测未来锡膏印刷质量
14     根据公式 (5.17) 和公式 (5.18) 优化预测模型  $Model$  的参数
15 end
/* 锡膏印刷参数预警 */
16 将锡膏印刷质量预测结果与生产质量标准比较以判断锡膏印刷参数是否不当
    
```

---

## 5.3 实验结果与分析

### 5.3.1 数据集和实验设置

#### 5.3.1.1 数据集描述

在锡膏印刷过程中，相对于 PCB 焊盘，X 和 Y 方向都有可能出现偏差。此外，锡膏体积也可能偏离生产质量标准。因此，检查印刷结果至关重要。从生产线上收集了锡膏印刷机无故障下 6 天锡膏印刷质量检测数据，经过数据清理后获得了 11,365 条可用检测记录。每个 PCB 包含 3152 个焊盘的锡膏印刷检测结果，每个检测结果包含锡膏体积、锡膏在 X 方向的位置偏移量、锡膏在 Y 方向的位置偏移量以及其他检测内容。本章根据三种典型的异常情况进行锡膏印

刷参数预警：少锡、X方向位置偏移缺陷和Y方向位置偏移缺陷。少锡与脱模速度、印刷间距、清洁频率等印刷参数设定不当强相关，占比总样本18.79%，Y方向偏移缺陷与Y方向偏移补偿设定不当强相关，占比总样本1.29%，X方向偏移缺陷与X方向偏移补偿设定不当强相关，占比总样本0.25%。使用滑动窗口处理数据，将窗口大小设为40，滑动步长设为1，预测窗口大小 $T$ 设为1或5。65%的数据被划分为训练集，35%的数据被划分为测试集。

### 5.3.1.2 数据分析

图5.5展示了本章使用的PCB布局，每个点代表一个元件。首先可以看出元件的分布是不均匀的，不同区域元件密度差异较大。其次由于同时印刷两块PCB，左右两侧关于裁板线旋转对称。从图5.5中可以看出，元件PC133\_1和PC133\_2是旋转对称，共享相同的局部结构，元件LA2\_1则是与PC133\_1位于相同的PCB，但距离较远。这三个元件都是2个引脚，即两个待印刷的焊盘(PC133\_1\_1, PC133\_1\_2, PC133\_2\_1, PC133\_2\_2, LA2\_1\_1和LA2\_1\_2)。

图5.6、图5.7、图5.8展示了元件PC133\_1、PC133\_2和LA2\_1在锡膏体积，锡膏X方向位置偏移，锡膏Y方向位置偏移的相关性。首先从图5.6中可以看出，元件PC133\_1、PC133\_2和LA2\_1内部各自引脚对应的焊盘间都存在很好的线性相关，如PC133\_1\_1和PC133\_1\_2，这证明相邻的焊盘锡膏体积变化是相似的。其次可以看出元件PC133\_1和PC133\_2不同元件间各自引脚对应的焊盘，如PC133\_1\_1, PC133\_2\_1，同样也具有较高的线性相关性。LA2\_1两个焊盘和PC133\_1和PC133\_2的4个焊盘的相关性明显较弱。这说明局部结构对锡膏体积有显著影响。

图5.7则呈现出与图5.6不一样的相关性分布，图5.7的相关性整体分布明显更强。这是因为PCB是沿着X方向进入锡膏印刷机，导致所有焊盘上锡膏的X方向位置偏移都具有较高的相关性。

图5.8的相关性分布与图5.6的相似。相邻焊盘以及具有相同局部结构焊盘之间具有很高的锡膏Y方向位置偏移相关性。距离较远，且局部结构不相似的焊盘间，锡膏Y方向位置偏移呈现出非常弱的特点。

### 5.3.1.3 实验指标

选择F1分数来衡量模型的性能。F1分数是模型对锡膏印刷参数不当的漏报率和误报率的总体衡量标准。F1分数范围为[0,1]。当F1分数为1时，表示该模型可以完美预警锡膏印刷参数不当。当F1分数为0时，表示模型崩溃，完全无法预警锡膏印刷异常。

为了计算F1分数，引入了真阳性(TP)、真阴性(TN)、假阳性(FP)和假阴

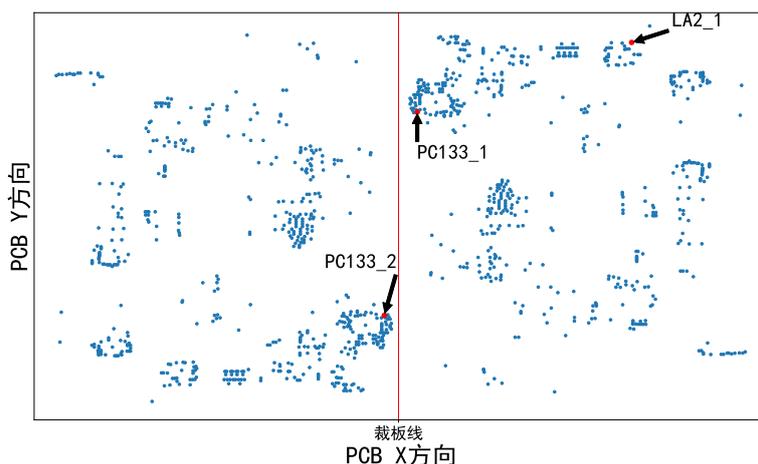


图 5.5 PCB 元件分布示意图

性 (FN)。有关 TP、TN、FP 和 FN 的详细信息如下。

- (1) TP: 准确预警的锡膏印刷参数不当的数量。
- (2) TN: 准确预警的锡膏印刷参数合理的数量。
- (3) FP: 被错误预警为锡膏印刷参数不当的合格数量。
- (4) FN: 被错误预警为锡膏印刷参数合理的异常数量。

如公式 (5.19) 所示, Recall 衡量的是漏报率。如公式 (5.20) 所示, Precision 用于衡量误报率。F1 分数是 Recall 和 Precision 的组合。

$$\text{Recall} = \frac{\text{TP}}{\text{TP} + \text{FN}}, \quad (5.19)$$

$$\text{Precision} = \frac{\text{TP}}{\text{TP} + \text{FP}}, \quad (5.20)$$

$$\text{F1} = \frac{2 \cdot \text{Recall} \cdot \text{Precision}}{\text{Recall} + \text{Precision}}. \quad (5.21)$$

#### 5.3.1.4 实验超参数

正则化系数  $\mu$  为 0.002, 正常样本的类别权重  $\omega_N$  为 1。批大小为 32, 学习率为 0.001。训练周期设置为 80。其他超参数如表 5.1 所示。

#### 5.3.1.5 基线方法

为证明所提算法的有效性, 本章选择了 8 个方法进行比较, 原因如下。

- (1) 问题相似性。当前锡膏印刷参数预警的工作比较少, 因此选择了 IAP<sup>[128]</sup>、DTCWT-LSTM<sup>[124]</sup> 这 2 个与本章研究问题高度相似的方法。
- (2) 时序预测方法的应用。锡膏印刷参数预警的本质仍然是时序问题, 因此选择 GRU<sup>[176]</sup>、LSTM<sup>[177]</sup> 这两个最经典的时序预测方法。

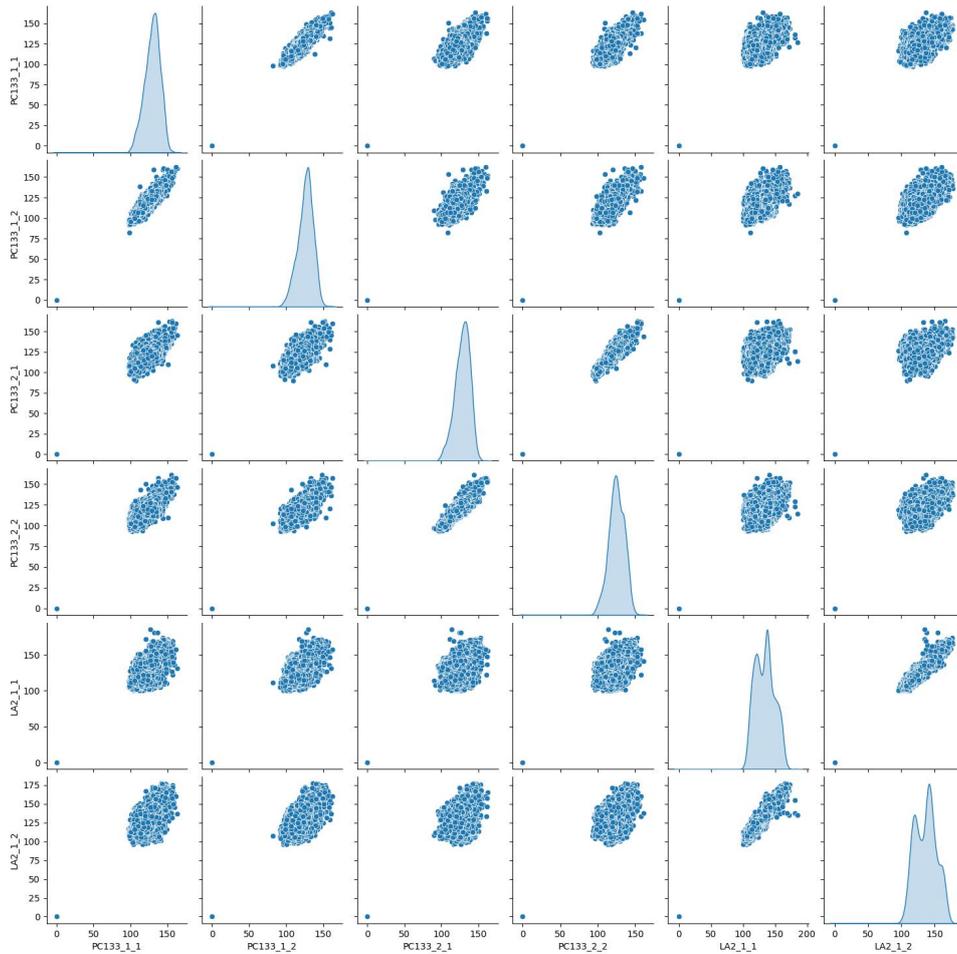


图 5.6 锡膏印刷体积相关性分析

表 5.1 模型超参数

锡膏印刷质量属性	$T = 5$		$T = 1$	
	$\omega_p$	$\lambda$	$\omega_p$	$\lambda$
X 方向位置偏移	250	0.3	500	0.3
Y 方向位置偏移	225	0.2	225	0.2
体积	40	0.4	20	0.4

(3) 空间建模方法的应用。为了验证将 PCB 布局建模成图的有效性，选择了 2-DConvLSTMAE<sup>[178]</sup>、MRFGCN<sup>[179]</sup>这二种方法进行对比，其中 2-DConvLSTMAE 将 PCB 网格化，而 MRFGCN 则是将 PCB 建模成图。

以下是对比方法的具体介绍。

- (1) **IAP<sup>[128]</sup>**: 手动设计特征，然后采用自适应增强技术，预警锡膏印刷参数不当。
- (2) **DTCWT-LSTM<sup>[124]</sup>**: 使用双树复小波变换对原始锡膏印刷质量数据进行过滤和重构，然后设计人工特征作为 LSTM 的输入进行预测。

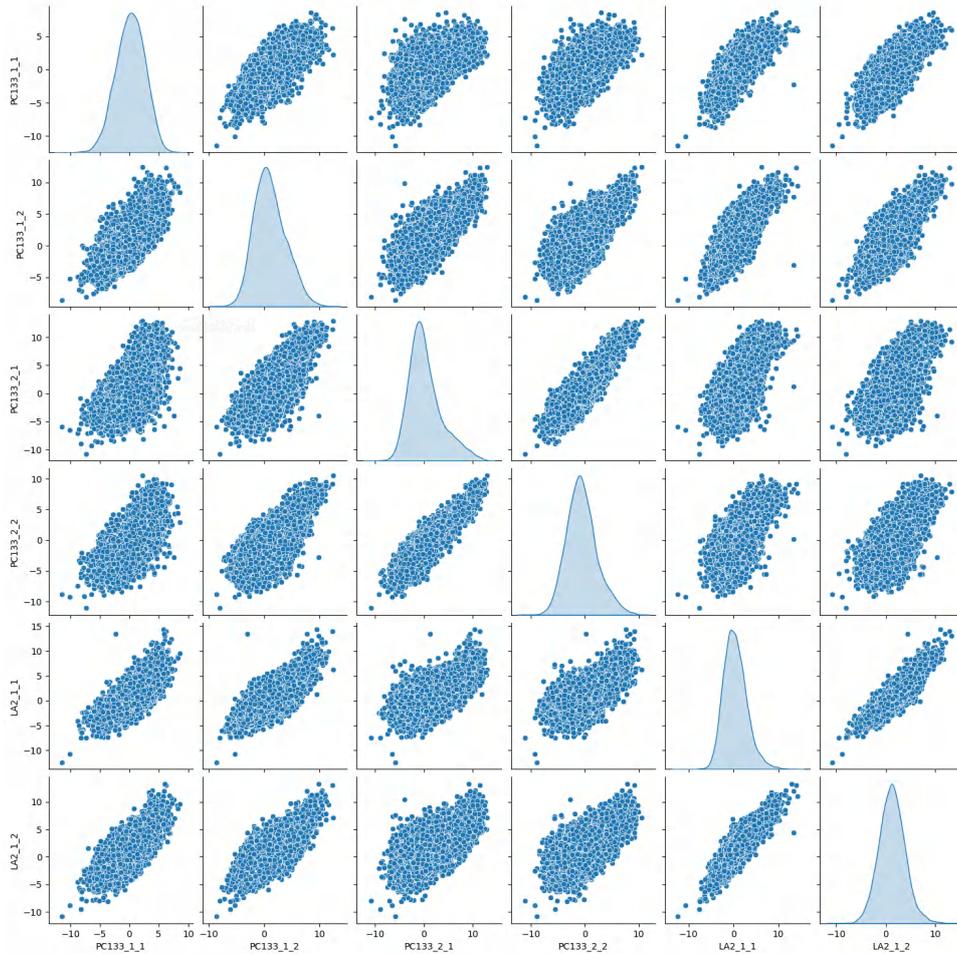


图 5.7 锡膏印刷 X 方向偏移相关性分析

- (3) **GRU-Single**<sup>[176]</sup>: 利用 GRU 搭建锡膏印刷参数预警模型, 每次输入一个焊盘的时序锡膏印刷质量数据, 输出未来时刻的锡膏印刷质量。然后将预测结果与生产质量标准进行比较, 从而预警锡膏印刷参数不当。
- (4) **GRU-Global**<sup>[176]</sup>: 利用 GRU 搭建锡膏印刷参数预警模型, 每次输入整个 PCB 的时序锡膏印刷质量数据, 输出未来时刻的整个 PCB 锡膏印刷质量。然后将预测结果与生产质量标准进行核对, 从而预警锡膏印刷参数不当。
- (5) **LSTM-Single**<sup>[177]</sup>: 利用 LSTM 搭建锡膏印刷参数预警模型, 每次输入一个焊盘的时序锡膏印刷质量数据, 输出未来时刻的锡膏印刷质量。然后将预测结果与生产质量标准进行比较, 从而预警锡膏印刷参数不当。
- (6) **LSTM-Global**<sup>[177]</sup>: 利用 LSTM 搭建锡膏印刷参数预警模型, 每次输入整个 PCB 的时序锡膏印刷质量数据, 输出未来时刻的整个 PCB 锡膏印刷质量。然后将预测结果与生产质量标准进行核对, 从而预警锡膏印刷参数不当。
- (7) **2-DConvLSTMAE**<sup>[178]</sup>: 通过 ConvLSTM 学习时间序列的时间临近性和网格划分的空间关系, 然后将预测结果与生产质量标准进行比较, 从而预警

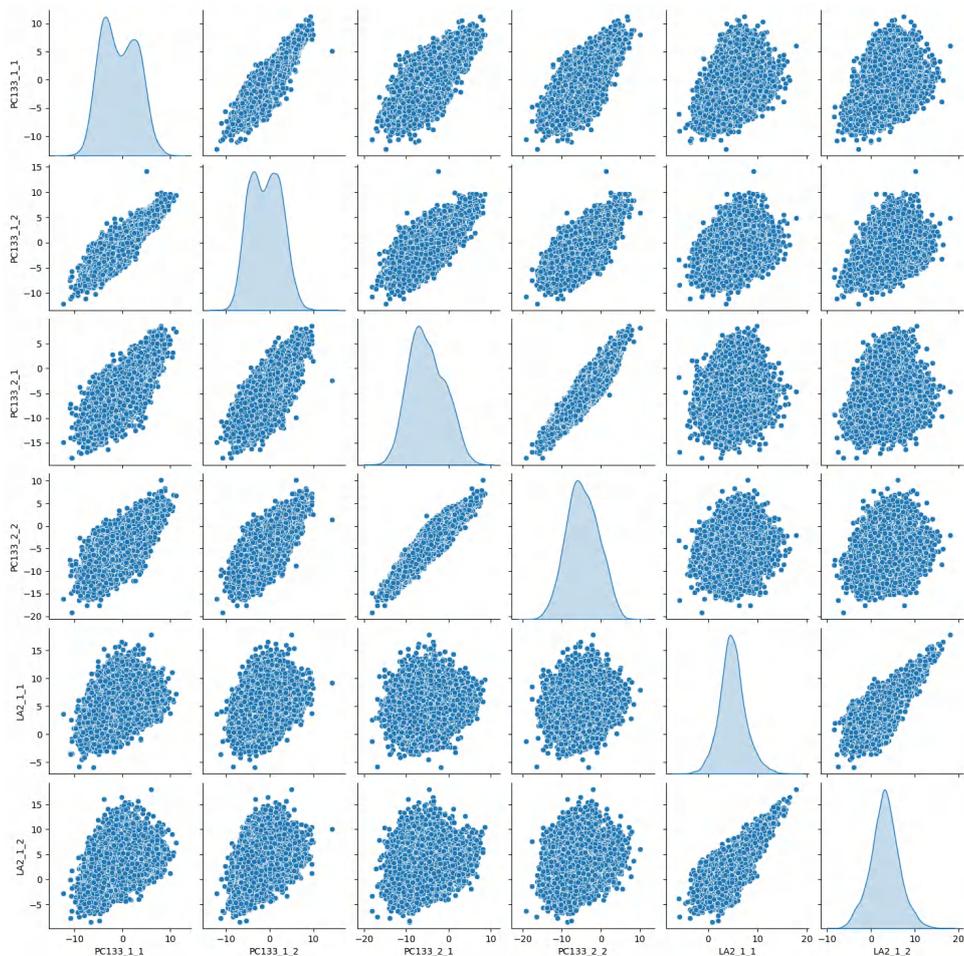


图 5.8 锡膏印刷 Y 方向偏移相关性分析

锡膏印刷参数不当。

- (8) **MRFGCN**<sup>[179]</sup>: 多感受野图卷积网络使用多个图的感受域来学习异常特征, 并融合所学特征进行特征增强, 从而预警锡膏印刷参数不当。

