

# 研究生毕业论文(申请工程硕士学位)

| 论  | 文   | 题   | 目  | 基于工业缺陷特征的图像扩增方法 |
|----|-----|-----|----|-----------------|
| 作  | 者   | 姓   | 名  | 陈楠              |
| 学利 | 斗、专 | 专业社 | 名称 | 工程硕士(软件工程领域)    |
| 研  | 究   | 方   | 向  | 软件工程            |
| 指  | 导   | 教   | 师  | 陈振宇 教授          |

2022年5月25日

学 号: MF20320016

论文答辩日期: 2022 年 5 月 20 日

指导教师:

(签字)

# Image Augmentation Method Based on Industrial Defect Features

by

Nan Chen

Supervised by

## Professor Zhenyu Chen

A dissertation submitted to the graduate school of Nanjing University in partial fulfilment of the requirements for the degree of MASTER OF ENGINEERING

> in Software Engineering



Software Institute Nanjing University

May 25, 2022

## 南京大学研究生毕业论文中文摘要首页用纸

毕业论文题目: 基于工业缺陷特征的图像扩增方法

<u>工程硕士(软件工程领域)</u>专业<u>2020</u>级硕士生姓名: 陈楠 指导教师(姓名、职称): 陈振宇教授

#### 摘 要

随着国内制造业的大力发展,行业内对金属板材外观与质量要求越来越高,金属材料表面缺陷检测随之也变得至关重要。机器学习在金属表面缺陷检测中的应用越来越广泛,其主要应用在缺陷的定位与分类。深度学习模型在训练过程中,需要依靠大量工业缺陷数据才能解决模型的过拟合问题,过拟合会导致检测模型发生错检与漏检。而在实际的工业环境中数据获取困难较大,主要是因为在复杂的工业生产环境下,由于机器视觉系统时效性影响,样本获取与数据标注困难,同时工业缺陷种类多、差异化较大加大了这一困难。要将机器学习应用于实际的工业缺陷检测中,必须解决缺陷样本数量不足、多样化程度低的问题。图像扩增是解决数据量不足的有效方法,但是通用的数据扩增方法在工业生产中应用效果一般,并且不具有工业领域的专业性,因此迫切需要探索工业领域的图像扩增方法。

为了解决工业生产中获取缺陷数据难的问题,提高工业金属表面缺陷检测 模型的精度,本文设计并实现工业图像数据扩增方法,通过分析工业图像采集 过程,模拟光源类别、镜头参数、相机姿态角变化与传感器特点,从而得到不 同工业生产环境下的真实样本;同时提取工业缺陷形态特征,分析缺陷产生原 因并进行归纳,模拟缺陷损伤程度、大小、长短、方向与方位变化等,从而得 到工业多样性特征下的真实样本。使用 Python 语言与 OpenCV 库实现工业缺陷 图像扩增方法,调整方法中不同模型与其控制参数进行工业图像数据自动化扩 增,还原真实工业生产环境与缺陷形态特征,生成大量工业缺陷图像数据。

本文使用钢带表面缺陷数据集(NEU-DET)对主流深度学习目标检测模型 (yolov5, SSD, Fast R-CNN)进行测试,模拟图像采集过程,研究缺陷形态 特征扩增数据对检测模型识别率的影响,对比经过扩增数据强化训练前后的模 型,证实方法能够明显提高模型的泛化能力与精度,相比传统数据扩增方法更 具有适用性,在一定程度上可有效的解决在工业生产环境中因为训练样本不足 而导致的工业缺陷检测模型过拟合、泛化能力差、检测精度低的问题,从而避 免在工业产品生产线上发生错检漏检等问题,大大地提高了金属板材的质量。

关键词: 深度学习,数据扩增,图像处理,工业特征,机器视觉

# 南京大学研究生毕业论文英文摘要首页用纸

THESIS Image Augmentation Method Based on Industrial Defect Features

| SPECIALIZATION: | Software Engineering  |  |
|-----------------|-----------------------|--|
| POSTGRADUATE:   | Nan Chen              |  |
| MENTOR:         | Professor Zhenyu Chen |  |

#### Abstract

With the vigorous development of the domestic manufacturing industry, the industry has higher and higher requirements for the appearance and quality of metal sheets, and the detection of surface defects of metal materials has also become critical. The application of machine learning in metal surface defect detection is more and more extensive, and its main application is in defect location and classification. During the training process of the deep learning model, it needs to rely on a large amount of industrial defect data to solve the problem of overfitting of the model. Overfitting will lead to false detection and missed detection of the detection model. In the actual industrial environment, data acquisition is difficult, mainly because in the complex industrial production environment, due to the timeliness of the machine vision system, sample acquisition and data labeling are difficult, and there are many types of industrial defects and large differences. exacerbated this difficulty. To apply machine learning to actual industrial defect detection, the problems of insufficient defect samples and low diversity must be solved. Image augmentation is an effective method to solve the insufficient amount of data. However, general data augmentation methods are generally used in industrial production and are not professional in the industrial field. Therefore, it is urgent to explore image augmentation methods in the industrial field.

In order to solve the problem of difficulty in obtaining defect data in industrial production and improve the accuracy of the industrial metal surface defect detection model, this paper designs and implements an industrial image data augmentation method. At the same time, the morphological characteristics of industrial defects are extracted, the causes of defects are analyzed and summarized, and the degree of damage, size, length, direction and orientation of defects are simulated, so as to obtain industrial diversity real samples under sexual characteristics. Using Python language and OpenCV library to realize industrial defect image augmentation method, adjust different models and control parameters in the method to automatically augment industrial image data, restore the real industrial production environment and defect morphological characteristics, and generate a large amount of industrial defect image data.

This paper uses the steel strip surface defect data set (NEU-DET) to test the mainstream deep learning target detection models (yolov5, SSD, Fast R-CNN), simulates the image acquisition process, and studies the detection model recognition rate of the defect morphological feature augmentation data. Compared with the model before and after the augmented data intensive training, it is confirmed that the method can significantly improve the generalization ability and accuracy of the model. Compared with the traditional data augmentation method, it is more applicable and can effectively solve the problem in industrial production to a certain extent. In the environment, due to insufficient training samples, the industrial defect detection model is over-fitting, poor generalization ability, and low detection accuracy, so as to avoid problems such as false detection and missed detection on the production line of industrial products, and greatly improve the performance of metal sheets quality.

**keywords:** Deep learning, data augmentation, image processing, industrial features, machine vision

| -1- |
|-----|

| 目录   | ↓ 录 · · · · · · · · · · · · · · · · · · |    |  |  |  |  |
|--|---|----|--|--|--|--|
| 插图清单                                       |   |    |  |  |  |  |
| 附表清单 · · · · · · · · · · · · · · · · · · · |   |    |  |  |  |  |
| 第一章  | 绪论 ·····                                | 1  |  |  |  |  |
| 1.1  | 研究背景及意义                                 | 1  |  |  |  |  |
| 1.2  | 国内外研究现状                                 | 3  |  |  |  |  |
| 1.3  | 论文研究内容及组织结构                             | 5  |  |  |  |  |
| 1.4  | 本章小结                                    | 6  |  |  |  |  |
| 第二章  | 相关理论介绍                                  | 7  |  |  |  |  |
| 2.1  | 机器视觉系统                                  | 7  |  |  |  |  |
|  | 2.1.1 系统构成                              | 7  |  |  |  |  |
|  | 2.1.2 工业应用实例                            | 10 |  |  |  |  |
| 2.2  | 数字图像处理技术                                | 10 |  |  |  |  |
|  | 2.2.1 图像的基本表示方法                         | 10 |  |  |  |  |
|  | 2.2.2 图像的色彩空间类型                         | 12 |  |  |  |  |
|  | 2.2.3 图像的仿射变换                           | 14 |  |  |  |  |
|  | 2.2.4 图像的弹性变换                           | 19 |  |  |  |  |
| 2.3  | 卷积神经网络                                  | 21 |  |  |  |  |
|  | 2.3.1 卷积层                               | 21 |  |  |  |  |
|  | 2.3.2 池化层                               | 22 |  |  |  |  |
|  | 2.3.3 全连接层                              | 23 |  |  |  |  |
| 2.4  | 本章小结                                    | 24 |  |  |  |  |
| 第三章  | 基于工业缺陷特征的图像扩增方法                         | 25 |  |  |  |  |
| 3.1  | 技术路线与研究过程                               | 25 |  |  |  |  |
| 3.2  | 工业图像采集过程分析                              | 26 |  |  |  |  |
|  | 3.2.1 光源对图像质量的影响                        | 27 |  |  |  |  |
|  | 3.2.2 镜头对图像质量的影响                        | 32 |  |  |  |  |

| vi   |   | 目     | 录  |
|------|---|-------|----|
|      | 3.2.3 相机传感器对图像质量的影响                     |       | 34 |
|      | 3.2.4 相机投影对图像质量的影响                      |       | 36 |
| 3.3  | 工业领域常见缺陷与原因分析                           |       | 36 |
|      | 3.3.1 铝材常见缺陷形态特征与产生原因                   |       | 37 |
|      | 3.3.2 钢材常见缺陷形态特征与产生原因                   |       | 38 |
|      | 3.3.3 工业缺陷形态特征归纳                        |       | 40 |
| 3.4  | 工业图像数据扩增方法                              |       | 42 |
|      | 3.4.1 工业图像采集过程模拟                        |       | 42 |
|      | 3.4.2 工业零件缺陷形态特征模拟                      |       | 48 |
| 3.5  | 工业图像数据扩增方法实现                            |       | 50 |
|      | 3.5.1 模拟工业图像采集过程扩增方法                    |       | 50 |
|      | 3.5.2 模拟工业零件缺陷形态特征扩增方法                  |       | 56 |
| 3.6  | 基于工业特征图像扩增的检测模型增强训练                     |       | 62 |
| 3.7  | 本章小结                                    |       | 63 |
| 第四章  | 扩增数据的准备与校验                              | ••••• | 65 |
| 4.1  | 数据准备与处理                                 |       | 65 |
|      | 4.1.1 基础数据集准备                           |       | 65 |
|      | 4.1.2 环境搭建与目标检测模型选择                     |       | 65 |
|      | 4.1.3 数据集标注格式转换                         |       | 66 |
|      | 4.1.4 扩增数据的准备                           |       | 67 |
| 4.2  | 扩增数据有效性检验                               |       | 68 |
|      | 4.2.1 研究问题                              |       | 68 |
|      | 4.2.2 实验对象                              |       | 69 |
|      | 4.2.3 实验设计                              |       | 69 |
|      | 4.2.4 指标评价                              |       | 71 |
| 4.3  | 实验结果与分析                                 |       | 71 |
| 4.4  | 本章小结                                    |       | 77 |
| 第五章  | 总结与展望                                   | ••••• | 79 |
| 5.1  | 本文研究内容总结                                |       | 79 |
| 5.2  | 本文工作内容局限与展望                             |       | 80 |
| 致 说  | 射 · · · · · · · · · · · · · · · · · · · | ••••• | 81 |
| 参考文南 | 武 · · · · · · · · · · · · · · · · · · · |       | 83 |

# 插图清单

| 1-1  | 工业数据四大难点              | 2  |
|------|-----------------------|----|
| 1-2  | 图像数据扩增方法              | 3  |
| 1-3  | 随机擦除与 cutout 对比       | 4  |
| 2-1  | 机器视觉系统                | 8  |
| 2-2  | 二值图像的表示方式             | 11 |
| 2-3  | 灰度图像的表示方式             | 11 |
| 2-4  | 彩色图像的表示方式             | 12 |
| 2-5  | RGB 图像和与之对应的 HSV 图像分量 | 13 |
| 2-6  | 图像的旋转数学原理             | 15 |
| 2-7  | 图像旋转示例图               | 16 |
| 2-8  | 图像缩放的表示               | 17 |
| 2-9  | 图像缩放示例图               | 17 |
| 2-10 | 图像水平翻转示例图             | 18 |
| 2-11 | 图像垂直翻转示例图             | 19 |
| 2-12 | 图像裁剪示例图               | 20 |
| 2-13 | 卷积神经网络示意图             | 21 |
| 2-14 | 卷积层示意图                | 22 |
| 2-15 | 池化层示意图                | 23 |
| 2-16 | 全连接层示意图               | 23 |
| 3-1  | 技术路线与研究过程示意图          | 25 |
| 3-2  | 机器视觉系统                | 27 |
| 3-3  | 利用补色光源进行照射            | 29 |
| 3-4  | 不同光源下成像效果             | 30 |
| 3-5  | 使用镜面反射前后对比            | 30 |
| 3-6  | 使用漫反射前后对比             | 31 |
| 3-7  | 使用透射前后对比              | 31 |

| 3-8  | 反射光照明与背光照明对比           | 31 |
|------|------------------------|----|
| 3-9  | 反射光与同轴入射对比             | 32 |
| 3-10 | 低角度照明与高角度照明对比          | 32 |
| 3-11 | 工业镜头成像原理               | 33 |
| 3-12 | 光圈与景深的影响关系             | 34 |
| 3-13 | 帧率过低导致的图像抖动            | 35 |
| 3-14 | 采集铝片样本时发生高光溢出          | 35 |
| 3-15 | 原始图像与噪声图像              | 35 |
| 3-16 | 相机的投影映射原理              | 36 |
| 3-17 | 相机投影倾斜角度变化前后对比         | 37 |
| 3-18 | 铝箔零件上的压伤缺陷             | 37 |
| 3-19 | 铝箔零件上的变形缺陷             | 38 |
| 3-20 | 钢材零件上的开裂缺陷             | 38 |
| 3-21 | 钢材零件上的氧化铁皮压入缺陷         | 39 |
| 3-22 | 钢材零件上的斑块缺陷             | 39 |
| 3-23 | 钢材零件上的麻点缺陷             | 39 |
| 3-24 | 钢材零件上的表面夹杂缺陷           | 40 |
| 3-25 | 钢材零件上的划痕缺陷             | 40 |
| 3-26 | 输入图像的拍摄条件示意图           | 43 |
| 3-27 | 缺陷擦除与融合示意图             | 50 |
| 3-28 | 缩放与方位变换过程示意图           | 50 |
| 3-29 | 基于工业图像采集过程的扩增方法流程图     | 51 |
| 3-30 | 标注变换与修正流程图             | 52 |
| 3-31 | 基于工业零件缺陷形态特征的扩增方法流程图   | 57 |
| 3-32 | 基于图像数据扩增的检测优化方法流程图     | 63 |
| 4-1  | 通过工业图像采集过程模拟扩增方法扩增图像   | 68 |
| 4-2  | 通过工业零件缺陷形态特征模拟扩增方法扩增图像 | 68 |
| 4-3  | 实验一基本设计思路              | 69 |
| 4-4  | 实验二基本设计思路              | 70 |
| 4-5  | 实验三基本设计思路              | 70 |
| 4-6  | 图像分辨率变化后对检测模型的影响       | 72 |
| 4-7  | 图像视角变化后对检测模型的影响        | 73 |
|      |                        |    |

| 4-8  | 图像色彩变化后对检测模型的影响     | 74 |
|------|---------------------|----|
| 4-9  | 缺陷损伤程度变化后对检测模型的影响   | 75 |
| 4-10 | )缺陷大小或长短变化后对检测模型的影响 | 75 |
| 4-11 | 缺陷位置变化后对检测模型的影响     | 76 |

# 附表清单

| 1-1  | 目标检测工业场景与自然场景对比                  | 2  |
|------|----------------------------------|----|
| 3-1  | 不同光源的优缺点                         | 27 |
| 3-2  | 工业图像采集过程中影响图像质量因素归纳表             | 42 |
| 3-3  | 影响工业零件缺陷形态特征因素归纳表                | 48 |
| 3-4  | 工业图像采集过程模拟扩增方法参数控制               | 51 |
| 3-5  | 工业缺陷形态特征模拟扩增方法参数控制               | 57 |
| 4 1  |                                  |    |
| 4-1  | 系统软硬件坏境衣                         | 66 |
| 4-2  | 扩增模型参数归纳表                        | 67 |
| 4-3  | 图像分辨率降低对检测模型 mAP 的影响             | 72 |
| 4-4  | 图像视角变化对检测模型 mAP 的影响              | 72 |
| 4-5  | 图像色彩变化对模型 mAP 的影响                | 73 |
| 4-6  | 缺陷损伤程度变化对模型 mAP 的影响              | 74 |
| 4-7  | 缺陷大小或长短变化对模型 mAP 的影响             | 75 |
| 4-8  | 缺陷位置变化对模型 mAP 的影响                | 76 |
| 4-9  | 缺陷图像变化前后模型识别率 mAP 值显著性检验         | 77 |
| 4-10 | 模型 mAP 在工业扩增方法、无扩增方法和通用扩增方法下对比 … | 77 |

# 第一章 绪论

# 1.1 研究背景及意义

随着国内制造业的大力发展,现代汽车、家电、食品罐头加工等行业对金属产品需求量越来越大,根据产业调研网发布的报告 [1] 来看,从 2017 年到 2020 年,金属产品销量呈现出持续增长的趋势,说明金属制造行业的市场规模在不断扩大。同样根据金属表面处理检验规范 [2] 来看,产品加工行业对铝箔、钢材等金属板材的外观和质量要求也越来越高,由于金属加工的工作环境普遍恶劣,制造过程速度较快,无法及时筛选残次品,因此金属的表面质量也无法保证。微小的表面缺陷 [3] 会严重影响金属制品的质量和外观,因此金属材料表面缺陷检测变得十分重要。

目前大部分工厂仍采用人工视觉检测来识别残次品或进行金属表面缺陷检测,人工检测受限于视觉疲劳、人工成本高、目检效率低等问题,在高速生产线上这些问题最终导致产品质量下降和资源浪费。因此,对于高品质金属零件生产工艺的要求,传统的人工视觉检测远远不能满足。为了解决人工视觉检测方法带来的问题,基于机器视觉的智能缺陷检测方法在缺陷检测和分类方面逐渐取代人工视觉检测方法,成为缺陷检测[4]的主要方法,但是实际生产过程中能提供的缺陷数据量太少,不能够支撑机器学习算法,从而导致实际工业生产中应用较少。

对于工业缺陷检测,其场景过于分散,不能达到统一标准的行业规范,缺 陷数据标注困难,并且理解数据需要复杂的过程。深度学习在目标检测方面已 经取得了良好的效果,但在工业生产环境下的金属零件表面缺陷检测还略显不 足,表1-1将工业场景与自然场景进行对比,工业场景下的缺陷目标较为微弱 [5],检测效果与缺陷的形态、颜色等有关,通常还存在有一些例如黑色纹理背 景上出现的黑色缺陷,以及检测效果受视角影响较大的缺陷等,同样缺陷检测 要求精度指标比较高,绝大多数情况下是不允许出现漏检与误检。

工业场景下的数据,目前面临图1-1的四大难点。工业数据通常多样性不够 [6],这点表现为缺陷种类内特征差异较大。例如划痕的表现形式多种多样,

| 特性 | 自然场景 | 工业场景 |
|----|------|------|
| 尺寸 | 变化大  | 变化小  |
| 形态 | 变化大  | 变化小  |
| 类别 | 类别多  | 类别少  |
| 光照 | 不稳定  | 稳定   |

表 1-1: 目标检测工业场景与自然场景对比

不同颜色、视角、长短、大小等,种种差异导致缺陷的表现形式不一样,因此 导致的问题是,真实的工业环境很难收集到所有形态的缺陷样本,因此模型在 测试数据集上的表现并没有达到预期标准,小样本训练数据集对模型的性能有 明显的影响;同时数据存在不平衡性,收集海量工业数据但有缺陷的数据非常 少,很多缺陷占比非常小。在工业场景采集样本的过程中会产生大量脏数据, 标注混乱。以上种种问题最终会导致模型训练的样本数量少,进而模型容易过 度拟合,大大影响缺陷检测模型的精度与分类效果,容易造成错检和漏检等 问题。



图 1-1: 工业数据四大难点

因此,将机器学习应用于实际的工业检测中,必须解决机器学习中训练阶段缺陷样本数量不足和多样化程度低等问题。相比于 ImageNet 数据集 [7] 中庞大数量的样本数据,在实际的工业生产环境下,行业所能提供的金属表面缺陷

