

中图分类号:

论文编号: 10357WA21301041



专业硕士学位论文

缺陷样本匮乏场景下的笔记本电脑表面缺陷检测方法研究

作者姓名 张杰
专业学位类别 电子信息
专业学位领域 人工智能
指导教师 赵鹏、赵云波

Surface defect detection methods for laptop computers in defect sample scarcity scenarios

A Dissertation Submitted for the Degree of Master

Candidate : Zhang Jie

Supervisor: Zhao Peng、 Zhao Yunbo

中图分类号:

论文编号: 10357WA21301041

硕士学位论文

缺陷样本匮乏场景下的笔记本电脑表面缺陷检测方法研究

作者姓名	张杰	申请学位级别	工程硕士
指导教师姓名	赵鹏、赵云波	职 称	副教授、教授
学科专业	人工智能	研究方向	工业缺陷检测
学习时间自	2021年 09月 07日	起至	2024年 07月 01日止
论文提交日期	2024年 05月 20日	论文答辩日期	2024年 05月 17日

独创性声明

本人声明所呈交的学位论文是本人在导师指导下进行的研究工作及取得的研究成果。据我所知，除了文中特别加以标注和致谢的地方外，论文中不包含其他人已经发表或撰写过的研究成果，也不包含为获得安徽大学或其他教育机构的学位或证书而使用过的材料。与我一同工作的同志对本研究所做的任何贡献均已在论文中作了明确的说明并表示谢意。

学位论文作者签名：张杰

签字日期：2024年5月17日

学位论文授权使用授权书

本学位论文作者完全了解安徽大学有关保留、使用学位论文的规定，有权保留并向国家有关部门或机构送交论文的复印件和磁盘，允许论文被查阅和借阅。本人授权安徽大学可以将学位论文的全部或部分内容编入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。

(保密的学位论文在解密后适用本授权书)

学位论文作者签名：张杰

导师签名：

张杰

签字日期：2024年5月17日

签字日期：

2024年5月17日

摘 要

工业产品的表面缺陷检测是保证产品质量的一项重要步骤，在生产线上及时检测并排除有缺陷的产品，可以确保制造出的产品符合质量标准和客户的期望，同时帮助企业及时分析潜在的生产风险，提升产线的稳定性与生产效率。

在现有的笔记本电脑生产线上，仍然使用效率低、主观性强、成本高的人工目检方式进行笔记本电脑的表面缺陷检测。随着计算机视觉、深度学习等人工智能技术的发展，在缺陷样本数据充足的条件下，基于深度学习的缺陷检测算法能够有效地识别不同类型的表面缺陷，具备较好的自适应性和准确性。然而，受限于笔记本电脑生产过程中严格把控产品质量，产生缺陷的概率很小，导致难以收集相对充足的缺陷样本用于训练深度学习算法。此外，基于有监督的深度学习检测算法往往难以检测训练集之外的未见缺陷类型。为此，本文针对缺陷样本匮乏场景下的笔记本电脑表面缺陷检测问题，从无监督学习、半监督学习的角度出发展开一系列研究，同时，通过合适的硬件选型构建图像采集单元，并结合软件开发技术完成笔记本电脑外观缺陷检测系统的搭建。本文的主要研究内容与工作如下：

- (1) 针对缺陷样本匮乏场景中难以获得足够的缺陷样本数据用于训练有监督缺陷检测算法的问题，借助于无监督学习的思想，提出了一种基于多尺度标准化流的笔记本电脑表面缺陷检测方法，在训练过程中仅利用正常样本。首先，通过多尺度特征提取网络获取正常样本图像的多尺度特征，提高检测方法的尺度不变性。其次，通过多尺度标准化流网络学习正常样本的特征分布，由于正常样本与缺陷样本之间存在着明显的特征分布差异，通过在训练过程中对正常样本特征分布的拟合，进而实现正常样本分布外的缺陷检测。
- (2) 针对实际工业场景中，在获取充足的正常样本的同时，可以收集少量的缺陷样本用于算法训练，借助于半监督、自监督学习的思想，提出了一种基于缺陷模拟的记忆化笔记本电脑表面缺陷检测方法。在训练阶段，通过事先设计好的缺陷模拟策略，在输入的正常样本的随机位置生成随机尺度大小的纹理缺陷，得到缺陷尺度各异的模拟缺陷样本。然后，将生成的缺陷样本分别与正常样本特征记忆池和缺陷样本特征记忆池进行最近匹配，利用与已知缺陷样本的共性和正常样本的差异性辅助模型学习，最后通过解码器网络检测模拟缺陷样本的缺陷区域。在测试

阶段，所提方法以端到端的方式对输入样本图像进行缺陷检测。

- (3) 针对笔记本电脑生产过程中的表面缺陷检测流程，开发了一款笔记本电脑表面缺陷检测系统。首先，基于工业相机、镜头、光源搭建实时图像采集单元。然后，基于 PyQt5 配合图像采集单元进行软件开发。最后，通过集成训练好的缺陷检测算法，该系统可以实时地对笔记本电脑进行表面缺陷检测，通过时耗分析，证明了该系统的有效性与可应用性。

关键词：表面缺陷检测，数据匮乏，多尺度特征，标准化流，缺陷模拟

Abstract

Surface defect detection of industrial products is an important step to ensure product quality, timely detection and elimination of defective products on the production line ensure that the manufactured products meet the quality standards and customer expectation, while helping companies to timely analyze the potential production risks and improve the stability of the production line and production efficiency.

In the existing laptop production line, the manual visual inspection method, which is inefficient, subjective, and costly, is still used to detect surface defects in laptop computers. With the development of artificial intelligence technologies such as computer vision and deep learning, under the condition of sufficient defect sample data, the defect detection algorithm based on deep learning is able to effectively recognize different types of surface defects with better adaptivity and accuracy. However, due to the strict control of product quality in the production process of notebook computers, the probability of defects is very small, which makes it difficult to collect relatively sufficient defect samples for training deep learning algorithms. In addition, supervised deep learning based detection algorithms often have difficulty detecting unseen defect types outside the training set. For this reason, this thesis focuses on the problem of detecting surface defects in laptop computers under the scenario of lack of defect samples, and carries out a series of studies from the perspectives of unsupervised learning and semi-supervised learning, at the same time, constructs an image acquisition unit through appropriate hardware selection, and completes the construction of the laptop appearance defect detection system by combining with software development techniques. The main research content and work of this thesis are as follows:

- (1) Aiming at the problem that it is difficult to obtain sufficient defect sample data for training supervised defect detection algorithms in defect sample scarcity scenarios, a multi-scale normalizing flow-based surface defect detection method for laptop computers is proposed with the help of the idea of unsupervised learning, where only normal samples are utilized in the training process. First, the multi-scale features of the normal sample image are obtained through a multi-scale feature extraction network to improve the scale invari-

ance of the detection method. second, the feature distribution of the normal samples is learned through the multi-scale normalizing flow network, and due to the obvious feature distribution difference between the normal sample and the defective sample, the normal sample distribution is fitted by fitting to the feature distribution of the normal samples during the training process, which in turn achieves the normal sample distribution defect detection outside the normal sample distribution.

- (2) Aiming at practical industrial scenarios where a small number of defective samples can be collected for algorithm training while obtaining sufficient normal samples, a memorized laptop computers surface defect detection method based on defect simulation is proposed with the help of semi-supervised and self-supervised learning ideas. In the training stage, texture defects of random scale size are generated at random locations of the input normal samples by a pre-designed defect simulation strategy, to obtain simulated defect samples with different defect scales. Then, the generated defect samples are recently matched with the normal sample feature memory pool and the defect sample feature memory pool, respectively, and the commonality with the known defect samples and the difference with the normal samples are utilized to assist the model learning, and finally the defective regions of the simulated defect samples are detected by the decoder network. In the testing phase, the proposed method performs defect detection on the input sample images in an end-to-end manner.
- (3) Aiming at the surface defect detection process in the production process of laptop computers, a surface defect detection system for laptop computers is developed. First, a real-time image acquisition unit is built based on industrial camera, lens and light source. Then, the software development is based on PyQt5 together with the image acquisition unit. Finally, by integrating the trained defect detection algorithm, the system can detect surface defects on laptop computers in real time, and the effectiveness and applicability of the system are proved by time consumption analysis.

Key words: Surface defect detection, Data scarcity, Multi-scale features, Normalizing flow, Defect simulation

目 录

第一章 绪论	1
1.1 研究背景和意义	1
1.2 国内外研究现状	2
1.2.1 基于传统机器学习的表面缺陷检测方法	3
1.2.2 基于深度学习的表面缺陷检测方法	3
1.3 论文研究内容与组织结构	6
1.3.1 研究内容	6
1.3.2 组织结构	7
第二章 相关理论基础与技术	8
2.1 标准化流	8
2.1.1 雅可比矩阵	8
2.1.2 变量替换定理	9
2.1.3 标准化流的构建	9
2.2 多尺度检测	10
2.2.1 图像金字塔	11
2.2.2 金字塔多层次特征	12
2.2.3 多尺度特征融合	12
2.3 缺陷模拟	13
2.4 评价指标	14
2.5 本章小结	16
第三章 基于多尺度标准化流的笔记本电脑表面缺陷检测方法	17
3.1 引言	17
3.2 模型构建	18
3.2.1 多尺度特征提取	18
3.2.2 置换注意力网络	20
3.2.3 多尺度标准化流	21

3.3	模型训练	22
3.3.1	训练目标	22
3.3.2	检测与定位	22
3.4	实验结果与分析	23
3.4.1	数据集与评价指标	23
3.4.2	实验设置	24
3.4.3	对比实验	24
3.4.4	消融实验	26
3.5	本章小结	26
第四章 基于缺陷模拟的记忆化笔记本电脑表面缺陷检测方法		27
4.1	引言	27
4.2	模型构建	28
4.2.1	缺陷模拟策略	28
4.2.2	特征记忆池	30
4.2.3	多尺度特征融合	31
4.3	模型训练	31
4.4	实验结果与分析	32
4.4.1	数据集与评价指标	32
4.4.2	实验设置	32
4.4.3	对比实验	33
4.4.4	消融实验	34
4.5	本章小结	35
第五章 笔记本电脑外观缺陷检测系统		36
5.1	硬件平台	36
5.1.1	工业相机	36
5.1.2	镜头	37
5.1.3	光源	37
5.2	检测软件开发	38
5.2.1	软件执行流程	38
5.2.2	软件界面设计	39

5.3 系统测试结果	40
5.4 本章小结	41
第六章 总结与展望	42
6.1 总结	42
6.2 研究展望	43
参考文献	44
攻读硕士学位期间取得的学术成果	51
致 谢	52

图 清单

图 1.1 同缺陷类型对比图	2
图 1.1 Comparison chart with the same defect type	2
图 1.2 表面缺陷检测技术发展	2
图 1.2 Development of surface defect inspection technology	2
图 2.1 标准化流模型示意图	9
图 2.1 Schematic diagram of the normalizing flows model	9
图 2.2 图像金字塔结构	12
图 2.2 Image pyramid structure	12
图 2.3 金字塔多层次特征结构	12
图 2.3 Pyramid multi-level feature structure	12
图 2.4 特征金字塔结构	13
图 2.4 Feature pyramid structure	13
图 2.5 二分类混淆矩阵	15
图 2.5 Binary confusion matrix	15
图 3.1 所提方法的整体执行流程	18
图 3.1 The overall implementation process of the proposed method	18
图 3.2 多尺度特征提取网络结构	19
图 3.2 Structure of multi-scale feature extraction network	19
图 3.3 置换注意力网络结构 ^[66]	20
图 3.3 Structure of shuffle attention network ^[66]	20
图 3.4 多尺度标准化流子网络结构	21
图 3.4 Structure of multi-scale normalizing flows subnetwork	21
图 3.5 图 3.4 中的全卷积子网络结构	22
图 3.5 The fully convolutional subnetwork structure in Figure 3.4	22
图 3.6 缺陷样本图像	23
图 3.6 Defective sample images	23

图 3.7 数据集分布可视化图	24
图 3.7 Visualization of dataset distribution	24
图 3.8 缺陷定位可视化结果	25
图 3.8 Visualization of defect location results	25
图 4.1 所提方法的整体执行流程	28
图 4.1 The overall implementation process of the proposed method	28
图 4.2 缺陷模拟策略示意图	29
图 4.2 Schematic diagram of defect simulation strategy	29
图 4.3 模拟生成的缺陷样本图像	30
图 4.3 Simulated defect sample images	30
图 4.4 记忆化池模块	30
图 4.4 Memorization Pool Module	30
图 4.5 多尺度特征融合网络	31
图 4.5 Multi-scale feature fusion network	31
图 4.6 缺陷定位可视化结果	34
图 4.6 Visualization of defect location results	34
图 5.1 缺陷检测系统样机	36
图 5.1 Prototype of defect detection system	36
图 5.2 软件执行流程	39
图 5.2 Software execution process	39
图 5.3 检测软件界面设计框架	40
图 5.3 Interface design framework of detection software	40
图 5.4 检测系统运行结果图	41
图 5.4 Detection system operation result chart	41

表 清 单

表 3.1 不同方法检测性能比较	25
表 3.1 Comparison of detection performance of different methods	25
表 3.2 消融实验性能比较	26
表 3.2 Performance comparison of ablation experiment	26
表 4.1 不同方法检测性能比较	33
表 4.1 Comparison of detection performance of different methods	33
表 4.2 不同缺陷模拟策略的性能比较	34
表 4.2 Performance comparison of different defect simulation strategies	34
表 5.1 检测系统平均用时 (单位 s)	40
表 5.1 Average time for detection system (in s)	40

第一章 绪论

1.1 研究背景和意义

随着互联网的飞速发展以及物联网技术的普及，新一代信息技术逐渐融入到各个行业，进而推动各行业的进一步发展。其中，信息技术与传统制造业的融合使其逐步向智能化、数字化发展^[1]，工业生产重心逐步从产品数量扩增向产品质量提升转变。《中国制造 2025》指出，将我国建设为制造强国需要进一步促进信息化与工业化的融合，并进一步推进企业生产研发全过程的智能化^[2]。工业缺陷检测一般是指在生产过程中检测出各种工业制品的表面缺陷，是提高产品质量和保证生产稳定的关键技术^[3]。因此，结合现代化信息技术的工业表面缺陷检测具有重要的研究价值和良好的应用价值。

在笔记本电脑生产制造过程中，生产线上装配完成的笔记本电脑有较小的概率会存在外观缺陷，如划痕、颗粒、指纹、污渍等，对于这类外观缺陷，需要在产品出厂前进行排查，以确保产出的笔记本电脑的外观符合既定标准，保证产品质量，并帮助工厂及时排查生产过程中的潜在问题从而改进生产工艺。以往的笔记本电脑表面缺陷检测需要人工目检，不仅成本高，而且检测效率较低，难以应用于大规模的产品质检，并且人工检测过程带有明显的主观性，不同质检人员对于缺陷的判断标准不一致。

近年来，随着计算机视觉和深度学习等技术的快速发展，基于机器视觉的缺陷检测技术在一些工业场景中不断迭代更新，展示出了不亚于人工目检的检测性能，已成为工业产品质检的有效方案之一。在缺陷样本数据充足的条件下，工业缺陷检测不仅可以用于各种工业产品的表面缺陷检测，同时具有优秀的检测精度与检测速度。此外，基于机器视觉的工业缺陷检测技术避免了生产过程中人的二次触碰，减少了因人工因素导致的质量问题，这在笔记本电脑生产过程以及一些精细的电子元器件加工过程中至关重要。然而，相比于其他工业产品的表面缺陷检测，针对笔记本电脑表面缺陷检测存在着以下难点：1) 缺陷样本匮乏，在笔记本电脑生产过程中严格把控产品的良率，产品出现缺陷的概率很小，因此可获取的缺陷样本的数量很少；2) 缺陷类型未知，在生产过程中无法预知产品出现的缺陷模式，难以通过人为归纳所有的缺陷类型，随着生产制造过程的进行，可能会出现未观测过的缺陷类型；3) 缺陷特征差异大，不仅体现在不同缺陷类型的类间差异大，同种缺陷类型在几何特征或纹理特征上具有多样性，也存在着较大

的类内差异，如图 1.1所示。由于以上原因导致笔记本电脑生产过程中难以收集到足够的缺陷样本，或收集到囊括所有缺陷类型的样本用于训练缺陷检测算法，进而导致许多缺陷检测性能优秀的方法难以应用于笔记本电脑表面缺陷检测领域，因此在缺陷样本匮乏场景下的笔记本电脑表面缺陷检测领域还存在大量问题亟待解决。