### 5.3.2 实验结果和分析

#### 5.3.2.1 与基线方法对比

表 5.2 显示了基线算法和所提算法在不同时间步长下锡膏印刷参数预警的实验结果。从总体来说, 所提算法的平均 F1 分数为 0.311, 取得最优效果, 次优的实验结果为 MRFGCN, 平均 F1 分数为 0.254, 所提算法的 F1 分数提升了 0.057。一方面这说明算法的有效性, 另一方面 MRFGCN 取得次优效果, 说明了将 PCB 布局转换成图的有效性。已有的锡膏印刷参数预警方法 IAP、DTCWT-LSTM 和时序数据预测方法 GRU-Single、LSTM-Single、GRU-Global、LSTM-Global 均具有较强的时序特征提取能力, 但是所提算法仍然取得较大的性能提升。这主要源于所提算法不仅仅考虑锡膏印刷质量的时序模式, 同时进一步考虑了焊盘分布的影响, 将 PCB 上焊盘的分布转换成图, 从而建模了这种影响。空间建模方

法 MRFGCN 和 2-DConvLSTMAE 中, MRFGCN 也可以取得较好的效果, 这说明将 PCB 布局建模成图这一思路的正确性, 有助于提高锡膏印刷参数预警的性能。但是同样考虑了 PCB 布局的空间分布, 2-DConvLSTMAE 则效果较差, 这是源于 2-DConvLSTMAE 强行将 PCB 划分成网格以建模 PCB 布局对锡膏印刷质量的影响, 这会破坏 PCB 布局的不规则结构, 反而恶化了锡膏印刷参数预警性能。这说明在建模 PCB 布局对锡膏印刷质量的影响时, 应该尽可能的遵循 PCB 布局天然的不规则性, 从而才能提升锡膏印刷参数预警性能。从具体的印刷参数不当类型来说, 在基于 X 方向偏移缺陷预警锡膏印刷参数不当方面, 当  $T = 1$  时, 所提算法的 F1 分数为 0.166, 次优的实验结果为 LSTM-Global 的 0.159, 在  $T = 5$  的情况下, 所提算法的 F1 分数为 0.521, 次优的实验结果为 LSTM-Global 的 0.513, 可以看出所提算法在两种不同时间尺度下均能实现最优的实验结果。在  $T = 1$  的情况下, 所提算法的 F1 分数提升了 0.007, 在  $T = 5$  的情况下, 所提算法的 F1 分数提升了 0.008。PCB 沿着 X 方向进入锡膏印刷机, 相较于 Y 方面偏移、锡膏体积, PCB 上锡膏 X 方向位置偏移整体相关性更高, 这也是 LSTM-Global 和 GRU-Global 在 X 方向位置偏移预测方面分别优于 LSTM-Single 和 GRU-Single 的主要原因。在基于 Y 方向偏移缺陷预警锡膏印刷参数不当方面, 当  $T = 1$  时, 所提算法的 F1 分数为 0.055, 次优的实验结果为 MRFGCN 的 0.046, 在  $T = 5$  的情况下, 所提算法的 F1 分数为 0.098, 次优的实验结果为 MRFGCN 的 0.093, 可以看出所提算法在两种不同时间尺度下均能实现最优的实验结果。在  $T = 1$  的情况下, 所提算法的 F1 分数提升了 0.009, 在  $T = 5$  的情况下, 所提算法的 F1 分数提升了 0.005。在基于 Y 方向位置偏移预测锡膏印刷参数预警方面, 所有方法都表现不佳。这是因为 Y 方向偏移相较于 X 方向偏移有更强的随机性, 所有方法都难以有效捕获到锡膏印刷 Y 方向位置偏移的变化趋势。在基于少锡预警锡膏印刷参数不当方面, 当  $T = 1$  时, 所提算法的 F1 分数为 0.493, 次优的实验结果为 MRFGCN 的 0.481, 在  $T = 5$  的情况下, 所提算法的 F1 分数为 0.532, 次优的实验结果为 GRU-Single 的 0.511, 可以看出所提算法在两种不同时间尺度下均能实现最优的实验结果。在  $T = 1$  的情况下, 所提算法的 F1 分数提升了 0.012, 在  $T = 5$  的情况下, 所提算法的 F1 分数提升了 0.021。需要指出的是, 在基于少锡预警锡膏印刷参数不当任务中, DTCWT-LSTM、GRU-Global、LSTM-Global 和 2-DConvLSTMAE 等基线模型表现出明显的性能缺陷。具体而言, 在  $T = 1$  时预测指标为 0.150, 在  $T = 5$  时预测指标为 0.382, 这些模型将所有样本都错误地判定为锡膏印刷参数不当。深入分析表明, 该性能缺陷源于锡膏体积受焊盘分布的影响, 锡膏体积之间存在复杂的非线性相关性, 其中包含大量负相关甚至无相关的特征关系。然而, 上述方法在建模过程中, 直接将所有焊盘的锡膏体积数据同时输入模型, 未施加任何约束条件, 导致模型无法有效捕捉关键特征间的

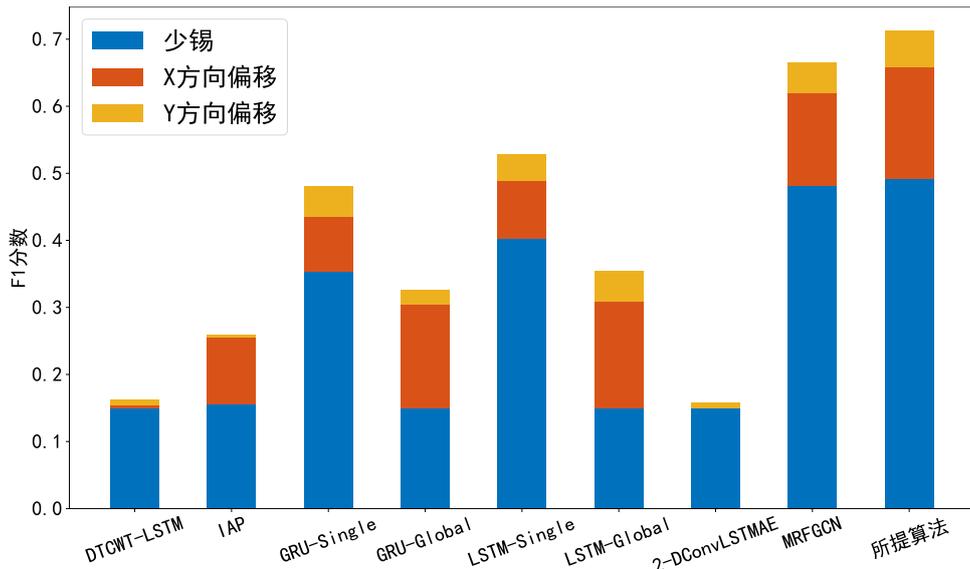
表 5.2 在两个时间尺度下所提算法与基线算法的锡膏印刷参数预警对比结果

方法	X 方向偏移缺陷		Y 方向偏移缺陷		少锡		均值
	$T = 1$	$T = 5$	$T = 1$	$T = 5$	$T = 1$	$T = 5$	
IAP	0.149	0.460	0.005	0.055	0.211	0.417	0.216
DTCWT-LSTM	0.005	0.020	0.008	0.040	0.150	0.382	0.101
GRU-Single	0.083	0.221	0.045	0.082	0.352	0.511	0.215
GRU-Global	0.155	0.513	0.021	0.088	0.150	0.382	0.218
LSTM-Single	0.086	0.290	0.039	0.083	0.403	0.506	0.235
LSTM-Global	0.159	0.513	0.046	0.070	0.150	0.382	0.220
2-DConvLSTMAE	0.000	0.102	0.008	0.040	0.150	0.382	0.114
MRFGCN	0.138	0.305	0.046	0.094	0.481	0.461	0.254
所提算法	<b>0.166</b>	<b>0.521</b>	<b>0.055</b>	<b>0.098</b>	<b>0.493</b>	<b>0.532</b>	<b>0.311</b>

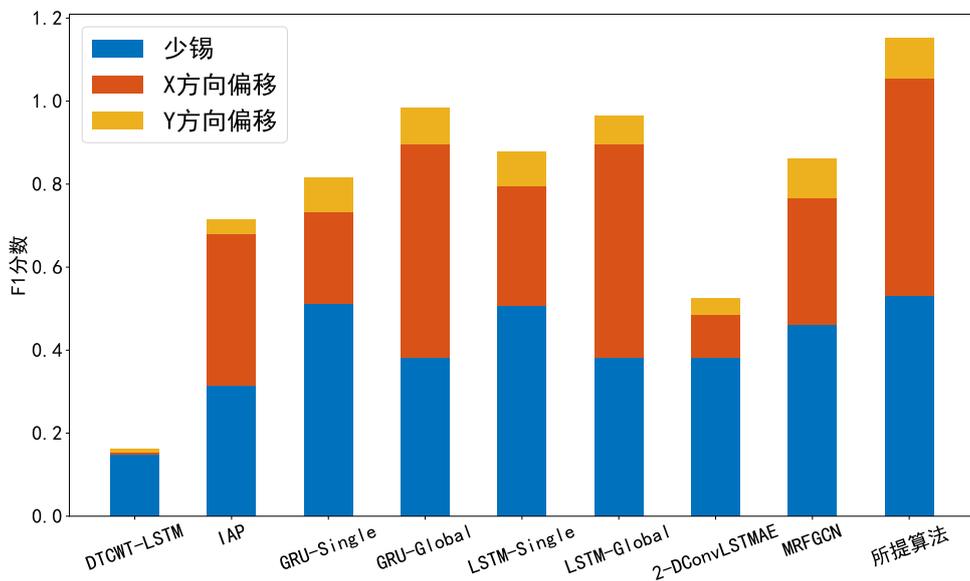
关联，从而造成锡膏印刷参数预警性能显著下降。相较于基于 X 方向和 Y 方向锡膏印刷位置偏移预警锡膏印刷参数不当，所提算法基于锡膏体积预警锡膏印刷参数不当的效果会更好。这是因为一方面 PCB 布局对锡膏体积的影响是最为显著的，锡膏通过钢网的网孔沉积到 PCB，而钢网上网孔的密度，间距，以及网孔的孔径都会对沉积过程产生显著影响。因此在考虑 PCB 焊盘分布的影响情况下，基于锡膏体积预警锡膏印刷参数不当的效果会更好。

图 5.9 展示了所有基线和所提算法在两个不同时间尺度上基于三种锡膏印刷质量属性预警锡膏印刷参数不当的总体预测结果。每个方法对应的柱状图越高，说明模型性能越好。可以看出，在  $T = 1$  和  $T = 5$  两种时间尺度下，所提算法均取得了最好的性能。

图 5.10、图 5.11、图 5.12 中依次显示了锡膏印刷过程中锡膏体积、Y 方向偏移和 X 方向偏移的预测结果。图 5.10、图 5.11、图 5.12 中的红色区域表示锡膏印刷质量超过了设定的阈值。数据脱敏后，少锡的阈值为 40%。X 方向和 Y 方向偏移的合格区间为  $[-25\%, 25\%]$ 。从图 5.11 中 Y 方向锡膏位置偏移的时间序列曲线可以看出，这些偏移缺陷主要是由严重的抖动造成的。因此，很难跟踪其恶化趋势，这也是所提算法和其他基线方法性能不佳的原因。图 5.10 和图 5.12 展示了锡膏体积和 X 方向位置偏移的时间曲线，可以明显看出锡膏体积和 X 方向位置偏移存在明显的变化趋势。因此，所提算法可实现有效的印刷参数预警结果。在早期阶段，X 方向位置偏移值较大，因此预测值也会稍大，以准确预警锡膏印刷参数不当。当后期 X 方向位置偏移值减小时，预测值也会立即减小。这表明所提算法能够捕捉质量变化的趋势。同时需要强调的是，在本章任



(a)  $T = 1$  时所有模型在三种典型异常上的预测效果



(b)  $T = 5$  时所有模型在三种典型异常上的预测效果

图 5.9 锡膏印刷参数预警性能可视化

务重点关注的是锡膏印刷参数不当。因此首要任务是能预测到锡膏印刷质量超出生产质量标准的情况，对于生产质量标准范围内的合格品，预测精度并不重要。基于此，可以看到所提算法在预测超出生产质量标准的质量异常时，展现出较为良好的性能，能够较好的预警锡膏印刷参数不当。对于合格品，虽然所提算法预测偏差较大，但仍然可以判断出这是合格品，因此这是可以接受的。

### 5.3.3 模型性能分析

#### 5.3.3.1 消融实验

为了分析所提算法的不同组成部分在锡膏印刷参数预警中的作用，本章设计了三种不同的变体，去掉部分结构，观察剩余部分的预警性能。

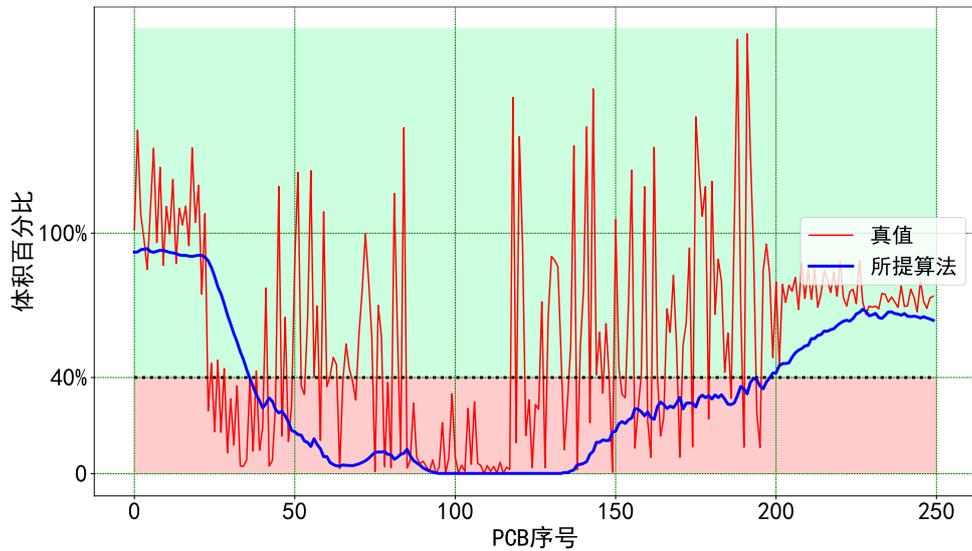


图 5.10 锡膏体积预测曲线

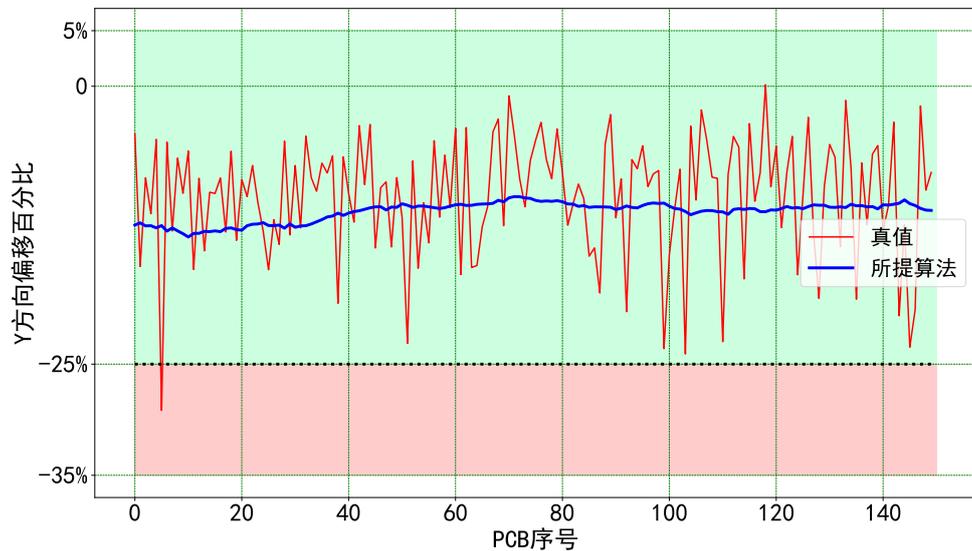


图 5.11 锡膏 Y 方向偏移预测曲线

- (1) **Variant-NTA:** 为了分析生产时间间隔对锡膏印刷参数预警的影响，删除了基于生产时间的注意力机制，其余部分保持不变。
- (2) **Variant-NGCN:** 为了分析将 PCB 焊盘分布建模为图对锡膏印刷参数预警的影响，删除了 GCN 模块，其余部分保持不变。
