

分类号: TP391

密 级: 公 开

学校代码: 10363

学 号: 2220130104



安徽工程大学

Anhui Polytechnic University

硕士学位论文

题 目

基于 3D 结构光视觉的焊缝

缺陷检测方法研究

论 文 作 者

蔡磊

指 导 教 师

吴路路 副教授

学 科 (专 业)

人工智能

研 究 方 向

机器视觉

论文提交日期: 2025 年 5 月 20 日

分类号：TP391

单位代码：10363

密 级：公 开

学 号：2220130104

基于 3D 结构光视觉的焊缝缺陷检测方法研究
RESEARCH ON WELD DEFECT DETECTION METHOD
BASED ON 3D STRUCTURED LIGHT VISION

学生姓名：_____蔡磊_____

指导教师：_____吴路路 副教授_____

专 业：_____人工智能_____

研究方向：_____机器视觉_____

论文答辩日期：2025 年 5 月 9 日

安徽工程大学学位论文原创性声明

本人郑重声明：我恪守学术道德，崇尚严谨学风。所呈交的学位论文，是本人在导师的指导下，独立进行研究工作所取得的成果。除文中已明确注明和引用的内容外，本论文不包含任何其他个人或集体已经发表或撰写过的作品及成果的内容。论文为本人亲自撰写，我对所写的内容负责，并完全意识到本声明的法律后果由本人承担。

学位论文作者签名：蔡磊

日期：2025 年 5 月 9 日

安徽工程大学学位论文版权使用授权书

学位论文作者完全了解学校有关保留、使用学位论文的规定，同意学校保留并向国家有关部门或机构送交论文的复印件和电子版，允许论文被查阅或借阅。本人授权安徽工程大学可以将本学位论文的全部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和汇编本学位论文。

保密 ☐，在_____年解密后适用本版权书。

本学位论文属于

不保密 ☒。

学位论文作者签名：蔡磊

指导教师签名：吴路路

日期：2025 年 5 月 9 日

日期：2025 年 5 月 9 日

基于 3D 结构光视觉的焊缝缺陷检测方法研究

摘 要

焊缝缺陷检测是保证焊接产品质量不可或缺的重要工序。传统的人工目视检查焊缝缺陷的方式不仅效率低下、成本高昂、易受检测人员主观影响，而且难以满足现代工业自动化焊接的需求。基于 2D 视觉的焊缝缺陷检测方法易受弧光、火花等环境因素的干扰，并且在检测焊瘤、气孔等具有明显深度特征的缺陷时难以保证检测精度。3D 结构光视觉测量因其精度高、穿透性好和抗电磁干扰能力强等优势，广泛应用于缺陷检测领域。针对现有焊缝缺陷检测方法的不足，本文基于 3D 结构光视觉测量技术，结合点云处理算法和深度学习网络模型，探索焊缝表面缺陷的智能化检测方法，主要研究内容如下：

（1）分析了线结构光视觉测量中垂直入射测量和斜入射测量两种三角测量模型的基本原理，并将两种模型的优缺点进行了对比，研究了线结构光视觉测量中的相机标定、线结构光中心线提取、光平面标定以及三维重建方法，提出一种基于改进 Steger 算法的线结构光中心线精确提取方法。

（2）深入调研了正常焊缝、焊瘤、凹陷和气孔四种焊缝表面形貌的几何特征，以平板对接焊缝为研究对象，通过结构光视觉测量系统获取焊缝表面的点云数据，采用半径滤波算法、体素降采样算法以及坡度滤波算法对点云数据进行预处理，结合 CloudCompare 开源软件完成了焊缝点云的语义标注与数据增强工作，构建了基于语义分割的焊缝表面点云数据集。

（3）为实现焊缝缺陷检测，提出了一种结合 PointNet++ 网络模型与 DBSCAN 聚类算法的焊缝缺陷检测方法，该方法通过 PointNet++ 分割网络模型处理焊缝点云，获取焊缝点云中每个点的预测分类结果，采用 DBSCAN 聚类算法将分割出的缺陷点云实例化为独立的焊缝缺陷对象，从而实现焊缝缺陷检测。