图 1.1 同缺陷类型对比图
Figure 1.1 Comparison chart with the same defect type

1.2 国内外研究现状

在机器视觉领域中，如何有效地检测出各种工业产品的表面缺陷是一项重要的研究课题^[4, 5]，利用机器视觉进行表面缺陷检测这一过程也被称为自动光学检测 (AOI, Automated optical inspection)。这项技术利用光学成像系统和计算机视觉算法来获取图像，并对采集的图像进行分析以判断是否存在缺陷，并已广泛应用于与笔记本电脑类似的工业产品生产过程中的缺陷检测，如钢材铸造^[6]、金属加工^[7]、手机生产^[8]、半导体元器件加工^[9] 等各行各业。现有的关于表面缺陷检测方法的研究，大体上可以分为基于手工特征工程的传统机器学习方法和基于自动特征提取的深度学习方法两大类，如图 1.2所示。




图 1.2 表面缺陷检测技术发展
Figure 1.2 Development of surface defect inspection technology

1.2.1 基于传统机器学习的表面缺陷检测方法

基于传统方法的表面缺陷检测主要是依据图像的颜色、形状、纹理等特征和图像统计信息，再利用传统图像处理技术或结合机器学习中的分类、聚类等方法进行缺陷检测。Song 等^[10]设计了一种自动检测木材表面缺陷的方法，该方法利用局部图像块的颜色直方图和特征向量纹理特征进行分类，能够很好地检测出木材表面的缺陷。Lee 等^[11]设计了一种缺陷识别方法，该方法基于颜色直方图，并利用差值、平均值和标准差等统计指标对缺陷图像进行分析。仰梓淮等^[12]针对二次利用电路板的缺陷特性，对电路板图像进行分块，并通过比较局部图像的颜色特征来进行缺陷检测。同时利用四分裂结构的颜色直方图结合 SVM 分类器进行缺陷分类，这种方法既保证了检测精度，又兼顾了检测速度。胡跃明等^[13]提出了一种基于单高斯模型的二维颜色分割的铜箔表面氧化缺陷检测方法，该方法通过提取图像的颜色矩、颜色占比等颜色特征，这些特征被输入到有向无环图支持向量机分类器中，以实现铜箔表面氧化缺陷的快速分级。Yan 等^[14]提出了一种完整的局部三元模式方法，用于焊接缺陷识别，该方法在不同的光照下提高了性能。郭萌等^[15]结合了 Kirsch 算子和 Canny 算子对瓷瓦表面图像中缺陷区域进行边缘检测，区别图像中的缺陷前景与背景。刘源等^[16]提出了一种带钢表面缺陷边缘检测算法。首先利用双边滤波去除输入图像的噪声，然后使用改进 Sobel 算子检测缺陷边缘，最后通过动态阈值进行二值化处理并细化缺陷边缘，实现了对带钢表面缺陷的有效检测。Hou 等^[17]利用 Gabor 小波算子提取频域特征信息，并结合支持向量机分类方法来检测纹理表面缺陷。

传统的基于机器视觉的表面缺陷检测算法计算复杂度低，可轻松移植在一些嵌入式设备中，但通常检测精度不高，且适应场景较为单一，可迁移性差，适用于简单的工业场景。另一方面，由于表面缺陷的类间差异性大，不同类型的缺陷需要不同的手工特征表示，所以提取的手工特征可能难以准确描述缺陷，同时手工特征的有效提取高度依赖于具备丰富经验的专家。因此，基于传统机器学习方法的表面缺陷检测缺乏缺陷检测任务所需要的泛化性和鲁棒性，限制了其在实际工业场景中的推广和应用。

1.2.2 基于深度学习的表面缺陷检测方法

深度学习最先由 LeCun 等^[18]提出，并且在图像分类^[9]任务中取得重大突破。随着深度学习方法在目标检测^[19, 20]、目标分割^[21, 22]、目标跟踪^[23, 24]等计算机视觉任务中的

快速发展，基于深度学习的工业缺陷检测方法层出不穷，并逐渐成为研究热门之一。在工业表面缺陷检测领域，相比于传统机器学习方法，基于深度学习的检测方法有如下优点：（1）深度学习方法可以通过端到端的训练过程，自动地从原始图像数据中学习高级特征表示，避免了手工特征设计的需要，并且能够更好地捕捉缺陷的复杂特征，提高了缺陷检测精度；（2）具有较好的泛化性，可以在不同类型的缺陷检测任务上表现出色。一旦模型经过充分的训练，它可以适应新的场景和缺陷类型，而无需重新设计和调整算法；（3）在大规模数据集上训练的情况下，深度学习方法通常具有较高的性能，通过大量的数据来学习抵抗噪声和干扰的能力，这使得深度学习模型对于复杂背景噪声和图像变换等因素更加鲁棒，能够更准确地检测和定位缺陷。

目前，大部分基于深度学习方法的表面缺陷检测研究都是基于完全监督的特征学习^[25]。特征学习^[26]的目的是从原始数据中自动提取出具有关键信息的高级特征，进而将缺陷检测问题转化为图像分类任务，根据不同任务的需要，可以进一步分为粗粒度的全局图像分类或局部图像分类，以及细粒度的像素分类。Deitsch 等^[27]对 VGG19^[28]网络进行改进用于识别太阳能面板表面图像缺陷，网络的准确率达到 88.42%，检测精度高于多种传统手工设计特征方法。陶志勇等^[29]使用 Ghost 卷积层替换 VGG 网络中的常规卷积层，同时引入了注意力机制和批规范化保证对电池片缺陷的高精度检测。借助于目标检测领域中优秀的检测算法，Tao 等^[30]设计了一种级联 Faster R-CNN^[31]模型，以两阶段的检测实现绝缘子的缺陷检测，首先使用目标检测来定位绝缘子位置，然后再次检测目标上的缺陷位置。Zhang 等^[32]采用迁移学习方法进一步改进了 YOLOv3^[33]用以检测桥梁缺陷，同时结合了批规范化与焦点损失提升检测精度。张乃雪等^[34]提出了 Smooth-DETR 缺陷检测算法，首先使用 DETR^[35]算法检测缺陷类别与位置，再利用 Smooth-L1 损失和 GIoU 损失改进损失函数进一步提升算法对小尺寸缺陷的检测精度。在实际应用场景中，除了检测图像中是否含有缺陷，对图中缺陷的精确定位同样重要。因此，研究人员基于一些优秀的目标分割算法对缺陷区域分割展开了一系列研究。Yu 等^[36]提出了一种高效的两阶段 FCN^[37]的表面缺陷检测方法。第一阶段利用轻量级的 FCN 处理原始图像得到粗略的缺陷位置，然后将前一阶段的输出作为第二阶段 FCN 的输入用于细化分割过程，得到更精确的检测结果。王延年等^[38]对 U-Net 网络^[39]进行改进后将其应用于太阳能电池缺陷检测，该方法首先引入密集连接结构缓解训练过程中的梯度消失问题，然后利用双注意力机制^[40]增强有效的目标信息，弱化背景信息的影

响，提高了缺陷检测和分割性能。

相对依赖于充足的缺陷样本数据的完全监督缺陷检测方法来说，仅基于正常样本训练的无监督缺陷检测方法或者半监督缺陷检测方法更符合实际工业场景，并逐渐成为学术界与工业界的研究重点。Cohen 等^[41] 在训练阶段存储只含正常样本的特征池，在测试阶段，寻找特征池中最近的 K 个特征计算异常得分来判断异常，然后通过特征金字塔进行像素级缺陷定位。然而训练时需要存储的特征与正常样本的数量呈线性关系，训练采用的正常图像越多，存储的特征也就越多，因此算法复杂度较高。Akçay 等^[42] 基于图像重构的思想，设计了一种编码-解码-再编码结构，训练目标旨在将输入图像重建为正常图像，在检测时根据重构差异判断是否异常。Defard 等^[43] 通过多层次特征估计正常样本图像中每一个位置的分布。在测试阶段，计算每个位置与对应分布之间的具体作为该位置异常得分，最后选取最大值作为图像异常得分。陈大鹏等^[44] 提出了一种基于多尺度特征重建的自编码器结构，结合迁移学习中的知识蒸馏思想增强自编码器重构过程的鲁棒性，在公开的无监督缺陷检测数据集 MVTEC^[45] 上验证了所提方法的有效性。

在大部分缺陷类型已知并且缺陷样本数据充足的条件下，基于完全监督学习的缺陷检测方法能实现优秀的检测性能，在部分实际工业应用场景中满足高精度、高速度的任务需求。然而，在面对缺陷类型未知、样本稀少的情况时，难以获取大量有标注的缺陷样本数据用于训练基于完全监督学习的缺陷检测方法。此外，基于完全监督学习的检测方法只能识别在训练数据中出现过的缺陷类型，对于未知的、新出现的缺陷类型，模型可能无法进行准确的缺陷检测。基于无监督学习的检测方法在训练阶段仅需要易被获取的正常样本图像，通过对正常样本图像的高级特征的学习，得以区分正常样本与缺陷样本之间的特征差异，解决了基于完全监督学习的检测方法无法发现未知缺陷的问题。基于半监督的缺陷检测方法则适用于可获取充足的正常样本与少量的缺陷样本数据的场景，同时利用正常样本与缺陷样本中的特征信息训练模型，提升缺陷检测性能。基于以上两种模式的缺陷检测方法由于减少对标注数据的依赖，克服了基于完全监督学习的检测方法存在的局限性，因而成为了当今的研究热点。

1.3 论文研究内容与组织结构

1.3.1 研究内容

本文以笔记本电脑表面缺陷检测问题为对象，结合深度学习中无监督学习和半监督学习两种学习模式，展开面向缺陷样本匮乏场景下的笔记本电脑表面缺陷检测方法研究，分别提出针对仅有正常样本以及少量缺陷样本两种场景下的笔记本电脑表面缺陷检测方法。最后搭建了一套笔记本电脑外观缺陷检测系统并验证其有效性。

本文的具体研究内容如下：

- (1) 针对实际笔记本电脑生产过程中，通常难以收集全部类型的足量缺陷样本数据用于训练，即使某些缺陷类型是已知的，由于制造过程中不可预见的事件，新的缺陷类型仍然可能随时产生。基于无监督学习的思想，提出了一种基于多尺度标准化流的笔记本电脑表面缺陷检测算法，仅基于正常样本图像进行训练。首先，构造一种基于双向特征融合的多尺度特征提取网络用于特征提取，通过构建两组相反的特征融合路径，有效地融合浅层特征的空间细节信息和深层特征的语义信息。然后基于级联标准化流对提取的多尺度特征进行密度估计。最后通过多尺度标准化流网络转换得到的潜在空间似然值进行缺陷检测与缺陷定位，实验结果证明了所提方法的有效性。
- (2) 针对实际笔记本电脑生产过程中，获得大量正常样本与少量缺陷样本的场景更加常见。因此，基于半监督学习的检测方法更贴合工业场景，可以更加充分利用样本数据。基于半监督学习的思想，提出了一种基于缺陷模拟的记忆化笔记本电脑表面缺陷检测方法。通过设计一种缺陷模拟策略从正常样本生成缺陷样本，同时构建正常样本特征记忆池与缺陷样本特征记忆池学习缺陷的共性与差异性辅助模型学习，进而提升缺陷检测性能。在训练阶段，通过显式地学习正常样本和模拟的缺陷样本之间的潜在特征差异，以获得鲁棒的缺陷检测性能。在推理阶段，以端到端的方式确定输入图像的缺陷区域，并通过实验证明了所提方法的有效性。
- (3) 外观缺陷检测系统的搭建：系统的搭建主要由硬件搭建和软件开发两个部分组成。在硬件搭建方面，根据实际应用场景选择合适的工业相机、镜头和光源搭建实时图像采集单元。软件部分则基于 PyQt5 框架设计并开发便于人机交互的可视化软件界面，然后通过集成训练好的算法模型实现缺陷检测任务。

1.3.2 组织结构

本论文共包含六章，各章内容简述如下：

第一章，绪论。主要介绍了研究缺陷样本匮乏场景下的笔记本电脑表面缺陷检测的背景与意义，然后根据传统机器学习与深度学习两方面总结相关工业缺陷检测技术的国内外研究现状，最后阐述本文研究内容和整体结构。

第二章，相关理论基础与技术。阐述本文所涉及到的标准化流、多尺度检测等理论知识与技术。

第三章，基于多尺度标准化流的笔记本电脑表面缺陷检测。针对实际工业场景中只有大量正常样本用于训练的场景，提出了一种基于多尺度标准化流的笔记本电脑表面缺陷检测方法。然后具体介绍了模型整体框架、网络细节，主要包括多尺度特征提取、级联标准化流模块。最后通过实验进行了对比分析和性能评估。

第四章，基于缺陷模拟的记忆化笔记本电脑表面缺陷检测。针对实际工业场景中有大量正常样本以及少量缺陷样本用于训练的场景，提出了一种基于缺陷模拟的记忆化笔记本电脑表面缺陷检测方法。然后具体介绍了模型整体框架、网络细节，主要包括缺陷模拟策略、特征记忆化池、多尺度特征融合。最后通过实验进行了对比分析和性能评估。

第五章，笔记本电脑外观缺陷检测系统。从硬件选型与软件开发两个方面对检测系统进行具体介绍。

第六章，总结与展望。概述全文研究内容，并根据现有的表面缺陷检测技术仍存在的问题给出合理分析与展望。

第二章 相关理论基础与技术

本章将具体介绍本文研究工作内容所涉及的各种理论技术。首先阐述了标准化流的理论基础与构建过程，然后详细介绍提升模型尺度不变性的多尺度检测技术，以及常见的缺陷模拟技术，最后介绍评估模型性能的评价指标。

2.1 标准化流

标准化流^[46] (Normalizing Flows) 是一种可逆生成模型，它能够简单的概率分布转换为复杂的概率分布。在标准化流中，通过定义一个可逆变换函数，它将输入样本从原始概率分布映射到目标概率分布。同时，因为变换是可逆的，在已知目标分布样本的条件下，可以逆向计算出原始分布的样本，因此标准化流是一种在密度估计中有效的统计工具。标准化流中的变换函数通常由一系列的可逆操作组成，并且通过组合这些操作可以得到整个变换。常用的可逆操作包括仿射变换、尺度变换、平移变换等。构建标准化流通常会用到雅可比矩阵、变量替换定理，下面对它们做简单介绍。

2.1.1 雅可比矩阵

给定变换 $f: \mathbb{R}^n \rightarrow \mathbb{R}^m$ ，将其 n 维向量 x 转化为 m 维的向量 y ，那么变换函数 f 的雅可比矩阵 J_f 表示如下：

$$J_f = \begin{vmatrix} \frac{\partial f_1}{\partial x_1} & \frac{\partial f_1}{\partial x_2} & \cdots & \frac{\partial f_1}{\partial x_n} \\ \frac{\partial f_2}{\partial x_1} & \frac{\partial f_2}{\partial x_2} & \cdots & \frac{\partial f_2}{\partial x_n} \\ \vdots & \vdots & \ddots & \vdots \\ \frac{\partial f_m}{\partial x_1} & \frac{\partial f_m}{\partial x_2} & \cdots & \frac{\partial f_m}{\partial x_n} \end{vmatrix} \quad (2.1)$$

当向量 x 与向量 y 维度相同，并且 f 是可逆变换时， f 的逆变换为 f^{-1} ，两者的雅可比矩阵 J_f 与 $J_{f^{-1}}$ 互为逆矩阵，同时又由行列式的性质可得它们的雅可比行列式互为倒数，即

$$|\det J_f| = |\det J_{f^{-1}}|^{-1} \quad (2.2)$$

2.1.2 变量替换定理

假设有一变量 z ，服从分布 $z \sim p_z(z)$ ， $p_z(z)$ 是已知的一种简单分布。有一可逆变换 f ，使得 $x = f(z)$ ，现在要求 $p_x(x)$ ，即变量 x 的概率密度函数，因为变量 z 与 x 的概率之和相等，即

$$\int_x p_x(x) dx = \int_z p_z(z) dz \quad (2.3)$$

上述式子两端对 x 求导化简为：

$$\begin{aligned} p_x(x) &= p_z(z) \left| \frac{dz}{dx} \right| \\ &= p_z(z) \left| \frac{\partial f^{-1}(x)}{\partial x} \right| \\ &= p_z(f^{-1}(x)) \left| \det J_{f^{-1}(x)} \right| \\ &= p_z(z) \left| \det J_{f(z)} \right|^{-1} \end{aligned} \quad (2.4)$$