- (3) **Variant-NGatedCNN:** 为了分析时序图特征提取模块中时序特征提取对锡膏印刷参数预警的影响，删除了 Gated CNN 模块，其余部分保持不变。

表 5.3 展示了在两个时间尺度下锡膏印刷参数预警的消融实验结果。首先从总体来说，结合图 5.13，所提算法在六种场景下平均 F1 分数为 0.311，Variant-NTA 的平均 F1 分数为 0.270，Variant-NGCN 的平均 F1 分数 0.244，Variant-NGatedCNN 的平均 F1 分数为 0.234。所提算法是显著优于其余三种变体，次优结果为 Variant-NTA 的 0.271，至少提升了 0.04 的 F1 分数。其次，与 Variant-

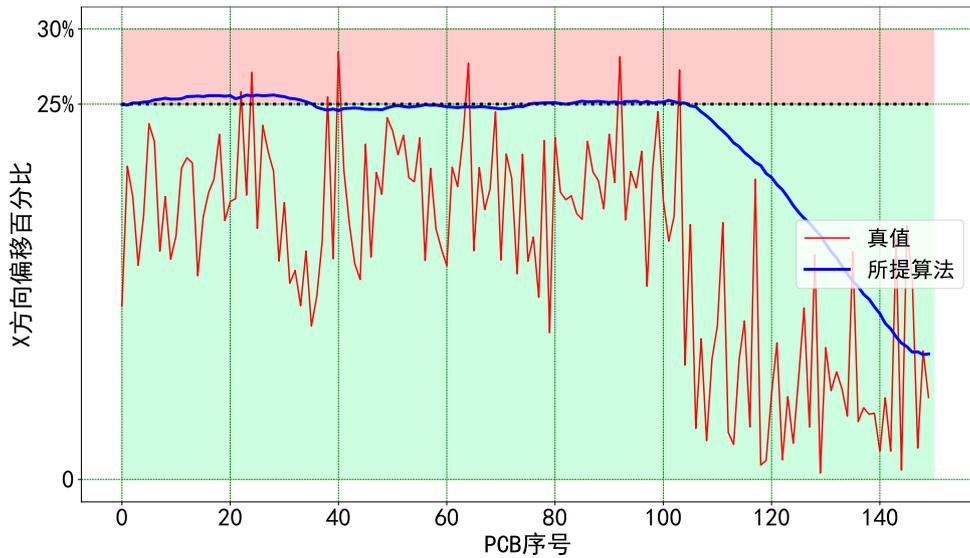


图 5.12 锡膏 X 方向偏移预测曲线

表 5.3 在两个时间尺度下所提算法的消融实验结果

方法	X 方向偏移缺陷		Y 方向偏移缺陷		少锡		均值
	$T = 1$	$T = 5$	$T = 1$	$T = 5$	$T = 1$	$T = 5$	
Variant-NTA	0.152	0.412	0.018	0.071	0.470	0.499	0.270
Variant-NGCN	0.150	0.492	0.024	0.068	0.302	0.426	0.244
Variant-NGatedCNN	0.152	0.511	<b>0.061</b>	0.057	0.242	0.382	0.234
所提算法	<b>0.166</b>	<b>0.521</b>	0.055	<b>0.098</b>	<b>0.493</b>	<b>0.532</b>	<b>0.311</b>

NTA 对比，可以发现引入基于生产时间的注意力后，锡膏印刷参数预警效果明显改善，尤其是在基于 X 方向偏移的锡膏印刷参数预警方面，当预测窗口  $T = 5$  时，Variant-NTA 的 F1 分数为 0.412，而本章设计的基于生产时间的注意力将 F1 分数提高到 0.521。这表明，基于生产时间的注意力捕捉到了生产时间对锡膏印刷质量的影响，特别是指锡膏的物理化学特性（如粘度）随着时间的推移而逐渐发生的变化。与 Variant-NGCN 对比可以发现，所提算法的在六种场景下预警性能均有显著提升。这证明了将 PCB 的焊盘分布建模成图的必要性，可以有效提高预警结果。Variant-NGatedCNN 在所有变体模型中表现是最差的，这是因为使用时序锡膏印刷质量数据进行锡膏印刷参数预警，Gated CNN 负责提取锡膏印刷质量数据中的时序演变模式，这对预警结果有重要影响。

### 5.3.3.2 超参分析

图 5.14(a)、图 5.14(c)、图 5.14(e) 显示了当  $T = 5$  时异常样本权重对实验结果的影响，固定相关性阈值并调整异常样本权重  $\omega_P$ 。模型在一定范围内对异常样本权重  $\omega_P$  不敏感。在基于锡膏印刷体积的锡膏印刷参数预警中，异常样本权

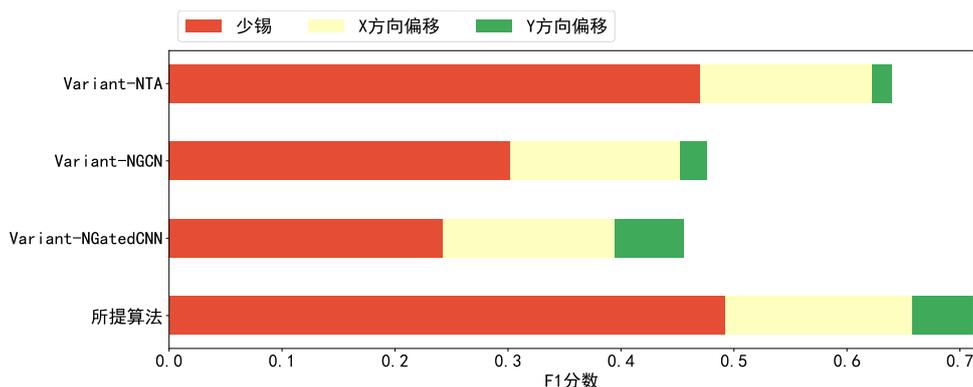
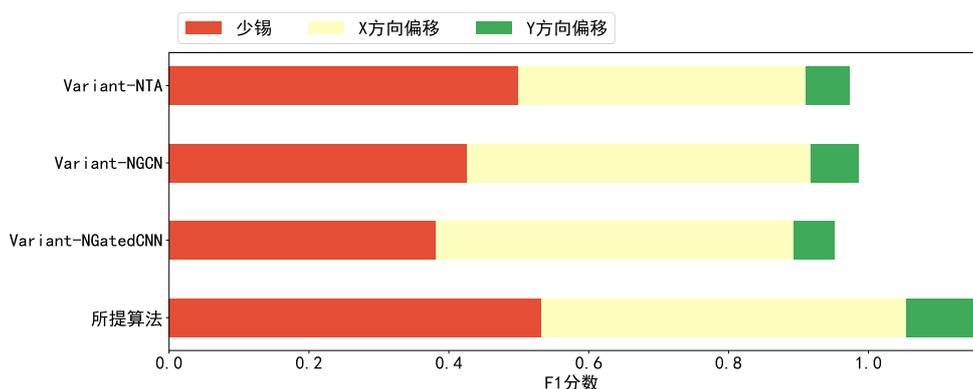
(a)  $T = 1$  时所有变体在三种典型异常上的预警效果(b)  $T = 5$  时所有变体在三种典型异常上的预警效果

图 5.13 消融实验结果可视化

重  $\omega_p$  在  $[40, 200]$  范围内具有稳定的良好性能。在基于锡膏印刷 X 方向位置偏移预测锡膏印刷质量异常中,  $[100, 750]$  的异常样本权重可以实现较好的预测。在基于锡膏印刷 Y 方向位置偏移的锡膏印刷参数预警中, 异常样本权重  $\omega_p$  在  $[100, 225]$  区间内也能达到相对较好的预测效果。异常样本权重通常与异常样本占总样本的百分比有关, 百分比越高, 异常样本权重越低, 例如少锡的异常样本权重明显低于 X 方向位置偏移缺陷和 Y 方向位置偏移缺陷的异常样本权重, 而少锡的频率也远高于它们。

图 5.14(b)、图 5.14(d)、图 5.14(f) 说明了当  $T = 5$  时锡膏印刷质量相关性阈值对锡膏印刷参数预警能力的影响。固定异常样本的权重, 调整相关性阈值。与预测 X 方向位置偏移缺陷和 Y 方向位置偏移缺陷相比, 预测少锡对相关性阈值的敏感度明显更高。这是因为 X 方向位置偏移具有更高的全局相关性, 因为 PCB 会沿 X 方向进入锡膏印刷机。而 Y 方向位置偏移缺陷则表现出突变特性。现有方法在预测这些缺陷方面表现不佳, 导致相关性阈值对实验结果的影响微乎其微。

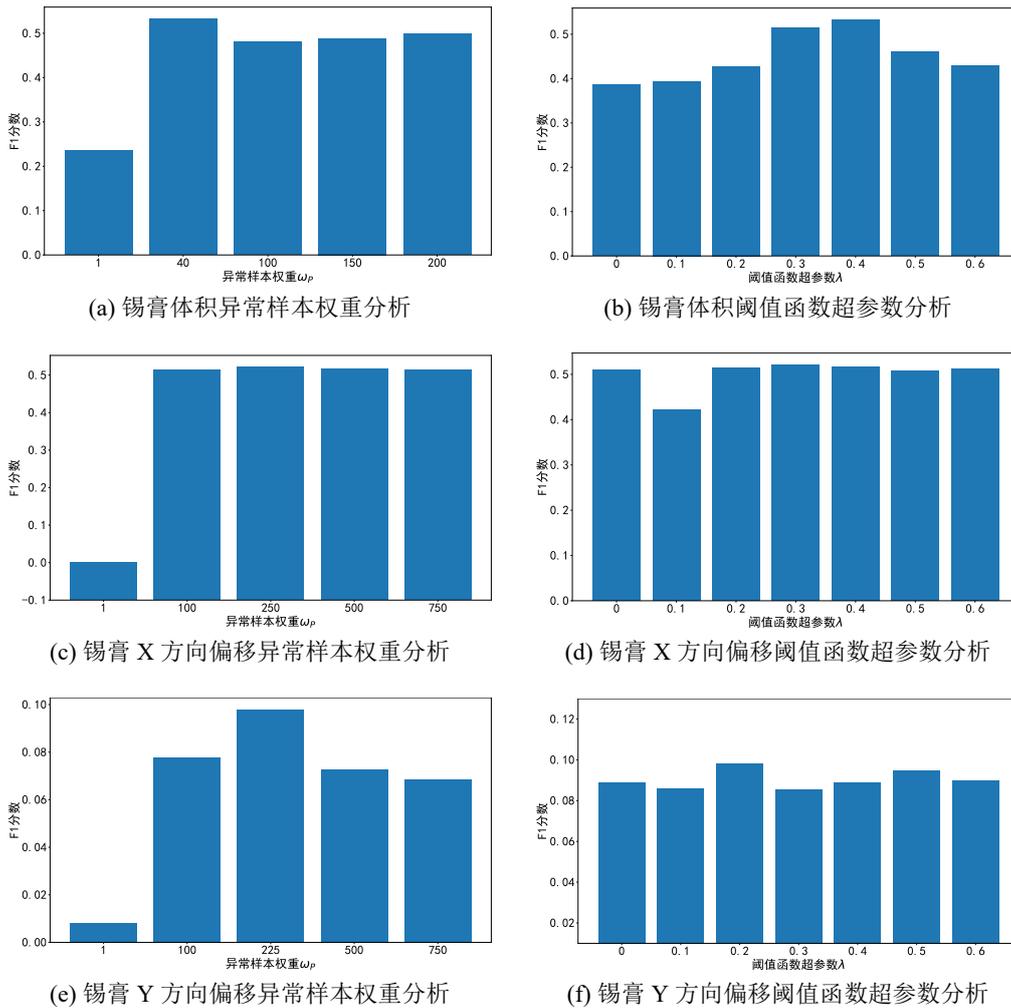


图 5.14 锡膏印刷参数预警的超参数敏感性分析

### 5.3.4 算法时间复杂度分析

所提算法的 FLOPs 为 3.24G，具有较高的时间复杂度，主要与焊盘的数量有关，因为利用图建模 PCB 上焊盘分布对锡膏印刷质量的影响时焊盘的锡膏印刷质量会根据图的边进行交互。在实际应用中，所提算法在  $T = 1$  时单次推理时间约为 0.005s，而印刷时间间隔约为 15 至 20s，因此所提算法的时间复杂度虽然较高，但仍然是可用的。

### 5.3.5 算法应用讨论

与剩余使用寿命预测不同，锡膏印刷参数预警模型在实际工业应用中需满足更高的性能要求。这是因为在剩余使用寿命预测场景下，即使模型预测精度有限，工厂仍可通过制定保守的维护策略（如提前维护）来规避风险。然而，锡膏印刷参数预警模型直接服务于印刷参数的动态优化，而锡膏印刷参数动态优化模型难以做出比较保守的调参决策——其调控有效性完全取决于能否精准避免质量异常的发生，因此对参数调整的容错率极低。这种应用特性决定了锡膏

印刷参数预警模型必须具备更高的预测精度，才能为动态优化印刷参数提供可靠的决策依据。

尽管所提算法在性能指标上尚未完全满足工业现场实际应用的要求，但其已实现了最优的预测精度，这一结果充分证明了将 PCB 焊盘分布建模为图结构的合理性与创新性。本章提出的算法框架为锡膏印刷参数预警研究提供了重要的理论依据和方法参考，基于该算法架构的持续优化与改进有望达到工业化应用标准。

所提算法在实际生产中存在以下的局限性。首先，锡膏印刷机的运行工况具有复杂多变的特点，在实际生产过程中可能出现不同型号 PCB 混合加工的情况。这种多型号混合的生产模式会导致基于 PCB 布局的图转换策略失效。鉴于此类情况发生频率较低且混合的其他型号 PCB 数量有限，可在算法应用前增加 PCB 型号校验环节。当识别到 PCB 型号混合时，可自动跳过当前 PCB，从而有效提升所提算法在实际生产环境中的适用性。其次，不同批次的锡膏在黏度、流变特性等关键参数上存在差异，这会影响锡膏通过网孔的沉积效率，进而引起锡膏体积的变化。而不同型号的锡膏印刷机在定位精度等方面上亦存在系统性偏差，这会造成锡膏印刷位置的变化。由于本研究所采用的锡膏印刷质量数据集采集自同一条生产线在六天内的生产数据，该数据集的单一性导致其无法充分表征锡膏批次差异和印刷机型号差异对印刷质量的潜在影响。该数据集的局限性使得当前算法设计未能充分考虑上述因素的影响。在未来工作中，拟采用迁移学习建模不同批次的锡膏、不同型号的锡膏印刷机对锡膏印刷质量的影响，克服上述因素所带来的差异，从而实现高性能的锡膏印刷参数预警。

## 5.4 本章小结

针对锡膏印刷参数预警问题，本章提出了一种基于 PCB 布局图卷积的锡膏印刷参数预警算法。相较于已有的锡膏印刷参数预警方法（IAP、DTCWT-LSTM）和典型时序预测方法（GRU-Single、LSTM-Single、GRU-Global、LSTM-Global），所提算法首次将 PCB 上焊盘的分布转换成图，以建模 PCB 布局对锡膏印刷质量的影响，从而提高了锡膏印刷参数预警的精度。与其他的空间建模方法（2-DConvLSTMAE，MRFGCN）相比，证明了所提算法将 PCB 天然不规则布局转换成图的合理性，能够更有效建模 PCB 布局对锡膏印刷质量的影响。首先，根据锡膏印刷质量的 Pearson 相关性将 PCB 上焊盘的分布转换为图，然后用相关性阈值修剪图的边，以建模焊盘的空间分布。然后对生产时间进行归一化，计算基于生产时间的注意力以建模锡膏的时变物理化学特性。然后，由于锡膏印刷质量异常的相对稀缺性，设计了一个加权损失来提高对锡膏印刷质量异常

的关注。最后，将预测的印刷质量与生产质量标准进行比较，以进行锡膏印刷参数预警。所提算法在私有的锡膏印刷机无机械故障下 6 天 11365 条实际锡膏印刷数据上得到验证，取得了最佳性能。

## 第6章 总结与展望

### 6.1 全文总结

锡膏印刷是 SMT 产线中核心的生产步骤，对 PCB 生产质量起着极为关键的作用。而锡膏印刷异常具有持续时间长，后果严重等特点，对工厂效益产生了显著的负面影响。对锡膏印刷异常进行预警可以为锡膏印刷的维护提供决策依据，从而有效提升锡膏印刷质量，降低返修成本，提高加工效率。因此锡膏印刷异常预警具有重要意义。

本文围绕锡膏印刷异常预警开展锡膏印刷机中关键部件早期故障预警、关键部件剩余使用寿命预测以及锡膏印刷参数不当预警三个研究内容，目前存在以下挑战。首先，对于锡膏印刷机中关键部件早期故障预警，健康样本中含有高噪声，导致基于重构的方法刻画的健康模式存在偏差。其次，对于锡膏印刷机中关键部件剩余使用寿命预测，传感器数据在不同退化阶段存在相似的表现，且难以收集到足够的带剩余使用寿命标签的数据，导致难以提取到高区分度的退化特征。最后，对于锡膏印刷参数不当预警，工业界通常用锡膏印刷机无硬件故障下的锡膏印刷质量异常来表征锡膏印刷参数不当，而锡膏印刷质量与 PCB 的焊盘分布存在较强相关性，只考虑锡膏印刷质量的时序模式难以准确的预警锡膏印刷参数不当。