（4）为验证所提焊缝缺陷检测方法的有效性与准确性，搭建了基于 3D 结构光视觉的焊缝缺陷检测实验平台，利用焊缝表面点云数据集完成了 PointNet++ 网络模型训练，设计了焊缝点云分割实验和缺陷点云实例化实验对所提方法的检测性能进行评估。实验结果表明，本文所提焊缝缺陷检测方法可以有效识别焊缝表面缺陷。

关键词：线结构光视觉，改进 Steger 算法，焊缝缺陷检测，PointNet++，DBSCAN 聚类算法

RESEARCH ON WELD DEFECT DETECTION METHOD BASED ON 3D STRUCTURED LIGHT VISION

ABSTRACT

Weld defect detection is to ensure the quality of welded products indispensable important process. The traditional manual visual inspection of weld defects is not only inefficient, costly, and subject to the subjective influence of inspectors, but also difficult to meet the needs of modern industrial automation welding. The 2D vision-based weld defect detection method is susceptible to the interference of arc light, sparks and other environmental factors, and it is difficult to ensure the detection accuracy when detecting defects with obvious depth characteristics such as weld tumors and pores. 3D structured light vision measurement is widely used in the field of defect detection due to its advantages of high accuracy, good penetrability and strong resistance to electromagnetic interference. Aiming at the shortcomings of the existing weld defect detection methods, this paper explores the intelligent detection method of weld surface defects based on 3D structured light vision measurement technology, combined with the point cloud processing algorithm and deep learning network model, and the main research contents are as follows:

(1) The basic principles of two triangulation models, vertical incidence measurement and oblique incidence measurement, are analyzed and the advantages and disadvantages of the two models are compared in line structured light vision measurement. Camera calibration, line structured light centerline extraction, optical plane calibration, and three-dimensional reconstruction methods in line structured light vision measurement are investigated, and an accurate extraction method of line structured light centerline based on the improved Steger algorithm is proposed.

(2) The geometric features of four types of weld surface features, namely normal weld seam, weld lump, depression and porosity, are investigated in depth. Taking the flat plate butt weld seam as the research object, the point cloud data of the weld seam surface is acquired by the structured light vision measurement system, and the radius filtering algorithm, voxel downsampling algorithm, and slope filtering algorithm are adopted to preprocess the point cloud data, and the semantic annotation and data

enhancement work is completed by combining with the open-source software of CloudCompare to construct a semantic segmentation-based point cloud data set. The semantic annotation and data enhancement work is completed with CloudCompare open source software, and the point cloud dataset of weld seam surface based on semantic segmentation is constructed.

(3) In order to realize weld defect detection, a weld defect detection method combining PointNet++ network model and DBSCAN clustering algorithm is proposed, which processes the weld point cloud through PointNet++ segmentation network model, obtains the prediction classification result of each point in the weld point cloud, and uses DBSCAN clustering algorithm to instantiate the segmented defect point cloud as an independent weld defect object, thus realizing weld defect detection.

(4) In order to verify the effectiveness and accuracy of the proposed weld defect detection method, an experimental platform for weld defect detection based on 3D structured light vision is built, the PointNet++ network model training is completed by using the weld surface point cloud dataset, and weld point cloud segmentation experiments and defect point cloud instantiation experiments are designed to evaluate the detection performance of the proposed method. The experimental results show that the proposed weld defect detection method can effectively identify the weld surface defects.

Cai Lei

Supervised by Associate Professor Wu Lulu

KEY WORDS: Line structured light vision, Improved Steger algorithm, Weld defect detection, PointNet++, DBSCAN clustering algorithm

目 录


摘 要	I
ABSTRACT	II
第 1 章 绪 论	1
1.1 研究背景及意义	1
1.2 基于视觉的焊缝缺陷检测方法研究现状	2
1.2.1 基于 2D 视觉的焊缝缺陷检测方法	2
1.2.2 基于 3D 视觉的焊缝缺陷检测方法	3
1.3 主要研究内容	5
1.4 论文章节安排	5
第 2 章 结构光视觉测量系统建模与分析	8
2.1 线结构光视觉测量原理	8
2.1.1 垂直入射测量	8
2.1.2 斜入射测量	9
2.1.3 对比分析	10
2.2 线结构光中心线提取算法	10
2.2.1 灰度重心法	10
2.2.2 Steger 算法	11
2.2.3 改进 Steger 线结构光中心精确提取方法	12
2.3 线结构光视觉测量系统标定及三维重建	17
2.3.1 相机标定	18
2.3.2 光平面标定	19
2.3.3 三维重建	20
2.4 本章小结	22
第 3 章 焊缝表面点云数据获取及数据集构建	23
3.1 焊缝点云数据获取	23
3.2 焊缝表面形貌特征分析	24
3.2.1 正常焊缝	24
3.2.2 焊瘤	24
3.2.3 凹陷	25
3.2.4 气孔	26
3.3 点云预处理	26