上述式子将求解 x 的概率分布问题转变成了求解 z 的概率分布问题。通过此定理，可以将难以求解的变量分布转化为易于求解的概率分布来进行计算。

2.1.3 标准化流的构建




图 2.1 标准化流模型示意图

Figure 2.1 Schematic diagram of the normalizing flows model

如图 2.1 所示，标准化流的构建就是通过很多个可逆变换来把一个简单的分布 $p_0(z_0)$ (如标准正态分布) 逐步转变成复杂的目标概率分布 $p(x) = p_k(z_k)$ ，即

$$x = z_k = f_k \cdot f_{k-1} \cdots f_1(z_0) \quad (2.5)$$

由式 (2.4) 可知:

$$p_k(z_k) = p_{k-1}(z_{k-1}) \left| \det J_{f_k(z_{k-1})} \right|^{-1} \quad (2.6)$$

对两端同时求对数化简可得:

$$\log p_k(z_k) = \log p_{k-1}(z_{k-1}) - \log \left| \det J_{f_k(z_{k-1})} \right| \quad (2.7)$$

上式结合式 (2.5) 可得:

$$\begin{aligned} \log p(x) &= \log p_k(z_k) \\ &= \log p_{k-1}(z_{k-1}) - \log \left| \det J_{f_k(z_{k-1})} \right| \\ &= \log p_{k-2}(z_{k-2}) - \log \left| \det J_{f_{k-1}(z_{k-2})} \right| - \log \left| \det J_{f_k(z_{k-1})} \right| \\ &= \dots \\ &= \log p_0(z_0) - \sum_{i=1}^k \log \left| \det J_{f_i(z_{i-1})} \right| \end{aligned} \quad (2.8)$$

通过最大化对数似然函数 $\log p(x)$ 就能训练标准化流模型, 即损失函数 $Loss = -\log p(x)$ 。如果 $\log p(x)$ 难以计算的话, 标准化流模型就难以训练, 所以 $\log p(x)$ 要便于计算, 也就是说可逆变换 f_i 的雅可比行列式 $\det J_{f_i}$ 要容易计算得到。通常构造可逆变换 f_i 使得其雅可比矩阵是三角矩阵^[47-49], 那么它的雅可比行列式 $\det J_{f_i}$ 就容易计算, 其值等于所有对角线元素相乘, 因此, 经过简便的运算即可优化标准化流模型。

总而言之, 标准化流模型是一种可逆生成模型, 通过学习一个可逆变换函数将原始分布映射到目标分布。通过最大似然估计原理, 模型可以学习到如何将数据从原始分布转换为目标分布的数据样本。

2.2 多尺度检测

在实际场景中, 目标物体的尺寸可能会有很大的变化。有些目标可能很小, 而有些可能相对较大。通过使用多尺度检测, 模型可以适应目标在不同尺寸下的变化, 提升检测模型的尺度不变性^[50, 51]。尺度不变性是目标检测中一个重要的概念, 指的是模型对

目标在不同尺度下的出现能够具有鲁棒性，即不受目标的缩放影响。在工业表面缺陷检测领域，由于缺陷的多样性和未知性，不同缺陷类型甚至同种缺陷类型之间都存在着较大的尺度差异性，因此缺陷检测模型需要具有一定的尺度不变性，以确保对缺陷的有效检测。

传统卷积神经网络通常采用从上到下的单行结构，通过多层卷积逐步提取图像深层特征信息，这些深层特征信息对于图像分类、目标检测、语义分割等计算机视觉任务通常具有更强的表达能力。在神经网络由浅至深的特征提取过程中，浅层的低级特征具有较小的感受野，缺乏对全局信息的提取导致语义信息较少，但其一般保持较大的分辨率，具有重要的几何细节信息。随着神经网络的叠加，深层的高级特征感受野变大，语义信息更丰富，但其分辨率变小，导致几何细节信息逐渐丢失。对于大尺度目标来说，需要在浅层网络中获取几何细节信息，在深层特征中获取语义信息；而对于小尺度目标，通过较浅的神经网络即可获取其细节信息与语义信息，而深层网络可能会丢失有用的局部特征信息。为了提升检测模型的尺度不变性，有一些经典的方法和策略，这些方法可以使模型更好地适应不同尺度的目标。以下是一些提升模型尺度不变性的经典方法。

2.2.1 图像金字塔

图像金字塔结构如图 2.2 所示，它是由一系列分辨率逐渐变小的源图像堆叠组成，通常采用下采样操作对图像进行放缩，直到图像分辨率达到一定缩放尺度才停止下采样，随着输入图像的分辨率变化，图像中的待检测目标也会呈现出多种尺度大小，再对不同尺度的图像提取特征并输入检测模型中，不论检测目标的尺度大与小，模型总能在多尺度特征中以擅长处理的特征尺度进行检测。整个过程可以简单理解为对原始图像进行不同比例的下采样，然后使用同一特征提取网络分别处理缩放后的图像，进而提取得到不同尺度的特征图用于后续任务。基于此思想，经典的人脸检测算法 MTCNN^[52]就是基于图像金字塔构建不同尺度的输入，提升了检测网络对不同尺度的人脸的检测性能，增强了算法的鲁棒性。这种处理方法通过对图像金字塔中不同尺度原始图像的特征提取，获得具有丰富语义信息的多尺度特征分别用于检测，解决了待检测目标尺度变化范围大的问题，但是对图像集合的多次特征提取操作意味着成倍的运算量，算法的训练和检测时间也会相应地增加。




图 2.2 图像金字塔结构
Figure 2.2 Image pyramid structure

2.2.2 金字塔多层次特征

金字塔多层次特征可以看做是一个由原始图像的特征图集合组成的图像金字塔，如图 2.3 所示。在神经网络中，浅层特征图保持着较大的分辨率，而随着网络的加深，逐渐利用跨步卷积或者池化操作来减小特征图的分辨率。基于金字塔多层次特征结构，可将浅层特征图和深层特征图都用做后续检测，其中浅层特征图的感受野较小，目标的边缘、纹理等细节信息更显著，便于检测小尺度目标，而深层网络的特征图经过一系列处理，具有较大的感受野，全局语义信息较明显，便于检测大尺度目标。检测算法^[53, 54]正是基于这种思想，从提取的多层级特征的多个分支出发，分别预测不同尺度大小的目标，提升了模型的尺度不变性。




图 2.3 金字塔多层次特征结构
Figure 2.3 Pyramid multi-level feature structure

2.2.3 多尺度特征融合

多尺度特征融合网络旨在利用卷积和池化等操作，以某种方式处理具有不同感受野的特征信息，充分利用多尺度特征提升图像处理任务的性能和准确性，以下是两种常见的多尺度特征融合网络。

并行多分支网络是一种常见的多尺度特征融合结构。它通过构建多个并行分支，在每个分支中使用不同步长的卷积操作，捕捉不同尺度下的细节和上下文信息，从而得

到具有不同感受野的多尺度特征。然后, 这些特征通过并行连接的方式进行融合, 以综合考虑不同尺度下的信息。基于此思想, Inception 网络^[55] 中的 Inception 基本模块, 分别利用卷积核大小为 1×1 、 3×3 、 5×5 的卷积操作以及 3×3 最大池化操作组成四个并行的分支结构, 最后对四个通道进行组合实现不同尺度特征融合。Deeplab V2^[56] 利用空洞卷积对输入以不同采样率并行采样, 从而以多个尺度捕获重要的上下文信息。在 PSPNet^[57] 中提出一种金字塔池化模块, 该模块利用不同核大小的池化操作并行处理主干网络提取的特征图, 进而获取具有不同感受野的特征图。

串行跳层连接结构是另一种常见的多尺度特征融合方式。它通过加入跳跃连接将浅层网络特征图与深层网络特征图进行有效融合, 这样做的目的是同时利用低级特征的几何细节信息和高级特征的语义信息, 提升网络的图像理解能力。基于此类思想, U-Net^[39] 利用跳层连接整合编码器-解码器中的特征, 帮助解码过程中可以获得更好的多尺度特征。特征金字塔 FPN^[58] 利用侧向连接和上采样操作, 通过自顶向下的路径融合网络中相邻层级的特征图, 从而构建不同尺度的具有高级语义信息的特征金字塔结构, 现已成为算法提升尺度不变性的一个标准组件。FPN 的结构如图 2.4 所示。




图 2.4 特征金字塔结构
Figure 2.4 Feature pyramid structure

2.3 缺陷模拟

相比于 ImageNet^[59] 数据集中千万级别的样本数据, 在很多真实的工业场景下往往只能采集到数十张缺陷样本图像。因此, 在工业表面缺陷检测领域中面临的一大难点

是小样本问题，针对此问题，模拟缺陷样本的生成并用以辅助模型训练是一种有效的解决方法，尤其是在数据不足或难以获取真实缺陷样本的情况下。

模拟缺陷样本的生成一般有传统方法和基于深度学习的方法。传统方法可以利用数据增强技术，例如平移、旋转、缩放和颜色变换等图像处理方法扩充缺陷样本数据，也可以利用图像融合技术，通过在原始正常图像上添加噪声、预定义的缺陷模板或将已有缺陷样本图像融合到正常图像上生成新的缺陷样本数据^[60,61]。传统的缺陷样本生成方法实现简单，并且可以根据需要控制缺陷的类型、位置和大小。

利用深度学习方法生成缺陷样本图像一般用 GAN^[62]、VAE^[63] 等生成模型，利用已知的缺陷样本训练模型，从而生成一系列逼真的模拟缺陷样本^[64]。GAN 模型由一个生成器和一个判别器组成，生成器被训练来生成与真实缺陷样本相似的图像，而判别器则被训练来区分真实缺陷样本和生成图像。在训练过程中，生成器试图生成使判别器无法辨别的生成图像。通过竞争与对抗的迭代训练，生成器逐渐学习生成逼真的缺陷样本图像。VAE 模型通过创建一个编码器和解码器，其中编码器负责将输入图像转变为潜在空间中的特征表示，而解码器则负责将潜在空间的表示映射回原始图像空间。训练过程中，模型将学会在潜在空间中编码图像，并能够从潜在空间中生成逼真的缺陷样本。

2.4 评价指标

评价指标是用于度量和评估模型性能的定量标准。本文只关注样本图像是否含有缺陷，将其考虑为一个二分类问题进行评估，首先明确二分类混淆矩阵中的一些基本术语，如图 2.5 所示。

由图 2.5 中的基本术语可以定义常用评价指标如下：

- (1) 精确率 (Precision)。精确率是指预测值为正样本中的真正样本所占比例。计算公式为：

$$Precision = \frac{TP}{TP + FP} \quad (2.9)$$

- (2) 召回率 (Recall)。召回率是指在所有的真正样本中被正确预测为正样本的比例。

	预测值=Positive	预测值=Negative	合计
真实值=Positive	TP	FN	P
真实值=Negative	FP	TN	N

图 2.5 二分类混淆矩阵
Figure 2.5 Binary confusion matrix

计算公式为：

$$Recall = \frac{TP}{TP + FN} \quad (2.10)$$

- (3) F1-Socre。在某些情况下，我们可能会综合考虑精确率和召回率的结果，对两者进行加权平均即可得到 F1-Score，其更适合用于不平衡类别的分类问题。计算公式为：

$$Precision = \frac{2 * Precision * Recall}{Precision + Recall} \quad (2.11)$$

- (4) 接受者操作特征曲线下面积 (AUROC, Area Under the Receiver Operating Characteristic curve)。即 ROC(Receiver Operating Characteristic) 曲线下面积，能够有效地评估二分类预测模型性能。ROC 曲线是以，真阳率 TPR(True positive rate) 为纵轴，假阳率 FPR(False positive rate) 为横轴绘制的性能评价曲线，两者的计算公式为：

$$TPR = \frac{TP}{P} \quad (2.12)$$

$$FPR = \frac{FP}{N} \quad (2.13)$$

曲线上的每个点对应于在不同阈值下的模型分类性能。在理想情况下，ROC 曲线会尽可能地靠近左上角，意味着模型在召回率较高的同时保持较低的假阳率，即

模型性能越好。在 ROC 曲线中，曲线下方的面积被称为 AUROC，它提供了一个单一的度量，表示模型在不同分类阈值下的整体性能，AUROC 值越大，模型性能越好。

在工业表面缺陷检测领域中一般使用准确率、漏检率和误检率来评判检测性能，这些指标与上述评价指标有着相似之处，只是更符合工业生产过程中的质量评估。将缺陷样本看作正例，即 Positive，正常样本看作负例，即 Negative。可定义评价指标如下：

- (1) 准确率 (Accuracy)。在工业表面缺陷检测中准确率指的是被正确预测的样本数量占总样本数量的百分比。准确率是评估算法检测性能的重要指标，其计算公式为：

$$Accuracy = \frac{TP + TN}{P + N} \quad (2.14)$$

- (2) 漏检率 MAR(Missing Alarm Rate)。漏检率指的是在检测中未发现的缺陷样本数量占实际缺陷样本总数的百分比。在某些工业场景中需要严格把控漏检率，因为高漏检率会直接导致大量不合格产品流向市场。其计算公式为：

$$MAR = \frac{FN}{TP + FN} = \frac{FN}{P} \quad (2.15)$$

- (3) 误检率 FAR(False Alarm Rate)。误检率指的是将正常样本检测为缺陷样本的数量占实际正常样本总数的百分比。其计算公式为：

$$FAR = \frac{FP}{FP + TN} = \frac{FP}{N} \quad (2.16)$$

2.5 本章小结

本章详细阐述了研究工作中涉及到的各种理论技术，包括标准化流的概念与构建过程、多尺度检测技术、缺陷模拟技术以及性能评价指标。

第三章 基于多尺度标准化流的笔记本电脑表面缺陷检测方法

在笔记本电脑表面缺陷检测任务中，受限于缺陷样本数据的匮乏，基于有监督学习的缺陷检测算法不能有效地应用于此任务。同时，由于缺陷类型的多样性，微小缺陷类型的有效检测也是笔记本电脑表面缺陷检测任务关注的重点问题。为此，本章提出了一种基于多尺度标准化流的缺陷检测算法。通过标准化流模型构建正常样本数据分布与预定义的正态分布隐变量之间的可逆映射，利用隐变量的似然估计来检测图像是否为缺陷样本。另外，通过设计一种基于双向融合路径的多尺度特征提取网络，有效地整合浅层特征的几何细节信息与深层特征的语义信息，提升了检测算法的尺度不变性。通过实验证明了本章所提方法在检测和定位笔记本电脑表面缺陷的有效性。

3.1 引言

在笔记本电脑生产制造过程中，需要准确可靠地检测出生产过程中出现的各种表面缺陷来保证产品质量。在工业表面缺陷检测领域中，基于有监督学习的缺陷检测方法在样本数量充足的条件下表现出了优秀的检测性能，并已成功应用于一些简单的工业场景。但是基于有监督学习的检测方法依赖于足量的标注样本数据，而数据的采集与标注过程往往费时费力，成本高昂。同时，在笔记本电脑生产过程中严格把控产品的良率，产生缺陷的概率很低，以至于难以收集制作包括所有类型的大批量缺陷样本数据集。即使某些缺陷类型是已知的，由于制造过程中不可预见的事件，可能随时产生新的缺陷类型，基于有监督学习的缺陷检测方法无法处理未见缺陷类型的检测问题。因此，基于有监督的缺陷检测方法不能很好地适用于笔记本电脑表面缺陷检测场景。

基于上述考虑，从无监督学习的角度出发解决上述问题，基于无监督学习的缺陷检测方法仅利用更容易被采集的正常样本训练模型，整个训练过程不再依赖于真实的缺陷样本，同时能够有效解决基于有监督学习的检测方法无法检测未知缺陷类型的问题。本章提出了一种基于多尺度标准化流的笔记本电脑表面缺陷检测方法。标准化流是一种通过最大似然优化将输入特征分布转换到具有预定义分布的潜在空间的生成模型，在训练过程中通过对正常样本数据分布进行建模，从而检测出异于正常样本分布之外的缺陷样本，因此在训练过程中仅需要正常样本数据。