针对上述挑战，本文首先利用健康状态下的关键部件多传感器监测数据，提出了基于多传感器双重对比的关键部件早期故障预警算法，能够有效发现关键部件的早期故障；然后在发现早期故障的基础上利用大量无剩余使用寿命标签的多传感器数据和少量的有剩余使用寿命标签的多传感器数据，提出了基于多传感器交替对比的锡膏印刷关键部件剩余使用寿命预测算法，能够准确预警关键部件的完全失效时间；接下来利用时序的锡膏印刷质量数据，提出了基于 PCB 布局图卷积的锡膏印刷参数预警算法，能有效预警印刷参数不当。

本文主要研究工作及创新点如下：

- (1) 针对锡膏印刷中关键部件早期故障预警问题，考虑到工厂中健康样本含有高噪声的难点，本文提出了一种基于多传感器双重对比的锡膏印刷关键部件早期故障预警算法，相较于基于重构的主流方法，设计了基于对比的时频对比模块和相关性对比模块，利用对比的方式提取关键部件在健康状态下多传感器时频信息的通用表示以及多传感器相关性的通用表示，有效抑制了多传感器数据中噪声的影响，从而显著提高了仅有健康样本下的关键部件故障预警性能。首先在训练阶段，通过不断迭代健康样本来生成健康中心，这表示关键部件的全局健康状态。然后在时频信息层面，设计了时

频对比模块, 利用 KL 散度对比健康中心的时频特征和当前训练样本的时频特征, 最小化健康状态下多传感器时频特征的 KL 散度, 从而挖掘健康时频信息之间的通用表征。随后, 在相关性层面, 设计了相关性对比模块, 利用 KL 散度对比健康中心的时频特征相关性和当前训练样本的时频特征相关性, 最小化健康状态下多传感器相关性的 KL 散度, 从而有效挖掘健康状态下多传感器相关性的通用表示。最后结合时频对比模块和相关性对比模块可以提取关键部件健康状态的通用特征, 从而克服健康样本含有高噪声问题。所提算法分别在私有的锡膏印刷机减震器数据和公开的轴承数据集、齿轮数据集上进行了验证。实验结果表明, 相较于基于重构 (LSTM-VAE、FGPAA、TimesNet、ATF-UAD、TranAD、MRRAE、SAT) 的主流方法, 所提方法利用时频对比模块和相关性对比模块可有效抑制噪声的不良影响, 相较于基于对比 (CPC) 的方法, 所提算法利用相关性对比模块更进一步地在相关性层面进行对比, 更全面的抑制了噪声的影响, 从而提高了关键部件早期故障预警性能。

- (2) 针对锡膏印刷中关键部件剩余使用寿命预测问题, 考虑到工厂中带剩余使用寿命标签的数据非常稀少、不同退化阶段间传感器数据相似性较高的难点, 本文提出了一种基于多传感器交替对比的锡膏印刷关键部件剩余使用寿命预测算法, 相较于以往基于退化阶段差异性的自监督方法, 设计了一种基于跨传感器相似度的交替对比过程, 能够从大量无标签的多传感器数据中挖掘跨传感器不变特征, 仅需少量带剩余使用寿命标签的数据对模型进行微调即可实现关键部件的剩余使用寿命预测。首先, 传感器数据通过傅里叶变换映射到时频域。然后, 设计了交替对比过程, 从大量无标签数据中提取跨传感器不变特征。在交替对比过程中, 多分支 ResNet18 作为特征提取器, 将多传感器特征映射至共现空间。在共现空间中, 任意传感器被选为主传感器, 其余传感器被视为辅传感器。辅传感器特征提取器采用动量更新来确保特征的一致性。然后计算主传感器特征和辅传感器特征之间的相似度, 并优化对比损失, 使同一时刻的主传感器特征和辅传感器特征最相似, 从而得到主传感器和辅传感器之间的不变特征。随后选择另一传感器作为主传感器, 重复上述过程, 直到每个传感器都充当了主传感器, 从而得到高区分度的跨传感器不变特征。最后, 使用少量带有剩余使用寿命标签的数据对模型进行微调, 从而实现了少量标签数据下的剩余使用寿命预测。所提算法在公开的轴承数据集和齿轮数据集上进行了验证。实验结果表明, 相较于监督方法 (CABLSTM、MSGCNN-TR、MSECNN-BIGRU、2DLSTM、HA-ConvLSTM、CVT-FT), 所提算法通过自监督架构可充分利用监督方法难以利用的大量无标签数据, 从中挖掘关键部件的退

化模式,相较于自监督方法(SSPCL、SSL、DeepSSL、USL),所提算法中交替对比过程利用跨传感器相似度挖掘跨传感器不变特征,有效提高了退化特征地区分度,从而显著提升了关键部件剩余使用寿命的预测精度。

- (3) 针对锡膏印刷中锡膏印刷参数不当预警问题,考虑到工业界通常用锡膏印刷机正常下的锡膏印刷质量异常来表征锡膏印刷参数不当,而锡膏印刷质量受PCB焊盘分布的影响,因此本文提出了一种基于PCB布局图卷积的锡膏印刷参数预警算法,相较于以往基于时序模式的方法,首次将PCB焊盘分布转换成图以建模PCB焊盘分布对锡膏印刷质量的影响。首先,由于锡膏印刷质量与PCB的焊盘分布有关,因此本文根据锡膏印刷质量之间的皮尔逊相关性构建了一个加权图,根据相关性阈值修剪图的边。进而考虑到锡膏的理化特性是时变的,将生产时间进行归一化编码,计算基于生产时间的注意力,并根据注意力重构锡膏印刷质量特征。由于锡膏印刷质量异常的稀缺性,设计了一种加权损失来提高锡膏印刷质量异常的权重,促进模型关注印刷质量异常。然后,将预测的印刷质量与生产质量标准进行比较,以预警锡膏印刷参数不当。所提算法在私有的锡膏印刷机无故障下6天11365条实际锡膏印刷数据上进行了验证。实验结果表明,与已有的锡膏印刷参数不当预警方法(IAP、DTCWT-LSTM)和典型时序预测方法(GRU、LSTM)相比,所提算法建模PCB布局对锡膏印刷质量的影响,可以有效提高锡膏印刷参数不当预警精度。与其他的空间建模方法(2-DConvLSTMAE, MRFGCN)相比,证明了所提算法将PCB天然不规则布局建模成图的合理性,能够更有效捕获PCB布局对锡膏印刷质量的影响。

基于多传感器双重对比的锡膏印刷关键部件早期故障预警算法和基于PCB布局图卷积的锡膏印刷参数预警算法已在生产线中进行了试点应用,虽然尚未满足实际应用的性能要求,但是仍可为锡膏印刷的维护决策提供参考依据。基于多传感器交替对比的锡膏印刷关键部件剩余使用寿命预测算法虽尚未投入实际应用,但相较于已有的监督方法,更贴合真实工厂中缺乏标签数据的场景,且相较于已有的自监督方法预测性能更加优异。因此以上所提算法均具备一定的工程应用价值,有力的推动了工程实际应用进展。

## 6.2 后续研究工作展望

本文提出了基于多维时序数据分析的锡膏印刷异常预警方法体系,同时在私有的锡膏印刷产线数据集和公开数据集上进行了有效性验证,证明了算法的优越性。但这些算法仍存在不足,有进一步改进的空间:

- (1) 针对锡膏印刷中关键部件早期故障预警问题，本文提出的基于多传感器双重对比的锡膏印刷关键部件早期故障预警算法依赖故障分数和故障阈值相比较才能实现故障预警。目前所提算法中故障阈值是静态的，但是由于工厂生产环境的复杂和工况多变，静态的故障阈值可能存在适应性不足的问题。未来可结合工况以及不同工况下健康状态数据分布来构建自适应的动态故障阈值。同时由于所提算法对于多工况情况下的早期故障预警性能仍有进一步提升的空间，未来拟采用类似迁移学习中域对抗的思路提取不同工况下的潜在共享特征，从而提高多工况下的故障预警性能。
- (2) 针对锡膏印刷中关键部件剩余使用寿命预测问题，本文提出的基于多传感器交替对比的锡膏印刷关键部件剩余使用寿命预测算法仅仅只考虑了数据的特性，而忽略了锡膏印刷场景下的先验知识，比如轴承和齿轮的转速和负载呈周期性变化。因此未来拟打算将关于工况的先验知识融入剩余使用寿命预测算法，以提高预测性能。
- (3) 针对锡膏印刷中锡膏印刷参数不当预警问题，本文提出一种基于 PCB 布局图卷积的锡膏印刷参数预警算法，该算法尚未考虑锡膏批次以及锡膏印刷机型号不同对锡膏印刷质量的影响，其泛化性存在一定局限性，因此未来计划收集更多具有差异性的锡膏印刷质量数据，拟采用迁移学习等思路挖掘锡膏印刷质量的共性时序变化模式以进一步提高锡膏印刷参数不当预警的性能。其次锡膏印刷参数不当预警服务于锡膏印刷参数调整，因此未来拟打算在未来拟打算利用离线强化学习以锡膏印刷质量为奖励，锡膏印刷参数为状态，以锡膏印刷参数变化为动作，从而动态实时的调整锡膏印刷参数。

## 参考文献

- [1] 李勋. SMT 产线数字孪生系统的研究与实现 [D]. 西安电子科技大学, 2022.
- [2] 李旭. SAC305 无铅焊锡膏制备及其性能研究 [D]. 西安工程大学, 2023.
- [3] 辛国胜. 2024 年全球 PCB 市场的挑战与未来期望 [J]. 玻璃纤维, 2024(06): 1-7+14.
- [4] AMIR D. Expert system for SMT assembly[C]//Proceedings of the Surface Mount International Conference and Exposition-Technical Program. San Jose CA, 1994: 691-699.
- [5] HUANG C Y. Applying the taguchi parametric design to optimize the solder paste printing process and the quality loss function to define the specifications[J]. Soldering & Surface Mount Technology, 2018, 30(4): 217-226.