3.3.1 点云滤波.....	26
3.3.2 点云降采样.....	27
3.3.3 焊道点云提取.....	28
3.4 基于语义分割的焊缝表面点云数据集构建.....	31
3.4.1 数据准备及语义标注.....	31
3.4.2 数据增强.....	32
3.5 本章小结.....	33
第 4 章 基于深度学习的焊缝表面缺陷检测	34
4.1 点云深度学习基础理论.....	34
4.2 基于 PointNet++与 DBSCAN 聚类算法的焊缝缺陷检测.....	36
4.2.1 PointNet++网络架构	36
4.2.2 基于 DBSCAN 聚类算法的缺陷点云实例化方法	39
4.3 焊缝缺陷检测方法效果评价.....	42
4.4 本章小结.....	43
第 5 章 焊缝缺陷检测实验与结果分析	44
5.1 实验平台.....	44
5.2 焊缝缺陷检测实验.....	44
5.2.1 焊缝点云分割实验.....	44
5.2.2 缺陷点云实例化实验.....	46
5.3 本章小结.....	48
第 6 章 总结与展望	49
6.1 总 结.....	49
6.2 展 望.....	50
参考文献	51
攻读硕士期间的主要成果	54
致谢	55


第 1 章 绪 论

1.1 研究背景及意义

随着现代工业技术的快速发展，焊接作为一种重要的金属连接工艺，广泛应用于管道连接、航空航天、船舶制造、汽车生产等领域^[1]。焊接结构的安全性和完整性直接影响焊接产品的质量与性能。然而，在实际的焊接过程中，焊接工艺、焊接材料、人工操作等因素的变化均可能导致焊接部位出现难以预测的缺陷，如咬边、焊瘤、未焊透以及气孔等^[2]。这些缺陷不仅会影响焊接结构的美观和使用寿命，还会削弱焊接产品的承载能力，进而增加发生安全事故的风险。因此，在焊接过程中以及焊后对焊缝表面缺陷进行检测是保证焊接结构安全性与稳定性的重要环节。



(a) 管道焊接



(b) 船舶焊接



(c) 航天焊接



(d) 汽车焊接

图 1-1 焊接应用

为了检测焊缝表面可能存在的各种外观缺陷，研究适用的缺陷检查和分类方法对提高焊接件加工整体质量至关重要^[3]。传统的焊缝缺陷检测主要依赖人工目视的检测方式，该方式存在效率低、成本高和易受主观影响等问题，难以满足现代工业对于焊缝缺陷高效、准确的检测需求。因此，如何实现焊缝表面缺陷的智能化检测一直是焊接工业领域重点关注的课题。近年来，焊缝缺陷检测领域的研究主要集中在 X 射线检测^[4]、超声检测^[5]、红外热成像^[6]以及机器视觉检测等方向。随着计算机科学与图像处理技术的飞速发展，机器视觉检测技术因其高效率、高精度、非接触等特点被广泛应用在工业领域中^[7]。将机器视觉检测技术引入焊缝缺陷检测领域不仅能够显著降低检测成本，避免接触式检测可能对焊缝造成的二次损伤，而且能够有效提升检测结果的准确性和时效性。

综上所述，本文针对当前焊缝缺陷检测领域存在的问题，围绕焊缝缺陷检测

所涉及的焊缝表面数据获取、数据预处理以及缺陷识别等关键技术展开研究，以平板对接焊缝为研究对象，探索基于 3D 结构光视觉的焊缝表面缺陷智能化检测方法。

1.2 基于视觉的焊缝缺陷检测方法研究现状

1.2.1 基于 2D 视觉的焊缝缺陷检测方法

根据视觉维度的差异，基于机器视觉的焊缝缺陷检测方法可划分为 2D 视觉和 3D 视觉两大技术分支。相较于传统的人工检测方式，基于 2D 视觉的焊缝缺陷检测方法通过视觉传感器采集二维焊缝图像，结合图像处理算法提取图像中所包含的焊缝缺陷特征，能够更高效地识别焊缝表面存在的缺陷。为提升缺陷检测精度，国内外许多研究人员围绕焊缝缺陷检测工作中焊缝图像预处理、缺陷特征提取和焊缝缺陷分类等多项关键技术展开了深入研究。