3.2 模型构建

图 3.1展示了本章所提出的基于多尺度标准化流的笔记本电脑表面缺陷检测方法的整体执行流程。所提方法大致分为两个步骤，即多尺度特征提取 ($X \rightarrow Y$) 和密度估计 ($Y \rightarrow Z$)。首先，在训练阶段，将预训练好的骨干网络 ResNet50^[65] 和金字塔特征融合模块整合在一起，从正常样本图像 x ($x \in X$) 中提取多尺度特征 y ($y \in Y$)，然后将其输入到结合置换注意力网络^[66] 的多尺度标准化流中，对其进行密度估计。密度估计可以将特征空间中的未知分布 p_Y 映射到多元标准正态分布 p_Z 。公式化描述如下：

$$f(y^{(1)}, \dots, y^{(s)}) = [z^{(1)}, \dots, z^{(s)}] = z \in Z \quad (3.1)$$

其中， s 表示多尺度特征中的特征数量， Y 与 Z 具有相同的维度。

经过训练后，该模型可以有效地拟合正常样本的数据分布。在测试阶段，通过对输入图像 x 的特征 y 进行密度估计得到似然值 $p_Z(z)$ ，并根据似然值 $p_Z(z)$ 判断输入样本是否为缺陷样本。由于在训练阶段只利用了正常样本，并在测试阶段能够有效地检测各种未知缺陷。因此，本章所提方法是一种高效的无监督缺陷检测方法。

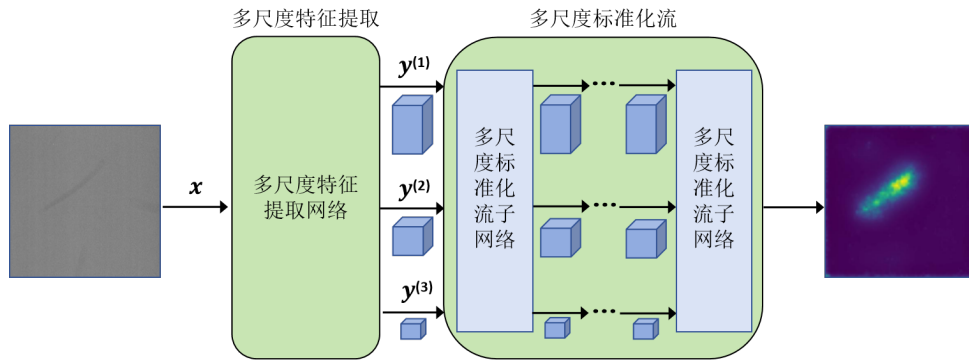


图 3.1 所提方法的整体执行流程

Figure 3.1 The overall implementation process of the proposed method

3.2.1 多尺度特征提取

受启发于^[58]，本章提出一种多尺度特征提取网络如图 3.2所示。其中左侧为预训练好的 ResNet50 骨干网络（去掉了末端用于分类的池化和全连接操作），利用骨干网络可以得到多级特征 $[c_1, c_2, c_3, c_4]$ 。右侧为两条相反的特征融合路径，在自顶向下的路径中，除了顶层特征 m_4 是利用核大小为 1×1 的卷积运算改变 c_4 的通道数目得到（输出通道数固定为 256），其余特征图 m_i ($i = 1, 2, 3$) 是通过一个浅层特征图 c_i 和更深层特征图

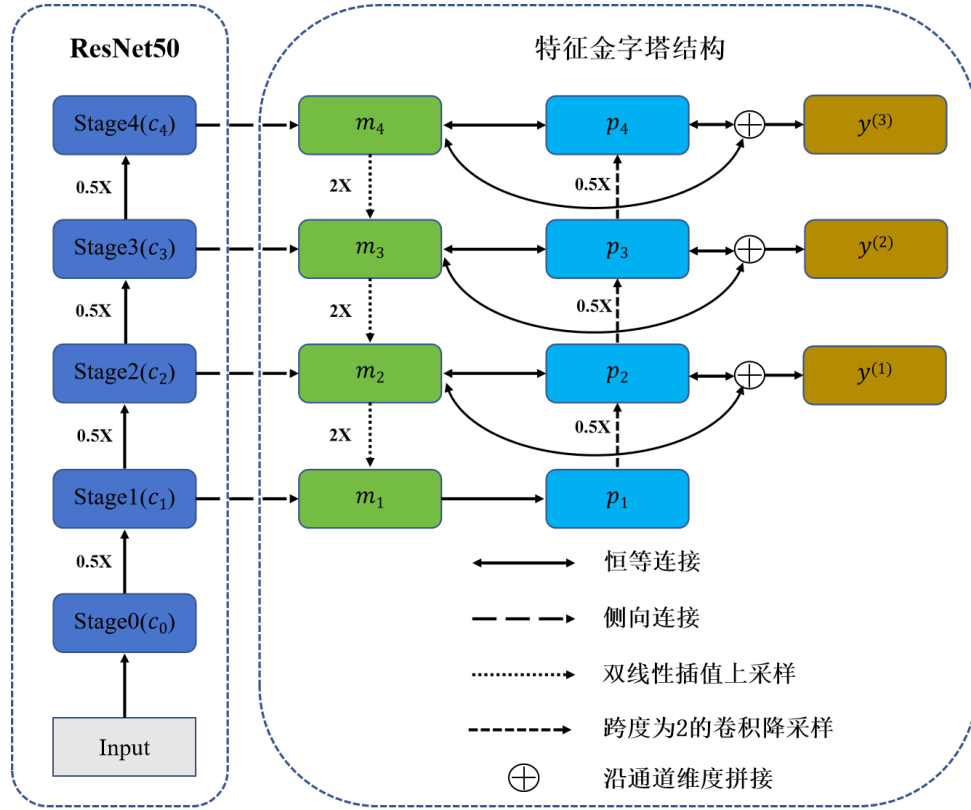


图 3.2 多尺度特征提取网络结构

Figure 3.2 Structure of multi-scale feature extraction network

m_{i+1} 融合得到，公式化描述如式 (3.2)。在自底向上的路径中，除了底层特征 p_1 是直接复制于 m_1 ，其余特征图 $p_i (i = 2, 3, 4)$ 是通过一个浅层特征 p_{i-1} 和一个深层特征 m_i 融合得到，公式化描述如式 (3.3)。最后将高级特征 $[m_2, m_3, m_4]$ 和 $[p_2, p_3, p_4]$ 沿通道拼接得到多尺度特征 $[y^{(1)}, y^{(2)}, y^{(3)}]$ 。

$$m_i = Conv_{1,3} (Conv_{1,1} (c_i) \oplus Up_2 (m_{i+1})) \quad (3.2)$$

$$p_i = Conv_{1,3} (Conv_{2,3} (p_{i-1}) \oplus m_i) \quad (3.3)$$

其中 $Conv_{s,k}$ 表示步长为 s ，核大小为 $k * k$ 的卷积运算； \oplus 表示逐元素加法； Up_2 表示 2 倍双线性插值上采样操作。

在双向特征融合路径中，自顶向下的特征融合路径将深层特征中的语义信息向浅层网络传递，增强低级特征的全局图像信息表征能力。自底向上的特征融合路径将浅层特征中丰富的空间细节信息向深层网络传递，增强高级特征的局部图像细节信息表征能力。通过这两条特征融合路径，使得提取的多尺度特征同时具有丰富的空间信息和语义信息，在降低计算复杂度的同时提高了微小缺陷的检测性能。

3.2.2 置换注意力网络

置换注意力^[66]SA-Net (Shuffle Attention) 是一种低复杂度的空间-通道注意力机制, 能方便地嵌入到神经网络中。与类似的注意力机制 CBAM^[67] 相比, 引入特征分组策略降低了计算复杂度。如图 3.3所示为置换注意力网络的整体结构框架。

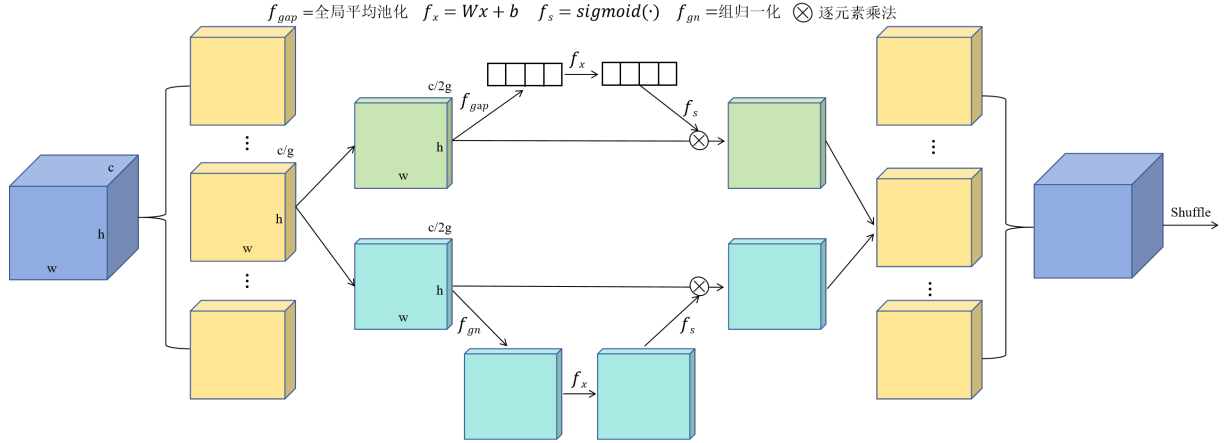


图 3.3 置换注意力网络结构^[66]

Figure 3.3 Structure of shuffle attention network^[66]

首先, 置换注意力机制将输入特征向量 $X (X \in R^{C \times H \times W})$ 沿通道维度进行分成 g 组, 即 $X = [X_1, \dots, X_g] (X_i \in R^{\frac{C}{g} \times H \times W}, i = 1, \dots, g)$, 接着每组特征再按通道维度将其分为两部分, 即 $X_i = [X_{i1}, X_{i2}] (X_{i1}, X_{i2} \in R^{\frac{C}{2g} \times H \times W})$ 。其中上部分 X_{i1} 学习通道注意力信息, 下部分 X_{i2} 学习空间注意力信息。

在通道注意力方面, 为了实现轻量化, 同时减少计算复杂度, 通过全局平均池化操作、线性函数、 sigmoid 函数实现通道注意力, 给不同特征通道分配相应的权重, 筛选重要的特征通道信息, 公式化描述如下:

$$s = f_{gap}(X_{i1}) = \frac{1}{H \times W} \sum_{h=1}^H \sum_{w=1}^W (h, w) \quad (3.4)$$

$$X'_{i1} = \text{sigmoid}(W_1 \cdot s + b_1) \cdot X_{i1} \quad (3.5)$$

在空间注意力方面, 首先利用组归一化操作^[68](Group Norm, GN) 对 X_{i2} 进行处理, 得到特征向量的空域统计信息, 然后使用线性函数和 sigmoid 函数进行处理, 进而实现空间注意力, 公式化描述如下:

$$X'_{i2} = \text{sigmoid}(W_2 \cdot \text{GN}(X_{i2}) + b_2) \cdot X_{i2} \quad (3.6)$$

最后，通过计算得到两种注意力特征后，沿通道维度对其进行拼接得到 $X'_i = [X'_{i1}, X'_{i2}]$ ，并将各组特征重新组合得到 $X' = [X'_1, \dots, X'_g]$ ，最后通过置换操作打乱通道顺序实现组间特征信息交互。由于最终输出特征与输入特征具有相同的维度与尺寸，因此可以简便地添加置换注意力网络到神经网络中用以提升模型检测性能。

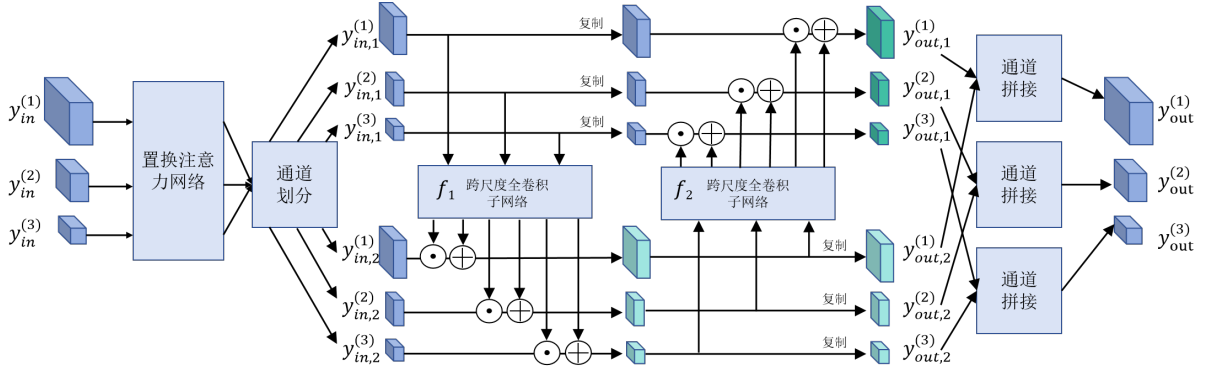


图 3.4 多尺度标准化流子网络结构

Figure 3.4 Structure of multi-scale normalizing flows subnetwork

3.2.3 多尺度标准化流

多尺度标准化流就是一系列神经网络串联组成的流模型，每经过一个子网络即等同于对输入进行一次仿射变换。我们用置换注意力机制扩展了^[69]中的子网络，使得模型关注到多尺度特征信息中重要的部分。如图 3.4所示，首先将多尺度特征 $y = [y^{(1)}, \dots, y^{(s)}]$ 分别输入到对应的置换注意力网络融合空间注意力和通道注意力，改善特征语义表达能力，随后将变换后的多尺度特征 $y_{in}^{(i)}$ 按通道维度分为两部分 $y_{in,1}^{(i)}$ 和 $y_{in,2}^{(i)}$ ，这两部分特征向量先后通过两个跨尺度全卷积子网络 f_1 和 f_2 得到尺度参数 $[s_1, s_2]$ 和位移参数 $[t_1, t_2]$ ，然后将其作用到对应的另一部分特征信息，公式化描述如下：

$$y_{out,2} = y_{in,2} \odot e^{\gamma_1 s_1(y_{in,1})} + \gamma_2 t_1(y_{in,1}) \quad (3.7)$$

$$y_{out,1} = y_{in,1} \odot e^{\gamma_1 s_2(y_{out,2})} + \gamma_2 t_2(y_{out,2}) \quad (3.8)$$

其中 $y_{out}^{(i)} (i \in \{1, \dots, s\})$ 表示当前子网络的输出， \odot 表示逐元素乘法。 $[\gamma_1, \gamma_2]$ 是初始化为 0 的可学习参数。内部全卷积子网络 f_1 和 f_2 的结构细节如图 3.5所示，将其实现为一个基于完全卷积操作的网络，不同尺度之间的交叉信息交互通过上采样和跨步卷积实现。聚合是通过逐元素求和实现的。将输出在通道维度上进行切分，以获得尺度参数 s 和位移参数 t 。




图 3.5 图 3.4 中的全卷积子网络结构

Figure 3.5 The fully convolutional subnetwork structure in Figure 3.4

3.3 模型训练

3.3.1 训练目标

在训练过程中，通过多尺度标准化流将原始特征空间 Y 映射到预定义的潜在空间 Z 。训练目标是通过正常样本图像优化标准化流网络并使其能够最大化特征张量 $p_Y(y)$ 的似然，通过映射 $z = f(y)$ ，根据变量替换定理，见式 (3.9)，可将训练目标描述为最大化 $p_Y(y)$ ：

$$p_Y(y) = p_Z(z) \left| \det \frac{\partial z}{\partial y} \right| \quad (3.9)$$

通过预定义 Z 为标准高斯分布，上式可化简等同为最小化负对数似然损失 $-\log p_Y(y)$ ：

$$\log p_Y(y) = \log p_Z(z) + \log \left| \det \frac{\partial z}{\partial y} \right| \quad (3.10)$$

$$\mathcal{L}(y) = -\log p_Y(y) = \frac{\|z\|_2^2}{2} - \log \left| \det \frac{\partial z}{\partial y} \right| \quad (3.11)$$

其中 $\left| \det \frac{\partial z}{\partial y} \right|$ 表示雅可比行列式的绝对值，在这里指的是式 (3.7) 和式 (3.8) 的雅可比行列式，因为两公式中的元素乘积算子的雅可比矩阵是一个对角矩阵，因此可以将其雅可比行列式化简为所有尺度参数 $[s_1, s_2]$ 的和。

3.3.2 检测与定位

在推理阶段，根据密度估计得到的 $p_Z(z)$ 的似然值和阈值 θ 来决定输入图像是否为缺陷样本，如式 (3.12) 所示。通过计算所有尺度上的似然平方的平均值，将其视为图像级别的异常分数。

$$\mathcal{A}(\mathbf{x}) = \begin{cases} 1 & \text{for } p_Z(z) \geq \theta \\ 0 & \text{otherwise} \end{cases} \quad (3.12)$$