- [6] 冼志军. 锡膏印刷机误差与锡膏印刷质量检测技术研究 [D]. 华南理工大学, 2015.
- [7] 李钦, 张宪民, 邝泳聪, 等. 全自动锡膏印刷机运动控制系统的研究 [J]. 微计算机信息, 2008(31): 1-3.
- [8] 高艳茹. 最新 IPC 标准——刚性及多层印制板基材规范及其发展综述 [J]. 印制电路信息, 2002(10): 62-66+70.
- [9] ZHOU D J, CHEN X Y. Discussion on application of intelligent manufacturing technology in SMT product assembly manufacturing system[C]//MATEC Web of Conferences: volume 63. EDP Sciences, 2016: 02035.
- [10] DING R W, DAI L H, LI G P, et al. TDD-net: a tiny defect detection network for printed circuit boards[J]. CAAI Transactions on Intelligence Technology, 2019, 4(2): 110-116.
- [11] VENKATESWARAN S, SRIHARI K, ADRIANCE J, et al. A realtime process control system for solder paste stencil printing[C]//Twenty First IEEE/CPMT International Electronics Manufacturing Technology Symposium Proceedings 1997 IEMT Symposium. IEEE, 1997: 62-67.
- [12] MONTGOMERY D C, KEATS J B, PERRY L A, et al. Using statistically designed experiments for process development and improvement: an application in electronics manufacturing[J]. Robotics and Computer-Integrated Manufacturing, 2000, 16(1): 55-63.
- [13] YOO Y H, KIM U H, KIM J H. Convolutional recurrent reconstructive network for spatiotemporal anomaly detection in solder paste inspection[J]. IEEE Transactions on Cybernetics, 2020, 52(6): 4688-4700.
- [14] CAI N, CEN G D, WU J X, et al. SMT solder joint inspection via a novel cascaded convolutional neural network[J]. IEEE Transactions on Components Packaging and Manufacturing Technology, 2018, 8(4): 670-677.
- [15] CHANG Y M, CHEN J, HSIEH P. Prediction of solder joint quality using a data mining

- methodology for surface mounted technology process[C]//Proceedings of the 1st International Conference on Big Data Research. 2017: 52-56.
- [16] GECZYA, FEJOS M, TERSZTYANSZKY L. Investigating and compensating printed circuit board shrinkage induced failures during reflow soldering[J]. *Soldering & Surface Mount Technology*, 2015, 27(2): 61-68.
- [17] CHANG Y M, WEI C C, CHEN J, et al. An implementation of health prediction in SMT solder joint via machine learning[C]//2019 IEEE International Conference on Big Data and Smart Computing (BigComp). IEEE, 2019: 1-4.
- [18] 李名昊. 面向 SMT 锡膏印刷过程的缺陷预测方法研究 [D]. 西安电子科技大学, 2019.
- [19] 廖帅冬. 基于深度学习的 SMT 故障诊断预警系统研究 [D]. 桂林电子科技大学, 2023.
- [20] 刘超. 面向 SMT 的锡膏印刷工艺参数优化方法研究 [D]. 西安电子科技大学, 2019.
- [21] 武彦斌. 基于人工智能的 SMT 产线关键工艺参数优化方法研究 [D]. 西安电子科技大学, 2021.
- [22] 李志求, 黄志仔. 利用 DOE 工具寻求最佳印刷工艺参数 [C]//2020 中国高端 SMT 学术会议. 2020: 10.
- [23] KHADER N, LEE J, LEE D, et al. Multi-objective optimization approach to enhance the stencil printing quality[C]//29th International Conference on Flexible Automation and Intelligent Manufacturing (Faim 2019): Beyond Industry 4.0: Industrial Advances, Engineering Education and Intelligent Manufacturing: volume 38. 2019: 163-170.
- [24] KHADER N, YOON S W. Stencil printing process optimization to control solder paste volume transfer efficiency[J]. *IEEE Transactions on Components Packaging and Manufacturing Technology*, 2018, 8(9): 1686-1694.
- [25] LU H, HE J, WON D, et al. A guided evolutionary search approach for real-time stencil printing optimization[J]. *IEEE Transactions on Components, Packaging and Manufacturing Technology*, 2021, 11(2): 333-341.
- [26] 余佳阳, 汤鹏. 智能制造 SMT 设备操作与维护 [M]. 1 版. 化学工业出版社: 344.
- [27] BOHLIN M, WÄRJAM. Maintenance optimization with duration-dependent costs[J]. *Annals of Operations Research*, 2015, 224(1): 1-23.
- [28] ZONTAT, DA COSTA C A, ZEISER F A, et al. A predictive maintenance model for optimizing production schedule using deep neural networks[J]. *Journal of Manufacturing Systems*, 2022, 62: 450-462.
- [29] CRESPO MARQUEZ A, SÁNCHEZ HEGUEDAS A. Models for maintenance optimization: a study for repairable systems and finite time periods[J]. *Reliability Engineering & System Safety*, 2002, 75(3): 367-377.
- [30] MARTORELL S, VILLAMIZAR M, CARLOS S, et al. Maintenance modeling and optimiza-

- tion integrating human and material resources[J]. *Reliability Engineering & System Safety*, 2010, 95(12): 1293-1299.