为解决照明不均匀、噪声干扰和对比度不足等问题，国外的 Kumar G S^[8]等人开发了一种基于机器视觉的对接型焊缝缺陷检测系统，该系统使用 CCD 工业相机和四个 LED 光源获取四帧连续图像序列，然后从这些图像中分割出感兴趣区域，并计算每帧图像的平均灰度值，最后采用 BPN 分类器识别焊缝表面存在的缺陷。通过对 80 个真实焊接样本进行检测，该检测系统的总体准确率达到了 95%。针对搅拌摩擦焊接过程中出现的焊缝缺陷，Ranjan R^[9]等人提出了一种基于图像金字塔与图像重建算法的焊缝缺陷检测方法，该方法通过绘制每种缺陷对应的垂直强度图与面积图，定位焊缝缺陷并评估其严重程度。实验结果表明，该方法为基于在线反馈控制的焊接参数监控系统提供了有效的理论支持。

由于焊接材料多样性以及焊缝缺陷种类繁多，传统的图像处理算法在处理复杂焊缝缺陷时存在一定的局限性，特别是在缺陷类型较多且焊缝形态复杂的情况下，这些方法往往难以有效提取焊缝缺陷的细微特征。因此，诸多学者结合深度学习技术，通过改进特征提取方法、优化网络结构等方式，提升焊缝缺陷检测的准确性和鲁棒性。Vasan V^[10]及其团队提出了一种基于集成深度学习网络的埋弧焊缝表面缺陷检测方法，该方法首先通过灰度差异法、离散小波变换和快速傅里叶变换等图像处理技术对焊缝图像进行预处理和缺陷特征提取，然后使用基于集成学习的深度神经网络模型实现焊缝表面缺陷的定位与分类。实验结果表明，该方法能够准确识别埋弧焊缝表面存在的裂纹、未焊透和气孔缺陷。Tripicchio P^[11]等人研发了一种基于深度卷积神经网络的智能监控系统以检测燃油喷射器在生产过程中产生的焊接缺陷。Girshick R^[12]及其团队首先通过 Selective Search 算法从焊缝图像中分割出待检测区域，然后利用卷积神经网络提取这些待检测区域内的缺陷特征，最后使用支持向量机（SVM）实现焊缝缺陷的识别。

在国内，许多学者也在焊缝缺陷检测领域开展了研究。张鹏贤^[13]等人提出了

一种焊缝缺陷特征提取方法,该方法首先将焊缝图像转换为灰度图像,并采用多尺度 Retinex 算法进行亮度校正,然后通过引入模糊边缘检测算法从焊缝图像中提取缺陷区域,进而计算出焊缝缺陷的几何参数。实验结果表明,该方法虽然能够有效提取咬边、气孔等常见焊缝缺陷的几何特征,但是提取效率较低,难以满足实时检测的需求。罗莉^[14]基于小波变换的多尺度以及对奇异点高度敏感的特性,提出了一种管道焊缝缺陷检测方法,该方法首先使用小波变换对焊缝图像进行多尺度分解,以提取出图像中的有效特征信息,然后通过对不同的小波基进行对比分析,选择最合适的基函数,最后结合模极大值法对焊缝表面存在的细小缺陷进行检测。针对焊缝表面下塌缺陷检测精度低的问题,李尚仁^[15]等人先采用直方图均衡化算法对焊缝图像进行增强,然后使用改进的 Grab Cut 算法提取出焊缝图像中的感兴趣区域,最后通过结合形态学处理与连通域查找算法检测焊缝表面的下塌缺陷,并计算其几何特征。王宸^[16]等人建立了一个轮毂焊缝图像数据集,使用 Mish 函数和完备交并比(CIoU)替换 YOLOv3 算法原有的激活函数与损失函数,进而提出了一种改进 YOLOv3 算法对轮毂焊缝缺陷进行检测。实验结果表明,该算法在测试集上的检测精度达到了 99.29%。为了在液体火箭发动机喷管焊接过程中同时进行焊接缺陷检测和焊缝宽度测量,Zhou^[17]等人提出了一种多任务卷积神经网络模型(WDS-net),与单任务模型相比,该网络能够从焊接图像中提取更多的特征信息。实验结果表明,WDS-net 能够准确定位和识别螺旋管对接焊缝缺陷,并且测量得到的焊缝宽度平均误差控制在 0.1mm 以内。