其中 $\mathcal{A}(\mathbf{x}) = 1$ 指示输入为缺陷样本，否则指示输入为正常样本。

对于缺陷区域定位，由于提出的方法基于卷积运算来处理特征图，保留了空间位置信息，这使得该方法可以用二维图像各个像素位置 (i, j) 的似然来进行缺陷的定位。通过沿着通道维度聚合输出 $\|z_{i,j}^s\|_2^2$ ，以获得特征图 $y^{(s)}$ 每个位置的异常得分，再利用双线性插值法将其上采样到输入图像的分辨率大小，最终得到了缺陷定位的可视化结果。

3.4 实验结果与分析

3.4.1 数据集与评价指标

本文使用章节五中外观缺陷检测系统搭建的图像采集单元拍摄笔记本电脑 A 面外壳图像，由于拍摄的笔记本电脑图像分辨率较大，我们将其裁剪为 512×512 分辨率大小的局部图像组成数据集。整个笔记本电脑外观数据集由 1300 张图像组成。其中包含 1050 张无缺陷图像以及 250 张有缺陷图像，分辨率均为 512×512 。在非监督学习缺陷检测算法中，一般只将图像分为有缺陷和无缺陷两种类别，因此数据集中有缺陷图像由各种缺陷类别组成，包括划痕、指纹、亮点、颗粒共四种类型的缺陷，如图 3.6 所示。




图 3.6 缺陷样本图像
Figure 3.6 Defective sample images

对上述数据集进行划分组成本章方法的实验数据集。具体来说，将所有的无缺陷图像中的 900 张图像划分为训练集，剩余的 150 张无缺陷图像与 250 张有缺陷图像划分为测试集。通过 t 分布式随机邻居嵌入^[70] (t-sne) 技术对数据集进行可视化如图 3.7 所示，可以看到正常样本分布与缺陷样本分布具有明显的差异，这也说明了本章所提方法的思想即对正常样本分布进行拟合从而检测出分布外的缺陷样本是可行的。本章采用章

节 2.4 中图像级别的 AUROC 分数以及工业表面缺陷检测中常用的精度、漏检率、误检率作为评价指标来评估所提方法的缺陷检测性能。




图 3.7 数据集分布可视化图
Figure 3.7 Visualization of dataset distribution

3.4.2 实验设置

本章方法中使用 $s=3$ 比例的特征尺度数量，输入图像的分辨率为 512×512 ，通过多尺度特征提取网络得到分辨率大小为 64×64 、 32×32 、 16×16 的多尺度特征图，每个特征图通道数为 512。在多尺度标准化流中使用了 4 个级联子网络。在训练阶段，设置批次大小为 16，训练总周期为 120，学习率初始化为 0.001。实验环境是在单个 NVIDIA GeForce RTX 3090 24G GPU 下进行的。

3.4.3 对比实验

为了验证本章所提方法的有效性，将所提方法和一些先进的缺陷检测方法在数据集上进行对比实验，包括 GANomaly^[42]、PaDim^[43]、DifferNet^[71]、CS-Flow^[69]。以上几种对比方法均基于正常样本进行训练，其中 GANomaly 通过编码器-解码器-编码器结构训练对抗自动编码器，学习正常样本潜在空间中的高级特征；PaDim 通过多层次特征估计正常样本图像中每一个位置的数据分布；DifferNet 利用标准化流构建正常样本与正态

表 3.1 不同方法检测性能比较

Algorithm	MAR(%)↓	FAR(%)↓	Accuracy(%)↑	AUROC(%)↑
GANomaly ^[42]	34.00	6.00	76.50	84.06
PaDim ^[43]	22.80	5.33	83.75	90.79
DifferNet ^[71]	13.10	8.00	91.00	92.77
CS-Flow ^[69]	7.20	8.00	92.50	95.83
Ours	6.80	6.67	93.25	96.30

分布隐变量的可逆映射；CS-Flow 在 DifferNet 的基础上改进了特征提取与多尺度特征交互。实验结果如表 3.1 所示。从实验结果中可以看到，本章所提方法具有最高的精度和图像级别 AUROC 分数，同时漏检率达到最低，误检率比最优的 PaDim 略高 1.34%，因此在大部分评价指标上所提方法均优于其他几种无监督检测方法，这充分证明了本章所提方法在笔记本电脑表面缺陷检测方面的有效性。




图 3.8 缺陷定位可视化结果

Figure 3.8 Visualization of defect location results

如章节 3.3.2 所述，对实验数据集中各种缺陷类型的检测可视化结果如图 3.8 所示，其中第一行为输入图像，第二行为检测结果热力图，第三行为前两者的叠加显示，图示结果表明所提出的方法能够有效地捕获各种类型的外观缺陷，并且能够定位到不同尺度的外观缺陷，证明了所提方法有较好的尺度不变性。由于通过上采样操作恢复的图像分辨率较高，导致缺陷边缘定位略显粗糙，但本章所提方法的目标不是实现对缺陷位置的精确分割，由此得到的可视化结果足以帮助检测人员快速定位缺陷。

3.4.4 消融实验

表 3.2 消融实验性能比较

Table 3.2 Performance comparison of ablation experiment

Multi-scale	Attention	Accuracy(%)↑	AUROC(%)↑
×	×	89.25	91.67
√	×	92.50	95.23
×	√	90.50	92.96
√	√	93.25	96.30

为了验证本章所提方法中的多个组成部分的有效性，通过比较不同配置策略下的缺陷检测性能来进行消融实验，评价指标采用图像级别的 AUROC 分数以及精度。设计四组消融实验如表 3.2 所示，在单独引入多尺度特征提取网络后，检测指标明显增加，这说明多尺度特征中浅层特征空间信息与深层特征语义信息的融合对缺陷检测起很大促进作用。单独加入置换注意力机制后，指标小幅上升，说明改善特征的语义表达能力也起到促进作用。同时加入两个模块后，评价指标达到最优，证明了所提方法在笔记本电脑外观缺陷检测领域的有效性。

3.5 本章小结

针对笔记本电脑表面缺陷检测领域中的缺陷样本数据匮乏问题，本章提出了一种基于多尺度标准化流的笔记本电脑表面缺陷检测方法，在训练过程中，所提方法仅基于正常样本进行训练，学习正常样本的数据分布，从而实现正常样本分布外的缺陷检测。同时，通过对多尺度特征进行有效的特征融合，提升了检测方法的尺度不变性。经过实验证明，所提方法是一种有效的无监督缺陷检测算法。

第四章 基于缺陷模拟的记忆化笔记本电脑表面缺陷检测方法

通过第三章的工作研究，从无监督学习的角度出发解决缺陷样本匮乏场景下的缺陷检测，基于无监督的缺陷检测方法虽然大大降低了缺陷样本的需求，也能较好地检测未见缺陷类型，但是在检测可靠性以及缺陷定位方面仍然无法替代有监督缺陷检测方法，比如在检测目标存在背景噪声干扰时可能会错误地把背景检测为缺陷。借助于半监督学习以及自监督学习的思想，在训练过程中可以用到大量的正常样本以及少量的缺陷样本，既避免了有监督学习的标注数据需求，同时能够利用少量缺陷样本提升检测方法的性能。因此，本章提出了一种基于缺陷模拟的记忆化缺陷检测方法用于笔记本电脑表面缺陷检测。通过设计一种缺陷模拟策略，从正常样本生成缺陷样本从而实现端到端地学习。同时引入正常记忆化池和异常记忆化池来学习输入样本与记忆池样本的共性和差异性，进一步提升检测性能。

4.1 引言

在实际工业生产环境中，在收集充足正常样本图像的同时，收集少量可标注缺陷样本的情况更加常见。随着生产制造过程的进行，可以获取少量真实的缺陷样本用以训练。因此，基于半监督学习或自监督学习的缺陷检测方法更贴合工业场景，可以更加充分地利用样本数据。在一般工业表面缺陷检测场景往往缺乏有标注的缺陷样本，可收集的标注数据难以支持深度学习方法的训练，因此进行适当的数据扩增也是提升检测性能的常用手段。常用的数据扩增方法包括对原始的缺陷样本采用裁切、旋转、放缩、色彩变换等，虽然这些方法可以改变缺陷的形状与位置，但是生成的缺陷样本缺乏多样性以及尺度差异性，并且存在图像失真的问题。为了解决此问题，利用随机噪声技术可以在正常样本图像的任意位置生成任意尺度的缺陷，生成的缺陷样本较好地模拟了缺陷的未知性与尺度差异性。

基于上述考虑，从半监督学习的角度出发，针对在拥有相对充分的正常样本与少量的缺陷样本的场景下，本章提出了一种基于缺陷模拟的记忆化笔记本电脑表面缺陷检测方法。通过缺陷模拟策略从正常样本生成模拟缺陷样本辅助模型训练，同时将部分正常样本和缺陷样本加入记忆池构成记忆化模块。因此，所提方法在训练过程中仅需正常

样本和少量缺陷样本即可，是一种有效的半监督缺陷检测方法。

4.2 模型构建

图 4.1展示了本章所提出的基于缺陷模拟的记忆化笔记本电脑表面缺陷检测方法的整体执行流程。首先，利用缺陷模拟策略对输入的正常样本进行处理得到模拟缺陷样本图像，然后利用编码器网络提取图像的多尺度特征，并将模拟缺陷样本特征分别与正常样本特征记忆池和缺陷样本特征记忆池进行最近邻匹配，分别找到匹配的记忆特征，并处理得到最终的差异特征信息与共性特征信息，将原始图像特征与差异特征信息与共性特征信息输入多尺度特征融合网络进行特征融合，最后将融合特征输入到一个解码器网络检测模拟缺陷样本的缺陷区域，可以看到，整个检测流程即将一个正常样本图像变为缺陷样本图像实现自监督的学习，同时利用额外的特征记忆池提升模型的检测性能。

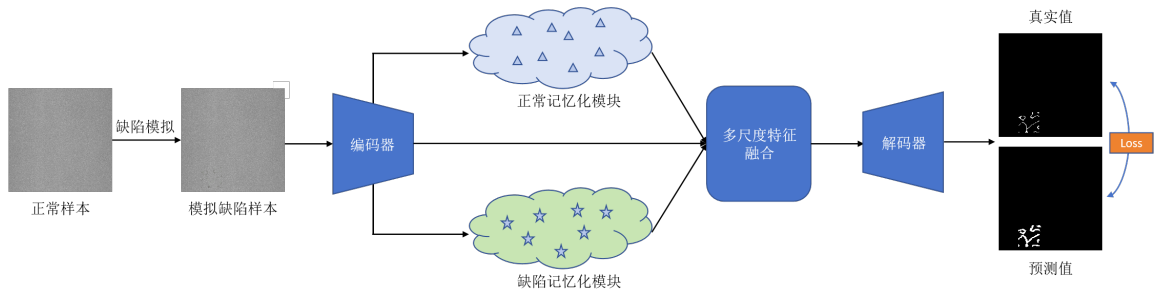


图 4.1 所提方法的整体执行流程

Figure 4.1 The overall implementation process of the proposed method

4.2.1 缺陷模拟策略

如图 4.2所示是本章方法所使用的缺陷模拟策略。该策略主要分为以下四个步骤：

- (1) 利用柏林噪声在原图尺寸中生成随机位置、随机尺度的二维柏林噪声图像 P ，然后通过阈值将原始噪声图像进行二值化后生成噪声掩码 M 。
- (2) 将原始正常样本图像 I 与取反后的噪声掩码 M' 进行逐元素相乘，得到正常样本背景图像 I' 。公式化描述如下：

$$M' = \bar{M} \quad (4.1)$$

$$I' = M' \odot I \quad (4.2)$$

- (3) 为了使得生成的缺陷样本更接近于真实缺陷样本，需要合理地选择缺陷前景图像

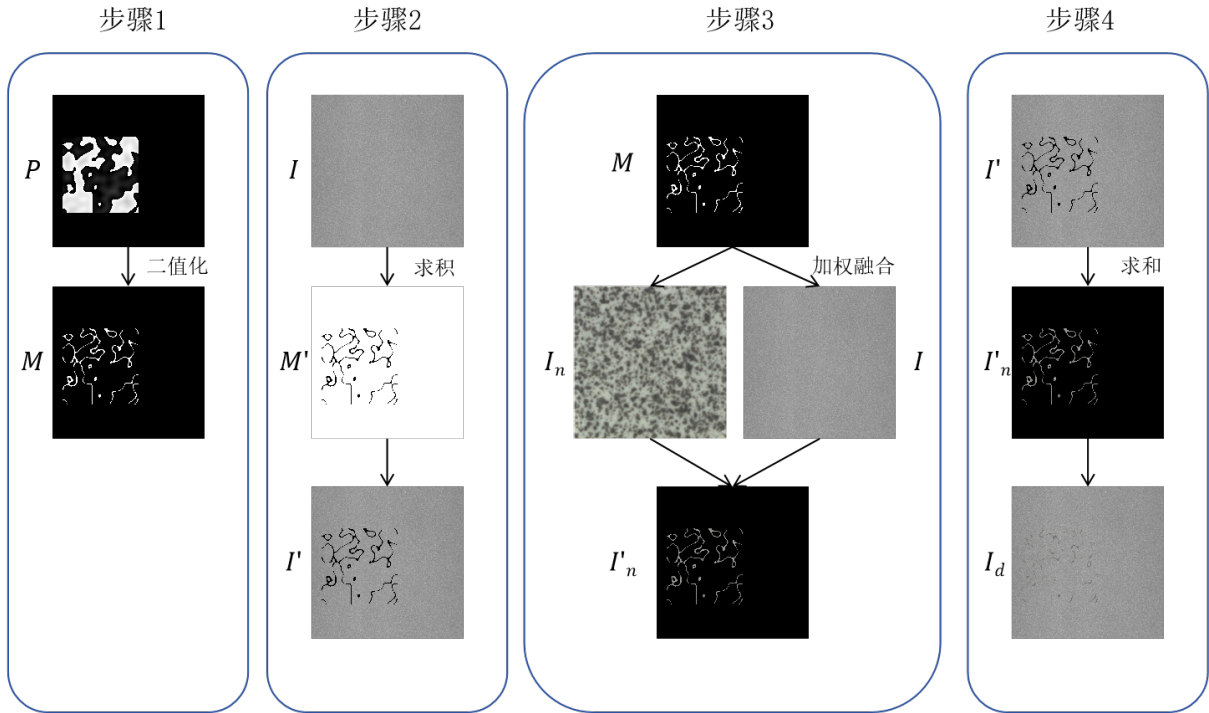


图 4.2 缺陷模拟策略示意图

Figure 4.2 Schematic diagram of defect simulation strategy

进行融合，Mvtec^[45] 数据集集中的瓷砖类别图像与笔记本电脑图像有着相似的纹理特征，将其正常图像和正常样本图像 I 噪声掩码 M 进行加权融合，得到前景缺陷图像 I'_n 。加权融合后的缺陷前景能够很好地嵌入笔记本电脑正常样本图像，使得生成的缺陷样本更加贴近真实情况。上述过程公式化描述如下：

$$I'_n = \delta(M \odot I) + (1 - \delta)(M \odot I_n) \quad (4.3)$$

其中 δ 为融合系数，用以平衡原始正常样本图像与额外纹理图像的融合。

(4) 将步骤二中得到的正常样本背景图像 I' 与步骤三中得到的前景缺陷图像 I'_n 进行逐元素求和，最终得到了缺陷模拟策略生成的缺陷样本图像 I_d 。公式化描述如下：

$$I_d = I' \oplus I'_n \quad (4.4)$$

通过柏林噪声结合纹理图像生成的缺陷样本具有自然的、随机的纹理结构，非常适合模拟笔记本电脑外观缺陷样本。利用上述缺陷模拟策略生成的缺陷样本图像如图 4.3 所示。可以看到模拟的缺陷样本可以生成在原始图像的任意位置，同时为了提升检测方法的尺度不变性，生成的缺陷也具有尺度差异性。