- [31] CHENG C, MA G J, ZHANG Y, et al. A deep learning-based remaining useful life prediction approach for bearings[J]. *IEEE-ASME Transactions on Mechatronics*, 2020, 25(3): 1243-1254.
- [32] DUYM S, STIENS R, REYBROUCK K. Evaluation of shock absorber models[J]. *Vehicle System Dynamics*, 1997, 27(2): 109-127.
- [33] DUAN G R, PATTON R J. Robust fault detection using luenberger-type unknown input observers-a parametric approach[J]. *International Journal of Systems Science*, 2001, 32(4): 533-540.
- [34] TERMEHCHY A, AFSHAR A. A novel design of unknown input observer for fault diagnosis in non-minimum phase systems[J]. *IFAC Proceedings Volumes*, 2014, 47(3): 8552-8557.
- [35] YANG Y, DING S X, LI L. On observer-based fault detection for nonlinear systems[J]. *Systems & Control Letters*, 2015, 82: 18-25.
- [36] GAO Z, DAI X, BREIKIN T, et al. Novel parameter identification by using a high-gain observer with application to a gas turbine engine[J]. *IEEE Transactions on Industrial Informatics*, 2008, 4(4): 271-279.
- [37] HERNANDEZ-ALCANTARA D, MORALES-MENENDEZ R, AMEZQUITA-BROOKS L. Fault detection for automotive shock absorber[J]. *Journal of Physics: Conference Series*, 2015, 659(1): 012037.
- [38] CHOW E, WILLISKY A. Analytical redundancy and the design of robust failure detection systems[J]. *IEEE Transactions on Automatic Control*, 1984, 29(7): 603-614.
- [39] 陈健军. 基于深度学习的电机智能故障诊断方法研究 [D]. 电子科技大学, 2024.
- [40] GROVER C, TURK N. Rolling element bearing fault diagnosis using empirical mode decomposition and hjorth parameters[J]. *Procedia Computer Science*, 2020, 167: 1484-1494.
- [41] 李心一, 谢志江, 罗久飞. 加窗插值快速傅里叶变换在滚动轴承故障诊断中的应用 [J]. *中国机械工程*, 2018, 29(10): 1166-1172.
- [42] SHI D F, WANG W J, QU L S. Defect detection for bearings using envelope spectra of wavelet transform[J]. *Journal of Vibration and Acoustics*, 2004, 126(4): 567-573.
- [43] DO V T, CHONG U P. Signal model-based fault detection and diagnosis for induction motors using features of vibration signal in two- dimension domain[J]. *Journal of Mechanical Engineering*, 2011, 57(9): 655-666.
- [44] ZHAO H, JIANG X, WANG B, et al. Bearing fault feature extraction method: stochastic resonance-based negative entropy of square envelope spectrum[J]. *Measurement Science and Technology*, 2024, 35(4): 045102.

- [45] WANG H, CHEN P. Fuzzy diagnosis method for rotating machinery in variable rotating speed[J]. IEEE Sensors Journal, 2011, 11(1): 23-34.
- [46] RAJAGOPALAN S, HABETLER T G, HARLEY R G, et al. Non-stationary motor fault detection using recent quadratic time-frequency representations[C]//Conference Record of the 2006 IEEE Industry Applications Conference Forty-First IAS Annual Meeting: volume 5. 2006: 2333-2339.
- [47] ROSERO J, CUSIDO J, ORTEGA J A, et al. PMSM bearing fault detection by means of fourier and wavelet transform[C]//IECON 2007 - 33rd Annual Conference of the IEEE Industrial Electronics Society. 2007: 1163-1168.
- [48] XI W, BAI L, HUI M, et al. A novel rolling bearing fault detect method based on empirical wavelet transform[C]//2018 13th IEEE Conference on Industrial Electronics and Applications (ICIEA). 2018: 2764-2768.
- [49] ZHANG Y, CHEN Y, WANG J, et al. Unsupervised deep anomaly detection for multi-sensor time-series signals[J]. IEEE Transactions on Knowledge and Data Engineering, 2023, 35(2): 2118-2132.
- [50] HUANG X, WEN G, DONG S, et al. Memory residual regression autoencoder for bearing fault detection[J]. IEEE Transactions on Instrumentation and Measurement, 2021, 70: 1-12.
- [51] YU J, SONG Y, TANG D, et al. Telemetry data-based spacecraft anomaly detection with spatial-temporal generative adversarial networks[J]. IEEE Transactions on Instrumentation and Measurement, 2021, 70: 1-9.
- [52] XU Z, CHENG Z, GUO B. A multivariate anomaly detector for satellite telemetry data using temporal attention-based LSTM autoencoder[J]. IEEE Transactions on Instrumentation and Measurement, 2023, 72: 1-13.
- [53] CHEN Z, CHEN D, ZHANG X, et al. Learning graph structures with transformer for multivariate time-series anomaly detection in iot[J]. IEEE Internet of Things Journal, 2022, 9(12): 9179-9189.
- [54] DING C, SUN S, ZHAO J. MST-GAT: A multimodal spatial-temporal graph attention network for time series anomaly detection[J]. Information Fusion, 2023, 89: 527-536.
- [55] ZHAO H, WANG Y, DUAN J, et al. Multivariate time-series anomaly detection via graph attention network[C]//2020 IEEE International Conference on Data Mining (ICDM). IEEE, 2020: 841-850.
- [56] LI Z, SUN Y, YANG L, et al. Unsupervised machine anomaly detection using autoencoder and temporal convolutional network[J]. IEEE Transactions on Instrumentation and Measurement, 2022, 71: 1-13.
- [57] 张鸾, 闵思垚, 张微. 基于 swin transformer 与无监督学习的滚动轴承故障诊断方法 [J].

- 沈阳航空航天大学学报, 2024, 41(03): 37-42.
- [58] 兰杰, 李志宁, 吕建刚. 基于 ELM-AE 的轴承性能退化和早期故障检测 [J]. 轴承, 2023 (02): 121-129.
- [59] 黄宇. 基于 LSTM 自编码器的振动信号故障检测方法研究 [D]. 山东大学, 2020.
- [60] YU P, PING M, MA J, et al. Unsupervised signal anomaly transformer method: Achieving bearing life anomaly detection without the need for failure samples[J]. Engineering Applications of Artificial Intelligence, 2024, 136: 108940.
- [61] BATSCH M, KICZEK B. Gear fault detection method based on convex hull clustering of autoencoder's latent space[J]. Applied Sciences, 2024, 14(12).
- [62] WEN G, LEI Z, CHEN X, et al. Memory residual regression autoencoder for bearing fault detection[M]. Singapore: Springer Nature Singapore, 2024: 37-62.
- [63] WU J, ZHAO Z, SUN C, et al. Fault-attention generative probabilistic adversarial autoencoder for machine anomaly detection[J]. IEEE Transactions on Industrial Informatics, 2020, 16(12): 7479-7488.
- [64] LIU H, ZHOU J, XU Y, et al. Unsupervised fault diagnosis of rolling bearings using a deep neural network based on generative adversarial networks[J]. Neurocomputing, 2018, 315: 412-424.
- [65] SHAO S, WANG P, YAN R. Generative adversarial networks for data augmentation in machine fault diagnosis[J]. Computers in Industry, 2019, 106: 85-93.
- [66] DAI J, WANG J, HUANG W, et al. Machinery health monitoring based on unsupervised feature learning via generative adversarial networks[J]. IEEE/ASME Transactions on Mechatronics, 2020, 25(5): 2252-2263.
- [67] WANG M, YU J, LENG H, et al. Bearing fault detection by using graph autoencoder and ensemble learning[J]. Scientific Reports, 2024, 14(1): 5206.
- [68] SIAVASH-ABKENARI N, RAHMANI-SANE G, TORKAMAN H, et al. Exploring a cutting-edge framework for bearing fault detection: A synergistic approach integrating statistical analysis and deep learning methods[J]. IEEE Journal of Emerging and Selected Topics in Industrial Electronics, 2024, 5(3): 1226-1233.
- [69] ZHANG W, SUN Z, LV D, et al. A time series prediction-based method for rotating machinery detection and severity assessment[J]. Aerospace, 2024, 11(7).
- [70] 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.
- [71] 李天梅, 司小胜, 刘翔, 等. 大数据下数模联动的随机退化设备剩余寿命预测技术 [J]. 自动化学报, 2022, 48: 2119-2141.

- [72] 赵磊, 张永祥, 朱丹宸. 复杂装备滚动轴承的故障诊断与预测方法研究综述 [J]. 中国测试, 2020, 46(1674-5124): 17-25.
- [73] 王婧, 许志伟, 刘文静, 等. 滚动轴承健康智能监测和故障诊断机制研究综述 [J]. 计算机科学与探索, 2024, 18(04): 878-898.
- [74] WEN Y, WU J, ZHOU Q, et al. Multiple-change-point modeling and exact bayesian inference of degradation signal for prognostic improvement[J]. IEEE Transactions on Automation Science and Engineering, 2019, 16(2): 613-628.
- [75] TAO F, QI Q, LIU A, et al. Data-driven smart manufacturing[J]. Journal of Manufacturing Systems, 2018, 48: 157-169.
- [76] 张杰, 马永亮. 3 种疲劳裂纹扩展速率模型比较 [J]. 实验室研究与探索, 2012, 31: 35-38.
- [77] PARIS P, ERDOGAN F. A critical analysis of crack propagation laws[J]. Journal of Basic Engineering, 1963, 85(4): 528-533.
- [78] BECHHOEFER E, BERNHARD A, HE D. Use of paris law for prediction of component remaining life[C]//2008 IEEE Aerospace Conference. 2008: 1-9.
- [79] FORMAN R G, KEARNEY V E, ENGLE R M. Numerical analysis of crack propagation in cyclic-loaded structures[J]. Journal of Basic Engineering, 1967, 89(3): 459-463.
- [80] LI Y, KURFESS T R, LIANG S Y. Stochastic prognostics for rolling element bearings[J]. Mechanical Systems and Signal Processing, 2000, 14(5): 747-762.
- [81] LI C J, LEE H. Gear fatigue crack prognosis using embedded model, gear dynamic model and fracture mechanics[J]. Mechanical Systems and Signal Processing, 2005, 19(4): 836-846.
- [82] 陈龙, 黄天立, 周浩. 基于比例型 Paris 公式和逆高斯过程的金属疲劳裂纹扩展随机模型 [J]. 工程力学, 2021, 38(10): 238-247.
- [83] OPPENHEIMER C H, LOPARO K A. Physically based diagnosis and prognosis of cracked rotor shafts[C]//Component and Systems Diagnostics, Prognostics, and Health Management II: volume 4733. 2002: 122-132.
- [84] 杨冰, 赵永翔, 张卫华. 基于 Forman 方程的随机疲劳长裂纹扩展概率模型 [J]. 交通运输工程学报, 2006(01): 25-28.
- [85] ZHANG J, HUANG X, FANG Y, et al. Optimal inspection-based preventive maintenance policy for three-state mechanical components under competing failure modes[J]. Reliability Engineering & System Safety, 2016, 152: 95-103.
- [86] HUANG Z, XU Z, WANG W, et al. Remaining useful life prediction for a nonlinear heterogeneous wiener process model with an adaptive drift[J]. IEEE Transactions on Reliability, 2015, 64(2): 687-700.
- [87] 裴洪, 胡昌华, 司小胜, 等. 不完美维护下基于剩余寿命预测信息的设备维护决策模型 [J]. 自动化学报, 2018, 44(04): 719-729.

- [88] ZHONGYI C, ZEZHOU W, YUNXIANG C, et al. Remaining useful lifetime prediction for equipment based on nonlinear implicit degradation modeling[J]. *Journal of Systems Engineering and Electronics*, 2020, 31(1): 194-205.
- [89] WANG X, LIN S, WANG S, et al. Remaining useful life prediction based on the wiener process for an aviation axial piston pump[J]. *Chinese Journal of Aeronautics*, 2016, 29(3): 779-788.
- [90] TAN L, CHENG Z, GUO B, et al. Condition-based maintenance policy for gamma deteriorating systems[J]. *Journal of Systems Engineering and Electronics*, 2010, 21(1): 57-61.
- [91] 李玲, 成国庆, 柳炳祥. 基于 Gamma 过程的加速劣化系统模型及其最优视情维修策略[J]. *计算机集成制造系统*, 2013, 19(11): 2922-2927.
- [92] WENJIA X, WENBIN W. An adaptive gamma process based model for residual useful life prediction[C]//*Proceedings of the IEEE 2012 Prognostics and System Health Management Conference (PHM-2012 Beijing)*. 2012: 1-4.
- [93] 李巍华, 李静, 张绍辉. 连续隐半马尔科夫模型在轴承性能退化评估中的应用[J]. *振动工程学报*, 27(4): 613-620.
- [94] XIANG Y, CASSADY C R, POHL E A. Optimal maintenance policies for systems subject to a markovian operating environment[J]. *Comput. Ind. Eng.*, 2012, 62(1): 190-197.
- [95] GHASEMI A, YACOUT S, OUALI M S. Optimal condition based maintenance with imperfect information and the proportional hazards model[J]. *International Journal of Production Research*, 2007, 45(4): 989-1012.
- [96] ZHU J, CHEN N, PENG W. Estimation of bearing remaining useful life based on multiscale convolutional neural network[J]. *IEEE Transactions on Industrial Electronics*, 2019, 66(4): 3208-3216.
- [97] CAO W, MENG Z, LI J, et al. A remaining useful life prediction method for rolling bearing based on TCN-Transformer[J]. *IEEE Transactions on Instrumentation and Measurement*, 2025, 74: 1-9.