1.2.2 基于 3D 视觉的焊缝缺陷检测方法

基于 2D 视觉的焊缝缺陷检测技术主要是先使用相机采集二维焊缝图像,然后通过图像处理技术与人工智能技术对焊缝图像进行预处理和特征提取操作,最终完成缺陷检测任务。然而,在实际焊接作业环境中,弧光、火花等环境因素的干扰往往导致获取到的焊缝图像质量较差,且存在大量噪声,极大地增加了焊缝缺陷检测工作的难度。同时,2D 视觉在数据采集的过程中无法获取焊缝表面的深度信息,因此在检测焊瘤、凹陷等深度特征较为明显的焊缝缺陷时,检测结果的准确性与检测效率较低。为解决这些问题,利用 3D 视觉定位并识别焊缝表面缺陷的焊缝缺陷检测方法得到了广泛关注与研究。相较于 2D 视觉,3D 视觉测量技术能够更全面地获取焊缝表面的几何特征,进而提升检测结果的准确性和稳定性。常用的 3D 视觉测量技术包括双目视觉^[18]、结构光视觉^[19]和光度立体视觉^[20]等。

针对焊接过程中对焊接熔池和焊缝几何形状的在线监测需求,Neill A M^[21]等人建立了一个基于双目视觉的焊接仿真成像模型以模拟焊接过程中焊接熔池与焊缝几何形状的动态变化,实现了熔池和焊缝的高精度三维重建,验证了基于双目视觉的焊缝缺陷检测方法的可行性。Boillot J P^[22]等人结合高精度结构光视

觉传感器和高速图像处理技术设计了一种激光焊接实时监测系统,该系统不仅能够精确测量激光焊缝的几何特征,自动识别气孔等焊缝表面缺陷,还支持自动化在线验证,确保激光焊缝满足质量标准和规格要求。Nguyen H C^[23]等人基于结构光视觉测量技术开发了一款焊接质量实时监测系统,并提出了一种基于滑动矢量方法的激光条纹特征点快速提取方法,实现了焊缝表面三维信息的实时获取。实验结果表明,该系统能够精确测量焊缝的高度及宽度,测量误差分别控制在 $\pm 0.1\text{mm}$ 和 $\pm 0.18\text{mm}$ 以内,并且可以有效识别错位、针孔等常见的焊缝表面缺陷。Lee K^[24]等人提出了一种线结构光中心线提取算法以实现焊缝外形的高精度测量,并基于深度神经网络建立了预测不同焊接工艺参数下焊缝内部几何特征与焊接接头拉伸强度的网络模型,提升了检测效率。Bestard G A^[25]等人通过融合结构光视觉传感器测量得到的焊缝几何特征、热成像数据以及焊接工艺参数,建立了基于多层感知机神经网络的焊缝动态几何模型。实验结果表明,该方法估算精度较高,计算延迟低,在工业生产环境中具有良好的应用前景。