图 4.3 模拟生成的缺陷样本图像
Figure 4.3 Simulated defect sample images

4.2.2 特征记忆池

本章所提方法中采用的特征记忆池模块如图 4.4 所示。通过使用预训练好的编码器网络来提取记忆样本的高级特征作为记忆信息，从而帮助模型学习。首先，在模型训练前利用预训练好的编码器网络对输入的 N 个正常样本提取多尺度特征，保存其多尺度特征信息构造正常样本特征记忆池。同时对输入的 N 个缺陷样本提取多尺度特征，保存其多尺度特征信息构造缺陷样本特征记忆池。然后在训练阶段或测试阶段，对于给定的输入图像，经过同样的特征提取阶段提取多尺度特征 F 。紧接着计算两种特征记忆池中的所有特征与 F 的 L_2 距离，进行最近邻匹配找到最相邻的记忆特征 MF_k 。其公式如下：

$$MF_k = \arg \min_{MF_i} \|MF_i - F\|_2 \quad (4.5)$$

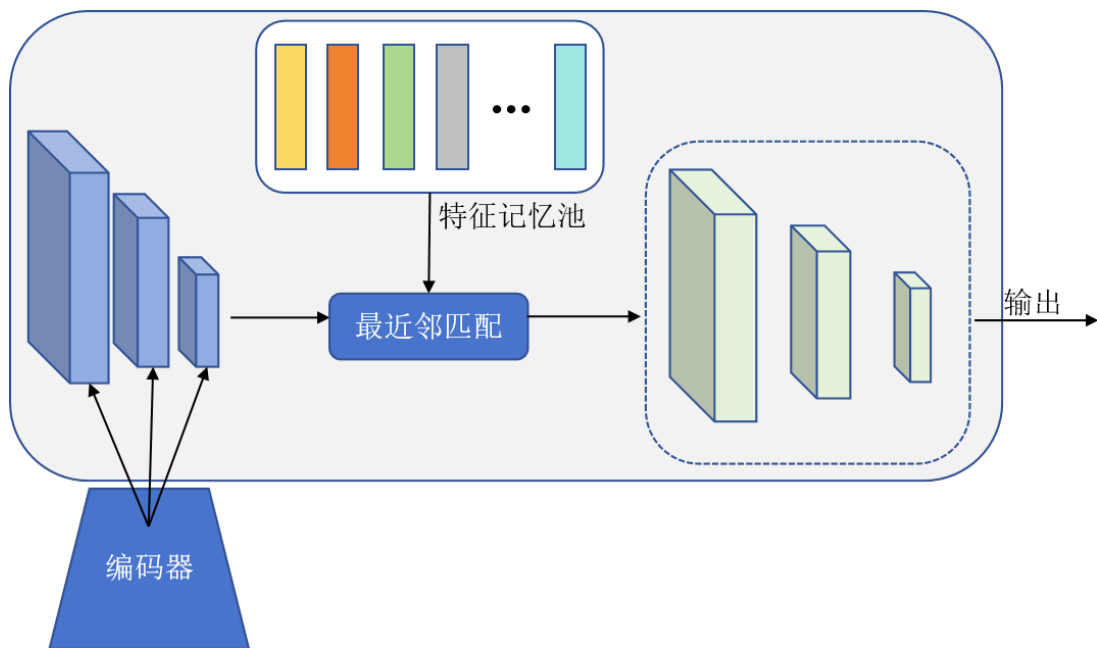


图 4.4 记忆化池模块
Figure 4.4 Memorization Pool Module

对于正常样本特征记忆池而言，目标是寻求其中的记忆特征与输入特征的差异性，故将其匹配得到的记忆特征与输入特征做差，并将其作为差异特征信息进行输出。而对于缺陷样本特征记忆池而言，目标是寻求与输入特征的共性，故将其匹配得到的记忆特征直接作为共性特征信息进行输出，辅助模型对缺陷模式进行学习。

4.2.3 多尺度特征融合

本章所使用的的多尺度特征融合网络如图 4.5 所示。首先，将输入的缺陷样本多尺度特征与得到的差异特征信息与共性特征信息沿通道维度进行拼接作为多尺度特征融合网络的输入 $[F_1, F_2, F_3]$ ，然后分别使用 3×3 的卷积对特征进行处理，增加通道融合之后的特征表征能力，紧接着将处理后的 F_1 进行两倍的上采样操作与 F_2 进行特征融合得到 F'_2 ，其中 1×1 的卷积操作是为了改变特征通道数量，使得不同尺度的特征能够进行融合。以同样的操作将 F'_2 与 F_3 进行融合得到 F'_3 ，最后利用 3×3 的卷积减少特征融合过程中重叠效应的影响，得到输出特征图 $[Y_1, Y_2, Y_3]$ 。

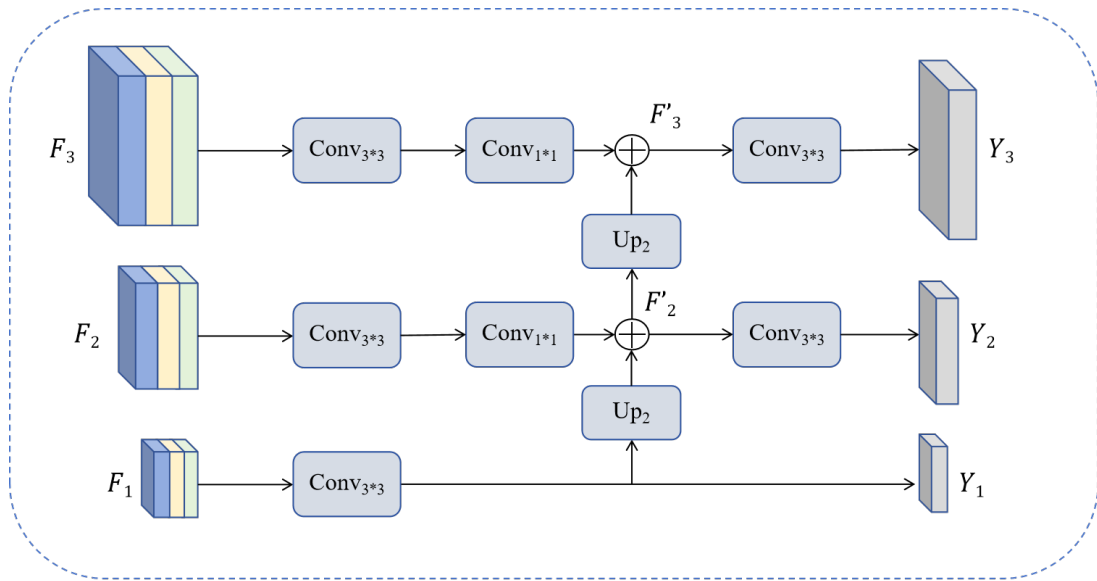


图 4.5 多尺度特征融合网络
Figure 4.5 Multi-scale feature fusion network

4.3 模型训练

在训练阶段，我们只将正常样本作为输入，并利用缺陷模拟策略生成缺陷样本，同时将生成的缺陷掩码作为真实值辅助模型训练。在测试阶段，则跳过缺陷模拟阶段，直接对输入样本以端到端方式进行缺陷检测。

在训练阶段，本章方法使用 L1 损失函数 L_{l1} 和焦点损失^[72](focal loss) 函数 L_f 使得

模型预测值 \hat{S} 接近真实值 S 。相对于 L2 损失，利用 L1 损失预测的分割结果保留了更多的边缘信息。同时，使用焦点损失减轻了样本图像中正常区域和缺陷区域之间的面积不平衡问题，使模型更加关注缺陷区域的分割，以提高缺陷分割的精度。

$$L_{l1} = \|S - \hat{S}\| \quad (4.6)$$

$$L_f = -(1 - p_t)^\gamma \log(p_t) \quad (4.7)$$

其中 p_t 表示样本真实类别的预测概率，当 S 中的对应像素点的标签真实值为 1 时， p_t 等于对应预测概率 p ，否则 $p_t = 1 - p$ 。 γ 为调节权重因子的超参数。

综合考虑以上两种损失函数，对其进行加权得到以下目标函数 $Loss$ ，在训练过程中，我们的目标是 minimized 该目标函数：

$$Loss = \lambda_1 L_{l1} + \lambda_2 L_f \quad (4.8)$$

其中 λ_1 和 λ_2 是可调节的超参数。

4.4 实验结果与分析

4.4.1 数据集与评价指标

本章对章节 3.4.1 中介绍的数据集进行划分组成实验数据集。具体来说，将数据集中的 950 张无缺陷图像与 50 张图像划分为训练集，剩余的 100 张无缺陷图像与 200 张有缺陷图像划分为测试集，其中训练集包含 50 张无缺陷图像与 50 张有缺陷图像作为特征记忆池样本。本章采用章节 2.4 中图像级别的 AUROC 分数以及像素级别的 AUROC 分数作为评价指标来衡量所提方法的检测性能。

4.4.2 实验设置

本章方法中编码器网络采用预训练好的 ResNet50 网络，通过去掉末端的池化层与全连接层，提取三个不同网络深度的多尺度特征。在缺陷模拟策略中随机使用五种尺度等级的生成策略，原始图像尺寸与生成的缺陷尺寸的比例分别为 1:1、2:1、3:1、4:1、5:1。在训练阶段，设置批次大小为 16，训练总周期为 100，学习率初始化为 0.005，设置 $Loss$ 中的超参数 $\gamma = 3$ ， $\lambda_1 = 0.6$ ， $\lambda_2 = 0.4$ 。实验环境是在单个 NVIDIA GeForce

RTX 3090 24G GPU 下进行的。所提方法以端到端方式获取图像中每个像素的缺陷得分，并以图像中得分最大的前 100 个像素点的缺陷分数平均值作为图像级的缺陷分数。

4.4.3 对比实验

为了验证本章所提方法的有效性，我们将所提方法和一些类似的半监督或自监督缺陷检测方法在数据集上进行对比试验，包括 MemAE^[73]、CutPaste^[74]、DRAEM^[75]。其中 MemAE 利用记忆模块将输入的正常样本和异常样本在潜在空间的表征替换为正常样本的表征，并将其重构为正常样本从而实现缺陷检测；CutPaste 通过对图像进行剪切和粘贴来模拟真实缺陷，进而学习正常样本和缺陷样本在特征空间上的差异；DRAEM 首先利用异常生成模块生成模拟缺陷样本，随后利用重构模块获取重建正常样本，最后将前两个样本进行拼接输入判别网络进行缺陷检测。实验结果如表 4.1 所示。可以看到在所有检测结果中，本章所提方法在图像级别和像素级别均取得最高的 AUROC 分数，而 MemAE 由于对一些缺陷区域往往也能很好地重构，从而导致较差的检测性能。因此在笔记本电脑表面缺陷检测任务中所提方法均优于其他几种缺陷检测方法，这充分证明了本章所提方法在笔记本电脑表面缺陷检测方面的有效性。

表 4.1 不同方法检测性能比较

Table 4.1 Comparison of detection performance of different methods

Algorithm	Image-level AUROC(%) \uparrow	Pixel-level AUROC(%) \uparrow
MemAE ^[73]	90.17	87.31
CutPaste ^[74]	93.75	91.39
DRAEM ^[75]	96.22	95.13
Ours	97.33	96.57

通过对预测结果特征图进行二值化，得到实验数据集中各种缺陷类型的检测可视化结果如图 4.6 所示，其中第一行为输入图像，第二行为检测结果图，第三行为真实标签的二值化图，图示结果表明所提方法在像素级的缺陷定位接近真实值，正常区域和缺陷区域之间的边界较为精确，这得益于通过缺陷模拟策略实现的端到端学习方法，模型的训练直接由模拟缺陷样本的像素级真实值来指导。所提出的方法能够定位出各种类型的外观缺陷。在模拟缺陷样本时，生成不同尺度的缺陷辅助模型学习，使得模型能够检测不同尺度的外观缺陷，这也证明了所提方法有较好的尺度不变性，是一种有效的笔记本电脑表面缺陷检测方法。




图 4.6 缺陷定位可视化结果

Figure 4.6 Visualization of defect location results

4.4.4 消融实验

为了验证本章所提方法中缺陷模拟策略生成不同尺度等级的缺陷对实验结果的影响，通过比较不同配置策略下的缺陷检测性能来进行消融实验，评价指标同样采用图像级别和像素级别的 AUROC 分数。设计三组消融实验如表 4.2 所示，maximum 表示缺陷模拟策略中只生成最大尺度等级的缺陷，即原图尺寸。medium 表示只生成中等尺度等级的缺陷，即原图尺寸的一半。minimum 表示缺陷模拟策略中只生成最小尺度等级的缺陷，即原图尺寸的五分之一。random 表示生成的随机尺度等级的缺陷，介于 maximum 与 minimum 之间。从实验结果可以看到，如果只生成最大尺度等级的缺陷的话，模型的检测性能明显降低，与其他两种尺度的实验结果有明显差距，而最小尺度的实验结果略优于中等尺度，达到最佳检测性能。这是因为在笔记本电脑表面缺陷检测数据集中，缺陷的尺度往往比较小，一般只占原图的很小比例，因此模拟生成的小尺度缺陷有利于模型对真实缺陷样本进行检测，当然我们也不排除有较大尺度缺陷类型的存在，因此，缺陷模拟策略中生成随机尺度的缺陷样本是有必要的。

表 4.2 不同缺陷模拟策略的性能比较

Table 4.2 Performance comparison of different defect simulation strategies

scale-level	Image-level AUROC(%)	Pixel-level AUROC(%)
maximum	91.47	90.23
medium	94.62	94.03
minimum	95.34	94.55
random	97.33	96.57

4.5 本章小结

本章介绍了基于缺陷模拟的记忆化笔记本电脑表面缺陷检测方法，在训练过程中通过正常样本模拟生成缺陷样本从而实现端到端的学习，利用正常样本与少量的缺陷样本构建特征记忆池辅助模型学习缺陷的共性与差异性。通过实验验证了本章所提方法具有良好的缺陷检测性能，通过端到端的学习能够实现较为精准的缺陷定位。

第五章 笔记本电脑外观缺陷检测系统

笔记本电脑外观缺陷检测系统由硬件平台和缺陷检测软件两部分组成。因此，本章从硬件和软件开发两个方面对检测系统做具体介绍。其中硬件平台部分主要介绍由工业相机、镜头、光源组成的图像采集单元，软件部分主要介绍执行流程和界面设计与功能组成。最后对检测系统做实际测试，证明该系统在笔记本电脑外观缺陷检测方面的有效性与实用性。

5.1 硬件平台

工业视觉系统可应用于各类工业产品质量检测，通常由三个主要部分构成：图像采集、图像处理与分析，以及输出与显示。其中，图像采集是系统的核心组成部分，其获取的图像质量直接影响着检测系统的整体性能。图像采集单元通常由工业相机、镜头和光源等组件组成，根据笔记本电脑实际生产场景，需要进行合理的硬件选型与设计，才能有效地采集到清晰的待检测图像。图 5.1所示为搭建的笔记本电脑外观缺陷检测系统样机。




图 5.1 缺陷检测系统样机
Figure 5.1 Prototype of defect detection system

5.1.1 工业相机

工业相机是工业视觉系统中的关键组件之一，其核心功能是将光信号转变成有序的电信号。相机的选择直接影响到采集的图像的分辨率、图像质量等因素，因此根据不同的应用场景选择合适的相机是工业视觉系统设计中的重要环节。工业相机在现代生产环境中扮演着至关重要的角色，它能够高速采集、传输、处理和分析高质量的图像和

视频数据，从而实现自动识别、检测、测量等工作。

工业相机一般可分成面阵和线阵两种不同结构特性的相机。机器视觉系统中普遍使用面阵相机，它使用面阵式成像传感器，其传感器包含多行感光元素，能够同时捕捉整个图像区域的像素阵列，适用于静态或缓慢运动的场景。线阵相机则通过沿一条直线方向逐行扫描图像，通常用于捕获连续运动的物体，适用于高速生产线上的检测。同时，线阵相机通常仅有一行感光元素，因此具有更高的扫描频率和分辨率，利用一台或多台相机对其逐行连续扫描，以达到对其整个表面均匀检测的目的，由于其逐行扫描的特性，线阵相机特别适合处理长条状物体，可以覆盖更大的检测区域。因此，结合考虑笔记本电脑生产线的高速度要求以及笔记本电脑外观成像的高分辨率要求，选择工业线阵相机组成图像采集单元。

5.1.2 镜头

工业视觉系统的镜头选型对于获取清晰、准确的图像同样重要。为了更好地配合线阵相机获取高清晰度、高分辨率的图像，检测系统选用线扫描镜头，线扫描镜头是一种专为线阵相机设计的镜头。线阵相机与面阵相机不同，它通过单一的线性感光元件来逐行扫描整个图像，而不是一次性捕捉整个图像。线扫描镜头的设计考虑到了这种工作原理，以满足线阵相机的特殊需求。线扫描镜头被设计为能够有效地匹配线性感光元件的工作方式。它们通常具有长条形的透镜设计，确保光线正确地投射到线性感光元件上，以满足线阵相机的特殊需求。此外，线扫描镜头通常具有高分辨率，并且在整个扫描线上保持低畸变，这是因为线扫描相机对于图像的几何精度要求较高，尤其是在需要进行精确测量的应用中。同时由于线扫描相机是逐行扫描的，适用于对长对象或生产线上高速运动的物体进行成像，契合了笔记本电脑生产线场景。