- [98] QIN Y, GAN F, XIA B, et al. Remaining useful life estimation of bearing via temporal convolutional networks enhanced by a gated convolutional unit[J]. *Engineering Applications of Artificial Intelligence*, 2024, 133: 108308.
- [99] WEN L, SU S, LI X, et al. GRU-AE-wiener: A generative adversarial network assisted hybrid gated recurrent unit with wiener model for bearing remaining useful life estimation[J]. *Mechanical Systems and Signal Processing*, 2024, 220: 111663.
- [100] LU W, WANG Y, ZHANG M, et al. Physics guided neural network: Remaining useful life prediction of rolling bearings using long short-term memory network through dynamic weighting of degradation process[J]. *Engineering Applications of Artificial Intelligence*, 2024, 127:

- 107350.
- [101] ZHU Z, LV Z, XIE T. Trend contrast features-based bearing remaining useful life prediction method[J]. *Control Engineering Practice*, 2025, 162: 106358.
- [102] QIN Y, XIANG S, CHAI Y, et al. Macroscopic–Microscopic attention in LSTM networks based on fusion features for gear remaining life prediction[J]. *IEEE Transactions on Industrial Electronics*, 2020, 67(12): 10865-10875.
- [103] YE Y, WANG J, YANG J, et al. Adaptive MAGNN-TCN: An innovative approach for bearings remaining useful life prediction[J]. *IEEE Sensors Journal*, 2025, 25(4): 7467-7481.
- [104] WU J, HE D, LI J, et al. Temporal multi-resolution hypergraph attention network for remaining useful life prediction of rolling bearings[J]. *Reliability Engineering & System Safety*, 2024, 247: 110143.
- [105] ZHOU L, WANG H, XU S. An adaptive multi-scale spatial-temporal graph attention ensemble network with physical guidance for remaining useful life prediction of multi-sensor equipment[J]. *Reliability Engineering & System Safety*, 2025: 111152.
- [106] ZHANG M, HE C, HUANG C, et al. A weighted time embedding transformer network for remaining useful life prediction of rolling bearing[J]. *Reliability Engineering & System Safety*, 2024, 251: 110399.
- [107] WEI Y, WU D. Conditional variational transformer for bearing remaining useful life prediction[J]. *Advanced Engineering Informatics*, 2024, 59: 102247.
- [108] MA P, LI G, ZHANG H, et al. Prediction of remaining useful life of rolling bearings based on multiscale efficient channel attention cnn and bidirectional GRU[J]. *IEEE Transactions on Instrumentation and Measurement*, 2024, 73: 1-13.
- [109] DING Y F, ZHUANG J C, DING P, et al. Self-supervised pretraining via contrast learning for intelligent incipient fault detection of bearings[J]. *Reliability Engineering & System Safety*, 2022, 218: 108126.
- [110] KROKOTSCH T, KNAAK M, GUHMANN C. Improving semi-supervised learning for remaining useful lifetime estimation through self-supervision[J]. *International Journal of Prognostics and Health Management*, 2022, 13(1): 1-19.
- [111] AKRIMA, GOGU C, VINGERHOEDS R, et al. Self-supervised learning for data scarcity in a fatigue damage prognostic problem[J]. *Engineering Applications of Artificial Intelligence*, 2023, 120: 105837.
- [112] KONG Z, JIN X, XU Z, et al. A contrastive learning framework enhanced by unlabeled samples for remaining useful life prediction[J]. *Reliability Engineering & System Safety*, 2023, 234: 109163.
- [113] 刘刚, 孙静静, 王铎, 等. 电子装联焊膏印刷工艺质量控制要求 [M]. SJ 21514-2018. 国

- 家国防科技工业局, 2018.
- [114] YANG T, TSAI T N, YE H J. A neural network-based prediction model for fine pitch stencil-printing quality in surface mount assembly[J]. *Engineering Applications of Artificial Intelligence*, 2005, 18(3): 335-341.
- [115] TSAI T N, CHEN L H. Monitoring of the stencil printing process using a modified regression residual control chart: An empirical study[J]. *International Journal of Industrial Engineering: Theory, Applications and Practice*, 2009, 16(4).
- [116] TSAI T N. Improving the fine-pitch stencil printing capability using the taguchi method and taguchi fuzzy-based model[J]. *Robotics and Computer-Integrated Manufacturing*, 2011, 27(4): 808-817.
- [117] LU H, WANG H, YOON S W, et al. Dynamic predictive modeling of solder paste volume with real time memory update in a stencil printing process[J]. *Procedia Manufacturing*, 2019, 38: 108-116.
- [118] LIUKKONEN M, HILTUNEN T, HAVIA E, et al. Modeling of soldering quality by using artificial neural networks[J]. *IEEE Transactions on Electronics Packaging Manufacturing*, 2009, 32(2): 89-96.
- [119] KRAMMER O, AL-MA'AITEH T, MARTINEK P, et al. Predicting the transfer efficiency of stencil printing by machine learning technique[C]//2020 43rd International Spring Seminar on Electronics Technology (ISSE). IEEE, 2020: 1-6.
- [120] MARTINEK P, ILLES B, CODREANU N, et al. Investigating machine learning techniques for predicting the process characteristics of stencil printing[J]. *Materials*, 2022, 15(14).
- [121] CHEN C S, WANG H, KAO Y C, et al. Predictive model of the solder paste stencil printing process by response surface methodology[J]. *Soldering & Surface Mount Technology*, 2022, 34(5): 292-299.
- [122] LU H, WANG H, YOON S W, et al. Real-time stencil printing optimization using a hybrid multi-layer online sequential extreme learning and evolutionary search approach[J]. *IEEE Transactions on Components, Packaging and Manufacturing Technology*, 2019, 9(12): 2490-2498.
- [123] WANG W, GUI W, XU Z. Solder paste printing quality prediction model based on PSO optimization[C]//FAN W, ZHANG L, LI N, et al. *Methods and Applications for Modeling and Simulation of Complex Systems*. Springer Nature Singapore: 538-547.
- [124] WANG H, LU H, ALELAUMI S M, et al. A wavelet-based multi-dimensional temporal recurrent neural network for stencil printing performance prediction[J]. *Robotics and Computer-Integrated Manufacturing*, 2021, 71: 102129.
- [125] WANG H, HE T, YOON S W. Recurrent neural network-based stencil cleaning cycle predic-

- tive modeling[J]. *Procedia Manufacturing*, 2018, 17: 86-93.
- [126] ALELAUMI S, KHADER N, HE J X, et al. Residue buildup predictive modeling for stencil cleaning profile decision-making using recurrent neural network[J]. *Robotics and Computer-Integrated Manufacturing*, 2021, 68: 102041.
- [127] ALELAUMI S, HE J X, LI Y Y, et al. Cleaning profile classification using convolutional neural network in stencil printing[J]. *IEEE Transactions on Components Packaging and Manufacturing Technology*, 2021, 11(11): 2003-2011.
- [128] ALELAUMI S, WANG H, LU H, et al. A predictive abnormality detection model using ensemble learning in stencil printing process[J]. *IEEE Transactions on Components, Packaging and Manufacturing Technology*, 2020, 10(9): 1560-1568.
- [129] 牛士林. 基于状态分析的钢网印刷清洁控制研究 [D]. 重庆大学, 2020.
- [130] 李正军. 基于可变阈值序列的锡膏印刷钢网清洗决策方法研究 [D]. 重庆大学, 2018.
- [131] 付豪. 基于隐马尔可夫模型的锡膏印刷系统钢网清洗维护策略研究 [D]. 重庆大学, 2020.
- [132] 余江游. 锡膏印刷过程钢网清洗决策方法研究 [D]. 重庆大学, 2020.
- [133] 张凯磊. 基于深度学习的 SMT 产线追溯方法研究 [D]. 西安电子科技大学, 2020.
- [134] 朱桂兵. 浅析金属模版对印刷质量的影响 [J]. *丝网印刷*, 2016(02): 18-22.
- [135] 王维芳, 董浩, 柳磊, 等. 故障检测方法、装置、电子设备及计算机可读存储介质: 中国, CN116067635A[P]. 2023-05-05.
- [136] IntelMining 智能矿业. “人工智能+”行动, 科大讯飞皮带托辊光纤声纹监测系统实现无人化巡检![EB]. 2024-03-13. <https://www.chinacaj.net/news/58035.html>.
- [137] 华为云. 因联 iPHM 设备健康智能维护云平台 [EB]. 2021-10-15. [https://www.huaweicloud.com/zhishi/marketplace\\_user\\_243714b0-87b5-4da4-a16d-7dc7ec596665.html](https://www.huaweicloud.com/zhishi/marketplace_user_243714b0-87b5-4da4-a16d-7dc7ec596665.html).
- [138] 设备工程. 预测性维护成功案例分享: 如何通过实践获得业务价值 [EB]. 2023-07-19. <https://zhuanlan.zhihu.com/p/644490003>.
- [139] 容知日新. 赋能青岛特钢设备智能运维建设实现厂区关键产线全覆盖 [EB]. 2020-06. <https://www.ronds.com.cn/case/6>.
- [140] 常建涛, 孔宪光, 李名昊, 等. 基于工业大数据的 SMT 印刷参数优化方法: 中国, CN110427593A[P]. 2019-11-08.
- [141] 陈怡如, 许涵婷, 艾雪芳. 产品印刷参数设定装置、方法及计算机可读存储介质: 中国, CN112801328B[P]. 2023-10-31.
- [142] 李上杰, 孙长伟, 朱晓岭, 等. 一种锡膏印刷机的印刷参数校正方法、系统及介质: 中国, CN119004214B[P]. 2024-12-31.
- [143] 张志林. 锡膏印刷参数确定方法、装置及存储介质: 中国, CN118094785A[P]. 2024-05-28.

- [144] 刘平. 基于机器视觉的三维锡膏检测关键技术及应用研究 [D]. 重庆大学, 2017.
- [145] YANG Y, ZHANG C, ZHOU T, et al. Dcdetector: Dual attention contrastive representation learning for time series anomaly detection[C]//Proceedings of the 29th ACM SIGKDD Conference on Knowledge Discovery and Data Mining. Association for Computing Machinery, 2023: 3033–3045.
- [146] CHEN X, HE K. Exploring simple siamese representation learning[C]//Proceedings of the IEEE/CVF conference on computer vision and pattern recognition. 2021: 15750-15758.
- [147] DOSOVITSKIY A, BEYER L, KOLESNIKOV A, et al. An image is worth 16x16 words: Transformers for image recognition at scale[C]//International Conference on Learning Representations. 2021.
- [148] 电子开发网. 汽车减震器的构造和工作原理（图解）[EB]. 2021-05-07. [http://www.dzkw.com.cn/Article/dipan/6603.html#google\\_vignette](http://www.dzkw.com.cn/Article/dipan/6603.html#google_vignette).
- [149] WANG J, ZHANG X, ZHANG Z, et al. Attention guided multi-wavelet adversarial network for cross domain fault diagnosis[J]. Knowledge-Based Systems, 2024, 284: 111285.
- [150] ZHANG X, WANG J, ZHANG Z, et al. Integrated decision-making with adaptive feature weighting adversarial network for multi-target domain compound fault diagnosis of machinery[J]. Advanced Engineering Informatics, 2024, 62: 102730.
- [151] HAN B, JIANG X, WANG J, et al. A novel domain adaptive fault diagnosis method for bearings based on unbalance data generation[J]. IEEE Transactions on Instrumentation and Measurement, 2023, 72: 1-11.
- [152] HAN B, YANG Z, ZHANG Z, et al. A novel rolling bearing fault diagnosis method based on generalized nonlinear spectral sparsity[J]. Measurement, 2022, 198: 111131.
- [153] SMITH W A, RANDALL R B. Rolling element bearing diagnostics using the case western reserve university data: A benchmark study[J]. Mechanical Systems and Signal Processing, 2015, 64-65: 100-131.
- [154] LESSMEIER C, KIMOTH O J K, ZIMMER D, et al. Condition monitoring of bearing damage in electromechanical drive systems by using motor current signals of electric motors: A benchmark data set for data-driven classification[C]//PHM Society European Conference: volume 3. 2016.
- [155] LI K, PING X, WANG H, et al. Sequential fuzzy diagnosis method for motor roller bearing in variable operating conditions based on vibration analysis[J]. Sensors, 2013, 13(6): 8013-8041.
- [156] CHEN S, LIU Z, HE X, et al. Multi-mode fault diagnosis datasets of gearbox under variable working conditions[J]. Data in Brief, 2024, 54: 110453.
- [157] PARK D, HOSHI Y, KEMP C C. A multimodal anomaly detector for robot-assisted feeding

- using an lstm-based variational autoencoder[J]. IEEE Robotics and Automation Letters, 2018, 3(3): 1544-1551.
- [158] WU H, HUT T, LIU Y, et al. TimesNet: Temporal 2D-Variation modeling for general time series analysis[C]//The Eleventh International Conference on Learning Representations. 2023.
- [159] FAN J, WANG Z H, WU H F, et al. An adversarial time-frequency reconstruction network for unsupervised anomaly detection[J]. Neural Networks, 2023, 168: 44-56.
- [160] TULI S, CASALE G, JENNINGS N R. TranAD: deep transformer networks for anomaly detection in multivariate time series data[J]. Proc. VLDB Endow., 2022, 15(6): 1201–1214.
- [161] LIU F T, TING K M, ZHOU Z H. Isolation forest[C]//2008 Eighth IEEE International Conference on Data Mining. 2008: 413-422.
- [162] TAX D M J, DUIN R P W. Support vector data description[J]. Machine Learning, 2004, 54(1): 45-66.
- [163] JIANG G, NIE S, XIE P, et al. Multiscale one-class classification network for machine health monitoring[J]. IEEE Sensors Journal, 2022, 22(13): 13043-13054.