样本数据量很少,许多工厂企业仅仅只能提供几张或几十张金属表面缺陷的样本,数据量不足是工业表面缺陷检测 [8] 中的一个重要问题。图像扩增是解决数据量不足的方法,但是通用的数据扩增方法在工业生产下应用效果一般,没有涉及工业生产环境变化与领域特性,因此迫切需要探索工业领域的图像扩增方法。

本文将工业缺陷特征、机器视觉系统与深度学习领域的图像扩增技术相结 合,在宏观上使用图像处理技术来模拟工业图像采集过程,在微观上模拟不同 工业缺陷形态特征来扩增工业图像数据,最终设计出一种基于工业缺陷特征的 图像扩增方法,通过本方法可以灵活动态地自动生成模拟工业生产环境扩增 数据。本方法能够降低数据采集成本,与工业领域技术结合,扩增数据覆盖面 广,在生产环境下更具有适用性和专业性。通过本方法对模型增强训练可以有 效地解决在工业环境下由于训练样本数据不足导致的目标检测模型过拟合、检 测精度低、识别率低与分类效果不好的问题。

# 1.2 国内外研究现状

图像数据扩增是指通过对原始图像数据进行一些有规则的变换与处理,进 而创造生成出更多与真实环境相接近的数据。主要用来丰富图像数据的多样 性、增加图像数据规模并且提高模型的泛化能力。

数据扩增的主要方法分为图像处理方法和深度学习方法[9],如图1-2所示。 传统的图像处理方法又可分为单样本扩增和多样本扩增,单样本扩增常见的方



图 1-2: 图像数据扩增方法

法包括平移、缩放、镜像、裁剪、模糊、亮度变换、饱和度变换、颜色变换、

灰度变换等。多样本扩增主要对图像进行融合处理,例如裁剪缺陷并融合到图像的不同位置,确保融合后生成的图像更接近真实图像。多样本扩增还需要一些融合的算法,例如泊松融合算法和与边缘融合算法等,其中最经典的是mixup,Zhang[10]等人提出了mixup,将两张图像进行一定比例上的融合,从而扩展了图像的多样性。随机擦除方法是指在图像中随机选定一块矩形区域,在区域内用随机像素值对其进行覆盖。此方法可以轻松地置入于大部分卷积神经网络模型中,能够使模型学习更多与图像有相关性特征的描述,从而防止模型偏向于过拟合的状态,使得模型关注整张图像,而不只是图像其中的一部分。Devries等人提出了cutout[11],对固定大小区域进行随机遮挡来提高模型的泛化能力。随机擦除和 cutout 方法的图像扩增效果如图1-3所示。



图 1-3: 随机擦除与 cutout 对比

深度学习方法通常使用 GAN 和 VAE 等生成模型, GAN 可以用来通过噪声数据来生成真实数据,但是生成的数据特征信息有限。Mehdi Mirza 等人提出了 Conditional GAN[12],在这篇论文中,作者提出的卷积神经网络模型不仅必须在一定条件下完成,而且还必须更加接近真实。由于它的模型包含了许多约束,因此使得这种根据约束条件扩增得到的数据有着非常强的效果。Jianmin Bao 等人提出了 CVAE-GAN[13] 概率模型,在这个生成式对抗网络中,判别器能够区分真实样本与虚假样本,使得生成器能够根据判别器提供的梯度来进行学习,使其能够在图像扩增方面取得良好效果,但在生成位置类别样本时仍然存在一些不足并需要继续去探索。

现阶段还有很多第三方开源数据扩增项目如 imgaug、Albumentation[14]、

Augmentor[15] 等辅助进行图像扩增,以及数据标注工具 labelImg 等。

上述扩增方法都是通用扩增方法,并未涉及相关领域,在自动驾驶、人脸 识别、人脸合成等自然环境下使用较为广泛,但工业环境与自然环境相比较为 复杂,这些方法不能均适用于复杂的工业生成环境下。在目前工业领域中,何 志勇等人提出一种面向外观缺陷视觉检测的数据集扩增方法 [16],该方法利用 生成对抗网络进行数据扩增,基于对抗式生成网络的数据扩增在一定程度上本 身就需要一定数量的数据集,不能满足极小样本数据集的条件,并且扩增得到 的数据并不能丰富其表面特征,对位置类缺陷并不能起到效果。刘孝保等人提 出一种基于超分辨率特征融合的扩增方法 [17],通过泊松融合超分辨率特征与 无缺陷样本的方式实现样本扩增,方法仅仅基于图像分辨率一种特征来进行数 据扩增,并未考虑更多的特征。以上这些方法均是通过多样化缺陷特征实现数 据扩增,都未考虑复杂的工业生产环境、不同的工业场景、复杂的机器视觉系 统、图像采集过程与不同工业缺陷形态特征,缺少对实际工业生产环境的模 拟。

# 1.3 论文研究内容及组织结构

本文将机器视觉系统、工业缺陷形态特征、深度学习领域的图像数据扩增 技术和计算机视觉领域的图像处理技术相结合,基于工业缺陷特征,通过分析 宏观上的工业图像采集过程与微观上的工业缺陷形态特征来设计并实现两种工 业图像数据扩增方法,模拟生成真实工业生产环境下的图像数据来测试深度学 习检测模型并且提升模型的性能。本文的主要结构如下:

第一章为绪论部分,主要介绍论文的研究背景与意义,图像数据扩增技术 的研究现状和存在的问题。最后简要阐述主要的技术路线、研究方法、研究工 作、研究内容与论文结构安排。

第二章为论文所需要的相关技术和理论介绍,主要内容为:机器视觉系统 的构成与应用实例,图像处理的相关技术和理论依据,最后介绍深度学习卷积 神经网络相关方面的知识,简要阐述论文中所用到的技术。

第三章主要介绍基于图像采集过程与缺陷形态特征模拟的工业图像扩增方法。首先介绍扩增方法的技术路线,其次对工业图像采集过程与工业领域常见缺陷及原因进行多角度分析与归纳,通过设计不同的变换模型对不同工业环境与缺陷形态特征进行模拟,并详细说明方法的流程与实现,最后设计并实现扩

增数据对深度学习目标检测模型增强训练的方法。

第四章主要介绍基础数据准备与扩增图像数据集验证实验。首先准备基础 数据集、扩增数据集与深度学习环境,其次对扩增数据有效性检验进行实验设 计与指标评价,最后对实验结果进行分析。

第五章主要对方法有效性验证实验,进行总结并分析。分析实验数据并对 实验的结果进行总结,指出实验中的问题。最后简要阐述论文的局限性与对未 来工作的展望。

# 1.4 本章小结

本章为绪论部分,首先介绍了本论文的研究背景与意义,分析实际工业场 景下面临的数据样本量不足的几大难题。其次介绍了图像数据扩增技术的发 展、研究现状和存在的问题。最后简要概括了研究内容与结构安排。

# 第二章 相关理论介绍

# 2.1 机器视觉系统

机器视觉系统 [18] 能够将图像转换为数字信号,是一种图像采集设备,其中包括 CMOS 和 CCD。图像采集设备将图像的颜色、像素和亮度等信号传输 到图像处理系统,将这些信息转换为数字信号,转换后的数字信号经过计算机 运算处理,对图像进行卷积运算并提取图像表面特征,最后通过机器视觉系统 对其进行判断,根据判断的结果控制现场设备,使得现场设备能够正确地检测 金属表面缺陷。

机器视觉系统的最大特点是在金属材料加工生产线上操作具有较高的自动 化程度与灵活性 [19]。人工视觉检测难以满足危险的生产环境,因此在金属材 料生产线上不适合人工视觉检测,通常用机器视觉代替人工视觉;同样,在大 型工业生产过程中,在外界加工设备的嘈杂环境下,会一定程度地干扰人工视 觉检测的质量并且影响视检工人的能动性,进而导致检测效率相对较低,机器 视觉代替人工视觉可以提高生产效率、产品质量与自动化程度。此外,机器视 觉比人工视觉更容易进行整合、存储与分析 [20]。机器视觉系统能够更快更好 地检测和识别生产线上的产品,以质量和数量的保障来完成生产任务。

## 2.1.1 系统构成

完整的机器视觉系统由图2-1四大组件组成,其中图像采集卡仅作为储存 设备,图像质量主要受到光源、镜头、相机组成的图像采集设备影响。

一、照明

照明 [21] 是影响图像质量的关键因素之一,自然环境下光源、照射方法和 照明方式将直接影响图像的质量。自然界中光源分为可见光和不可见光,可见 光包含白炽灯、汞灯和荧光灯,其缺点是光能不稳定。根据照明方法 [22] 可分 为不同光源,按照光的照射方向可分为背光照明与同方向光照明;按照光源形 式可分为结构光照明和频闪光照明。其中,背光照明是将被捕捉物体位于光源 和相机镜头之间,被捕捉物体的背景为光源主要照射部分,可以增强图像的对



图 2-1: 机器视觉系统

比度。同方向光照明是指光源和相机镜头位于被捕捉物体的同一侧,被捕捉物体为光源主要照射部分,可以增强图像的亮度。结构光照明是指将均匀线性光源投射到被捕捉物体上,可以一定程度展现出被测物体的三维效果。频闪光照明是指将频率较高的光照射到被捕捉物体上。

二、镜头

工业镜头对于图像质量的影响 [23] 必须考虑以下因素:镜头的放大倍数, 所导致视场大小,即成像区域的大小;镜头的工作距离,相机镜头与目标物体 之间的距离;相机成像传感器件的尺寸。这些因素都对于图像质量有着不可忽 视的影响。

#### 三、相机

工业相机在机器视觉系统中作为处理光信号的组件,能够将光信号转换成 可由电子设备处理的有序电信号,然后由传感器对电信号进行处理、分析和识 别。工业相机参数和传感器类型不仅能直接决定图像分辨率大小,并且会影响 图像的整体质量。

(1) 相机分类

工业相机的分类方法主要有以下四种。

1. CCD 相机与 CMOS 相机: CCD 相机 [24] 的图象传感器使用的是 CCD 感光 芯片,其中 CCD 是电荷耦合器件的缩写,它能够将光能转化为电荷,随后 将电荷进行储存与转移。CMOS 相机 [25] 与 CCD 相机相比,其图像传感器

使用 CMOS 感光芯片,尽管 CMOS 相机能够灵活采集图像,但在制造过程 中和 CCD 存在一定的差距,限制了其图像处理能力,在降低噪声和灵敏度 方面不如 CCD 相机,因此,CMOS 相机对图像质量有更重要的影响。

- 黑白相机与彩色相机:黑白相机输出为单通道灰度图像,彩色相机输出为 RGB 三通道彩色图像。彩色相机的感光度远低于黑白相机,由于彩色相 机的像素只能存储光色一种灰度值,彩色相机的分辨率要比黑白相机低得 多。因此彩色相机面对黑白单色物体时,输出图像的精度与分辨率要低于 黑白相机。
- 3. 面阵相机与线阵相机:面阵相机是 CCD 光敏芯片上的点阵呈平面状分布的相机,其图像是二维的图像。线阵相机是 CCD 光敏芯片上带有线性点阵呈行状分布的相机,其图像是一维的图像。线阵相机采集到的图像,呈线状分布,线状分布较长,为了获得完整的二维图像,通常需要移动被捕捉物体或移动线阵相机进行拍摄。线阵相机将多次捕捉到的图像进行合成,得到完整的高分辨率图像,提高图像质量的同时还需要配置大光圈的镜头、选择高亮度的光源来适配其工业特性。
- 4. 模拟相机与数字相机:模拟相机将信号转换成模拟电压信号,然后将其传输到图像采集卡进行进一步的图像处理。数字信号相机将信号从图像传感器转换为数字信号,数字信号直接被计算机识别并进行处理。由于数字相机以数字信号的方式进行传输,信号受到干扰损失较小,因此在噪声处理上数字信号相机要优于模拟信号相机,所采集到的图像更为真实。
  - (2) 相机基本参数

相机有七大基本参数:

- 1. 分辨率: 用来描述相机传感器有效像素的分布。
- 像素深度:图像的大小由像素深度和分辨率共同决定。像素深度的增加可以增强图像检测的精度,但降低了机器视觉系统的速度并且增加了系统集成的难度。
- 3. 最大帧率:相机捕捉图像、收集图像、处理图像的速度,每秒能够处理图像的最大帧数。
- 4. 曝光方式:不同的曝光方法影响输出图像的质量,曝光方式可以是一致的,也可以是不一致的。同样曝光也可以分为帧曝光和行滚动曝光。
- 5. **像素大小**:相机捕捉到的物体表面大小由像素大小和分辨率决定,工业相 机的像素越小,输出图像质量越低。

9

- 6. 光谱响应特性: 指图像像素传感器对不同光谱的光源反应的灵敏度。
- 6噪比:噪声指的是在图像捕捉过程中不期望被收集到的信号。相机的信
   噪比定义为信号与噪音的比值,图像质量在一定程度上可以用信噪比反
   映,图像质量随着相机信噪比的提升而提高。

#### 2.1.2 工业应用实例

机器视觉系统在真实工业下应用实例如下 [26]:

#### 一、金属板表面自动控伤系统

金属板的表面质量要求是非常高的,比如大型电力变压器线圈和柔性扁平 电缆无线电盖的质量。最初的人工视觉控制检测方法不仅受到人类视觉主观因 素的影响,而且由于人工视觉可能发生疲劳,因此缺陷可能会被忽视并受到新 的表面划伤。金属板表面损伤自动控制系统通过机器视觉、金属表面缺陷自动 检测系统,可在生产过程中快速准确地检测金属表面缺陷。

#### 二、汽车车身检测系统

英国罗孚汽车公司对 800 系列车体尺寸有 100% 的精度的要求,因此公司 采用了工业在线测量控制系统的机器视觉系统,获得了很好的效果。该系统由 62 个测量单位组成,每个单位包括一台激光和一台 CCD 相机,共同用于确定 车体中需要测量尺寸精度的 288 个点。

## 2.2 数字图像处理技术

#### 2.2.1 图像的基本表示方法

图像的基本表示方法 [27] 有三种:

(1) 二值图像: 只包含黑色与白色,在计算机中,图像由矩阵来表示和 处理,例如,图2-2(a) 它是一个字母A的图像,计算机在处理图像的时候, 会先把它分成小方块,每个小方块是一个独立的处理单元,叫做像素。接下 来,计算机将白色区域的像素置为"1",将黑色区域的像素置为"0",便于 计算机的存储和处理。根据上述处理方法,图2-2(a)中的字母A在计算机内 的存储形式如图2-2(b)所示。上面的图像比较简单,图像中只有黑白两种不 同的颜色,因此可以只用 2bit 来表示。

(2) 灰度图像:二值图像每个像素只需要 2bit 就能表示,简单又方便,



图 2-2: 二值图像的表示方式

但由于只以黑白的形式存在,因此图像显示比较单一,展示不出细节。如果要 刻画出图像的细节,则需要有更多的颜色来表示。例如,图2-3(a)中的 lena 图像是灰度图像,其每个像素值使用 0 和 1 以外的数值来反映图像的不同的颜 色,能够丰富图像的细节。

计算机会用 0 到 255 的灰度区间来表示灰度值。其中数值 255 代表纯白,数值 0 则代表纯黑,纯白到纯黑的不同层次灰度则由其余数值表示。图 2-3中的图像需要用矩阵表示,每一行和每一列的值都在 [0,255] 之间。例如,图 2-3(b)是 lena 图像在数字表示形式下的灰度图像。在灰度空间下,灰度值 255 用于表示白色,灰度值 0 用于表示黑色。此时,二值图像像素中只有 0 和 255 两种数值,没有其他灰度值的像素。



(a)lena 图像的灰度图像

(b)计算机内 lena 图像的储存形式

图 2-3: 灰度图像的表示方式

(3)彩色图像: 与二值图像和灰度图像相比, 生活中常见的是彩色图

像,可以展示出图像更多的细节信息。

神经生理学实验表明,在人类的视觉感受器下,可以感知三种不同的颜 色:红色、绿色和蓝色。在自然界中,常见的彩色光都是由红黄绿三基色按一 定比例混合而成。

在 RGB 颜色空间中,共有三个通道,即 R (红色)通道、G (绿色)通道 和 B (蓝色)通道,其像素取值范围在 [0,255],彩色图像通过组合三通道像 素值能够表示不同颜色。例如,对于图 2-4左的彩色图像,根据 RGB 颜色空间 可表示为为右侧的 R 通道、G 通道、B 通道三个通道。其中,每个通道可作为 一个单独的灰度图像来表示。彩色图像左侧白色块中的面积对应右侧三个通道 的三个矩阵,白色块左上角顶点的 RGB 值为 (205,89,68)。



图 2-4: 彩色图像的表示方式

### 2.2.2 图像的色彩空间类型

颜色空间是一种对色彩进行编码的方法。图像的颜色空间 [28] 主要有以下 几类:

#### (1) RGB 色彩空间

RGB 代表红绿蓝,其三原色组合可以涵盖人类视觉能够感知到的所有颜色,是目前使用最为广泛的色彩空间。R、G、B 三个通道颜色的像素值范围都是 [0,255],那么每个像素中混合的三种颜色就可以形成 1677216 种不同的颜色。

#### (2) CMY 色彩空间

CMY 代表青色、品红色、黄色,是一种颜色混合模式。CMY 和 RGB 的 区别在于 RGB 是一种加法混合模式,每种颜色的成分越多,颜色越亮。CMY 是一种颜色生成方法,可以减少视觉颜色识别所需的反射光,因此也称为减色 法。CMY 和 RGB 的转换公式 [29] 为:

$$C = 255 - R$$
  
 $M = 255 - G$  (2-1)  
 $Y = 255 - B$ 

#### (3) HSV 色彩空间

HSV 是一种数字图像模型,是色调、饱和度、亮度的缩写。HSV 的亮度分量在图像中不能决定颜色信息,只有色调和饱和度分量能够决定图像的颜色信息。HSV 色彩模型在这些特点下非常适用于颜色特征的检测和分析。颜色模型见图2-5,其中三大参数:



图 2-5: RGB 图像和与之对应的 HSV 图像分量

(a) 色调 H (Hue): 色调的大小与光的波长有关,不同波长的光颜色也不同,不同颜色的光有着不同的色调。

(b) 饱和度 S (Saturation): 饱和度与图像的鲜艳程度成正比。

(c) 亮度 V (Value): 亮度对应图像的灰度值,灰度值的大小就代表着 图像颜色亮度的大小。

RGB 转换为 HSV 的公式 [30] 为:

$$H = \begin{cases} \theta & B \le G \\ 360 - \theta & B > G \end{cases}$$
(2-2)

$$\theta = \arccos\left\{\frac{\frac{1}{2}[(R-G) + (R-B)]}{\left[(R-G)^2 + (R-B)(G-B)\right]^{\frac{1}{2}}}\right\}$$
(2-3)

$$S = 1 - \frac{3}{(R+G+B)}[\min(R,G,B)]$$
(2-4)

$$V = \frac{1}{3}(R + G + B)$$
(2-5)

## 2.2.3 图像的仿射变换

仿射变换 [31],是空间线性变换或多个不同空间线性变换的组合。仿射变换后保持平直性与平行性,但不能保证线段的长度和线段之间的夹角不变。

假设有向量空间 *m* = (*x*, *y*) 与向量空间 *n* = (*x*', *y*'),向量空间从 *m* 到 *n* 的变换 *n* = *A* \* *m* + *b*,整理得到:

$$x' = A_{00} * x + A_{01} * y + b_0$$
  
y' = A\_{10} \* x + A\_{11} \* y + b\_1 (2-6)

将等式变换为矩阵的形式,得到仿射矩阵  $M = \begin{bmatrix} A_{00} & A_{01} & b_0 \\ A_{10} & A_{11} & b_1 \end{bmatrix}$ 。不同的 M 有着不同的二维仿射变换效果,常见的图像仿射变换有以下四种:

(1) 图像旋转

图像旋转同样也可以使用矩阵变换来表示,图像的旋转数学原理如图2-6所示。设点 P(x,y) 为点  $P_0(x_0,y_0)$  逆时针旋转 $\theta$ 角后的对应点,那么旋转前点  $P_0(x_0,y_0)$  的坐标是:

$$\begin{cases} x_0 = r \cos \phi \\ y_0 = r \sin \phi \end{cases}$$
(2-7)