5.1.3 光源

光源的选取与打光合理与否也直接影响着成像质量，通过适当的光源照明设计，使图像中的目标信息与背景信息得到最佳分离，以确保在各种环境条件下获得清晰、准确的图像，可以大大降低检测算法识别缺陷的难度，同时提高检测系统的精度，使检测系统的可靠性和综合性能得到提高。反之，如果光源设计不当，会导致采集图像质量变差，进而导致缺陷检测精度的降低。

常用的光源有环形光源、线形光源、同轴光源等，针对不同的应用场景需要选用不

同的光源。由于系统采用了工业线阵相机配合滑杆对笔记本电脑进行线性扫描成像，因此选择线性光源进行照明，线性光源与笔记本电脑的形状匹配，在扫描过程中可以提供沿其扫描方向均匀分布的照明，有助于检测表面缺陷或特定的形状特征。此外，线形光源能够突出物体的表面细节，特别是在垂直于光源方向的角度上，这使得线形光源在需要强调表面纹理、划痕或其他细微特征的应用中非常有用，能够有效地配合线阵相机运用于笔记本电脑生产流水线场景。

在光源颜色上选择红光和蓝光两种独立线性光源，其中蓝光的短波长有助于边缘检测和轮廓分析，产生更为清晰的图像，能够突显检测目标的边缘和细节，在一些情况下蓝光可以增强光学亮度对比度，也有助于检测表面微小的特征。而红光对于表面的透射和反射较好，能够突显材料表面的不平整性，更凸显有起伏变化的瑕疵，尤其是对于金属材质的表面缺陷成像更为有效。

5.2 检测软件开发

缺陷检测软件是检测系统的重要组成部分，合理的软件设计便于人机交互使用，提高检测系统的可操作性。因此，在软件部分基于 PyQt5 框架进行系统的软件界面开发与功能设计，并集成训练好的缺陷检测算法对图像采集单元获取的图像进行检测。

5.2.1 软件执行流程

检测系统的软件部分主要包括图像获取、图像预处理、缺陷检测算法集成、检测结果可视化与保存。软件开发基于 Python 编程语言，使用 PyCharm 进行软件开发，利用 OpenCV 库实现图像预处理算法。软件部分的具体执行流程如图 5.2 所示。

具体流程如下：

- (1) 采集图像获取。利用工业相机接口获取实时采集图像。
- (2) 图像预处理。该模块主要是对获取的原始图像做一些预处理操作，包括利用滤波技术对原始图像进行去噪，使用边缘检测算法强调检测目标，帮助裁剪目标主体，最后对图像进行局部裁剪得到待检测的图像数据。
- (3) 算法检测。该模块通过加载训练好的检测算法，并将预处理后的图像数据作为输入进行算法检测，最终输出检测结果与可视化图像数据。
- (4) 结果可视化与保存。该模块可在软件的图形用户界面显示检测结果与检测可视化

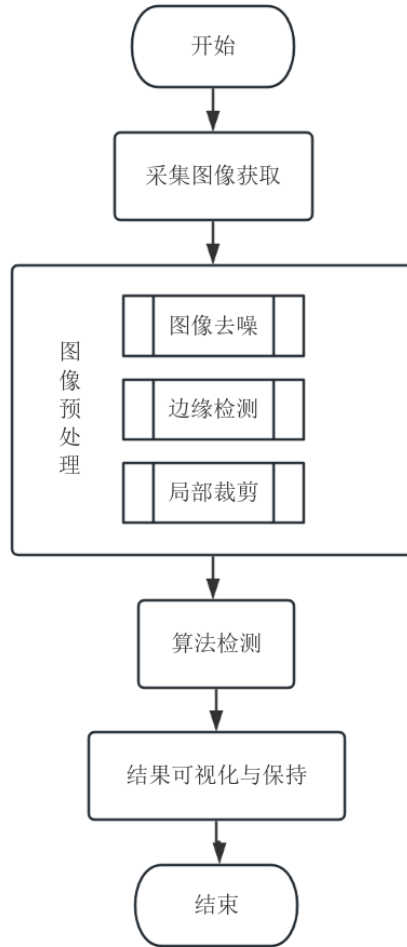


图 5.2 软件执行流程

Figure 5.2 Software execution process

图像，并保存图像数据与检测结果到本地文件。

通过解耦算法检测模块与图像预处理以及可视化模块，降低检测系统软件模块之间的耦合度，使得可以方便地在检测系统上部署各种检测算法，同时提高了检测系统的可扩展性和可维护性。

5.2.2 软件界面设计

本文基于 PyQt5 框架设计软件的图形化界面，PyQt5 是跨平台 C++ 图形用户界面应用程序开发框架 Qt5 的 Python 版本，同时 PyQt 提供了 QT designer 工具便于用户进行开发，开发人员通过拖拽和编写少量代码，使用控件实现不同的功能即可完成软件界面开发。

通过需求分析，设计缺陷检测软件的界面框架如图 5.3 所示，共包括四个模块：系统名称、原图-检测可视化、检测结果、功能按钮。界面顶部的系统名称设置为笔记本

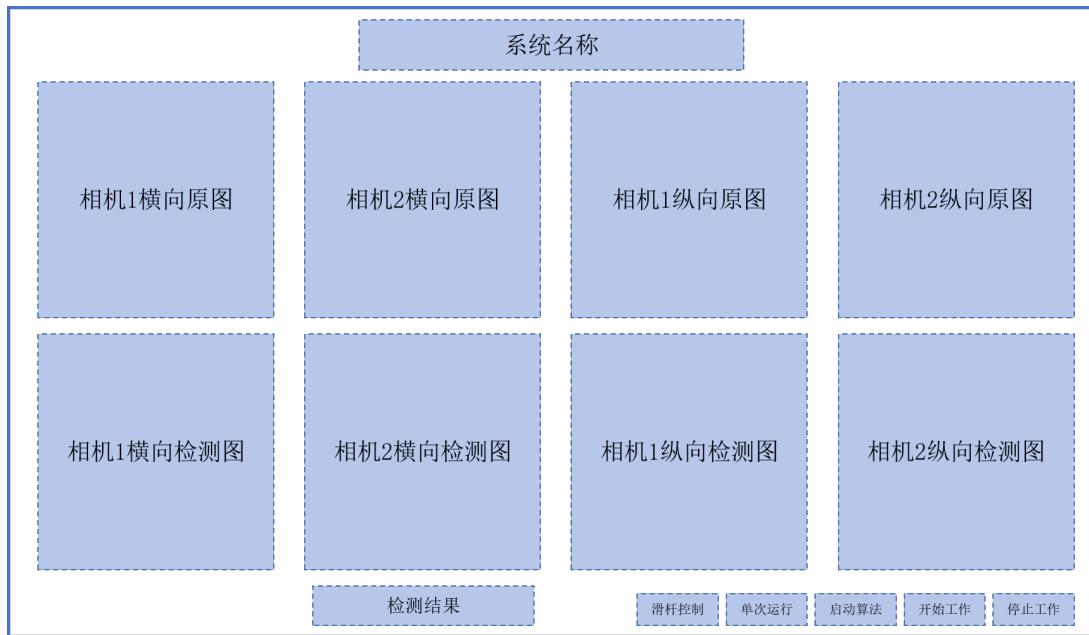


图 5.3 检测软件界面设计框架

Figure 5.3 Interface design framework of detection software

外观缺陷人机交互智能检测系统；界面中部的原图-检测可视化模块上部分展示由图像采集单元采集到的原图像，下部分展示利用检测算法进行检测得到的可视化检测结果，其中每个图像与上部分图像一一对应；界面底部左侧的检测结果模块显示此次检测的样本是否存在缺陷；界面底部右侧功能按钮模块则是一些便于人机交互的功能按钮，可以调整滑杆运动速度、进行单次图像采集、启动检测算法以及连续检测的开启与关闭。考虑到从不同角度观测缺陷时呈现的差异性，因此检测样机需要从横向和纵向两个角度进行图像采集。同时采用双相机设置，避免了图像采集死角问题。因此，原图-检测可视化模块中共有四列图像，第 1、2 列图像是横向采集的原图和检测结果，第 3、4 列图像是纵向采集的原图和检测结果。

5.3 系统测试结果

通过集成训练好的缺陷检测算法，笔记本电脑外观缺陷检测系统的运行结果如图 5.4 所示，可以看出检测系统能准确地执行各个流程，并将检测结果显示在软件界面上。同时对系统的运行时间做出分析如表 5.1 所示。可以看到系统主要耗时在图像采集

表 5.1 检测系统平均用时 (单位 s)

Table 5.1 Average time for detection system (in s)

图像采集	图像预处理	算法检测	后处理操作	总时间
4.1437	0.3205	0.4742	0.6035	5.5419

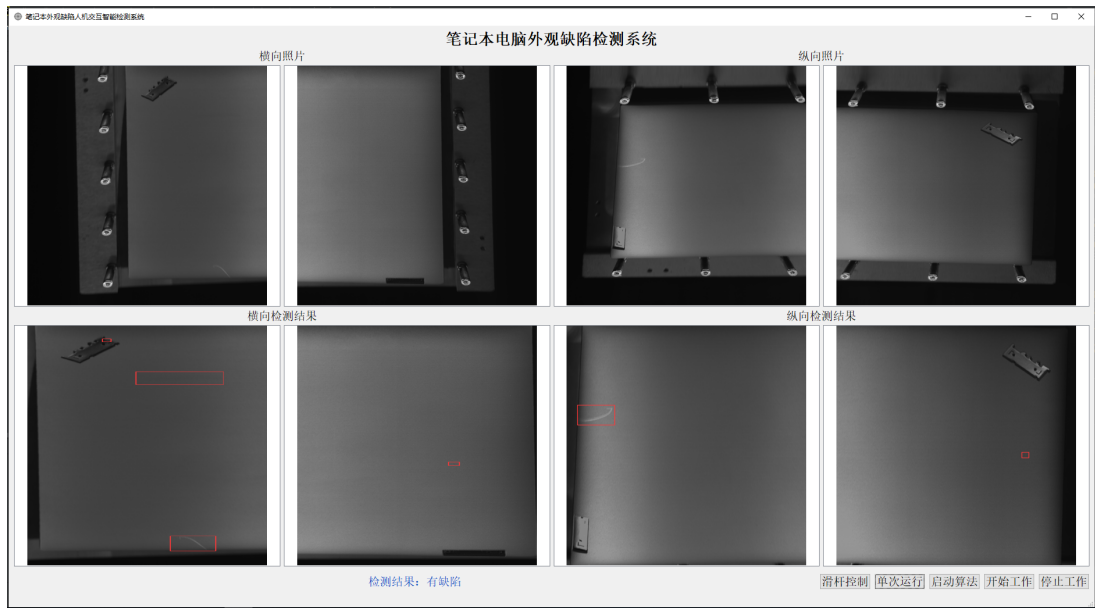


图 5.4 检测系统运行结果图

Figure 5.4 Detection system operation result chart

部分，这是因为图像采集单元是依靠滑杆滑动配合线阵相机对目标进行两次逐行扫描，在实际产线上，这部分时间可以转换为传送带的运动时间，并不影响检测过程。其次耗时较长的是后处理操作部分，主要是用于保存图像操作。算法检测的时间并不固定，会根据检测算法的不同而发生波动，不同的应用可能对实时性有不同的要求，在笔记本电脑外观缺陷检测领域，算法检测时间占总时间的比例控制在一个相对较小的范围即可。在实际应用中可以通过更换性能更好的 GPU 来减少图像预处理、算法检测以及后处理部分的耗时。从检测效果和实时性来说，本系统基本满足了实际需求，同时对于其它工业缺陷检测领域具有一定的参考意义。

5.4 本章小结

本章对笔记本电脑外观缺陷检测系统做了详细介绍，将检测系统分为硬件部分和软件部分。在硬件方面，基于实际生产场景以及笔记本电脑的成像需求，介绍了图像采集单元所涉及的工业相机、镜头、光源的选型。在软件部分，介绍了检测软件总体执行流程，并基于 PyQt5 进行软件界面开发与功能设计。最后，通过集成缺陷检测算法对检测系统进行实际应用，验证其有效性与实用性。

第六章 总结与展望

6.1 总结

本文主要针对笔记本电脑表面缺陷检测问题进行相关研究，由于在笔记本电脑表面缺陷检测领域中难以收集大量的缺陷样本，传统的基于有监督学习的缺陷检测算法不能有效地应用在此领域。因此，从无监督学习以及半监督学习的角度出发，展开了面向缺陷样本匮乏场景的笔记本电脑表面缺陷检测研究。本文的主要工作和贡献如下：

- (1) 考虑到真实笔记本电脑生产制造过程中，产生缺陷的概率很小，往往只能获取到大量的正常样本图像，在此场景下，借助于无监督学习的思想，本论文提出了一种基于多尺度标准化流的笔记本电脑表面缺陷检测方法。首先引入了多尺度特征提取网络，充分利用浅层特征重要的细节信息与深层特征丰富的语义信息。然后利用标准化流网络对正常样本的多尺度特征进行密度估计，拟合正常样本的特征分布，进而实现分布外的缺陷样本检测。实验结果证明了所提方法仅基于正常样本训练就能较好地检测和定位各种表面缺陷。
- (2) 在实际工业场景中，不仅能够获取相对充分的正常样本图像，同时也能够收集到少量可标注的缺陷样本图像，这部分缺陷数据有助于改善缺陷检测方法的性能，在此场景下，借助于半监督学习和自监督学习的思想，本论文提出了一种基于缺陷模拟的记忆化笔记本电脑表面缺陷检测方法。首先，利用缺陷模拟策略对输入的正常样本图像进行缺陷生成。然后，通过预训练网络提取生成图像的多尺度特征，并基于最近邻匹配获取正常记忆化池与缺陷记忆化池中的记忆特征，将其与原始多尺度特征进行拼接，最后利用多尺度特征融合网络与解码器网络得到缺陷检测结果。实验结果证明了所提方法在利用正常样本进行自监督学习以及结合少量缺陷样本的情况实现较好的缺陷检测性能。
- (3) 为满足笔记本电脑产线上进行实时缺陷检测的需求，基于工业相机等硬件与 PyQt5 软件开发技术开发了笔记本电脑表面缺陷检测系统，通过合理的硬件选型并搭建图像采集单元实时获取待检测图像，利用集成的缺陷检测方法对图像进行实时检测，并对检测流程进行耗时分析，该系统具备良好的稳定性与应用性。

6.2 研究展望

本文针对缺陷样本匮乏场景下的笔记本电脑表面缺陷检测问题展开研究，提出了两种在不同场景下适用的缺陷检测方法，并通过实验证明其良好的缺陷检测性能。但目前的检测方法中任然存在一些不足之处，因此，未来可以从以下方面进行改进与研究：

- (1) 针对本文提出的基于多尺度标准化流的缺陷检测方法，由于方法仅基于正常样本进行训练，那么在检测图像存在背景干扰的情况下，检测方法可能不能很好地区分待检目标背景信息与目标缺陷信息，导致在检测过程将小部分背景信息也作为缺陷检测出来。因此，在以后的无监督缺陷检测研究中还需关注对检测目标的有效特征提取，避免目标背景信息的干扰。
- (2) 针对本文提出的基于缺陷模拟的记忆化缺陷检测方法，在缺陷模拟策略中，我们仅利用柏林噪声以及纹理图片生成缺陷，因此产生的缺陷模式较为固定。在以后的研究中，同时考虑将已知的缺陷样本添加到缺陷模拟策略，将已有的缺陷模式通过图像融合的方式生成新的缺陷样本，扩展模拟缺陷类型的多样性，使得生成缺陷样本更接近真实缺陷样本图像，提升检测方法的检测性能。
- (3) 本文搭建的笔记本电脑表面缺陷检测系统任具有可扩展性。在硬件方面，考虑到不同的光源打光方式可能对不同缺陷类型呈现不同的成像效果，现在的光源调整方式比较繁琐，需要重新拆卸光源才能调整打光角度，后续可以将光源调整为可旋转结构，便于打光角度的调整。在软件方面，需要进一步改进预处理过程中待检目标的裁剪方式，尽可能避免目标背景信息的干扰，提升检测系统的稳定性。

参考文献

- [1] Gao R X, Wang L, Helu M, et al. Big data analytics for smart factories of the future[J]. *CIRP Annals*, 2020, 69(2): 668–692.
- [2] 罗东亮, 蔡雨萱, 杨子豪, 等. 工业缺陷检测深度学习方法综述[J]. *中国科学: 信息科学*, 2022, 52: 1002–1039.
- [3] Gao Y, Li X, Wang X V, et al. A review on recent advances in vision-based defect recognition towards industrial intelligence[J]. *Journal of Manufacturing Systems*, 2022, 62: 753–766.
- [4] 李少波, 杨静, 王铮, 等. 缺陷检测技术的发展与应用研究综述[J]. *自动化学报*, 2020, 46: 2319–2336.
- [5] 朱云, 凌志刚, 张雨强. 机器视觉技术研究进展及展望[J]. *图学学报*, 2020, 41: 871–890.
- [6] Luo Q, Sun Y, Li P, et al. Generalized completed local binary patterns for time-efficient steel surface defect classification[J]. *IEEE Transactions on Instrumentation and Measurement*, 2018, 68(3): 667–679.
- [7] Tao X, Zhang D, Ma W, et al. Automatic metallic surface defect detection and recognition with convolutional neural networks[J]. *Applied Sciences*, 2018, 8(9): 1575.
- [8] Lei J, Gao X, Feng Z, et al. Scale insensitive and focus driven mobile screen defect detection in industry[J]. *Neurocomputing*, 2018, 294: 72–81.
- [9] Kyeong K, Kim H. Classification of mixed-type defect patterns in wafer bin maps using convolutional neural networks[J]. *IEEE Transactions on Semiconductor Manufacturing*, 2018, 31(3): 395–402.
- [10] Song W, Chen T, Gu Z, et al. Wood materials defects detection using image block percentile color histogram and eigenvector texture feature[C]. *First International Conference on Information Sciences, Machinery, Materials and Energy*. 2015: 779–783.
- [11] Lee S, Chang L M, Skibniewski M. Automated recognition of surface defects using digital color image processing[J]. *Automation in Construction*, 2006, 15(4): 540–549.