- [164] DENG A, HOOI B. Graph neural network-based anomaly detection in multivariate time series[C]//Proceedings of the AAAI conference on artificial intelligence: volume 35. 2021: 4027-4035.
- [165] YANG Z, HUANG Y, NAZEER F, et al. A novel fault detection method for rotating machinery based on self-supervised contrastive representations[J]. Computers in Industry, 2023, 147: 103878.
- [166] HE K, FAN H, WU Y, et al. Momentum contrast for unsupervised visual representation learning[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. 2020: 9729-9738.
- [167] GOUSSEAU W, ANTONI J, GIRARDIN F, et al. Analysis of the rolling element bearing data set of the center for intelligent maintenance systems of the university of Cincinnati[C]//2016.
- [168] WANG B, LEI Y, LI N, et al. A hybrid prognostics approach for estimating remaining useful life of rolling element bearings[J]. IEEE Transactions on Reliability, 2020, 69(1): 401-412.
- [169] NECTOUX P, GOURIVEAU R, MEDJAHHER K, et al. PRONOSTIA : An experimental platform for bearings accelerated degradation tests[C]//IEEE International Conference on Prognostics and Health Management, PHM'12. IEEE Catalog Number : CPF12PHM-CDR, 2012: 1-8.
- [170] LUO J, ZHANG X. Convolutional neural network based on attention mechanism and Bi-LSTM for bearing remaining life prediction[J]. Applied Intelligence, 2022, 52(1): 1076-1091.

- 
- [171] LI Y, WANG H, LI J, et al. A 2-D long short-term memory fusion networks for bearing remaining useful life prediction[J]. *IEEE Sensors Journal*, 2022, 22(22): 21806-21815.
- [172] GUO D, CAO Z, FU H, et al. Remaining useful life estimation for rolling bearings using MSGCNN-TR[J]. *IEEE Sensors Journal*, 2022, 22(24): 24333-24343.
- [173] ZUO T, ZHANG K, ZHENG Q, et al. A hybrid attention-based multi-wavelet coefficient fusion method in RUL prognosis of rolling bearings[J]. *Reliability Engineering & System Safety*, 2023, 237: 109337.
- [174] KRAMMER O, GYARMATI B, SZILAGYI A, et al. The effect of solder paste particle size on the thixotropic behaviour during stencil printing[J]. *Journal of Materials Processing Technology*, 2018, 262: 571-576.
- [175] KRAMMER O, GYARMATI B, SZILAGYI A, et al. Investigating the thixotropic behaviour of type 4 solder paste during stencil printing[J]. *Soldering & Surface Mount Technology*, 2017, 29(1): 10-14.
- [176] CHO K, VAN MERRIËNBOER B, GÚLËEHRE C, et al. Learning phrase representations using RNN encoder–decoder for statistical machine translation[C]//*Proceedings of the 2014 Conference on Empirical Methods in Natural Language Processing (EMNLP)*. 2014: 1724-1734.
- [177] HOCHREITER S, SCHMIDHUBER J. Long short-term memory[J]. *Neural Computation*, 1997, 9(8): 1735-1780.
- [178] ESSIEN A, GIANNETTI C. A deep learning model for smart manufacturing using convolutional LSTM neural network autoencoders[J]. *IEEE Transactions on Industrial Informatics*, 2020, 16(9): 6069-6078.
- [179] LI T, ZHAO Z, SUN C, et al. Multireceptive field graph convolutional networks for machine fault diagnosis[J]. *IEEE Transactions on Industrial Electronics*, 2020, 68(12): 12739-12749.

## 致谢

六年的硕博生涯弹指一挥间，硕士入学仿佛近在眼前，又仿若隔世。回望硕博生涯，虽然一路坎坷，但也收获良多，增长了大量的见识，也极大的充实了人生经历。能够按时毕业离不开老师的指导，实验室同学的帮助，朋友的鼓励以及家人的支持，念此感激之情难以言表。

首先，感谢我的校内导师赵云波老师，我能够如期完成学业离不开老师的指导和帮助。赵老师是一位严谨，睿智，极具思想性的老师。他对我从科研能力到办事以及个人性情等方面进行了全面的培养。在科研中，赵老师反复锤炼我的写作逻辑，完善我的不足，用心打磨我的论文，精益求精，促使我的论文最终发表。在生活中，也教导我如何待人接物，感谢赵老师的言传身教，让我从刚入学时的懵懂稚嫩，逐渐变成现在的成熟稳重。让我改掉做事急躁的缺点，明白路要一步一步走，事要一点一点做的道理。还要感谢康宇老师，曹洋老师，许镇义师兄，李鹏飞师兄以及陈绍冯师姐，在论文的构思与撰写过程中给我详细的指点。我从中获益匪浅。

其次，感谢同组的谢飞、青凡迪、陈龙鑫、李佳玉、余碧桢、王晓莹、徐晨伟等同学。他们帮我整理毕业相关的材料，完成部分论文的调研与实验，分担了很多科研任务，帮我节省了很多的时间。我们相互扶持，砥砺前行。此外还要感谢翟卫民、卢昊天等人，我们从事相似的研究，在具体的研究任务上可以互相启发，给予很多有价值的建议。能和这群同学共事是我三生有幸，愿各位都能有锦绣前程。

然后，感谢人机组的卢峻森、周雅情、蒋舒悦、陈少军、汪洋、夏睿钰、张雯等同学。我们经常聚餐，互相鼓励，分享各自的见闻，交流对科研的看法，让我汲取精神上的养分。尤其是卢峻森，在我迷茫的时候，每天都陪着我，和我聊到深夜，安抚我低落的情绪。非常有幸交到这群朋友，愿我们的友谊地久天长。

我还要感谢联宝的锡膏印刷工程师李小冬，AOI工程师刘家付，以及优秀的PCB设计师孙晓会，在论文的工程背景方面给予我很大的帮助与指导。他们容忍我一遍又一遍的打扰，帮我完善论文的工程背景，提供很多的真实工程数据，让我的学位论文更符合工程博士的要求。

最后，感谢我的家人。来合肥十年，舅舅舅妈也照顾了我十年，给我添衣加餐。每次放假开学都是小姨和姨父接送我去高铁站。我叔叔和姑姑也常常给我生活费。而爸爸妈妈的默默付出与支持是我坚持下来最主要的原因。读博是荣誉、是收获、是前程似锦，也同样是困苦、是迷茫、是熬尽心血。爸爸妈妈虽然不善言辞，不清楚我的研究内容，但每每在我论文被拒的时候，也会默默的陪伴

我，是我人生中最重要锚点。弟弟妹妹们虽然都还小，完全听不懂我在做什么，但能敏锐的察觉到我的情绪变化，我高兴的时候他们会一起高兴，我难过的时候他们用自己的方式安慰我，鼓励我。在外游学已有十年，从最初的每逢节假日就回家到只有寒暑假才能短暂的和父母团聚，以后更是可能只有过年才能回家。我如同风筝，离父母越飞越远，越飞越远，越飞越远。毕业后我还要在外漂泊不知多少年，但愿我能回家安身立业，常伴父母左右！

人生路漫漫，往事已已。希望我能以全新的精神面貌迎接下一个人生阶段。

## 在读期间取得的科研成果

### 期刊论文

1. **Liu Binkun**, Kang Yu, Zhao Yunbo, Cao Yang, and Xu Zhenyi. Multi-Sensor Contrast Neural Network for Remaining Useful Life Prediction of Rolling Bearing under Scarce Labeled Data. *Frontiers of Information Technology & Electronic Engineering*. 2024. Accepted. (对应正文第四章)
2. **Liu Binkun**, Kang Yu, Zhao Yunbo, Cao Yang, and Xu Zhenyi. PCB Layout-Based Spatio-Temporal Graph Convolution Network for Anomaly Prediction in Solder Paste Printing. *IEEE Transactions on Components, Packaging and Manufacturing Technology*. vol. 15, no. 1, pp. 214-223, Jan. 2025. (对应正文第五章)
3. Zhu Huijuan, Zhao Yunbo, Yan Xiaohui, Kang Yu, and **Liu Binkun**. Cross-Sensor Generative Self-Supervised Learning Network for Fault Detection Under Few Sample. *Journal of Systems Science & Complexity*. 2025. Accepted.

### 待投论文

1. **Liu Binkun**, Zhao Yunbo, Kang Yu, Cao Yang, Yu Bizhen, and Xu Zhenyi. A Multi-Sensor Double Contrast Denoising Network for Fault Detection with Consideration of Inaccurate Measurement of The Healthy State. (对应正文第三章)

### 会议论文

1. **Liu Binkun**, Zhao Yunbo, Kang Yu, Cao Yang, Bai Peng, and Xu Zhenyi. A Feature Engineering-based Method for PCB Solder Paste Position Offset Prediction. 2023 6th International Symposium on Autonomous Systems (ISAS), Nanjing, China, 2023, pp. 1-6.
2. **Liu Binkun**, Zhao Yunbo, Kang Yu, Cao Yang, and Xu Zhenyi. "A Robustness Benchmark for Prognostics and Health Management," 2022 41st Chinese Control Conference (CCC), Hefei, China, 2022, pp. 7338-7342.
3. Longxin Chen, Yunbo Zhao, **Liu Binkun**, Shaojie Dong, Huijuan Zhu, and Peng Bai, A Reliable Ensemble Model based on Hierarchical Component Features for Repair Label Prediction of Soldering Defects. 2024 14th Asian Control Conference (ASCC), Dalian, China, 2024, pp. 1563-1568.

4. Jiayu Li, Yunbo Zhao, and **Liu Binkun**. Functional Evaluation for Printed Circuit Board Based on Surface Mount Technology Process Data. Shenzhen, China, 2024, pp. 18-21.
5. Xu Zhenyi, Wu Qilai, Wei Xiaolong, **Liu Binkun**, Guo Yanming, Kang Yu. MCNN-Based Model for Rotating Equipment Fault Diagnosis. Advances in Guidance, Navigation and Control. ICGNC 2024. Lecture Notes in Electrical Engineering, vol 1347.

## 已授权专利

1. 赵云波, **刘斌琨**, 康宇, 曹洋, 余碧桢, 陈龙鑫. 液压减震器无监督故障检测方法、系统、设备与存储介质 [P]. 安徽省:CN202411593785.8, 2024-12-13.
2. 赵云波, **刘斌琨**, 康宇, 曹洋, 陈龙鑫, 李佳玉. 锡膏印刷质量异常预测方法、系统、设备及存储介质 [P]. 安徽省:CN202411566368.4, 2024-12-03.
3. 康宇, 余乾子, 曹洋, **刘斌琨**, 许镇义. 一种轴承故障诊断方法、系统、存储介质及设备 [P]. 安徽省:CN202111340215.4, 2024-09-13.

## 实审专利

1. 赵云波, **刘斌琨**, 康宇, 曹洋, 许镇义. 减震器故障检测方法、装置、设备及存储介质 [P]. 安徽省:CN202211313138.8, 2023-01-06.
2. 许镇义, **刘斌琨**, 康宇, 赵云波, 曹洋. 一种基于特征迁移的轴承剩余使用寿命预测方法 [P]. 安徽省:CN202311050585.3, 2023-10-17.
3. 康宇, **刘斌琨**, 赵云波, 曹洋, 许镇义, 柏鹏. 一种基于时间重构图卷积的PCB 锡膏印刷质量预测方法 [P]. 安徽省:CN202310560285.3, 2023-09-22.
4. 曹洋, **刘斌琨**, 赵云波, 康宇, 许镇义. 基于特征工程的PCB 板焊盘偏移预测方法及存储介质 [P]. 安徽省:CN202211302346.8, 2023-03-07.
5. 康宇, **刘斌琨**, 赵云波, 许镇义, 曹洋. 一种基于多传感器特征融合的轴承故障诊断方法 [P]. 安徽省:CN202311108715.4, 2023-12-12.
6. 赵云波, 陈龙鑫, **刘斌琨**, 朱慧娟, 许镇义, 柏鹏. 故障诊断模型的训练方法、装置、电子设备及存储介质 [P]. 安徽省:CN202310901745.4, 2023-09-19.
7. 赵云波, 董少杰, **刘斌琨**, 朱慧娟, 许镇义, 柏鹏. 产线设备故障预测方法、装置、电子设备及存储介质 [P]. 安徽省:CN202311068429.X, 2023-11-24.
8. 赵云波, 李佳玉, 康宇, 柏鹏, 谈正军, 徐久存, **刘斌琨**, 许镇义. 基于图注意力神经网络的印刷电路板质量预测方法 [P]. 安徽省:CN202410915657.4, 2024-10-29.

9. 魏晓龙, 赵云波, 孙浩, 谭娜, 吴启来, 许镇义, 刘斌琨. 盾构机刀具故障诊断方法、装置和系统、程序产品和介质: 河南省, CN119646655A[P]. 2025-03-18.

### 授权软著

1. 赵云波, 刘斌琨, 曹洋, 康宇, 许镇义. 锡膏印刷机离线故障预测软件 V1.0. 登记号: 2023SR0142087.
2. 许镇义, 刘斌琨, 康宇, 曹洋, 赵云波. 锡膏印刷机参数调整数据处理软件 V1.0. 登记号: 2022SR097608.

### 科学技术成果鉴定证书

1. 导师排名 19/28, 本人排名 21/28, 盾尾密封状态监测系统

### 参与科研项目

1. 安徽省重点研发, 人机智能协同关键技术及其在智能制造中的应用.
2. 安徽省发改委重大专项, 非可信智能驱动的可靠智造.
3. 企业横向, 掘进机盾尾密封及刀具状态智能诊断与评价技术研究