图 2-6: 图像的旋转数学原理

由图 2-6得出旋转  $\theta$  角后点 P(x, y) 的坐标:

$$\begin{cases} x = r\cos(\phi + \theta) = r\cos\phi\cos\theta - r\sin\phi\sin\theta = x_0\cos\theta - y_0\sin\theta\\ y = r\sin(\phi + \theta) = r\cos\phi\sin\theta + r\sin\phi\cos\theta = x_0\sin\theta + y_0\cos\theta \end{cases}$$
(2-8)

转化为矩阵的表达形式,对于矩阵变换:

$$\begin{vmatrix} x \\ y \end{vmatrix} = \begin{bmatrix} \cos(\theta) & -\sin(\theta) \\ \sin(\theta) & \cos(\theta) \end{bmatrix} \times \begin{bmatrix} x_0 \\ y_0 \end{bmatrix} + \begin{bmatrix} 0 \\ 0 \end{bmatrix}$$
(2-9)

得到变换矩阵 M:

$$M = \begin{vmatrix} \cos(\theta) & -\sin(\theta) & 0\\ \sin(\theta) & \cos(\theta) & 0 \end{vmatrix}$$
(2-10)

图像旋转示例图如图 2-7。

#### (2) 图像缩放

原始图像中选择哪些像素值去映射以及如何确定所选像素值的权重是图像 缩放的两个关键问题。设点 *P*<sub>0</sub>(*x*<sub>0</sub>, *y*<sub>0</sub>)缩放后的对应点为 *P*(*x*, *y*)。

图像每个像素的位置都可以被视为二维平面上的向量。图像缩放本质上是 在 x 轴和 y 轴方向上缩放每个像素的位置向量,也就是对像素 x 轴和 y 轴方向 的坐标值进行缩放。缩放前后两点 *P*<sub>0</sub>(*x*<sub>0</sub>, *y*<sub>0</sub>) 和 *P*(*x*, *y*)间的关系:

$$\begin{cases} x = f_x x_0 \\ y = f_y y_0 \end{cases}$$
(2-11)



(a)字母R图像绕中心点旋转45度



(b)lena图像绕中心点旋转45度

图 2-7: 图像旋转示例图

转化为矩阵的表达形式,对于矩阵变换:

$$\begin{bmatrix} x \\ y \end{bmatrix} = \begin{bmatrix} f_x & 0 \\ 0 & f_y \end{bmatrix} \times \begin{bmatrix} x_0 \\ y_0 \end{bmatrix} + \begin{bmatrix} 0 \\ 0 \end{bmatrix}$$
(2-12)

对图像的伸缩变换的变换矩阵 M 为:

$$M = \begin{vmatrix} f_x & 0 & 0 \\ 0 & f_y & 0 \end{vmatrix}$$
(2-13)

通过上面的变换矩阵,可以将原图像中的每一个像素向前映射到新图像中对应的像素。同样可以通过变换矩阵 *M* 对图像进行缩放,但由图2-8(a)中坐标的空间变化中,可以看到图像放大后,出现很多空白区域。原始图像中 x 和 y 的值是自然数,但是 x 和 y 乘以图像缩放的比例因子可能会得到浮点数,这个结果无法在图像中表示,因此计算机会自动向上取整,这样就会造成如图2-8(a)所示的白色空洞区域,因此需要使用插值法 [32] 通过空白像素周围像素点信息来进行预测,进而来填补这些空白区域。图像缩放示例图如图2-9。

#### (3) 图像翻转

图像翻转可以分为水平与垂直翻转。图像的水平翻转以图像二分法的垂直



图 2-9: 图像缩放示例图

中心为轴来变换图像的左半部和右半部,图像的垂直翻转以图像二分法的水平中心为轴来变换图像的上半部和下半部。

(a) 对于水平翻转,设点 P(x, y) 为点  $P_0(x_0, y_0)$  水平翻转后的对应点。水

平翻转前后两点 P<sub>0</sub>(x<sub>0</sub>, y<sub>0</sub>) 和 P(x, y) 间的关系为:

$$\begin{cases} x = -x_0 + width \\ y = y_0 \end{cases}$$
(2-14)

水平镜像的矩阵变换为:

$$\begin{vmatrix} x_0 \\ y_0 \end{vmatrix} = \begin{bmatrix} -1 & 0 \\ 0 & 1 \end{bmatrix} \times \begin{bmatrix} x \\ y \end{bmatrix} + \begin{bmatrix} \text{width} \\ 0 \end{bmatrix}$$
(2-15)

得到变换矩阵 M:

$$M = \begin{vmatrix} -1 & 0 & \text{width} \\ 0 & 1 & 0 \end{vmatrix}$$
 (2-16)

图像水平镜像示例图如图 2-10。



图 2-10: 图像水平翻转示例图

(b) 对于垂直翻转, 设点 *P*(*x*,*y*) 为点 *P*<sub>0</sub>(*x*<sub>0</sub>,*y*<sub>0</sub>) 垂直翻转后的对应点。垂 直翻转前后两点 *P*<sub>0</sub>(*x*<sub>0</sub>,*y*<sub>0</sub>) 和 *P*(*x*,*y*) 间的关系为:

$$\begin{cases} x = x_0 \\ y = -y_0 + \text{ height} \end{cases}$$
(2-17)

垂直镜像的矩阵变换为:

$$\begin{bmatrix} x_0 \\ y_0 \end{bmatrix} = \begin{bmatrix} 1 & 0 \\ 0 & -1 \end{bmatrix} \times \begin{bmatrix} x \\ y \end{bmatrix} + \begin{bmatrix} 0 \\ \text{height} \end{bmatrix}$$
(2-18)

得到变换矩阵 M:

$$M = \begin{vmatrix} 1 & 0 & 0 \\ 0 & -1 & \text{height} \end{vmatrix}$$
(2-19)

图像垂直镜像示例图如图2-11。



图 2-11: 图像垂直翻转示例图

#### (4) 图像裁剪

图像裁剪是指根据图像新的尺寸大小信息来剪切原始图像的一部分来生成 新的图像。图像裁剪通常按照需要指定坐标进行裁剪,方法较为简单,图像裁 剪示例图如图2-12。

# 2.2.4 图像的弹性变换

弹性形变算法最先是由 Patrice 等人在 2003 年的 ICDAR 上 [33] 提出的,最 开始它被应用于 mnist 手写数字识别数据集,这是一种非常常见的图像处理方



(b)lena图像裁剪

图 2-12: 图像裁剪示例图

法。基本原理是选择卷积因子对原始图像进行卷积处理来得到弹性变换后的图像,常见的图像弹性变换[34]有以下两种:

#### (1) 对比度偏移

对比度偏移技术可以灵活地控制输出图像不同分布的对比效果,一定程度 上来调整感兴趣的区域,进而提高图像质量。将灰度值映射到更大的灰度空间 公式如下:

$$I(x, y) = \frac{I(x, y) - \text{Imin}}{\text{Imax} - \text{Imin}} (MAX - MIN) + MIN$$
(2-20)

Imin 代表原图像最小灰度值, Imax 代表原图像最大灰度值, MIN 代表将要映 射到新的灰度空间的最小灰度值, MAX 代表将要映射到新的灰度空间的最大灰 度值。除上述方法外,还有直方图平移法进行对比度平移,公式如下:

$$I(x, y) = I(x, y) + \text{ offset}$$
(2-21)

offset 代表为灰度偏移量增量。offset 为正数时,图像亮度变亮; offset 为负数时,图像亮度变暗。

(2) 亮度偏移

亮度偏移同样作为图像弹性变换的关键技术之一,它在数学运算上属于点
运算。点运算的特点是仅根据输入像素值和整体图像信息计算相应输出图像的 像素值。最常用的亮度偏移点运算的数学公式是像素值乘以一个常数再加上一 个常数,公式如下:

$$g(x) = a * f(x) + b$$
 (2-22)

其中 *f*(*x*) 代表原图像的像素值大小, *g*(*x*) 代表输出图像的像素值大小。参数 *a*(*a* > 0) 叫做亮度的增益效果,参数 *b* 叫做亮度的偏移量,两者共同作用来控制图像的亮度。

# 2.3 卷积神经网络

卷积神经网络 [35] 是具有代表性的深度学习算法之一,作为前馈式神经网络,其具有深度结构和卷积运算。

21 世纪以后,由于计算设备的进步与深度学习理论的发展,神经网络的发展速度加快,不仅在计算机视觉中得到了广泛的应用,而且在自然语言处理等领域也得到了广泛的应用。一个卷积神经网络包含卷积层、池化层和全连接层,卷积神经网络示意图如图2-13。



图 2-13: 卷积神经网络示意图

# 2.3.1 卷积层

卷积层将原始图像通过特征卷积系数或过滤器将每个像素元素进行卷积, 卷积运算的大致步骤是将图2-14中的两个 3x3 的矩阵进行相乘后再相加。



图 2-14: 卷积层示意图

以图 2-14(a)为例,计算过程为: 0\*0+0\*0+0\*1+0\*1+1\*0+0\* 0+0\*0+0\*1+0\*1=0。计算每个特征矩阵中的信息,最后得到完整的特征 矩阵,如图 2-14(b)。图像在输入上进行多次卷积,每次操作使用不同的过 滤器或卷积因子会输出不同的特征图。与其他神经网络一样,卷积的输出最后 将通过激活函数。

每个卷积过滤器的步长大小通常为1,由此可知过滤器随着每个步长大小 逐像素进行滑动。过滤器在输入上滑动的间隔随着步长的增加而增加,因此会 导致单元之间的重叠变得更少。由于特征图的大小总是小于输入大小,因此必 须采取一些防止特征图逐渐缩小的措施,在输入参数周围添加零值像素,这样 最终得到的特征图就不会缩小,这样不仅可以保持卷积后的空间大小,还可以 提高性能,保证适当的步长和内核的输入尺寸。

# 2.3.2 池化层

池化层位于卷积层之后,加入池化层后减少了网络模型的训练时间,并且 一定程度上控制了模型的过度拟合。在池化层中,最常见的池类型是最大池, 它能够在每个移动窗口中占据一个最大值,前提是这些窗口的大小必须在计算 前指定,最大池能够在保留重要信息的同时仍然能够减小特征图的大小,池化 层示意图如图2-15。



图 2-15: 池化层示意图

# 2.3.3 全连接层

根据卷积神经网络表征学习的观点,卷积层和池化层网络可以从输入数据 中提取特性,而整个全连接层本身不具备特征提取能力,而是将提取的特征进 行线性输出,将输出的结果展平,然后连接到最基本的神经网络,全连接层示 意图如图2-16。



图 2-16: 全连接层示意图

# 2.4 本章小结

本章主要介绍了本文所用到的相关技术、概念和理论基础。首先介绍了机 器视觉系统,整个系统的构成与工业应用实例,为图像采集过程分析提供重要 的支撑。其次介绍了数字图像处理的相关技术,主要包括图像的表示和图像变 换的基本方法,这些技术理论为本文数据扩增方法及其实现提供主要支撑。最 后介绍了深度学习过程中的卷积神经网络知识,并简要介绍了卷积神经网络的 结构,这些理论知识为扩增图像有效性的检验提供了重要支撑。以这些理论知 识为基础,本方法可以结构化分析设计与实现基于图像采集过程与缺陷形态特 征模拟的工业图像扩增方法并对方法进行实验结果分析与扩增数据检验。

# 第三章 基于工业缺陷特征的图像 扩增方法

# 3.1 技术路线与研究过程

本章主要研究以下三方面内容:首先是基于工业特征的图像数据扩增方法,用于工业领域下目标检测模型小样本训练过拟合问题;其次是将此扩增方法用于工业领域下目标检测模型精度的提升;最后是对扩增数据集做有效性校验并对比本文不同方法对目标检测模型的优化效果。技术路线与研究过程如图3-1所示。



图 3-1: 技术路线与研究过程示意图

对于工业缺陷特征分析,本文分为宏观角度与微观角度上的特征分析,宏 观角度即从零件缺陷图像在工业相机整个采集过程中所发生变化来进行分析, 微观角度即从零件具体缺陷形态特征来进行分析。

对于工业图像采集过程的分析,本文通过视角控制来模拟工业相机采样时 成像的镜头角度变换,对内部传感器光路与相机姿态参数分析来模拟图像在工 业镜头下的空间几何变换;通过色彩控制来模拟工业相机图像采集过程中环境 变化(明暗度,亮度,曝光度,背光)以及相机内部具体参数的设置;通过分 辨率控制来模拟工业相机通过不同参数设置与不同传感器缺点而造成的分辨率 低的情况。

对于工业领域常见缺陷与作用机理分析,本文通过对缺陷类别进行提取并 分析作用机理,对工业零件缺陷形态特征进行分类与归纳,对缺陷特征的多样 性分析后,可以通过改变缺陷的损伤程度、大小、长短、方向与方位来模拟不 同缺陷形态特征。

通过上述分析可以设计并实现基于工业缺陷特征的图像扩增方法,对缺陷 零件原始数据集进行扩增来模拟不同的工业环境与缺陷形态特征,还原真实工 业场景得到大量数据集,通过扩增数据集对深度学习目标检测模型进行增强训 练来提升工业零件缺陷检测模型的精度。

同样对于扩增数据集的有效性校验设计了实验。通过对验证数据集扩增来 模拟不同工业环境与缺陷形态特征,输入至深度学习目标检测模型来分析不同 环境模拟下的工业缺陷图像与不同形态缺陷图像对于检测模型精度的影响。同 时对使用扩增方法优化后的目标检测模型与未使用扩增方法的原模型在识别率 mAP指标上进行对比,来验证检测模型的优化效果、扩增数据集的有效性与本 方法在工业生产环境下的适用性。

# 3.2 工业图像采集过程分析

典型的机器视觉系统主要由采集光源、工业镜头、工业相机、图像采集 卡、图像处理与输出单元等硬件组成,整个机器视觉系统如图3-2所示。本节 的主要任务是根据光源、镜头、工业相机传感器以及相机外姿态参数来分析工 业图像采集过程相对于人的目标认知过程,图像发生了何种变换导致检测模型 精度低。



### 3.2.1 光源对图像质量的影响

图像采集所需要的相机光源 [36] 的在一定程度上会影响图像数据输入的质量。对于不同的工业环境与条件,不同的光源和不同的照明方式与方法对图像的输入有着不同的变换效果。常见的几种可见光源与优缺点见表 3-1。

| 光源类别  | 优点   |                |  |
|-------|------|----------------|--|
| LED 灯 | 响应快  | 颜色表示较差         |  |
| 萤光灯   | 分散性好 | 响应慢,亮度暗        |  |
| 光纤卤素灯 | 亮度高  | 反应缓慢,亮度和色温变化不大 |  |

表 3-1: 不同光源的优缺点

关于光源对画质的影响,本文从光线颜色、照明方式与照明方法三个方面 来分析:首先是光线颜色或波长,对于工业零件和背景材质的颜色不同,使用 不同颜色的光源对图像的影响也不同;其次是照射方式,不同的照射方式下 零件和缺陷也有着不同的特征,例如零件是否存在损坏、缺陷的形状、零件上 缺陷的有无、零件表面为平面还是曲面或者是不平表面等。针对以上特点,使 用不同的照明方法,如镜面反射光、漫反射光和透射光,会在图像质量和效果 上显示出很大的差异;最后是照明方法:根据零件的不同工况和设置条件,不 同形状和尺寸的光源具有不同的图像检测范围,如环形光、低角度光、同轴光 等。

### 3.2.1.1 光线颜色

在工业图像采集过程中,光源颜色和补色的选择尤为重要。光源的选择可 以基于同色照明或互补色照明。使用彩色相机时,通常使用白光。如果使用 黑白相机,则需要使用补色或波长进行检测。在色相环上,黄色和紫色相差 180°,红色和绿色相差180°,蓝色和橙色相差180°,因此当红光照射到绿色物 体上时,会产生黑色,当红光照射到红色物体时,会产生红色,用黑白相机拍 摄后,同色为白色,补色为黑色。互补色的计算需要将 RGB 空间转换为 HSV 空间 [37]:

$$R' = R/255$$
  
 $G' = G/255$   
 $B' = B/255$   
 $Cmax = max (R', G', B')$   
 $Cmin = min (R', G', B')$   
 $\Delta = Cmax - Cmin$   
(3-1)

计算色调 Hue:

$$H = \begin{cases} 0^{\circ} \qquad \Delta = 0\\ 60^{\circ} \times \left(\frac{G' - B'}{\Delta} \mod 6\right) \quad , C_{\max} = R'\\ 60^{\circ} \times \left(\frac{B' - R'}{\Delta} + 2\right) \quad , C_{\max} = G'\\ 60^{\circ} \times \left(\frac{R' - G'}{\Delta} + 4\right) \quad , C_{\max} = B' \end{cases}$$
(3-2)

计算饱和度 Saturation:

$$S = \begin{cases} 0 , C_{\max} = 0\\ \frac{\Delta}{C_{\max}} , C_{\max} \neq 0 \end{cases}$$
(3-3)

计算亮度 Value:

$$V = C \max \tag{3-4}$$

取色调值相反值,饱和度和亮度保持不变。计算后再转换为 RGB 空间:

$$C = V \times S$$
  

$$X = C \times (1 - |(H/60^\circ) \mod 2 - 1|)$$
  

$$m = V - C$$
  
(3-5)

$$(R', G', B') = \begin{cases} (C, X, 0) &, 0^{\circ} \le H < 60^{\circ} \\ (X, C, 0) &, 60^{\circ} \le H < 120^{\circ} \\ (0, C, X) &, 120^{\circ} \le H < 180^{\circ} \\ (0, X, C) &, 180^{\circ} \le H < 240^{\circ} \\ (X, 0, C) &, 240^{\circ} \le H < 300^{\circ} \\ (C, 0, X) &, 300^{\circ} \le H < 360^{\circ} \end{cases}$$
(3-6)

 $(R, G, B) = ((R' + m) \times 255, (G' + m) \times 255, (B' + m) \times 255)$ (3-7)

通过实验 [38] 发现,当用互补色光照射时,会产生类似黑色的效果。使用 与被测物体同样的颜色光源照射图像会使图像亮度变亮,例如红色光源照射红 色物体会使其变亮。相反,使用与被测物体相对颜色光源会使图像亮度变暗, 例如红色光源照射蓝色物体会使其变暗,蓝光光源照射亮黄色物体会变成黑 色。如图 3-3所示,用蓝色 LED 检测红色零件时,只有红色会变成黑色,这样 对比度更亮,检测效果稳定。当红色 LED 用于检测红色零件时,红色区域会更 亮。类比工业图像处理,对于三通道图像,可以通过改变图像的 RGB 色调、 亮度和饱和度来模拟不同颜色光源的效果。对于灰度图像,可以通过改变图像 的亮度来模拟零件在同色光源和补色光源下的效果。



图 3-3: 利用补色光源进行照射

不同波长的光线具有不同的颜色、散射率和透射率等特性。红外光线的穿透能力强,适用于检测透光率较低的物体,如检测棕色口服液玻璃瓶表面中的杂质。紫外光线对物体表面的缺陷很灵敏,适用于检测对比度不够明显环境下的的物体,如检测食用油瓶上的文字细节。如图3-4所示,在需要透过塑料膜拍摄金属薄片上细节特征的过程中,透射率越高的红色光源相比蓝色光源能展现出更高的对比度。可以通过加强图像的亮度和改变饱和度来模拟红紫外线这种穿透性强、对缺陷细节反映较好的光源。



图 3-4: 不同光源下成像效果

### 3.2.1.2 照射方式

根据特征(损伤、形状、有无等)和表面(平面、曲面、有无凹凸),零件的形状和检验的目的,所呈现的图像效果是不同的。

LED 的照明种类大致为:

1. 镜面反射型:镜头接收到的光来自被摄物体的镜面反射。

2. 漫反射型:避开被摄物体的镜面反射光,接收整体均匀的光线。

3. 透射型:光源透过背景,通常用于检测轮廓。

图 3-5通过镜面反射能够增强平整的金属表面与金属表面上有起伏不平机 器雕刻字符部分之间的反差,能够发现图像整体亮度偏高,从而可以更好的提 取缺陷的轮廓;图 3-6通过漫反射防止产生强烈视觉上的光晕,能够增强杂质 与零件表面之间的反差,同时发现图像整体饱和度偏低,能够拉平不同区域亮 度不同的问题;图 3-7通过来自零件背面的透射光使零件杂质的黑色阴影展现 出来,发现图像整体亮度与饱和度都偏高,能够清晰的展现缺陷轮廓。可以通 过对工业图像的亮度、对比度、RGB 三通道值进行变换来模拟三种照射方式下 所呈现的图像。



图 3-5: 使用镜面反射前后对比



图 3-6: 使用漫反射前后对比



图 3-7: 使用透射前后对比

### 3.2.1.3 照明方法

按照照明的方法可分为五类,背光照射可以使图像轮廓清晰,但不能显示 图像的具体细节,如图3-8所示,可以通过对缺陷部分的亮度与饱和度降低, 对缺陷以外的部分亮度与饱和度提升来模拟背光照射的效果。



图 3-8: 反射光照明与背光照明对比

同轴光的照射可以改善不同角度的表面特征,改善表面纹理,例如表面的 划痕与凹槽,并且能够减少阴影。常用于划痕、金属、玻璃等光滑表面缺陷检 测;硅片、晶体破损检测;金属零件冲压字符检测;电路板焊点、符号检测; 集成电路的引脚线检测等,如图3-9所示,可以通过对缺陷部分的亮度与饱和 度提升,对缺陷以外部分的亮度与饱和度降低来模拟同轴光照射的效果。

高角度照射对于图像质量的影响是会使图像整体变的明亮,通常被用于表 面无反射光的零件;低角度照明对于图像质量的影响是会加强零件表面的白色



图 3-9: 反射光与同轴入射对比

特征,能够突出被测零件的轮廓和零件表面杂质与粗糙度的变化;低角度照明 对于图像质量的影响是会使图像整体效果更加柔和,通常用于检测曲面物体。 高角度照明与低角度照明对图像质量的影响对比见图3-10,两种照明效果明显 相反,可以使缺损部分和缺损外部分的色相反转,同时增加或减少其亮度和饱 和度。



(a) 低角度照明

(b)高角度照明.csdn.net/vishuihand

图 3-10: 低角度照明与高角度照明对比

### 3.2.2 镜头对图像质量的影响

镜头 [39] 能够改变光线传播的路径,主要作用是配合图像传感器将图像表示为数字形式,同时镜头的各项参数也会影响被捕捉图像的整体质量,是系统中不可或缺的一部分。

### 3.2.2.1 镜头原理与参数

工业相机的镜头由多个镜头和一个光圈或聚焦装置组成。通过工业相机镜 头可以获得明亮清晰的图像,焦距是镜头的参数之一。相机镜头成像原理如 图 3-11所示。



图 3-11: 工业镜头成像原理

工业镜头对于图像质量的影响,一般从分辨率、锐度和景深等几个实际参数来判断:

- 1. 分辨率:指的是镜头清晰区分图像细节与场景环境的能力。
- 景深:镜头在真实图像平面上,可以捕捉到清晰图像的景物空间所处的深度范围。
- 3. 明锐度:指的是在整体图像中最亮的部分与最暗部分之间的对比度。
- 4. 相对孔径:入射光孔直径 D 与焦距 f 之比。

根据图像成像过程中需要的视场、焦距等参数,可以计算出参数之间的换 算公式:

$$PMAG = \frac{Sensor Size (mm)}{Field of View (mm)} = \frac{H_i}{H_0}$$
(3-8)

$$f = \frac{WD * PMAG}{1 + PMAG}$$
(3-9)

$$LE = Di - f = PMAG * f \qquad (3-10)$$

其中 WD 为物距, Firld of View 为相机视野, Sensor Size 为景深,  $H_0$  为视野高度,  $H_i$  为传感器大小, f 为镜头的焦距, LE 为镜头像平面的扩充距离, PMAG 为镜头放大倍数。公式能够证明镜头各项参数之间的影响关系:

- 1. **焦距大小的影响情况:** 焦距越小,景深越大,失真越大,光晕越大,像差 边缘照度越低;
- 光圈大小的影响情况:更高的光圈,更高的图像亮度,更低的景深,更高的分辨率,影响关系如图 3-12所示。

对于光圈大小的改变,可以通过变换图像的亮度来进行模拟,光圈大小同 样会改变景深,也可以通过改变图像的分辨率来模拟景深对图像质量的影响; 对于焦距大小的改变,通过改变图像的分辨率来模拟焦距对图像质量的影响, 对于明锐度,可以通过提高图像的对比度来模拟不同工业相机明锐度的变化。



图 3-12: 光圈与景深的影响关系

### 3.2.3 相机传感器对图像质量的影响

相机传感器能够将光信号转化为电信号。CCD 传感器 [40] 和 CMOS 传感器内部不同的原理与特性会在一定程度上影响所捕捉图像的质量与分辨率等。

### 3.2.3.1 CCD 传感器

CCD 传感器基本工作原理是:一个像素的光电二极管接收光源,然后将光转化为电荷并积累,所有接收单元上的累积负载同时转移到垂直 CCD 位移寄存器,通过垂直 CCD 位移寄存器的负载转移到水平 CCD 位移寄存器,最后从水平 CCD 位移寄存器发送的负载转换为电压,在放大器中放大,并发送到相机进行信号处理。

CCD 图像采集后,按列依次输出信号,然后进行信号放大等处理。采 集的图像质量好,噪声低,灵敏度好,但缺点也很明显,首先不灵活的窗口 (ROI)和低帧率的采集会导致抖动的图像变得模糊和难以识别,如图 3-13所 示,可以通过降低图像分辨率来模拟 CCD 产生画面抖动的缺点;其次会产生 高光溢出现象,例如太阳光直射的明亮像素会发生电荷溢出现象,而背景边缘 的较暗像素过度曝光。高光溢出不仅会失去图像中的细节,而且还会增加紫色 边缘的可能性,如图 3-14所示,可以通过提高图像的亮度,隐藏零件边缘细节 来模拟 CCD 产生高光溢出的缺点。



图 3-13: 帧率过低导致的图像抖动



(a)彩色图像

(b)黑白图像

图 3-14: 采集铝片样本时发生高光溢出

# 3.2.3.2 CMOS 传感器

CMOS 传感器与 CCD 传感器不同。CMOS 传感器将每个像素上的电荷转 化为电压,这带来了许多独特的优点和缺点。

CMOS 相机与 CCD 相机相比,其具有灵活的画面开窗,可以有效提高帧 率,帧率会更高,但图像灵敏度差,图像噪声多,基本是由于光电基本性质导 致的噪声,如图 3-15所示,可以通过对图像随机添加噪声来模拟 CMOS 最明显的缺点。



图 3-15: 原始图像与噪声图像

### 3.2.4 相机投影对图像质量的影响

相机通过一定的倾斜角度拍摄到物体后,得到的图像会有一定程度的变形。如果将拍摄的图像投影到被摄物体的背景平面上,则相当于将相机垂直放置在背景平面上,从而获得透视变换后图像的实际形状。这种投影映射相当于将捕获的图像投影到另一个平面上。这种映射投影方法也称为透视变换,原理如图3-16所示。



图 3-16: 相机的投影映射原理

透视变换会改变被捕捉物体图像的尺寸和形状,以矩形和圆形为例,经过 透视变换,矩形的四个顶点会以两两相反的方向移动,虽然矩形边界的直线经 过变换后仍然为直线,但是平行的两条边经过变换后会相交,最终经过透视变 换后在图像中的展现形式为矩形会变形为梯形;同样如图3-17可以看出,圆形 经过透视变换四周的环带曲率会发生一定的变化,在图像中展现形式为一侧半 径变大一侧半径变小,随即圆形变形为椭圆形,并且面积比也出现变化。透视 变换在一定程度上会使图像失真并且影响深度学习目标检测模型的正确判断。 通过利用相机内姿态参数与外姿态参数 [41] 来模拟相机在三维空间中通过绕 x、y、z 轴旋转,对图像重新投影来获取经过相机视角变换后得到的新图像。

# 3.3 工业领域常见缺陷与原因分析

工业领域常见缺陷本文以铝材 [42] 与钢材 [43] 为例,两种材质的金属有较好的代表性,铝材数据集来自于真实企业,钢材数据集来自东北大学开源数据集。其中铝材上选取两种比较常见的缺陷,钢材上选取六种比较常见的缺陷。

3.3 工业领域常见缺陷与原因分析



(a)相机投影 倾斜角较小时

(b)相机投影 倾斜角较大时

图 3-17: 相机投影倾斜角度变化前后对比

# 3.3.1 铝材常见缺陷形态特征与产生原因

1. 压伤形态特征:表面呈明显的长条状或点状,颜色为黑色,如图 3-18所示。



图 3-18: 铝箔零件上的压伤缺陷

**产生原因:** 1) 轧制环境中设备清洁条件不好; 2) 轧制过程中使用的润滑剂 不干净; 3) 在制作过程中铝箔表面有非金属杂质压入; 4) 铝箔内部组织不 纯,含有非金属杂质。

2. 变形(波浪)形态特征:由于变形不均匀,铝箔表面局部不平整。在边缘的波浪成为边缘波,在中间的波浪称为中间波,两者结合称为合成波,既不在中间也不在边缘的称为二肋波,如图3-19所示。
 产生原因: 1)材质不好,材质差异超标; 2)压力调节不平衡,辊型控制不合理; 3)压力分布不合理。



图 3-19: 铝箔零件上的变形缺陷

### 3.3.2 钢材常见缺陷形态特征与产生原因

1. **开裂形态特征**: 在钢表面,裂纹通常是线性的,有些是 Y 形的,大部分方向与轧制方向一致,但也有横向或其他方向,如图 3-20所示。



图 3-20:钢材零件上的开裂缺陷

产生原因: 1) 轧制时加热不均匀,各个部分延伸方向不一致; 2) 轧制时 温度过低,导致塑性变差; 3) 冷却不当,导致塑性变差; 4) 轧制时存在缩 孔、夹杂产生裂纹。

- 氧化铁皮压入形态特征:表面以点状、块状或条状的形式出现,颜色为灰 黑色或红棕色,分布区域或大或小,如图 3-20所示。
   产生原因: 1)加热条件产生一定的影响,加热时间越长,加热温度越高, 表面产生的氧化铁皮铁垢粘结; 2)水压不足,导致出水口堵塞; 3) 镍合金 元素含量高。
- 3. 斑块形态特征: 在钢材表面形成疤痕。其大小和形状非常不规则,常以钉 子、鳞片、块状、舌状等形状不规则地分布在钢表面,如图 3-22所示。

#### 3.3 工业领域常见缺陷与原因分析





图 3-22: 钢材零件上的斑块缺陷

产生原因: 1) 由于钢坯未清洗干净, 轧制后钢表面仍残留原有的斑块。

4. 麻点形态特征:钢材表面有连续或周期的局部性出现的不平整的粗糙表面,如图 3-23所示。



图 3-23:钢材零件上的麻点缺陷

**产生原因:** 1) 轧制时冷却不足,造成严重表面磨损; 2) 轧制的材质较差导 致硬度过低或不均匀; 3) 钢材使用时间过长,表面磨损严重。

5. 表面夹杂形态特征: 颜色呈黑灰色或白色形状以块状、点状或长条状不规则出现, 如图 3-23 所示。



图 3-24:钢材零件上的表面夹杂缺陷

产生原因: 1)表面杂质在轧制后仍然遗留在钢材表面中; 2)对钢材高温加热时有泥沙、硅质物等非金属材料落在钢材表面,导致轧制时这些非金属材料被压入钢材表面。

**划痕形态特征:**一般呈线状,长度分布由肉眼可见到几毫米不等,划痕呈 间断分布或连续分布,如图3-25所示。



图 3-25:钢材零件上的划痕缺陷

**产生原因:** 1) 钢材表面不光滑,有一定程度磨损; 2) 钢材表面不光滑,有 划痕; 3) 钢材表面在运输过程中被划伤。

# 3.3.3 工业缺陷形态特征归纳

通过缺陷的归类去分析工业缺陷形态特征,本文给出三种归纳方法:

(1) 按照缺陷所属金属表面特征

#### 3.3 工业领域常见缺陷与原因分析

- 纹理缺陷:缺陷破坏金属纹理,缺陷出现的位置、大小、形状都不固定, 缺陷上一般会出现划痕、麻点等;
- 2. 结构缺陷: 与金属结构有关, 缺陷出现的位置和形状都相对固定;
- 3. 其他缺陷:一些红外热成像,超声波成像等。可能无法用肉眼正确地识别 出缺陷位置与大小。

对于此类纹理缺陷可以按照延伸的长度与方向进行变换,从而得到不同纹 理方向下或逆纹理方向下的缺陷,模拟不同纹理延伸方向下形态特征的变化; 对于结构缺陷出现位置形状相对固定,改变缺陷的位置从而得到不同结构的缺 陷形态。

#### (2) 按照正常样本建模的角度

- 1. 纹理缺陷:一般指重复结构,有颗粒较大的缺陷;
- 2. 非纹理对齐缺陷: 与结构相关, 但缺陷可以与金属自身的纹理方向对齐;
- 3. 非纹理无法对齐缺陷: 缺陷无法与金属自身的纹理方向对齐。

对于纹理缺陷可以按照延伸的长度进行变换,从而得到同纹理方向下的缺陷,模拟同方向纹理延伸方向下形态特征的变化;对于非纹理缺陷可以按照延伸的方向进行变换,从而得到不同纹理方向下的缺陷,模拟不同方向纹理延伸方向下形态特征的变化。

#### (3) 按照缺陷在金属表面展现形态

- 加法:缺陷在金属表面呈突出状产生,如金属表面出现脏污、异物或粘连 其他非金属;
- 减法:缺陷在金属表面呈陷入状产生,如金属表现不完整、有划痕或产生 损坏;
- 替换:金属表面平整但是仍然具有与金属表面颜色或材质不一致的缺陷, 如表面产生混色或异色,有杂质混入金属表面;
- 变形:缺陷不以金属表面的形式所呈现,一般是以金属受到外力作用后导 致结构发生变化,如金属板材弯折或产生褶皱。

对于在金属表面不同展现形态的缺陷,通过改变缺陷的方位角、镜像方 向、方位与大小来进行变换,模拟突出、陷入、变形状的缺陷。

# 3.4 工业图像数据扩增方法

根据上一节的综合分析,本文把工业图像扩增方法分为两类:工业图像采 集过程模拟扩增方法与工业零件缺陷形态特征模拟扩增方法。

### 3.4.1 工业图像采集过程模拟

在工业图像采集过程中,图像质量会受到光源、相机姿态参数、工业镜头参数、工业相机传感器等多因素的影响。关于这些影响对于图像质量的改变,本文对采集过程中所属的组件模块以及模块下具体原因进行细分,对不同模块影响图像质量的因素与对应到图像处理下的参数进行归纳总结,详细归纳表见表3-2。得到视角变换模型、色彩变换模型、分辨率变换模型。

| 图像采集过程<br>所属模块 | 详细分类   | 影响图像质量的因素       | 变换模型    | 参数控制    |
|----------------|--------|-----------------|---------|---------|
| 光源             | 照射方式   | 图像亮度发生变化        | 色彩变换模型  | 亮度      |
|                | 照明方法   | 图像对比度发生变化       | 色彩变换模型  | 对比度     |
|                | 光线颜色   | 图像 RGB 三通道色调值变化 | 色彩变换模型  | RGB 色调  |
| 工业镜头           | 焦距大小   | 图像分辨率变化         | 分辨率变换模型 | 分辨率     |
|                | 明锐度    | 图像对比度变化         | 色彩变换模型  | 对比度     |
|                | 景深     | 图像边缘宽度不等区域分辨率变化 | 分辨率变换模型 | 分辨率     |
|                | 光圈大小   | 图像亮度变化          | 色彩变换模型  | 亮度      |
| 相机姿态           | 航向角    | 三维场景下图像按 z 轴旋转  | 视角变换模型  | X轴旋转角度  |
|                | 横滚角    | 三维场景下图像按 x 轴旋转  | 视角变换模型  | Y 轴旋转角度 |
|                | 俯仰角    | 三维场景下图像按 y 轴旋转  | 视角变换模型  | Z轴旋转角度  |
|                | 相机高度   | 图像一定比例放大或缩小     | 视角变换模型  | 相机调整高度  |
| 相机传感器          | CMOS   | 今至片面面封动 喜来淡山    | 分辨率变换模型 | 分辨率     |
|                | CINIOS |                 | /色彩变换模型 | /亮度     |
|                | CCD    | 图像感光差           | 色彩变换模型  | 亮度      |

表 3-2: 工业图像采集过程中影响图像质量因素归纳表

### 3.4.1.1 视角变换模型

根据上一节所述,在工业相机图像采集过程中,由于相机视角的改变, 会使图像发生透视变换,导致零件缺陷部位面积比与形状发生改变。相机 的外部参数变化导致相机视角与倾斜角的变化。相机的外部参数通常由 航向角 *α*,俯仰角 *β*,横滚角 *γ* 三个姿态参数与 *x*<sup>e</sup>,*y*<sup>e</sup>,*z*<sup>e</sup> 三个位置参数共同 表示物体方位模型。根据图 3-26可以确定相机正常捕捉姿态的外部参数为 $\alpha_0 = 0^\circ, \beta_0 = 0^\circ, \gamma_0 = 0^\circ, x_0^c = y_0^c = 0, z_0^c = H_\circ$ 



图 3-26: 输入图像的拍摄条件示意图

视角变换模型将三个姿态参数的变换具象化为工业图像按照图 3-26绕三个 坐标轴 x、y、z 来旋转重新变换得到。在讨论过程中,本文使用了 OpenGL[44] 中定义的右手坐标系。

对于俯仰角与横滚角,当俯仰角与横滚角变化时,投影的倾斜角也发生变 化,导致图像一定程度上的失真,如块状缺陷由于角度变换会变成条状、圆斑 缺陷会变换为椭圆状、正方形状的缺陷会变换为梯形、面积比相应发生变化。 对于航向角,当航向角变换时,缺陷图像的位置会发生改变,同样缺陷的标注 也会因此发生改变。

当俯仰角变化时,图像相当于在三维场景中,点 P(x,y,z)绕 x 轴旋转β角 得到点 P'(x',y',z')。因为图像是绕 x 轴旋转,因此 x 轴坐标不变, y 轴和 z 轴组 成的 yoz 平面进行二维平面旋转。二维平面旋转中 y 轴相当于 x 轴, z 轴相当 于 y 轴,于是有:

$$x' = x$$
  

$$y' = y \cos\beta - z \sin\beta$$
  

$$z' = y \sin\beta + z \cos\beta$$
  
(3-11)

将等式用矩阵来表示:

$$\begin{bmatrix} x' \\ y' \\ z' \\ 1 \end{bmatrix} = \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & \cos\beta & -\sin\beta & 0 \\ 0 & \sin\beta & \cos\beta & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix} * \begin{bmatrix} x \\ y \\ z \\ 1 \end{bmatrix}$$
(3-12)

当横滚角变化时,图像相当于在三维场景中,点 P(x,y,z)绕 y 轴旋转 γ 角 得到点 P'(x',y',z')。图像绕 y 轴的旋转,因此 y 轴坐标不变,z 轴相当于二维 平面旋转中的 x 轴, x 轴相当于二维平面旋转的 y 轴,由 zox 组成的平面进行 二维平面上的旋转,同样有:

$$x' = z \sin \gamma + x \cos \gamma$$
  

$$y' = y$$
  

$$z' = z \cos \gamma - x \sin \gamma$$
  
(3-13)

将等式用矩阵来表示:

$$\begin{bmatrix} x'\\y'\\z'\\1 \end{bmatrix} = \begin{bmatrix} \cos\gamma & 0 & \sin\gamma & 0\\0 & 1 & 0 & 0\\-\sin\gamma & 0 & \cos\gamma & 0\\0 & 0 & 0 & 1 \end{bmatrix} * \begin{bmatrix} x\\y\\z\\1 \end{bmatrix}$$
(3-14)