- [12] 仰梓淮, 黄海鸿, 刘贺, 等. 基于颜色直方图的电路板表面缺陷检测[J]. 计算机集成制造系统: 1–15.
- [13] 胡跃明, 李璐, 罗家祥. 高密度柔性集成电路基板的表面氧化缺陷检测[J]. 计算机集成制造系统, 2020, 26: 2379–2387.
- [14] Yan K, Dong Q, Sun T, et al. Weld defect detection based on completed local ternary patterns[C]. Proceedings of the International Conference on Video and Image Processing. 2017: 6–14.
- [15] 郭萌, 胡辽林, 赵江涛. 基于 kirsch 和 canny 算子的陶瓷碗表面缺陷检测方法[J]. 光学学报, 2016, 36: 27–33.
- [16] 刘源, 夏春蕾. 一种基于 sobel 算子的带钢表面缺陷图像边缘检测算法[J]. 电子测量技术, 2021, 44: 138–143.
- [17] Hou Z, Parker J M. Texture defect detection using support vector machines with adaptive gabor wavelet features[C]. 2005 Seventh IEEE Workshops on Applications of Computer Vision. 2005: 275–280.
- [18] LeCun Y, Bengio Y, Hinton G. Deep learning[J]. nature, 2015, 521(7553): 436–444.
- [19] Girshick R. Fast r-cnn[C]. Proceedings of the IEEE international conference on computer vision. 2015: 1440–1448.
- [20] Redmon J, Divvala S, Girshick R, et al. You only look once: Unified, real-time object detection[C]. Proceedings of the IEEE conference on computer vision and pattern recognition. 2016: 779–788.
- [21] He K, Gkioxari G, Dollár P, et al. Mask r-cnn[C]. Proceedings of the IEEE international conference on computer vision. 2017: 2961–2969.
- [22] Lin G, Milan A, Shen C, et al. Refinenet: Multi-path refinement networks for high-resolution semantic segmentation[C]. Proceedings of the IEEE conference on computer vision and pattern recognition. 2017: 1925–1934.
- [23] Wang Q, Zhang L, Bertinetto L, et al. Fast online object tracking and segmentation: A unifying approach[C]. Proceedings of the IEEE/CVF conference on Computer Vision and Pattern Recognition. 2019: 1328–1338.
- [24] Yan B, Peng H, Fu J, et al. Learning spatio-temporal transformer for visual tracking

- [C]. Proceedings of the IEEE/CVF international conference on computer vision. 2021: 10448–10457.
- [25] Yang W. A survey of surface defect detection based on deep learning[C]. 2022 7th International Conference on Modern Management and Education Technology (MMET 2022). 2022: 362–367.
- [26] Bengio Y, Courville A, Vincent P. Representation learning: A review and new perspectives[J]. IEEE transactions on pattern analysis and machine intelligence, 2013, 35(8): 1798–1828.
- [27] Deitsch S, Christlein V, Berger S, et al. Automatic classification of defective photovoltaic module cells in electroluminescence images[J]. Solar Energy, 2019, 185: 455–468.
- [28] Simonyan K, Zisserman A. Very deep convolutional networks for large-scale image recognition[J]. arXiv preprint arXiv:1409.1556, 2014.
- [29] 陶志勇, 杜福廷, 任晓奎, 等. 基于 t-vgg 的太阳电池片缺陷检测[J]. 太阳能学报, 2022, 43: 145–151.
- [30] Tao X, Zhang D, Wang Z, et al. Detection of power line insulator defects using aerial images analyzed with convolutional neural networks[J]. IEEE transactions on systems, man, and cybernetics: systems, 2018, 50(4): 1486–1498.
- [31] Ren S, He K, Girshick R, et al. Faster r-cnn: Towards real-time object detection with region proposal networks[J]. Advances in neural information processing systems, 2015, 28.
- [32] Zhang C, Chang C c, Jamshidi M. Concrete bridge surface damage detection using a single-stage detector[J]. Computer-Aided Civil and Infrastructure Engineering, 2020, 35(4): 389–409.
- [33] Redmon J, Farhadi A. Yolov3: An incremental improvement[J]. arXiv preprint arXiv:1804.02767, 2018.
- [34] 张乃雪, 钟羽中, 赵涛, 等. 基于 smooth-detr 的产品表面小尺寸缺陷检测算法[J]. 计算机应用研究, 2022, 39: 2520–2525.
- [35] Carion N, Massa F, Synnaeve G, et al. End-to-end object detection with transformers[C]. European conference on computer vision. 2020: 213–229.

- [36] Yu Z, Wu X, Gu X. Fully convolutional networks for surface defect inspection in industrial environment[C]. Computer Vision Systems: 11th International Conference. 2017: 417–426.
- [37] Long J, Shelhamer E, Darrell T. Fully convolutional networks for semantic segmentation [C]. Proceedings of the IEEE conference on computer vision and pattern recognition. 2015: 3431–3440.
- [38] 王延年, 刘宏涛, 刘航宇, 等. 基于改进 u-net 的太阳能电池图像缺陷检测方法[J]. 电子测量技术, 2021, 44: 117–121.
- [39] Ronneberger O, Fischer P, Brox T. U-net: Convolutional networks for biomedical image segmentation[C]. Medical Image Computing and Computer-Assisted Intervention. 2015: 234–241.
- [40] 郭玥, 于希明, 王少军, 等. 遥感图像云检测的多尺度融合分割网络方法[J]. 仪器仪表学报, 2019, 40: 31–38.
- [41] Cohen N, Hoshen Y. Sub-image anomaly detection with deep pyramid correspondences [J]. arXiv preprint arXiv:2005.02357, 2020.
- [42] Akcay S, Atapour-Abarghouei A, Breckon T P. Ganomaly: Semi-supervised anomaly detection via adversarial training[C]. Asian Conference on Computer Vision. 2019: 622–637.
- [43] Defard T, Setkov A, Loesch A, et al. Padim: a patch distribution modeling framework for anomaly detection and localization[C]. International Conference on Pattern Recognition. 2021: 475–489.
- [44] 陈大鹏, 姚剑敏, 严群, 等. 基于自编码器结构改进的无监督图像异常检测[J]. 信息技术与信息化, 2023, 08: 4–7.
- [45] Bergmann P, Fauser M, Sattlegger D, et al. Mvtec ad—a comprehensive real-world dataset for unsupervised anomaly detection[C]. Proceedings of the IEEE/CVF conference on computer vision and pattern recognition. 2019: 9592–9600.
- [46] Rezende D, Mohamed S. Variational inference with normalizing flows[C]. International conference on machine learning. 2015: 1530–1538.
- [47] Dinh L, Krueger D, Bengio Y. Nice: Non-linear independent components estimation[J].

- arXiv preprint arXiv:1410.8516, 2014.
- [48] Dinh L, Sohl-Dickstein J, Bengio S. Density estimation using real nvp[J]. arXiv preprint arXiv:1605.08803, 2016.
- [49] Kingma D P, Dhariwal P. Glow: Generative flow with invertible 1x1 convolutions[J]. Advances in neural information processing systems, 2018, 31.
- [50] Singh B, Davis L S. An analysis of scale invariance in object detection snip[C]. Proceedings of the IEEE conference on computer vision and pattern recognition. 2018: 3578–3587.
- [51] Ma W, Wu Y, Cen F, et al. Mdfn: Multi-scale deep feature learning network for object detection[J]. Pattern Recognition, 2020, 100: 107149.
- [52] Zhang K, Zhang Z, Li Z, et al. Joint face detection and alignment using multitask cascaded convolutional networks[J]. IEEE signal processing letters, 2016, 23(10): 1499–1503.
- [53] Liu W, Anguelov D, Erhan D, et al. Ssd: Single shot multibox detector[C]. Computer Vision–ECCV 2016: 14th European Conference. 2016: 21–37.
- [54] Najibi M, Samangouei P, Chellappa R, et al. Ssh: Single stage headless face detector[C]. Proceedings of the IEEE international conference on computer vision. 2017: 4875–4884.
- [55] Szegedy C, Liu W, Jia Y, et al. Going deeper with convolutions[C]. Proceedings of the IEEE conference on computer vision and pattern recognition. 2015: 1–9.
- [56] Chen L C, Papandreou G, Kokkinos I, et al. Deeplab: Semantic image segmentation with deep convolutional nets, atrous convolution, and fully connected crfs[J]. IEEE transactions on pattern analysis and machine intelligence, 2017, 40(4): 834–848.
- [57] Zhao H, Shi J, Qi X, et al. Pyramid scene parsing network[C]. Proceedings of the IEEE conference on computer vision and pattern recognition. 2017: 2881–2890.
- [58] Lin T Y, Dollár P, Girshick R, et al. Feature pyramid networks for object detection[C]. Proceedings of the IEEE conference on computer vision and pattern recognition. 2017: 2117–2125.
- [59] Deng J, Dong W, Socher R, et al. Imagenet: A large-scale hierarchical image database [C]. 2009 IEEE conference on computer vision and pattern recognition. 2009: 248–255.
- [60] Song J, Kong K, Park Y I, et al. Anoseg: Anomaly segmentation network using self-

- supervised learning[J]. arXiv preprint arXiv:2110.03396, 2021.
- [61] Yang M, Wu P, Feng H. Memseg: A semi-supervised method for image surface defect detection using differences and commonalities[J]. *Engineering Applications of Artificial Intelligence*, 2023, 119: 105835.
- [62] Goodfellow I, Pouget-Abadie J, Mirza M, et al. Generative adversarial nets[J]. *Advances in neural information processing systems*, 2014, 27.
- [63] Kingma D P, Welling M. Auto-encoding variational bayes[J]. arXiv preprint arXiv:1312.6114, 2013.
- [64] Isola P, Zhu J Y, Zhou T, et al. Image-to-image translation with conditional adversarial networks[C]. *Proceedings of the IEEE conference on computer vision and pattern recognition*. 2017: 1125–1134.
- [65] He K, Zhang X, Ren S, et al. Deep residual learning for image recognition[C]. *Proceedings of the IEEE conference on computer vision and pattern recognition*. 2016: 770–778.
- [66] Zhang Q L, Yang Y B. Sa-net: Shuffle attention for deep convolutional neural networks [C]. *ICASSP 2021-2021 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*. 2021: 2235–2239.
- [67] Woo S, Park J, Lee J Y, et al. Cbam: Convolutional block attention module[C]. *Proceedings of the European conference on computer vision (ECCV)*. 2018: 3–19.
- [68] Wu Y, He K. Group normalization[C]. *Proceedings of the European conference on computer vision (ECCV)*. 2018: 3–19.
- [69] Rudolph M, Wehrbein T, Rosenhahn B, et al. Fully convolutional cross-scale-flows for image-based defect detection[C]. *Proceedings of the IEEE/CVF Winter Conference on Applications of Computer Vision*. 2022: 1088–1097.
- [70] Van der Maaten L, Hinton G. Visualizing data using t-sne.[J]. *Journal of machine learning research*, 2008, 9(11).
- [71] Rudolph M, Wandt B, Rosenhahn B. Same same but differnet: Semi-supervised defect detection with normalizing flows[C]. *Proceedings of the IEEE/CVF winter conference on applications of computer vision*. 2021: 1907–1916.
- [72] Lin T Y, Goyal P, Girshick R, et al. Focal loss for dense object detection[C]. *Proceedings*

- of the IEEE international conference on computer vision. 2017: 2980–2988.
- [73] Gong D, Liu L, Le V, et al. Memorizing normality to detect anomaly: Memory-augmented deep autoencoder for unsupervised anomaly detection[C]. Proceedings of the IEEE/CVF International Conference on Computer Vision. 2019: 1705–1714.
- [74] Li C L, Sohn K, Yoon J, et al. Cutpaste: Self-supervised learning for anomaly detection and localization[C]. Proceedings of the IEEE/CVF conference on computer vision and pattern recognition. 2021: 9664–9674.
- [75] Zavrtnik V, Kristan M, Skočaj D. Draem-a discriminatively trained reconstruction embedding for surface anomaly detection[C]. Proceedings of the IEEE/CVF International Conference on Computer Vision. 2021: 8330–8339.

攻读硕士学位期间取得的学术成果

论文:

- [1] **Jie Zhang**, Zerui Li, Yunbo Zhao. Defect detection of laptop appearance based on improved multi-scale normalizing flows[C]//2023 38th Youth Academic Annual Conference of Chinese Association of Automation (YAC). IEEE, 2023: 311-316.

发明专利:

- [1] 赵云波, **张杰**, 李泽瑞, 等. 基于多尺度标准化流的无监督笔记本外观缺陷检测方法 [P]. 安徽省:CN116205876A,2023-06-02.(公开)

致 谢

时光如白驹过隙，转眼间硕士三年的学习生涯也即将画上句号，站在毕业的门槛上，回首往昔，奋斗和辛劳已成为人生中美好的记忆。在这里，我要向那些在学习生活中帮助过我的人们致以由衷的感谢。

首先感谢我的实践导师赵云波老师，赵老师在这三年间的科研生活中给予我莫大的帮助。在科研学习中，赵老师为我指明研究方向和思路，使我得以更清晰地了解自己的研究领域，深入探索问题的本质，从而为我的研究工作奠定了坚实的基础。生活中，赵老师以平易近人的生活态度对待学生，在关乎学生的切身利益上为学生着想。同时感谢智能院的李泽瑞老师和吕文君老师，在初入项目组的时候，两位老师在科研项目上给予我充分的指导，使我的专业水平有了很大的提高，感谢你们对我的科研项目和论文撰写上的悉心指导和帮助。在此，谨向以上尊敬的各位老师致以衷心的感谢。

感谢我的校内导师赵鹏老师，赵老师在校内组会中悉心指导学生分享阅读论文，鼓励我们进行学术探讨，培养了我的学术素养和独立思考的能力。她严谨的科研素养，虚心的科研态度深深的感染和激励着我。在此，谨向尊敬的赵鹏老师致以衷心的感谢。

感谢实验室的各位同学，在这个温馨的大家庭里，我们一起探索、一起奋斗、一起成长，留下了无数美好的回忆，感谢你们在平时的相处中给予过我的支持、理解和帮助。同时感谢我的室友，两年多的相处使我们建立了深厚的友谊。愿我们保持对生活的热爱，对梦想的追求，在未来的岁月里，勇敢地面对挑战。

最后感谢我的家人和朋友，感谢你们一直以来的关爱与支持，陪伴着我顺利地完学业。

毕业不是结束，而是新生活的开始，我将带着这份珍贵的记忆，迈向人生的下一阶段。