当航向角变化时,图像相当于在三维场景中,点 P(x,y,z)绕 z 轴旋转 α 角 得到点 P'(x',y',z')。与前两种变换类似,同样有:

$$x' = x \cos \alpha - y \sin \alpha$$
  

$$y' = x \sin \alpha + y \cos \alpha$$
 (3-15)  

$$z' = z$$

将等式用矩阵来表示:

-

$$\begin{bmatrix} x' \\ y' \\ z' \\ 1 \end{bmatrix} = \begin{bmatrix} \cos \alpha & -\sin \alpha & 0 & 0 \\ \sin \alpha & \cos \alpha & 0 & 0 \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix} * \begin{bmatrix} x \\ y \\ z \\ 1 \end{bmatrix}$$
(3-16)

将三个变换矩阵组合为一个变换矩阵:

$$M = M_{z}(\alpha)M_{x}(\theta)M_{y}(\gamma)$$

$$= \begin{bmatrix} \cos\gamma\cos\alpha & \sin\theta\sin\gamma\cos\alpha - \cos\theta\sin\alpha & \cos\theta\sin\gamma\cos\alpha + \sin\theta\sin\alpha\\ \cos\gamma\sin\alpha & \sin\psi\sin\gamma\sin\alpha + \cos\theta\cos\alpha & \cos\theta\sin\gamma\sin\alpha - \sin\theta\cos\alpha\\ -\sin\gamma & \sin\theta\cos\gamma & \cos\theta\cos\gamma \end{bmatrix}$$
(3-17)

计算相机相对于投影平面 xoy 高度 H:

$$H = \frac{\sqrt{w^2 + h^2}}{2\tan\frac{fov}{2}}$$
(3-18)

其中 w 为图像宽度, h 为图像高度, fov 为相机可视角角度。通过上述矩阵变 化后重新生成图像的四点坐标,对每个坐标进行二维平面上的投影:

$$x_{\text{new}} = \frac{H}{H - z'} \cdot x' + x_0$$
  

$$y_{\text{new}} = \frac{H}{H - z'} \cdot y' + y_0$$
(3-19)

其中 *H* 为相机高度, *x*'、y'、z' 分别为图像在三维坐标系中 x、y、z 轴上的坐标, (x<sub>0</sub>, y<sub>0</sub>)为图像中心点坐标。

对于相机高度,当相机高度变化时,图像的大小会发生变化,根据变换后相机高度 H' 与初始相机高度 H 的比值来对图像进行缩放处理,模型使用双线性插值算法来对图像进行缩放。

视角变换模型适用于视角变化影响较大的缺陷,面积占比较大的缺陷容易 受到视角的影响,如划痕、斑块等外力作用导致的缺陷,这类缺陷在视角变换 之后会导致其面积比发生变换,并且在一定程度发生失真,通过视角变换模型 可以模拟类似面积比发生变换的情况,以及能够一定程度上模拟缺陷因视角变 化后导致的失真现象。

### 3.4.1.2 色彩变换模型

根据上一节所述,在机器视觉系统中,光线的颜色、不同的照射方式、不同的照射方法会改变所采集零件图像的灰度、亮度、明暗度等,会不同程度上影响所检测的零件缺陷的形态特征,工业镜头的参数也会影响图像的对比度与明暗度。

色彩变换模型输入由 RGB 三通道表示的彩色图像 [45]。图像 RGB 三 通道的平均值分别为 *m<sub>r</sub>*, *m<sub>g</sub>*, *m<sub>b</sub>*, 同样的,图形 RGB 三通道标准差分别为 *m<sub>r</sub>*, *m<sub>g</sub>*, *m<sub>b</sub>*。模型通过图像三个颜色通道的平均值来进行亮度变化的控制,通过 图像三个颜色通道的标准差来进行对比度变化的控制,通过三个颜色通道百分 比范围的变化来进行色调变化的控制。如果处理图像为灰度图像,则三个通道 的色调值是相同的值。

R 通道的变换公式为:

$$\begin{cases} m'_r = m_r \cdot (1 + \alpha_l) + h_r \cdot m_r \\ \sigma'_r = \sigma_r \cdot (1 + \alpha_s) \\ r_{new} = \frac{(r - m_r)}{\sigma_r} \cdot \sigma'_r + m'_r \end{cases}$$
(3-20)

G 通道的变换公式为:

$$\begin{cases} m'_g = m_g \cdot (1 + \alpha_l) + h_g \cdot m_g \\ \sigma'_g = \sigma_g \cdot (1 + \alpha_s) \\ g_{new} = \frac{(g - m_g)}{\sigma_g} \cdot \sigma'_g + m'_g \end{cases}$$
(3-21)

B 通道的变换公式为:

$$\begin{cases} m'_{b} = m_{b} \cdot (1 + \alpha_{l}) + h_{b} \cdot m_{b} \\ \sigma'_{b} = \sigma_{b} \cdot (1 + \alpha_{s}) \\ b_{new} = \frac{(b - m_{b})}{\sigma_{b}} \cdot \sigma'_{b} + m'_{b} \end{cases}$$
(3-22)

其中  $\alpha_l \in (-1, +1)$  是图像亮度调节参数,  $\alpha_s \in (-1, +1)$  是图像饱和度调节参数,  $h_r, h_s, h_b \in (-1, +1)$  是图像色调调节参数。

色彩变换模型适用于工业生产环境中光线与光源变化较为频繁的生产环境,不同采集设备使用的工业相机规格也出入较大,大多数为红外相机或黑白相机,同时现场光线由于时效性变化,导致工业生产环境复杂,此类场景均可采用色彩变换模型来模拟不同光源条件,光源变化导致缺陷在亮度、对比度、灰度上的变换,能够更好的适应光源时效性变化,一定程度上能够解决光源对缺陷色彩变换的影响。同样在不同光线颜色对于缺陷的照射下,工业相机所捕捉到的图像也有所不同,因此导致缺陷 RGB 色调会发生变化,对于不同颜色光源下,色彩变换模型对于 RGB 三通道色调的变换也能够解决不同光源颜色对于工业缺陷 RGB 色彩的影响。

#### 3.4.1.3 分辨率变换模型

根据上一节所述,在机器视觉系统中,工业镜头的参数与工业相机图像传 感器的参数同样会影响到图像分辨率的大小,并且不同的相机传感器会导致 捕捉图像时画面抖动,同时在嘈杂的工业生产环境中会导致相机发生抖动, 导致捕捉到的图形一定程度上会变模糊并且失真,造成图像分辨率下降。为 了在分辨率维度模拟多样化的缺陷样本,分辨率变换模型对工业领域缺陷零 件图像进行分辨率变换。首先将图像缩小s倍,缩小后的图像代表的是低分 辨率的图像。其次,将图像放大s倍,恢复到原来的大小。这张图像虽然像素 和原图像一致,但是它的信息完全来自于缩小了s倍的图像,因此本质上是 低分辨率的图像。对于图像的放大与缩小使用双线性插值算法 [46]。双线性差 值算法分别向 x 轴与 y 轴方向进行线性插值,假设缩放后像素值函数 *f* 在点 *P* 的值为 P = (x,y),假设缩放前像素值函数 *f* 在点 *Q* 的值为  $Q_{11} = (x1,y1)$ 、  $Q_{12} = (x1,y2), Q_{21} = (x2,y1) 以及 <math>Q_{22} = (x2,y2)$ 。在 x 轴方向线性插值得到:

$$f(R_1) \approx \frac{x_2 - x}{x_2 - x_1} f(Q_{11}) + \frac{x - x_1}{x_2 - x_1} f(Q_{21}) \quad \text{where} \quad R_1 = (x, y_1)$$

$$f(R_2) \approx \frac{x_2 - x}{x_2 - x_1} f(Q_{12}) + \frac{x - x_1}{x_2 - x_1} f(Q_{22}) \quad \text{where} \quad R_2 = (x, y_2)$$
(3-23)

在 y 轴方向线性插值得到:

$$f(P) \approx \frac{y_2 - y}{y_2 - y_1} f(R_1) + \frac{y - y_1}{y_2 - y_1} f(R_2)$$
(3-24)

最终得到缩放后像素值 f(x,y):

$$f(x,y) \approx \frac{f(Q_{11})}{(x_2 - x_1)(y_2 - y_1)} (x_2 - x)(y_2 - y) + \frac{f(Q_{21})}{(x_2 - x_1)(y_2 - y_1)} (x - x_1)(y_2 - y) + \frac{f(Q_{12})}{(x_2 - x_1)(y_2 - y_1)} (x_2 - x)(y - y_1) + \frac{f(Q_{22})}{(x_2 - x_1)(y_2 - y_1)} (x - x_1)(y - y_1) (3-25)$$

分辨率变换模型适用于不同相机特性与相机传感器特性,大部分情况下传 感器会产生模糊或抖动的现象,尤其是工业生产线由于嘈杂的生产环境,导致 相机产生剧烈抖动,造成工业缺陷图像一定程度上的模糊并且失真,通过分辨 率变换模型可以做到模拟相机抖动或不同相机参数下的变化与影响,能够一定 程度上解决图像分辨率降低的情况。

### 3.4.2 工业零件缺陷形态特征模拟

对于工业零件缺陷形态特征,本文将其缺陷形态特征分为三大类:缺陷类别,缺陷位置,缺陷等级。同样对影响缺陷特征的因素与图像处理参数进行统计与归纳,详细归纳表见表 3-3。

| 工业缺陷<br>特征分类 | 详细分类<br>/参数 | 影响缺陷形态特征的因素       | 变换模型     | 参数控制    |
|--------------|-------------|-------------------|----------|---------|
| 缺陷位置         | 方位          | 缺陷部分图像在整体零件图像上    | 方位本地構刊   | 随机中心坐标  |
|              |             | 发生位置变化            | 力位文沃侠生   | (有效范围内) |
|              | 角度          | 缺陷部分图像自身发生角度变化    | 旋转变换模型   | 缺陷旋转角度  |
|              | 镜像          | 缺陷部分图像横向/纵向发生翻转变化 | 翻转变换模型   | 缺陷翻转类型  |
| 缺陷类别         | 损伤程度        | 缺陷部分图像亭度与对比度发生变化  | 色彩变换模型   | 缺陷亮度    |
|              |             | 或招助力 出            |          | /对比度    |
|              | 长钜/大小       | 缺陷部分图像会有横向        | 缩放变拖横刑   | 缺陷横向拉伸比 |
|              |             | /纵向程度的拉伸变化        | 1程度的拉伸变化 |         |
| 缺陷等级         | 大小          | 缺陷部分图像会发生缩小或放大变化  | 缩放变换模型   | 缺陷缩放倍数  |

表 3-3: 影响工业零件缺陷形态特征因素归纳表

### 3.4.2.1 缺陷类别

根据上一节所述,本文列举了铝箔和钢材中常见的缺陷特征及形成原因, 并对其作用机理进行了归类,主要分为以下几大类:

由于外力作用导致的缺陷,如划痕、压伤、变形等。此类缺陷边缘轮廓灰度值与缺陷附近灰度值有明显差异,但其内部灰度值并无太大差异,且面积较大或作用范围大,通常按照金属延展方向延伸。可以通过对缺陷的轮廓灰度值按公式:

$$f(r) = a * r + b \tag{3-26}$$

进行变换,来模拟不同程度外力作用导致的缺陷。通过参数 *a* 用来控输出制图 像的整体对比度,当 *a* > 1 时表示图形对比度增大,当 *a* < 1 时则表示图像对比 度减小;通过参数 *b* 控制输出图像的整体亮度,当 *b* > 0 时表示增大亮度,当 *b* < 0 时则表示减小亮度。

由于生产过程中掺入异物而导致的缺陷,如生产过程中氧化铁皮轧入、表 面夹杂,内含物等。此类缺陷整体灰度值与附近灰度值有明显差异,较为明显 的是色差对比明显,对图像进行二值化处理效果明显:

$$g(x, y) = \begin{cases} 255, & \text{if } f(x, y) \ge T \\ 0, & \text{else} \end{cases}$$
(3-27)

其中 *T* 为二值化分割的阈值,不同的算法对阈值的处理不同,得到的二值化后的图像也有所不同。缺陷通常为块状或点状,对于此类缺陷本方法可以对整体缺陷进行灰度值变换,来模拟不同异物导致的缺陷,如氧化铁皮、铝皮等。

由于生产过程中零件遇冷或预热导致的缺陷,如开裂等。此类缺陷通常为 线状且为波浪线,延伸有长有短,可以按比例对此类缺陷进行长度上的伸缩变 换,来模拟生产过程中零件遇冷或遇热导致的缺陷。

由于零件自身性质原因导致的如氧化或腐蚀等缺陷,如麻点、斑块等,此 类缺陷分布区域总是聚集在一起,如麻点在钢材上的表现为斑点状在一定区域 内分布,斑块是成片分布,可以对成片的斑点进行噪声处理:

Pout = Pin + X Means + sigma 
$$*G(d)$$
 (3-28)

添加高斯噪声来模拟麻点或斑块的疏密程度,其中公式 G(x, sigma) 决定了高斯 噪声的密度,其中 sigma 为标准方差,X 为平均值,输入的每个像素值大小 Pin 通过高斯采样分布公式 G(d) 最终得到输出像素值大小 Pout。

#### 3.4.2.2 缺陷位置

缺陷在零件上出现的位置同样与缺陷的形态特征有关,不同形态的缺陷, 由于产生原因与作用机理的不同,大多数会产生在变化范围很小的同一区域 内,这也造成位置类缺陷数据多样性不足,缺陷方位变换模型会对缺陷进行随 机移动以达到生成不同方位类缺陷的目的。同样延展性较强的缺陷延展方向也 较为单一,大多数延展类缺陷通常会与零件纹理延展方向保持一致,造成延展 类缺陷数据多样性不足,缺陷旋转变换模型与缺陷翻转变换模型对缺陷方向进 行改变达到生成不同方向缺陷的目的。对于缺陷出现的位置,首先通过缺陷的 标注将缺陷进行擦除,其次通过缺陷的标注将原位置上的缺陷进行裁剪,对缺 陷进行旋转与翻转等处理。通过两种方式处理后,再将裁剪下来的缺陷移动至 零件任意的有效区域,使用泊松融合将经过变换的缺陷图像与擦除缺陷的零件 图像进行融合,具体过程示意图如图 3-27。



### 3.4.2.3 缺陷等级

根据金属检测行业规范,不同的缺陷等级对应缺陷面积与缺陷数量也有所不同,同时缺陷间距也有一定要求。对于不同的缺陷等级,首先将原位置的缺陷按照标注进行裁剪,其次对此位置的缺陷进行擦除,再将裁剪得到的缺陷放大或缩小s倍,使用泊松融合将的缺陷图像与擦除缺陷的零件图像进行融合,具体过程示意图如图3-28。



图 3-28: 缩放与方位变换过程示意图

# 3.5 工业图像数据扩增方法实现

### 3.5.1 模拟工业图像采集过程扩增方法

### 3.5.1.1 数据扩增流程

基于工业图像采集过程模拟的扩增方法流程图如图 3-29所示。扩增过程的 输入是原始的工业图像数据集与缺陷标注数据。

1. 将初始工业图像输入至视角变换模型进行视角和视距维度下的图像处理;



图 3-29: 基于工业图像采集过程的扩增方法流程图

| 变换模型    | 变换参数    | 参数范围           | 参数控制变换效果    |  |
|---------|---------|----------------|-------------|--|
| 色彩变换模型  | 亮度      | [-1,1]         | 大于0增大,小于0减小 |  |
|         | 对比度     | [-1,1]         |             |  |
|         | R通道色调   | [-1,1]         |             |  |
|         | G 通道色调  | [-1,1]         |             |  |
|         | B通道色调   | [-1,1]         |             |  |
| 视角变换模型  | x 轴旋转角度 | [0,70]         |             |  |
|         | y 轴旋转角度 | [0,70]         | 左手坐标系顺时针旋转  |  |
|         | z 轴旋转角度 | [0,360]        |             |  |
|         | 相机高度    | [-1000,1000]mm | 大于0增大,小于0减小 |  |
| 分辨率变换模型 | 分辨率减小倍数 | [0.5,1]        | 呈比例减小       |  |

表 3-4: 工业图像采集过程模拟扩增方法参数控制

- 将上一步处理后的图像数据输入至色彩变换模型进行亮度、饱和度、色调 维度下的图像处理;
- 将上一步处理后的图像数据输入至分辨率变换模型进行分辨率维度的图像 处理;
- 对于三种变换模型的参数控制见表 3-4,方法在每种模型入口前加了开关控制,可以选择是否使用该模型。
- 通过三种变换模型后会生成扩增图像数据集,由于视角变换模型会导致 工业的缺陷标注数据发生变化,因此会根据规则重新生成扩增图像的标 注集。

### 3.5.1.2 数据标注的处理

由于视角变换会导致零件缺陷标注数据(中心坐标与图像尺寸)发生变 化,根据上一小节的坐标变换公式,根据视角变换的角度与视距变换的高度重 新计算缺陷位置的平面坐标。由于平面坐标变换后缺陷标注框会改变位置,因此需要重新计算标注框中心以及尺寸,标注修正流程如图 3-30所示。假设坐标 变换后四点坐标为  $P_1(x_1,y_1)$ ,  $P_2(x_2,y_2)$ ,  $P_3(x_3,y_3)$ ,  $P_4(x_4,y_4)$ ,根据下面公式, k = 1, 2, 3, 4:

$$u_{\min} = \min_{k} (x_k) \quad u_{\max} = \max_{k} (x_k)$$
 (3-29)

$$v_{\min} = \min_{k} (y_k) \quad v_{\max} = \max_{k} (y_k)$$
 (3-30)

重新计算标注左上 *P<sub>min</sub>* 和右下 *P<sub>max</sub>* 两点坐标,根据计算后坐标将图像进行裁剪 后二值化处理,修正标注,使得标注适应缺陷轮廓,并重新计算标注值。



图 3-30: 标注变换与修正流程图

### 3.5.1.3 算法实现

#### (1) 色彩变换模型

色彩变换模型通过改变图像的亮度、对比度、RGB 色调来模拟不同镜头 明锐度参数、镜头光圈大小、照明方法、照明方式、光线颜色与 CCD 图像感 光的影响。对其主要的色彩变换,将不同环境下的图像色彩影响因素抽象成色 彩变换模型并且控制参数来进行调节模拟不同工业生产环境下色彩的变换对 图像影响与作用效果,通过输入原始工业图像数据,对图像进行色彩维度的变 换。色彩变换模型的核心是将图像的像素值在色彩扰动范围内对 RGB 三通道 像素值标准差与平均值进行归一化处理并向前或向后映射到更大的色彩空间, 因此首先计算得到图像 RGB 三通道像素值的均值与方差,具体计算步骤如算法3.1所示。

#### 算法 3.1 计算图像 RGB 三通道像素均值与方差

- 1: Input: image data
- 2: **Onput:** image RGB mean and var
- 3: *Rmean*, *Gmean*, *Bmean* = np.mean(img[:, :, 2])
- 4: *Gmean* = np.mean(img[:, :, 0])
- 5: Bmean = np.mean(img[:, :, 1))
- 6: *Rvar* = np.var(img[:, :, 2])
- 7: *Gvar* = np.var(img[:, :, 0])
- 8: *Bvar* = np.var(img[:, :, 1])
- 9: return Rmean, Gmean, Bmean, Rvar, Gvar, Bvar

将图像每个像素点的像素值通过计算得到的均值与方差进行归一化处理, 控制亮度参数与饱和度参数与 RGB 色调参数,将其进行映射,得到新的像素 值,并填充至新图像中。通过色彩变换来达到图像模拟不同生产环境下光源的 变化从而扩增图像,色彩变换模型的具体实现如算法 3.2所示。

算法 3.2 色彩变换模型

- 1: Input: image data,light,saturation,toneR,toneG,toneB
- 2: **Onput:** image data
- 3: compute Rmean,Gmean,Bmean,Rvar,Gvar,Bvar
- 4: for all i in row do
- 5: **for all** j in col **do**
- 6: R, B, G = img[i, j][2, 1, 0]
- 7: RmeanNew = (1 + light) \* Rmean + toneR \* Rmean
- 8: RvarNew = (1 + saturation) \* Rvar
- 9: Rnew = (R Rmean) / Rvar \* RvarNew + RmeanNew
- 10: imgNew[i, j][2] = Rnew
- 11: GmeanNew = (1 + light) \* Gmean + toneG \* Gmean
- 12: GvarNew = (1 + saturation) \* Gvar
- 13: Gnew = (G Rmean) / Gvar \* GvarNew + GmeanNew
- 14: imgNew[i, j][0] = Gnew
- 15: BmeanNew = (1 + light) \* Bmean + toneB \* Bmean
- 16: BvarNew = (1 + saturation) \* Bvar
- 17: Bnew = (B Bmean) / Bvar \* BvarNew + BmeanNew
- 18: imgNew[i, j][1] = Bnew
- 19: end for
- 20: **end for**
- 21: retrun imgNew

#### (2) 分辨率变换模型

**算法33**双线性插值算法

分辨率变换模型通过改变图像的分辨率来模拟不同镜头焦距、镜头景深与 CMOS 抖动的影响。对其主要的分辨率变换,将不同环境下的图像分辨率影响 因素抽象成分辨率变换模型并且控制参数来进行调节模拟不同工业生产环境 下分辨率的变换对图像影响与作用效果,通过输入原始工业图像数据,对图像 进行分辨率维度的变换。分辨率变换模型的核心是对图像进行缩放处理来得到 低分辨率图像,因此模型使用双线性插值算法将图像像素坐标映射到不同的空 间,双线性插值算法缩放图像的实现步骤如算法所示3.3,在线性空间通过双

| 21.0 |  |  |
|------|--|--|
| 1:   | Input: image data,dstH,dstW  |  |
| 2:   | Onput: image data  |  |
| 3:   | scrH, scrW, channel = img.shape  |  |
| 4:   | img = np.pad(img, ((0, 1), (0, 1), (0, 0)), 'constant')                          |  |
| 5:   | retimg = np.zeros((int(dstH), int(dstW), 3), dtype=np.uint8)                     |  |
| 6:   | for all i in dstH do   |  |
| 7:   | for all j in dstW do   |  |
| 8:   | scrx = (i + 1) * (scrH / dstH) - 1   |  |
| 9:   | scry = (j + 1) * (scrW / dstW) - 1   |  |
| 10:  | x = math.floor(scrx)   |  |
| 11:  | y = math.floor(scry)   |  |
| 12:  | x1 = scrx - x  |  |
| 13:  | y1 = scry - y  |  |
| 14:  | imgNew[i, j] = (1 - x1) * (1 - y1) * img[x, y] + x1 * (1 - y1) * img[x + 1, y] + |  |
|      | (1 - x1) * y1 * img[x, y + 1] + x1 * y1 * img[x + 1, y + 1]                      |  |
| 15:  | end for  |  |
| 16:  | end for  |  |
| 17:  | return retimg  |  |
|      |  |  |

线性插值算法将图像缩小s倍,其次将图像放大s倍,目的是不改变图像大小进而来缩小图像的分辨率,能够得到通过分辨率变换模型变换后的图像,通过分辨率变换来达到图像模拟不同生产环境下镜头景深与像素深度的变化从而扩增图像,分辨率变换模型的具体实现如算法3.4所示。

#### (3) 视角变换模型

视角变换模型通过改变图像在三维空间角度与大小来模拟不同相机姿态与 相机高度的变换。对其主要的视角变换,将不同环境下的图像投影视角影响因 素抽象成视角变换模型并且控制参数来进行调节模拟不同工业生产环境下图 像投影视角的变换对图像影响与作用效果,通过输入原始工业图像数据,对图

#### 算法 3.4 分辨率变换模型

- 1: Input: image data,s
- 2: Onput: image data
- 3: rows, cols = img.shape
- 4: imgLarge = biLinearInterpolation(img, rows \* s, cols \* s)
- 5: rows, cols = imgLarge.shape
- 6: imgSmall = biLinearInterpolation(imgLarge, rows / s, cols / s)
- 7: return imgSmall

像进行视角维度的变换。视角变换模型的核心是对图像在二维平面上进行三维的透视变换与相机视角范围内大小变换,因此要对图像进行矩阵变换将图像像 素值映射到新的三维空间后转换为二维图像,视角变换模型的具体实现如算 法3.5所示。

#### 算法 3.5 视角变换模型

- 1: Input: image data,anglex,angley,anglez,H
- 2: Onput: image data
- 3: fill image edges
- 4: compute image height, width, fov
- 5: z = np.sqrt(width \*\* 2 + height \*\* 2) / 2 / np.tan(rad(fov / 2))
- 6: rx = np.array([[1, 0, 0, 0], [0, np.cos(rad(anglex)), -np.sin(rad(anglex)), 0], [0, -np.sin(rad(anglex)), np.cos(rad(anglex)), 0, ], [0, 0, 0, 1]])
- 7: ry = np.array([[np.cos(rad(angley)), 0, np.sin(rad(angley)), 0], [0, 1, 0, 0], [-np.sin(rad(angley)), 0, np.cos(rad(angley)), 0, ], [0, 0, 0, 1]])
- 8: rz = np.array([[np.cos(rad(anglez)), np.sin(rad(anglez)), 0, 0], [np.sin(rad(anglez)), np.cos(rad(anglez)), 0, 0], [0, 0, 1, 0], [0, 0, 0, 1]])

```
9: r = rx.dot(ry).dot(rz)
```

10: get the three-dimensional coordinates of the image(dst1,dst2,dst3,dst4) according to the transformation matrix r

```
11: for all i in 4 do
```

12: dst[i, 0] = listDst[i][0] \* z / (z - listDst[i][2]) + pcenter[0]

```
13: dst[i, 1] = listDst[i][1] * z / (z - listDst[i][2]) + pcenter[1]
```

14: end for

```
15: get result according to perspective transformation of an image
```

16: return result

模型通过对图像进行预处理,扩展图像边界,使得图像在视角变换后依旧 能保持原图像边界细节,不损失图像边界信息。获取输入图像的宽度 w 与高度 h 并计算相机距离图像的视距 H,构造三维空间中图像绕 x、y、z 轴旋转具体 角度的变换矩阵,通过矩阵运算得到最终图像的三维变换矩阵,通过变换矩阵 得到变换后的图像三维坐标并且将其坐标值投影至二维平面,同时计算缺陷位 置的坐标值,生成新的缺陷标注信息。根据相机高度调节参数计算变换后相机 高度与原高度的比值作为缩放系数,通过双线性插值算法对图像进行缩放处理 来进行相机与图像之间高度的变换,最终能够得到通过视角变换模型变换后的 图像,通过视角变换来达到图像模拟不同生产环境下相机姿态参数与相机高度 的变化从而扩增图像。

### 3.5.2 模拟工业零件缺陷形态特征扩增方法

### 3.5.2.1 数据扩增流程

基于工业零件缺陷形态特征模拟的扩增方法流程图如图 3-31 所示。扩增过 程的输入是原始的工业图像数据集与缺陷标注数据。

- 根据缺陷的标注信息对零件缺陷进行擦除得到正常没有缺陷的零件图像数据,同时将零件上的缺陷按照标注信息裁剪后用于后续变换处理。
- 通过对缺陷图像进行对比度、亮度、灰度维度上的色彩变换,来模拟不同 损伤程度的缺陷;
- 通过对缺陷图像进行横向拉伸与纵向拉伸维度上的缩放变换,来模拟不同 损伤等级的缺陷与不同大小的缺陷;
- 通过对缺陷图像进行角度维度上的旋转变换,来模拟在零件上不同方向的 缺陷;
- 5. 通过对缺陷图像进行翻转变换,同样来模拟在零件上不同方向的缺陷;
- 6. 通过对缺陷图像进行方位变换,来模拟零件上不同位置的缺陷。
- 对于工业零件缺陷形态特征的五种变换的参数控制见表 3-5,方法同样在每 种模型入口前加了开关控制,可以选择是否使用该模型。
- 8. 最后经过五种变换模型后会生成缺陷样本的扩增图像数据集,此时只是缺陷样本的数据集,因此还需要对扩增的缺陷样本与最初擦除缺陷后的正常零件图像根据标注进行缺陷与零件的融合,由于位移变换与缩放会导致工业的缺陷标注数据会发生变化,因此会生成新的扩增图像标注集。


图 3-31: 基于工业零件缺陷形态特征的扩增方法流程图

| 变换模型        | 变换参数      | 参数范围      | 参数控制变换效果  |
|-------------|-----------|-----------|---|
| 缩故娈拖横刑      | 横向拉伸系数 fx | [0.7,1.3] | fr fy>1时博士 fr fy<1时减小   |
| 油灰又沃快主      | 纵向拉伸系数 fy | [0.7,1.3] | $\int \mathcal{X} = \int \mathcal{Y} = \mathcal$ |
| 翻转变换模型      | 翻转类型      | 0,1       | 0水平翻转,1垂直翻转   |
| 方位变换模型      | 中心坐标      | random    | 缺陷在零件有效范围内移动  |
| <b>鱼彩</b> 本 | 亮度        | [-1,1]    | 会粉 >0 钟览宫度/对比度博士 会粉 <0 减小   |
| 口心文沃快主      | 对比度       | [-1,1]    | 多数 / 0 叭阳元反/小口反相八,多数 / 0 顷小   |
| 旋转变换模型      | 旋转角度      | [0,360]   | 左手坐标系缺陷顺时针旋转  |

表 3-5: 工业缺陷形态特征模拟扩增方法参数控制

## 3.5.2.2 标注数据处理

旋转、缩放、方位变换模型会导致缺陷标注数据发生变换,对于变换的标 注重新按照缺陷的尺寸与零件的尺寸来计算宽度比与高度比,对于缺陷位于零 件的中心坐标,如果不进行方位变换则在原图像基础上的中心坐标来对缺陷图 像与零件图像进行泊松融合,否则按照方位变换模型重新生成中心坐标。

#### 3.5.2.3 算法实现

#### (1) 缺陷色彩变换模型

缺陷色彩变换模型通过改变零件缺陷的亮度与对比度来模拟缺陷的不同损 伤程度与缺陷等级。对其缺陷主要的色彩变换,将缺陷的不同损伤程度与缺陷 等级抽象成缺陷色彩变换模型并且控制参数来进行调节模拟不同形态缺陷,通 过输入原始工业图像数据,对缺陷进行色彩维度的变换并与原图像进行融合。 缺陷色彩变换模型的核心是将缺陷的像素值在色彩扰动范围内对 RGB 三通道 像素值标准差与平均值进行归一化处理并向前或向后映射到更大的色彩空间, 因此首先计算得到图像 RGB 三通道像素值的均值与方差,缺陷色彩变换模型 的具体实现如算法3.6所示。

算法 3.6 缺陷色彩变换模型

- 1: Input: image data,light,saturation,toneR,toneG,toneB
- 2: **Onput:** image data
- 3: compute Rmean,Gmean,Bmean,Rvar,Gvar,Bvar
- 4: convert the image through a binarization algorithm
- 5: bin = binarization(img)
- 6: *rows*, *cols* = img.shape
- 7: for all i in rows do
- 8: **for all** j in cols **do**
- 9: **if** bin[i, j] == 0 **then**
- 10: R = img[i, j][2]
- 11: B = img[i, j][1]
- 12: G = img[i, j][0]
- 13:  $\operatorname{RmeanNew} = (1 + \operatorname{light}) * \operatorname{Rmean} + \operatorname{toneR} * \operatorname{Rmean}$
- 14: RvarNew = (1 + saturation) \* Rvar
- 15:  $\operatorname{Rnew} = (\operatorname{R} \operatorname{Rmean}) / \operatorname{Rvar} * \operatorname{RvarNew} + \operatorname{RmeanNew}$
- 16:  $\operatorname{imgNew}[i, j][2] = \operatorname{Rnew}$
- 17: GmeanNew = (1 + light) \* Gmean + toneG \* Gmean
- 18: GvarNew = (1 + saturation) \* Gvar
- 19: Gnew = (G Rmean) / Gvar \* GvarNew + GmeanNew
- 20: imgNew[i, j][0] = Gnew
- 21: BmeanNew = (1 + light) \* Bmean + toneB \* Bmean
- 22: BvarNew = (1 + saturation) \* Bvar
- 23: Bnew = (B Bmean) / Bvar \* BvarNew + BmeanNew
- 24: imgNew[i, j][1] = Bnew
- 25: retrun imgNew
- 26: **end if**
- 27: end for
- 28: **end for**

模型通过对图像进行二值化处理将缺陷图像分隔为缺陷部分和非缺陷部分,二值化处理实现如算法3.7所示,对缺陷部分进行色彩变换,将缺陷部分每个像素点的像素值通过计算得到的均值与方差进行归一化处理,控制亮度参数与饱和度参数,将图像像素的灰度值向更小或更大的空间做映射处理,得到新的像素值,并将其填充至新的图像中,得到通过缺陷色彩变换模型变换后的图像,通过色彩变换来达到图像模拟不同损伤程度与缺陷等级下缺陷形态的变化从而扩增图像。

(2) 缺陷缩放变换模型

缺陷缩放变换模型通过改变零件缺陷的横纵拉伸比模拟缺陷的不同大小与

58

| <b>算法 3.7</b> 二值化处理  |
|--|
| 1: Input: image data   |
| 2: <b>Onput:</b> image data  |
| 3: convert RGB image to grayscale image                                      |
| 4: retval, dst = $cv2$ .threshold(gray, 0, 255, $cv2$ . <i>THRESH_OTSU</i> ) |
| 5: $dst = cv2.dilate(dst, None, iterations=1)$                               |
| 6: $dst = cv2.erode(dst, None, iterations=4)$                                |
| 7: return dst  |
|  |

长短。对其缺陷主要的缩放变换,将缺陷的不同大小与长短抽象成缺陷缩放变 换模型并且控制参数来进行调节模拟不同形态缺陷,通过输入原始工业图像数 据,对缺陷进行缩放维度的变换并与原图像进行融合。缺陷缩放变换模型的 核心是将缺陷按照横纵拉伸比进行缩放,缺陷缩放变换模型的具体实现如算 法3.8所示。模型通过对缺陷部分图像进行横向与纵向的拉伸,如果缩放后的

#### 算法 3.8 缺陷缩放变换模型

- 1: **Input:** image data,fx,fy
- 2: **Onput:** result image
- 3: res = cv2.resize(defect\_img, None, fx, fy,cv2.*INTER\_CUBIC*)
- 4: return res

缺陷图像尺寸超过零件的尺寸,按照尺寸比重新对缺陷图像进行缩小处理防止 缺陷像素值相对零件图像发生越界。通过缺陷缩放变换来达到图像模拟缺陷大 小与长短的变化从而扩增图像。

#### (3) 缺陷方向变换模型

缺陷方向变换模型通过改变零件缺陷的角度并且对缺陷进行翻转模拟缺陷 的不同方向。对其缺陷主要的方向变换,将缺陷旋转的角度与对缺陷的翻转抽 象成缺陷方向变换模型并且控制参数来进行调节模拟不同形态缺陷,通过输入 原始工业图像数据,对缺陷进行方向维度的变换并与原图像进行融合。缺陷缩 放变换模型的核心是将缺陷按照角度进行旋转或对缺陷进行水平或垂直方向的 翻转,缺陷旋转变换模型的具体实现如算法3.9所示,缺陷翻转变换模型的具体 实现如算法3.10所示。模型通过二维空间仿射变化构造旋转矩阵,通过变换矩 阵计算缺陷旋转后得到的新的尺寸,并且通过变换矩阵对图像进行变换,同时 对缺陷进行水平或垂直方向上的翻转,如果旋转变换后的缺陷图像尺寸超过零 件的尺寸,则按照尺寸比重新对缺陷图像进行缩小处理防止像素值越界。通过 缺陷方向变换来达到图像模拟缺陷不同方向的变化从而扩增图像。 算法 3.9 旋转变换模型

- 1: Input: image data,degree
- 2: **Onput:** result image
- 3: h, w = img.shape
- 4: heightNew = int(width \* fabs(sin(radians(degree))) + h \* fabs(cos(radians(degree))))
- 5: widthNew = int(height \* fabs(sin(radians(degree))) + w \* fabs(cos(radians(degree))))
- 6: matRotation = cv2.getRotationMatrix2D((width / 2, height / 2), degree, 1)
- 7: matRotation[0, 2] += (widthNew width) / 2
- 8: matRotation[1, 2] += (heightNew height) / 2
- 9: imgRotation = cv2.warpAffine(defect\_img, matRotation, (widthNew, heightNew), borderValue=(255, 255, 255))
- 10: res = imgRotation
- 11: return res

#### 算法 3.10 缺陷翻转变换模型

- 1: Input: image data
- 2: **Onput:** image data
- 3: if type==0 then
- 4: img = np.fliplr(img)
- 5: else if type==1 then
- 6: img = np.flipud(img)
- 7: end if
- 8: return img

#### (4) 缺陷方位变换模型

缺陷方位变换模型通过改变零件缺陷的方位模拟缺陷的不同位置。对其缺陷主要的方位变换,将缺陷位置变换抽象成缺陷方位变换模型并且控制参数来进行调节模拟不同形态缺陷,通过输入原始工业图像数据,对缺陷进行方位维度的变换并与原图像进行融合。同时缺陷方位变换会导致缺陷图像在一定程度上会失真,所以对于方位变换的坐标需要严格进行控制,保证其变换在有效区域内,进而达到缺陷方位变化达到高保真的目的。缺陷方位变换模型的具体实现如算法3.11所示。模型根据零件尺寸大小与缺陷尺寸大小计算中心坐标生成边界值,随机生成中心点坐标,根据重新随机生成的中心坐标转化为宽度高度比与中心坐标比。通过缺陷方位变换来达到图像模拟缺陷不同位置的变化从而扩增图像。

#### (5) 缺陷擦除算法

对于工业缺陷形态特征方法需要将标注信息位置上的缺陷样本进行擦除从

60

#### 算法 3.11 方位变换模型

- 1: Input: defect label information
- 2: Onput: defect transfored label information
- 3: xStart = ceil(defectW / 2)
- 4: xEnd = floor(width defectW / 2)
- 5: yStart = ceil(defectH / 2)
- 6: yEnd = floor(height defectH / 2)
- 7: xmin = int(centerx defectW / 2)
- 8: ymin = int(centery defectH / 2)
- 9: xmax = int(centerx + defectW / 2)
- 10: ymax = int(centery + defectH / 2)
- 11: return xmin,ymin,xamx,ymax

而得到正常的工业零件图像用于缺陷样本融合,缺陷擦除的核心原理是根据目标区域附近像素值来进行填充,并且覆盖其要擦除的区域。缺陷擦除算法根据零件尺寸大小生成全黑图像,根据缺陷标注裁剪缺陷,并且覆盖到全黑图像生成 mask 图像,即要擦除的图像,通过初始图像与 mask 图像对缺陷进行擦除处理,具体实现如算法 3.12。

#### 算法 3.12 缺陷擦除算法

```
1: Input: image img
```

- 2: Onput: dst image
- 3: if type == 'ns' then
- 4:  $cv2.INPAINT_NS$
- 5: else if type == 'telea' then
- 6:  $flags = cv2.INPAINT_TELEA$
- 7: **end if**
- 8: height, width = img.shape[0:2]
- 9: size = [width, height]
- 10: Convert yolo coordinates to voc coordinates
- 11: target = np.zeros((height, width), dtype=np.uint8)
- 12: defect image overlay mask image
- 13: dst = cv2.inpaint(img, mask, 3, flags)
- 14: return dst

#### (6) 缺陷融合算法

对于工业缺陷形态特征方法需要将扩增后的缺陷样本与工业零件图像进行 融合,缺陷融合的核心原理是降低融合图像与目标图像边界梯度值,做到高保 真条件下的融合,泊松融合对于缺陷融合效果较好。缺陷融合算法根据零件尺 寸大小生成全黑图像,根据缺陷标注裁剪缺陷,并且覆盖到全黑图像生成 mask 图像,即要融合的图像,通过初始图像与 mask 图像对缺陷进行融合处理,具体实现如算法 3.13。

算法 3.13 缺陷融合算法

```
1: Input:Part image obj and defect image img
2: Onput: mixed image
3: if type == 'normal' then
     flags = cv2.NORMAL CLONE
4:
5: else if type == 'mixed' then
     flags = cv2.MIXED CLONE
6:
7: else
     flags = cv2.MONOCHROME TRANSFER
8:
9: end if
10: mask = 255 * np.ones(img.shape, img.dtype)
11: h, w = obj.shape[0:2]
12: x = int(centerx * w)
13: y = int(centery * h)
14: center = (x, y)
15: mixed = cv2.seamlessClone(img, obj, mask, center, flags)
16: return mixed
```

# 3.6 基于工业特征图像扩增的检测模型增强训练

在小样本数据集下训练的检测模型,数据集样本数量少,通过上一节所述 的工业图像数据扩增方法对小样本数据集进行扩增,通过扩增的数据集对检测 模型进行增强训练,使检测模型在识别率、精度与分类效果上得到提升。

基于工业特征图像扩增的检测优化方法流程图如图 3-32所示。输入初始数 据集与缺陷标注数据至深度学习检测模型中进行训练,训练得到检测模型 A, 此时的模型 A 是最初训练得到的模型,目的是为了优化此模型,让其具有更高 的检测精度与更好的分类效果。通过上一小节所述的工业缺陷形态特征扩增方 法与工业图像采集过程方法,在配置文件内对模型调节参数与模型开关根据目 的性需要进行调整,启动主扩增单元对小样本工业数据集进行图像数据扩增, 得到大量的扩增图像数据集,其次将扩增图像数据集与缺陷标注数据输入至检 测模型 A 中进行增强训练,得到优化后的检测模型 B,检测模型 B 相对于检测 模型 A 所训练使用的数据集在数量与多样性上呈现一定优势,检测模型在识别 率上也会有提升,扩增数据集的有效性检验与扩增数据集增强训练模型识别率 检验通过第四章设计实验来验证。

62



图 3-32: 基于图像数据扩增的检测优化方法流程图

# 3.7 本章小结

本章为论文的核心部分,首先本章分析了工业图像采集过程。通过对机器 视觉系统中图像光源、镜头、工业相机参数、相机传感器、图像投影角度进行 研究,得到每个因素对图像质量的影响。对于光源分析了不同照射方式、照射 方法、光线颜色对采集得到的图像所产生的图像分辨率、色彩的影响;对于工 业镜头分析了镜头各个参数,分辨率、敏锐度、景深等参数对于图像分辨率、 色彩、方位变换的影响;对于工业相机传感器分析了市面上常见的两种传感器 (CCD 传感器与 CMOS 传感器),通过对两种传感器的作用原理与各自缺点 的分析,总结出两种传感器根据独自特性对图像质量的影响;通过对图像投影 倾斜角变化的分析,得到了图像经过倾斜角变化发生透视变换的规律。其次 本章分析了工业零件中常见的缺陷(以铝箔和钢材为例分析)与作用机理,归 纳了不同缺陷形态的特征,不同的缺陷所导致的原因不同,因此特征也相应 不同。

扩增方法作为数据扩增的核心是本文研究的重点工作。通过以上的研究内 容,本章对其进行工业图像采集过程模拟与工业零件缺陷形态特征模拟来实现 对图像数据的扩增。本章归纳总结得出两种工业特征图像扩增方法:基于工业 图像采集过程模拟的扩增方法与基于工业零件缺陷形态特征模拟的扩增方法。 并实现了主要的工业图像数据扩增单元,将参数控制与开关控制与主方法解 耦,可做到自由调参来控制主扩增单元。

最后,通过两种工业图像数据扩增方法对零件缺陷检测模型进行加强训练,在模型的精度上能够实现一定程度上的提升。

# 第四章 扩增数据的准备与校验

# 4.1 数据准备与处理

本文研究的对象为工业图像数据,所采集的工业图像均为金属材料零件图像,工业企业大多通过红外工业相机或黑白工业相机对金属零件图像进行采集,因此多数工业图像数据为灰度图像,少数工业图像数据为彩色图像。对数据的准备同样需要每张工业图像所对应的缺陷标注。同时为了保证深度学习目标检测模型充分性,对数据量也有一定的要求。

### 4.1.1 基础数据集准备

对于基础数据的准备,本文选择东北大学 [47] 开源的钢带表面缺陷数据集(NEU-DET)。

在东北大学的钢带表面缺陷数据库中,一共收集了六种比较典型的缺陷 [48],六种缺陷分别为钢带内含氧化皮、钢带表面附着斑块、钢带表皮开裂、 钢带表面含有点状侵蚀,钢带内含其他杂质和钢带表面划痕。此表面缺陷数据 库每种缺陷类型均有 300 张样本,共计灰度图像 1800 张。其中每种类型缺陷全 量 300 张样本作为训练数据集,每种缺陷类别中选取 30 张样本作为验证数据 集。对于表面缺陷检测任务,每张图像对缺陷位置与类别提供了对应的标注。

## 4.1.2 环境搭建与目标检测模型选择

本文中所使用的本地环境为: windows 7 + Anaconda 3.7+ CUDA 9.1.84 + Python 3.7.5 + Pytorch1.10.0 + Opencv-python4.5.4.60。具体环境如表 4-1所示。 对于目标检测模型的训练,需要高配置的 GPU 来提供计算能力,因此在使用本 地环境的同时,搭配使用云端 GPU google colab[49] 来训练目标检测模型。

由于单一的深度神经网络具有一定的局限性,因此选择机器视觉检测业内常用的一阶段目标检测模型 Fast R-CNN[50] 和二阶段目标检测模型 SSD[51] 与 yolov5[52],以保证得到的数据与结果的客观性与准确性。

| 系统软硬件      | 环境名称       | 版本号                  |
|------------|------------|----------------------|
| CPU        | Inter Core | i5-4210H             |
| GPU        | NVDIA      | GeForce GTX 950M(4G) |
| 内存         | Kingston   | 8G                   |
| 操作系统       | Windows    | Windows 7            |
| 环境管理工具     | Anaconda   | Anaconda 3.7         |
| NVDIA 运算平台 | CUDA       | cuda 9.1.84          |
| 编程语言       | Python     | python 3.7.5         |
| 机器学习库      | Pytorch    | pytorch 1.10.0       |
| 计算机视觉库     | OpenCV     | opency-python        |
| 包安装与管理工具   | pip        | pip 19.0.3           |

表 4-1: 系统软硬件环境表

RCNN 在 VGG-16 网络模型下,voc2007 数据集上的准确率高达 66%,但 是检测的速度比较慢,并且内存消耗较大。

yolov5 对比 RCNN 损失了一部分的精度,但是引入了 RCNN 的锚框架系统,大大改善了模型的 mAP。由于没有区域采样,在大规模数据上表现较好,但在小规模数据上表现较差。

SSD 模型平衡了 yolov5 和 Fast R-CNN 优缺点。SSD 相比 R-CNN 目标检测 速度较快,但 mAP 与召回率较低,与 yolov5 相比精度较高但是速度较慢。

## 4.1.3 数据集标注格式转换

本文准备的数据集标注为 VOC 格式,对于 Fast R-CNN 与 SSD 目标检测模型数据集格式无需转换,但由于使用的深度学习目标检测模型 yolov5 所用到标 注格式为 txt 文本,因此训练目标检测模型前需要对数据集标注进行预处理,将 VOC 格式的 xml 标注文件转换为 yolov5 需要的 txt 标注文件。yolo 格式的标签为 txt 格式的文件,文件名跟对应的图片名一样,除了后缀改为了.txt,具体格式如下:

- 每个目标一行, 整个图片没有目标的话不需要有 txt 文件;
- 每行的格式为 class\_num x\_center y\_center width height;
- 其中 class\_num 取值为0至 total\_class 1, 框的四个值 x\_center y\_center width

height 是相对于图片分辨率大小正则化的 0-1 之间的数, 左上角为 (0,0), 右下角为 (1,1)。

同时需要将 VOC 数据集标注转化为 yolov5 数据集标注,以便使用 yolov5 模型来进行训练。

# 4.1.4 扩增数据的准备

对于两种扩增方法每种扩增模型做了参数统计,扩增模型参数归纳表见 表4-2。

| 扩撞方注      | <b>本</b> 塩 柑 刊 | 本       |              | 参数控制                 |
|-----------|----------------|---------|--------------|----------------------|
| J) 78/J14 | 又厌快主           | 又沃罗奴    | 多或他回         | 变换效果                 |
|           |                | 亮度      | [-1,1]       |                      |
|           |                | 对比度     | [-1,1]       | ◆粉、0 協士              |
|           | 色彩变换模型         | R 通道色调  | [-1,1]       | 参数 ≥0 增入<br>会数 ≤0 尾小 |
|           |                | G通道色调   | [-1,1]       | ◎ 奴 < 0 颅小           |
| 工业图像      |                | B通道色调   | [-1,1]       |                      |
| 采集过程模拟    |                | x 轴旋转角度 | [-70,70]     | 七王从左系                |
|           | 视角变换模型         | y 轴旋转角度 | [-70,70]     | [ 工于坐你系              |
|           |                | z轴旋转角度  | [0,360]      |                      |
|           |                | 相机高度    | [-1000,1000] | 参数 >0 增大, 参数 <0 减小   |
|           | 分辨率变换模型        | 分辨率缩小倍数 | [0.5,1]      | 减小                   |
|           | 缩故本地構刊         | 横向拉伸系数  | [0.7,1.3]    | 参数 >1 增大             |
|           | 加放文沃快至         | 纵向拉伸系数  | [0.7,1.3]    | 参数 <1 减小             |
| 工业重化轴收    | 翻转变换模型         | 翻转类型    | 0,1          | 0水平,1垂直              |
| 工业令什听阳    | 方位变换模型         | 中心坐标    | random       | 有效范围内改变              |
| 10芯竹Ш沢1以  |                | 亮度      | [-1,1]       | 参数 >0 增大             |
|           | 口心文沃快生         | 对比度     | [-1,1]       | 参数 <0 减小             |
|           | 旋转变换模型         | 旋转角度    | [0,360]      | 左手坐标系顺时针旋转           |

表 4-2: 扩增模型参数归纳表

使用两种方法每种变换模型的不同参数,对训练数据集与检验数据集分别 进行扩增,得到的扩增训练数据集用于检测模型的增强训练,扩增检验数据 集用于测试三种目标检测模型识别率 mAP。通过工业图像采集过程模拟扩增 方法扩增图像如图4-1所示,通过工业缺陷形态特征模拟扩增方法扩增图像如 图4-2所示。

#### 第四章 扩增数据的准备与校验



图 4-2: 通过工业零件缺陷形态特征模拟扩增方法扩增图像

#### 扩增数据有效性检验 4.2

#### 研究问题 4.2.1

型垂直翻转

扩增数据集是相对于原始小样本数据集模拟了不同的工业环境与缺陷形态 特征扩增得到的数据集,为了探究不同工业环境与缺陷形态特征对于目标检测

#### 4.2 扩增数据有效性检验

模型的影响、讨论目标检测模型对扩增前后数据判别的差异性、检验通过扩增 数据集增强训练后的模型检测与分类效果是否提升、验证工业扩增方法相对于 其他通用扩增方法对于工业的适用性,本节设计了扩增数据有效性检验的实 验。

### 4.2.2 实验对象

本实验使用 1800 张 6 类别工业缺陷数据作为训练集,使用其中的 180 张 6 类别工业缺陷数据(每类缺陷 30 张数据,占总数据集 10%)作为检验数据 集。重点考察的深度神经网络模型为 yolov5、Fast R-CNN、SSD,通过 1800 张 工业缺陷训练数据集对三种深度神经网络模型进行 300 epoch 训练。

## 4.2.3 实验设计

(1)实验一:为了探究不同工业生产环境与缺陷形态特征对于目标检测 模型的影响、讨论目标检测模型对扩增前后数据判别的差异性,基本实验思 路如图4-3所示。通过调整不同参数利用本文工业图像扩增方法模拟不同工业 生产环境与工业缺陷形态特征扩增得到的扩增验证集,对Fast R-CNN、SSD、 yolov5 深度学习目标检测模型进行检验,以模型检验结果中的识别率 mAP 来 探究不同工业环境与缺陷形态特征对于目标检测模型的影响,讨论目标检测模 型对扩增前后数据判别的差异性。模拟不同工业生产环境下图像的变化是否会 影响检测模型,是否能够说明在工业数据量少的情况下目标检测模型泛化能力 低,不能够适应多种生产环境的变化下采集到的图像。



图 4-3: 实验一基本设计思路

(2) 实验二:为了检验扩增数据集对深度神经网络模型模型泛化能力的

提升效果,基本实验思路如图4-4所示。对训练数据集通过工业图像采集过程 模拟扩增方法与工业缺陷形态特征模拟扩增方法进行自动化扩增得到两类不 同的扩增训练数据集,其次对 Fast R-CNN、SSD、yolov5 深度学习目标检测模 型进行增强训练,得到基于工业图像采集过程模拟扩增训练集增强训练模型 B 与基于工业缺陷形态特征模拟训练集增强训练模型 C,对模型 A、B、C进行 mAP上的对比,来检验扩增数据集对深度学习目标检测模型增强训练效果相对 于原模型是否提升。



图 4-4: 实验二基本设计思路

(3) 实验三:为了验证工业扩增方法相对于其他通用扩增方法对于工业 场景的适用性,基本实验思路如图4-5所示。对训练数据集通过本文工业图像 扩增方法与通用扩增方法进行扩增得到两类不同的扩增训练数据集,其次对 Fast R-CNN、SSD、yolov5 深度学习目标检测模型进行增强训练,得到基于工 业扩增方法扩增训练集增强训练模型 B 与基于通用扩增方法训练集增强训练模 型 C,对模型 B 和 C 进行 mAP 上的对比,来验证工业扩增方法相对于其他通 用扩增方法对于工业场景的适用性。



图 4-5: 实验三基本设计思路

#### 4.2.4 指标评价

对于模型的泛化能力本文主要通过模型 mAP(IoU 在 [0.5,0.95] 每 0.05 一 个阈值共十个阈值下的平均精度值),也可以称为识别率,相对于 Recall 和 Precision 更能全方位评价模型的泛化能力。

(1) 对于实验一,本文通过三种深度学习目标检测模型检验结果中的识 别率 mAP 作为实验的指标,同时在对扩增图像检测时以缺陷分类效果与置信 度作为工业生产环境变化对检测模型的影响。扩增的检验数据集相对于原始检 验数据集,通过对模型识别率的检验,验证模型是否能够准确识别出不同工业 生产环境与不同工业形态特征下的缺陷,如果识别率较低,说明原始小样本数 据集多样性方面欠缺,对于检测模型的识别率有不同程度上的影响,容易出现 错检与漏检。

(2)对于实验二,本文通过三种深度学习目标检测模型检验结果中的识 别率 mAP 作为实验的指标。通过本文两种工业图像扩增方法进行模型的增强 训练,相对于原始无扩增方法训练得到的模型,如果 mAP 对比在不同程度上 有所提升,说明通过本文两种工业图像扩增方法扩增得到的数据集对模型增强 训练在训练效果上相对于无扩增方法是更为有效的。

(3) 对于实验三,本文通过三种深度学习目标检测模型检验结果中的识别率 mAP 作为实验的指标。通过本文工业图像扩增方法进行模型的增强训练,相对于通用扩增方法训练得到的模型,如果 mAP 对比在不同程度上有所提升,说明通过本文工业图像扩增方法相对于通用扩增方法具有工业场景的适用性。

# 4.3 实验结果与分析

(1)通过实验一探究不同工业环境与缺陷形态特征对于目标检测模型的 影响:

图像分辨率变化对模型 mAP 的影响见表 4-3,随着图像分辨率变换因子的 逐渐减小,不同深度深度学习目标检测模型的识别率 mAP 也随之逐渐减小, 说明图像分辨率的变化对模型识别率的影响成正比。

图像分辨率变化后对检测模型的影响如图4-6所示,可以发现在分辨率降低后,工业图像受到一定程度的模糊,从而导致检测模型在对缺陷的识别上发生漏检,并且对缺陷检测的置信度与精度有所下降。

| 深度学习目标检测模型 | 原图像   | s=0.5 | s=0.3 | s=0.2 | s=0.1 |
|------------|-------|-------|-------|-------|-------|
| yolov5     | 0.928 | 0.811 | 0.594 | 0.447 | 0.135 |
| SSD        | 0.917 | 0.802 | 0.543 | 0.482 | 0.11  |
| Fast R-CNN | 0.932 | 0.804 | 0.598 | 0.452 | 0.201 |
| ROMA       |       |       |       |       |       |

表 4-3: 图像分辨率降低对检测模型 mAP 的影响



图 4-6: 图像分辨率变化后对检测模型的影响

图像视角变化对模型 mAP 的影响见表 4-4,对于工业相机采集图像高度变换,无论是增加或减小相机与捕捉物体之间的距离都对于模型识别率 mAP 没有太大影响,相机姿态参数中俯仰角与横滚角的变化对于模型识别率 mAP 的影响较大、航向角次之。

| 深度学习       | 百团侮   | anglex | angley | anglez | U-500 | U- 500 |
|------------|-------|--------|--------|--------|-------|--------|
| 目标检测模型     | 历日家   | =60    | =60    | =60    | п-300 | п300   |
| yolov5     | 0.928 | 0.643  | 0.498  | 0.421  | 0.935 | 0.912  |
| SSD        | 0.917 | 0.622  | 0.467  | 0.482  | 0.912 | 0.918  |
| Fast R-CNN | 0.932 | 0.638  | 0.532  | 0.445  | 0.921 | 0.915  |

表 4-4: 图像视角变化对检测模型 mAP 的影响

图像视角变化后对检测模型的影响如图4-7所示,可以发现在视角变化 后,零件与缺陷都在一定程度上变形,缺陷容易发生失真现象,对于检测模型 有较大的影响,检测模型在对缺陷的识别上容易发生漏检,并且对缺陷检测的 置信度与精度下降;但是在相机高度变化后,对于检测模型并没有太大影响。



图像色彩变化对模型 mAP 的影响见表4-5,对于工业相机采集图像色彩 变换,其中 RGB 色调的变化对于模型识别率 mAP 有一定的影响但基本影响较 小,对于饱和度变换与亮度变化对于模型识别率 mAP 影响较大。

| 深度学习       | 百团侮   | sat   | light | hue_r | hue_g | hue_b |
|------------|-------|-------|-------|-------|-------|-------|
| 目标检测模型     | 尿囵豚   | =0.5  | =0.5  | =0.5  | =0.5  | =0.5  |
| yolov5     | 0.928 | 0.502 | 0.355 | 0.7   | 0.601 | 0.802 |
| SSD        | 0.917 | 0.473 | 0.35  | 0.722 | 0.589 | 0.762 |
| Fast R-CNN | 0.932 | 0.545 | 0.406 | 0.692 | 0.632 | 0.811 |

表 4-5: 图像色彩变化对模型 mAP 的影响

图像色彩变化后对检测模型的影响如图4-8所示,可以发现图像在对比度 变化后,模型对缺陷检测的置信度下降,并且会发生漏检的情况,在亮度变化 后由于部分区域曝光明显导致模型发生错检的现象,三通道色调值变化导致模 型对缺陷检测置信度下降。

缺陷损伤程度变化对模型 mAP 的影响见表 4-6,对于缺陷损伤程度的变化,其中图像饱和度的变化对于模型识别率 mAP 有一定的影响但基本影响较小,亮度变换对于模型识别率 mAP 影响较大,当灰度发生变化时,由于其中



图 4-8: 图像色彩变化后对检测模型的影响

亮度发生变化导致灰度变化对于模型识别率 mAP 影响较大,整体来看缺陷损伤程度的变化对于模型识别率 mAP 有较大影响。

| 深度学习       | 百図侮   | sat=0.5 | light=0.5 | sat=0.5   |
|------------|-------|---------|-----------|-----------|
| 目标检测模型     | 冰口肉   | sat=0.5 | ngm=0.5   | light=0.5 |
| yolov5     | 0.928 | 0.735   | 0.318     | 0.29      |
| SSD        | 0.917 | 0.701   | 0.304     | 0.287     |
| Fast R-CNN | 0.932 | 0.736   | 0.32      | 0.341     |

表 4-6: 缺陷损伤程度变化对模型 mAP 的影响

缺陷损伤程度变化后对检测模型的影响如图4-9所示,可以发现缺陷损伤 程度变化后,损伤程度减弱(亮度发生变化)导致模型发生漏检的现象,损伤 增强(对比度发生变化)导致模型对于缺陷检测置信度降低。

缺陷大小或长短变化对模型 mAP 的影响见表 4-7,对于缺陷大小或长短变化,整体来看缺陷大小的变化(缩小/放大)与缺陷长短的变化(横向拉伸/纵向拉伸)对于模型识别率 mAP 有一定影响。

缺陷大小或长短变化后对检测模型的影响如图4-10所示,可以发现缺陷大小发生变化后,会造成不同缺陷连接成为整体一块缺陷,在检测模型检测时会将此区域内连接得到的缺陷识别为整体一块缺陷,导致模型在检测缺陷时容易发生误检的现象,并且缺陷检测置信度有一定程度的降低。

缺陷位置变化对模型 mAP 的影响见表 4-8,对于缺陷方位变化,整体来看



图 4-9: 缺陷损伤程度变化后对检测模型的影响

表 4-7: 缺陷大小或长短变化对模型 mAP 的影响

| 深度学习       | 百团伤   | fx=0.5 | fx=1.5 | fx=1.5 | dx=1.0 |
|------------|-------|--------|--------|--------|--------|
| 目标检测模型     | 历日承   | fy=0.5 | fy=1.5 | fy=1.0 | fy=1.5 |
| yolov5     | 0.928 | 0.312  | 0.671  | 0.765  | 0.571  |
| SSD        | 0.917 | 0.362  | 0.64   | 0.662  | 0.543  |
| Fast R-CNN | 0.932 | 0.332  | 0.712  | 0.775  | 0.621  |
|            |       |        |        |        |        |

缺陷横向翻转与纵向翻转对于模型识别率 mAP 有较小影响,缺陷对于零件的 位置变化对于模型识别率 mAP 有较大的影响。



图 4-10: 缺陷大小或长短变化后对检测模型的影响

| 深度学习目标检测模型 | 原图像   | 横向翻转  | 纵向翻转  | 位置变换(随机) |
|------------|-------|-------|-------|----------|
| yolov5     | 0.928 | 0.724 | 0.748 | 0.611    |
| SSD        | 0.917 | 0.701 | 0.73  | 0.587    |
| Fast R-CNN | 0.932 | 0.801 | 0.766 | 0.642    |

表 4-8: 缺陷位置变化对模型 mAP 的影响

缺陷位置变化后对检测模型的影响如图4-11所示,可以发现缺陷位置发生 变化后,导致模型在检测缺陷时置信度有一定程度的降低。



图 4-11: 缺陷位置变化后对检测模型的影响

通过对模拟多种工业环境变化与不同形态特征的缺陷的扩增图像进行实验 后,通过显著性检验 t 检验对图像变化前后模型识别率 mAP 做差异性比较, 表4-9结果表明变化前后差异显著,能够总结分析得到:模拟不同工业生产环 境下图像的变化会导致检测模型精度降低、识别率降低,同时会使目标检测模 型发生误检、漏检、错检,检测目标置信度低。综上能够表明在工业数据量少 的情况下目标检测模型泛化能力低,不能够适应工业相机在多种生产环境的变 化下采集到的图像。

(2)通过实验二检验扩增数据集对深度学习目标检测模型泛化能力的提升效果:模型 mAP 在工业扩增方法与无扩增方法下对比见表4-10,通过显著性检验 t 检验对表中数据做差异性比较,得到 p=0.0011<0.05(阈值),说明模型 mAP 在无扩增方法和工业缺陷扩增方法下差异显著,两种工业扩增方法对于深度神经网络模型模型泛化能力的提升效果都优于无扩增方法,在此次实验</p>

| 图像变化类型  | t检验p值    | 统计学意义 |
|---------|----------|-------|
| 分辨率     | < 0.0001 | 差异显著  |
| 视角      | =0.0001  | 差异显著  |
| 色彩      | < 0.0001 | 差异显著  |
| 缺陷损伤    | < 0.0001 | 差异显著  |
| 缺陷大小/长短 | < 0.0001 | 差异显著  |
| 缺陷方位    | < 0.0001 | 差异显著  |

表 4-9: 缺陷图像变化前后模型识别率 mAP 值显著性检验

中能够明显提升目标检测模型的精度与识别率。本文设计并实现的两种模拟扩增方法在提升效果上的表现差距较小,为用户自定义扩增规则赋予更多变化。

(3)通过实验三验证工业扩增方法相对于其他通用扩增方法对于工业场 景的适用性:模型 mAP 在工业扩增方法与通用扩增方法下对比见表4-10,通 过显著性检验 t 检验对表中数据做差异性比较,得到 p=0.0056<0.05(阈值), 说明模型 mAP 在通用扩增方法和工业缺陷扩增方法下差异显著。对比三种主流 图像扩增工具: imgaug、Albumentation 和 Augmentor,针对工业图像数据集, 工业缺陷特征模拟扩增方法与工业图像采集过程模拟扩增方法在工业场景下更 具有适用性与专业性。

表 4-10: 模型 mAP 在工业扩增方法、无扩增方法和通用扩增方法下对比

| 深度学习       | 无扩增   | img   | Albumen | Aug    | 工业缺陷形态   | 工业图像采集过程 |
|------------|-------|-------|---------|--------|----------|----------|
| 目标检测模型     | 方法    | aug   | tation  | mentor | 特征模拟扩增方法 | 模拟扩增方法   |
| yolov5     | 0.928 | 0.845 | 0.912   | 0.933  | 0.955    | 0.963    |
| SSD        | 0.917 | 0.862 | 0.903   | 0.911  | 0.933    | 0.952    |
| Fast R-CNN | 0.932 | 0.902 | 0.899   | 0.905  | 0.956    | 0.94     |

# 4.4 本章小结

本章主要介绍了基本工业缺陷图像数据的准备、环境搭建、目标检测模型 的选择与扩增数据集的准备。对于扩增数据有效性检验本文设计了三个实验来 探究不同工业生产环境与缺陷形态特征的变化对于深度学习目标检测模型的影 响、讨论目标检测模型对扩增前后数据判别的差异性、检验扩增数据集对深度 学习目标检测模型泛化能力的提升效果、验证工业扩增方法相对于其他通用扩 增方法对工业的适用性,并最终分析实验结果得到以下结论:本方法通过模拟 工业生产环境与不同形态特征缺陷得到的扩增数据对模型精度有一定程度上的 影响,通过本方法对模型进行强化训练后对模型泛化能力提升效果明显,说明 在工业场景下本方法较通用数据扩增方法与无扩增方法对于模型精度优化效果 更好。

# 第五章 总结与展望

# 5.1 本文研究内容总结

本文基于工业缺陷特征模拟包括工业图像采集过程模拟与工业零件缺陷形态特征模拟对工业环境中的工业相机采集的图像数据进行扩增研究。本文分析了工业图像采集过程与常见缺陷形态特征与产生原因并对缺陷形态特征进行归纳,总结并设计了基于工业图像采集过程模拟的扩增方法与基于工业零件缺陷形态特征模拟的扩增方法,得出了不同的变换模型与扩增规则,并基于 Python 语言和 OpenCV 库,实现了工业缺陷图像数据的扩增工具。该工具可以模拟不同工业生产环境下的采集图像,如不同相机视角、采集光源、相机传感器;缺陷方位、缺陷大小、缺陷长度、缺陷种类等不同的工业环境与缺陷形态。通过深度学习检测模型的初始训练与扩增数据的增强训练,结合不同实验设计与实验数据结果的分析,本文的工业图像数据扩增方法可有效提高模型的泛化能力和精度,并且对于工业生产环境更具有适用性,大大提高工业零件缺陷检测的精度与分类效果。本文主要的研究工作与成果如下:

- 基于工业图像采集过程分析所设计得到工业图像采集过程模拟图像扩增方法,方法包括视角变换模型、色彩变换模型与分辨率变换模型,对图像进行多环境模拟达到图像扩增的目的。基于工业零件缺陷形态特征分析设计得到工业零件缺陷形态特征模拟方法,方法包括对不同缺陷类别、缺陷位置、缺陷等级进行模拟达到图像扩增的目的。以上两种方法通过 Python 代码与 OpenCV 库进行设计与实现,通过调整不同模型参数来对不同工业环境进行模拟达到自动化扩增的目的。
- 2. 本文对钢带表面缺陷数据集(NEU-DET)1800张六类工业缺陷图像,使用 Anaconda本地环境搭建框架与 google colab云端 GPU 对系统整体环境进行 配置,对 yolov5、SSD、Fast R-CNN 三种主流深度学习网络进行训练,得 到实验所使用的网络模型,并用180张6类别缺陷图像作为检验集评价扩增 数据有效性。
- 3. 本文设计三种实验来验证扩增数据有效性,探究不同工业环境与缺陷形

态特征对于目标检测模型的影响,检验扩增数据集对检测模型泛化能力的 提升效果,验证工业扩增方法相对于其他通用扩增方法对于工业场景的适 用。

- 4. 本文通过实验得到扩增图像对于模型识别率的影响结果,不同扩增方法 与本文方法对比结果,得到以下结论:本方法模拟采集光源类别、镜头参 数、相机姿态角变化、传感器缺点、缺陷损伤程度、缺陷大小与长短、缺 陷方位与方向、缺陷等级因素,对目标检测模型泛化能力影响较大,能够 反映出在复杂工业生产环境下检测模型在数据量少的情况下泛化能力低, 因此本文基于工业缺陷特征的图像扩增方法对于检测模型泛化能力的提升 效果都优于无扩增方法,对比通用领域的扩增方法,更具有工业领域的适 用性。
- 本方法与工业领域技术结合,扩增数据覆盖面广更具专业性;自动化生成 模拟工业生产环境图像数据,降低数据采集成本;灵活动态控制模型开关 与参数,为用户自定义扩增规则赋予更多变化;能够在未来为技术人员提 供攻克工业数据少的难题的方法。

# 5.2 本文工作内容局限与展望

尽管本论文提出的基工业缺陷特征的图像扩增方法对工业缺陷图像数据扩 增研究具有一定价值,但是在实际的过程中还存在一些问题有待进一步优化:

- 大多数工业场景中所使用的采集相机为动态捕捉,部分相机采集所到的为 视频数据而非图像数据,图像扩增方法对于这一类环境具有局限性。
- 本文通过对工业图像采集过程与工业零件缺陷特征模拟进行图像数据扩 增,都是对于现有图像数据进行扩增,除了对现有数据进行扩增以外,可 以对每种缺陷进行提取并进行仿真处理来生成大量数据集。
- 工业扩增图像数据没有具体的评估方式,后续增加扩增图像质量评估 方法。

致 谢

从刚入学那天起觉得硕士两年是如此漫长,伴随着焦躁、忐忑的心情踏入 研究生生活,从入学那天起就已经盼望着要毕业了,到今天即将面临毕业的时 候,才发觉这两年过的这么快。想要珍惜的时候发现一切已经太晚,感谢身边 每个人的悉心帮助与背后的默默支持。

从论文的选题、开题、论文的撰写与修改,陈老师帮助了许多。陈老师在 我心中是典型的刀子嘴豆腐心,看似面无表情、犀利,实则背后为论文操碎了 心,不论是提供论文意见还是请专家进行点评,都废了不少心血。陈老师不仅 仅是科研中的导师,更是我的人身道路上的导师!在即将毕业之际,衷心的向 陈老师致以敬意与感谢。

特别感谢实验室刘佳玮学姐研究生两年多来在学习和生活上提供了许多帮助,能够使我很快地适应新环境,不论是在论文、学业、实习都提供了很多宝贵的意见,顺利完成了学业。同时也感谢实验室同组小伙伴们曾经给予的各项帮助,正是你们的的帮助,能够使我在集体学习中完成毕业论文。

感谢我的室友陪伴我读过两年的研究生生活,感谢曾经充满欢声笑语的南园 11 舍 201。

最后感谢父母背后的支持与亲戚朋友默默的关心。

# 参考文献

- [1] 中国产业调研网. 中国金属结构制造行业调查分析及发展趋势预测报告 (2022-2028 年): 2185637[R]. 2021.
- [2] 潘新亮. 金属表面处理新工艺新技术及全过程质量控制检验标准规范实用 手册 [M]. [S.1.]:金属表面处理新工艺新技术及全过程质量控制检验标准规 范实用手册, 2005.
- [3] 于清峻. 探析金属材料焊接成型中的主要缺陷及控制措施 [J]. 科技创新与应用, 2013(11): 2.
- [4] 吴远峰; 金翠娥; 刘颖卓;. 基于机器视觉的智能检测方法研究 [C] // 第十一届 全国磁粉渗透检测技术年会论文集. 2017.
- [5] 丁雪, 刘颖. 复杂工业场景模式识别的探索与研究 [J]. 科技创新导报, 2012(35): 53-53.
- [6] 张恒喜. 小样本多元数据分析方法及应用 [M]. [S.1.]: 小样本多元数据分析 方法及应用, 2002.
- [7] JIA D, WEI D, SOCHER R, et al. ImageNet: A large-scale hierarchical image database[C] // . 2009: 248-255.
- [8] 陶显,侯伟,徐德.基于深度学习的表面缺陷检测方法综述 [J]. 自动化学报, 2021,47(5):18.
- [9] 冯晓硕, 沈越, 王冬琦. 基于图像的数据增强方法发展现状综述 [J]. 计算机科 学与应用, 2021, 11(2): 13.
- [10] ZHANG H, CISSE M, DAUPHIN Y N, et al. mixup: Beyond Empirical Risk Minimization[J], 2017.
- [11] DEVRIES T, TAYLOR G W. Improved Regularization of Convolutional Neural Networks with Cutout[J], 2017.

- [12] MIRZA M, OSINDERO S. Conditional Generative Adversarial Nets[J], 2014.
- [13] BAO J, CHEN D, WEN F, et al. CVAE-GAN: Fine-Grained Image Generation through Asymmetric Training[C] // 2017 IEEE International Conference on Computer Vision (ICCV). 2017: 2764–2773.
- [14] BUSLAEV A, PARINOV A, KHVEDCHENYA E, et al. Albumentations: fast and flexible image augmentations[J], 2018.
- [15] BLOICE M, ROTH P M, ANDREAS H. Biomedical image augmentation using Augmentor[J]. Bioinformatics, 2019(21): 21.
- [16] 何志勇, 林嵩. 一种面向外观缺陷视觉检测的数据集扩增方法 [P]..
- [17] 刘孝保, 刘佳, 阴艳超, et al. 基于超分辨率特征融合的工件表面细微缺陷数 据扩增方法 [J]. 计算机集成制造系统, 2021: 1-17.
- [18] 刘兆妍, 马翠红, 刘兆妮. 基于机器视觉的机械零件测量技术 [J]. 机械设计与制造, 2005(07): 144-146.
- [19] 陈兴,凌志浩.视觉检测技术在零件生产线上的应用 [C] // 2008 工业自动化 与仪表应用学术交流会. 2008.
- [20] 陈若望,周小红,高贵.机器视觉中图像匹配问题研究 [J].现代电子技术, 2011,34(18):5.
- [21] 黄英, 王永红. 传感器原理及应用 [M]. [S.1.]: 传感器原理及应用, 2016.
- [22] 赵士滨. 多媒体技术应用 [M]. [S.1.]: 多媒体技术应用, 2009.
- [23] 孙小燕. 基于机器视觉的粉末冶金零件缺陷检测系统研究 [J]. 中国金属通报, 2017(4): 2.
- [24] 李和仙. CCD 相机的微距测量补光装置设计 [J]. 重庆科技学院学报: 自然 科学版, 2020, 22(2): 4.
- [25] 邓海龙. 传感器与检测技术 [M]. [S.1.] : 传感器与检测技术, 2008.
- [26] 马玉真, 陶立英, 王新华. 计算机视觉技术的应用 [J]. 工程与试验, 2006, 46(1): 60-65.

- [27] 李立宗. 博文视点 AI 系列: OpenCV 轻松入门: 面向 Python[M]. [S.l.]: 电子工业出版社, 2019.
- [28] KOSCHAN A, ABIDI M. 彩色数字图像处理 [M]. [S.1.]: 彩色数字图像处理, 2010.
- [29] 黄小花. RGB 与 CMYK 色彩模式 [J]. 信息通信, 2012.
- [30] 袁奋杰, 周晓, 丁军, et al. 基于 FPGA 的 RGB 和 HSV 色空间转换算法实现 [J]. 电子器件, 2010, 33(4): 5.
- [31] 李迎春,曾峦,丁向丽. 图像的几何运算方法 [J]. 装备指挥技术学院学报, 2000(01):46-49.
- [32] 符祥, 郭宝龙. 图像插值技术综述 [J]. 计算机工程与设计, 2009(1): 5.
- [33] SIMARD P Y, STEINKRAUS D, PLATT J C. Best Practices for Convolutional Neural Networks Applied to Visual Document Analysis[C] // 7th International Conference on Document Analysis and Recognition (ICDAR 2003), 2-Volume Set, 3-6 August 2003, Edinburgh, Scotland, UK. 2003.
- [34] 霍宏涛. 数字图像处理 [M]. [S.l.]: 数字图像处理, 2003.
- [35] ZEILER M D, FERGUS R. Visualizing and Understanding Convolutional Neural Networks[J]. Springer International Publishing, 2013.
- [36] YAMAUCHI S, OSAMOTO A, INAMORI S, et al. Digital still camera system and method[J]. US, 2003.
- [37] 石美红, 申亮, 龙世忠, et al. 从 RGB 到 HSV 色彩空间转换公式的修正 [J]. 纺 织高校基础科学学报, 2008(03): 351-356.
- [38] 赵华龙, 梁志毅, 石兴春, et al. 利用 LED 的投影系统光源设计 [J]. 光子学报, 2007, 36(2): 244-246.
- [39] 王亚鹏. 机器视觉系统中镜头的选用技巧 [J]. 自动化博览, 2006, 23(1): 29-31.
- [40] 程正桦. CCD 与 CMOS 传感器技术与应用 [J]. 电子产品世界, 2003(04B): 4.

- [41] 付森原, 陈姝, 张钧, et al. 基于相机姿态信息的图像投影 [J]. 计算机与数字 工程, 2015, 43(10): 5.
- [42] 中国标准出版社第二室. 铝及铝合金标准汇编 [M]. [S.I.]: 铝及铝合金标准 汇编, 2004.
- [43] 王会凤. 型钢生产工艺 [M]. [S.1.]: 型钢生产工艺, 2006.
- [44] WOO M, NEIDER J, DAVIS T. OpenGL Programming Guide[J]. Addison Wesley Longman, 1993.
- [45] ZHILONG Z, 张志龙, CHUWEI L, et al. 基于成像过程模拟的图像数据扩增 方法研究 [C] //..
- [46] 王森,杨克俭.基于双线性插值的图像缩放算法的研究与实现 [J]. 自动化技术与应用, 2008, 27(7): 44-45.
- [47] SONG K, YAN Y. A noise robust method based on completed local binary patterns for hot-rolled steel strip surface defects[J]. Applied Surface Science: A Journal Devoted to the Properties of Interfaces in Relation to the Synthesis and Behaviour of Materials, 2013, 285(Nov.15 Pt.B): 858-864.
- [48] 蔡聪艺. 金属表面缺陷的机器视觉检测方法研究与实现 [J]. 成都大学学报: 自然科学版, 2020, 39(2): 4.
- [49] PAPER D. Build Your First Neural Network with Google Colab[M]. [S.l.]: TensorFlow 2.x in the Colaboratory Cloud, 2021.
- [50] LI J, LIANG X, SHEN S M, et al. Scale-aware Fast R-CNN for Pedestrian Detection[J]. IEEE Transactions on Multimedia, 2015, PP(99): 1-1.
- [51] HAGER G D, DEWAN M, STEWART C V. Multiple Kernel Tracking with SSD[C] // IEEE Computer Society Conference on Computer Vision Pattern Recognition. 2004.
- [52] 江磊, 崔艳荣. 基于 YOLOv5 的小目标检测 [J]. 电脑知识与技术: 学术版, 2021, 17(26): 3.