在国内,济南大学的齐天宇^[26]在对双目视觉测量系统所获取的焊缝三维点云进行滤波、降采样等预处理操作后,将预处理得到的焊缝点云转换为焊缝深度图像,并提出了一种改进 YOLOv7 网络模型以识别焊缝深度图像中所包含的焊缝缺陷类型。实验结果表明,该网络模型能够有效提升咬边、焊瘤等焊缝表面缺陷的识别率。王荣浩^[27]等人首先建立了余高过高、咬边和未焊满三种常见焊缝缺陷的几何模型,然后将线结构光视觉传感器获取到的焊缝表面三维信息与几何模型进行对比,实现焊缝缺陷的快速识别与定位。哈尔滨工程大学的 Chu H H^[28]等人提出了一种基于线结构光视觉的焊后质量评估方法,该方法首先采用 RANSAC 算法从线结构光图像中提取焊接轮廓与特征点,然后结合三维重建算法计算特征点的三维坐标,实现焊接质量评估与缺陷检测。针对线结构光视觉传感器在扫描焊缝表面过程中出现的数据丢失问题, Jiang^[29]等人提出了一种焊缝表面点云修复算法,该方法通过结合双向反射分布函数(BRDF)与焊缝表面截面模型,推导出适用于描述待测焊缝表面三维点的公式。实验表明这一方法能够有效修复因环境光干扰、传感器角度等因素丢失的焊缝表面点云数据,进而提升焊缝缺陷检测的准确性。针对钢轨焊缝缺陷的检测需求,韦逍遥^[30]等人提出了一种基于光度立体视觉的钢轨焊缝打磨表面缺陷检测方法,该方法首先在多照明角度下采集钢轨焊缝打磨表面的光照图像,然后使用光度立体重建算法计算出焊缝表面的法向信息,最后通过结合横向纹路缺陷检测算法与高度突变缺陷检测算法对钢轨焊缝表面存在的缺陷进行检测。实验结果表明,该方法能够满足实际钢轨焊接生产中的检测需求。

综上所述,相较于基于 2D 视觉的焊缝缺陷检测方法,基于 3D 视觉的焊缝缺陷检测方法在准确性、稳定性以及实时性方面均展现出明显的优势。其中,3D

结构光视觉测量技术因其高抗干扰性、高精度等特点被广泛应用于缺陷检测领域。同时,随着点云神经网络的不断发展,基于点云数据处理的缺陷检测方法能够从焊缝点云中提取出更丰富的缺陷特征信息,进而提升检测精度。因此,本文将结合点云预处理算法和深度学习网络模型,探索基于 3D 结构光视觉的焊缝表面缺陷智能化检测方法。

1.3 主要研究内容

针对现有焊缝缺陷检测方法的不足,本文结合 3D 结构光视觉与深度学习网络模型,探索焊缝表面缺陷的智能化检测方法,主要研究内容如下:

(1) 对现有的焊缝缺陷检测方法进行了系统调研,分析了线结构光视觉测量中两种三角测量模型——垂直入射测量与斜入射测量的基本原理,并将两种模型的优缺点进行了对比,探讨了线结构光视觉测量系统中的关键环节,包括相机标定、线结构光中心线提取、光平面标定及三维重建等过程。此外,针对 Steger 算法提取线结构光中心线出现大量冗余点,导致中心线提取精度降低的问题,提出了一种基于改进 Steger 算法的线结构光中心线精确提取方法。

(2) 为实现焊缝表面缺陷检测,深入调研了正常焊缝、焊瘤、凹陷和气孔四种焊缝表面形貌的几何特征,并以平板对接焊缝为对象开展研究。通过结构光视觉测量系统获取焊缝表面的点云数据,采用半径滤波算法、体素降采样算法以及坡度滤波算法对焊缝点云进行预处理。结合 CloudCompare 开源软件,标注出焊缝点云中的缺陷区域,构建基于语义分割的焊缝表面点云数据集,并通过旋转变换点云的方式对数据集进行扩充。

(3) 论述了点云深度学习的基本理论,阐述了 PointNet++ 分割网络架构和 DBSCAN 聚类算法的基本原理,在此基础上提出一种结合 PointNet++ 网络模型与 DBSCAN 聚类算法的焊缝缺陷检测方法。同时分析了点云分割任务和缺陷检测任务中常用的评价指标,为后续评估所提焊缝缺陷检测方法的检测性能提供了理论依据。

(4) 搭建基于 3D 结构光视觉的焊缝缺陷检测实验平台。在上述构建的焊缝表面点云数据集的基础上,使用训练集和验证集对 PointNet++ 网络模型进行训练,并结合 DBSCAN 聚类算法完成了焊缝缺陷的检测任务。为验证所提方法的有效性与准确性,设计了焊缝点云分割实验和缺陷点云实例化实验,并通过对测试集中的焊缝样本进行检测,评估所提方法的检测性能。

1.4 论文章节安排

本文的组织结构如图 1-2 所示,具体内容如下:




图 1-2 文章组织结构

第 1 章：绪论。阐述了论文的选题背景及课题研究意义；概括了基于 2D 视觉和 3D 视觉的焊缝缺陷检测方法的研究现状；论述了本文的研究目的、研究内容以及论文组织结构。

第 2 章：结构光三维测量系统建模与分析。阐述了线结构光视觉中垂直入射测量和斜入射测量两种三角测量模型的基本原理，并对两种模型的优缺点进行了对比分析；总结了常用的线结构光中心线提取算法，提出了一种基于改进 Steger 算法的线结构光中心线精确提取方法；论述与分析了线结构光视觉测量中的相机标定、光平面标定以及三维重建方法。

第 3 章：焊缝表面点云数据获取及数据集构建。对获取到的实际焊缝表面点云数据进行了分析；针对原始焊缝表面点云数据的特点，采用半径滤波算法、体

素降采样算法以及坡度滤波算法对焊缝点云进行预处理；使用 CloudCompare 开源软件完成语义标注与数据增强的工作，构建了基于语义分割的焊缝表面点云数据集，为后续的缺陷检测工作提供数据基础。

第 4 章：基于深度学习的焊缝表面缺陷检测。概述了点云深度学习的基本理论；详细阐述了通过 PointNet++ 分割网络模型实现焊缝点云分割、获取焊缝点云中每个点的预测分类结果的流程；论述了采用 DBSCAN 聚类算法将分割出的缺陷点云实例化为独立的焊缝缺陷对象的基本原理，提出了一种基于 PointNet++ 网络模型和 DBSCAN 聚类算法的焊缝缺陷检测方法；对点云分割与缺陷检测中常用的评价指标进行了总结，以便后续评估所提焊缝缺陷检测方法的检测性能。

第 5 章：焊缝缺陷检测实验与结果分析。概述了焊缝缺陷检测实验平台的硬件组成；使用第三章构建的焊缝表面点云数据集训练深度学习网络模型，结合聚类算法以实现焊缝缺陷检测，设计了焊缝点云分割实验与缺陷点云实例化实验，以验证本文所提出的焊缝缺陷检测方法的有效性以及检测结果的准确性，对所提方法的检测性能进行评估。

第 6 章：总结与展望。对本文主要研究内容与研究结果进行总结，并对基于本研究内容的后续发展方向进行分析与展望。

第 2 章 结构光视觉测量系统建模与分析

在实际焊缝表面缺陷检测的过程中,由于焊接作业环境的复杂性与人工操作的不确定性,传统的焊缝表面缺陷检测方式如基于焊缝图像进行焊缝表面缺陷检测等方法容易受到弧光、火花等环境因素的干扰,难以保证检测精度。因此,本文选择使用线结构光视觉测量系统采集焊缝表面的点云数据。线结构光视觉测量具有穿透性好、抗干扰能力强、系统成本低和安装简单等优点,能够在抑制外部环境因素干扰的同时,更加精确地获取焊缝表面的三维信息。

本章从理论层面出发,首先对线结构光视觉测量的核心原理及常用的两种测量模型进行阐述,然后总结了常用的线结构光中心线提取算法存在的问题及解决思路,最后论述了使用线结构光视觉测量系统获取焊缝表面点云数据过程中涉及到的相机标定、光平面标定以及三维重建方法。

2.1 线结构光视觉测量原理

使用线结构光视觉获取焊缝表面三维信息的主要原理是通过向焊缝表面投射一束激光条纹,然后使用相机捕捉激光条纹在焊缝表面产生的形状畸变。当焊缝表面的空间坐标发生变化时,其反射光线在相机感光元件上的成像位置也会发生变动。通过解析焊缝表面空间坐标和成像位置之间的数学转换关系,最终能够计算出整个待测焊缝表面的三维空间坐标。

由于在上述测量过程中,必须确保相机与激光发射器之间的相对位置保持不变,且二者与待测焊缝构成一个三角形,因此该测量模型被称为三角测量模型。根据光源入射角的不同,三角测量模型可以分为垂直入射测量和斜入射测量。

2.1.1 垂直入射测量

当激光器发射的激光光束垂直于待测物体表面时,此时入射光线与反射光线不遵循反射定律。这种测量模型被称为垂直入射测量,如图 2-1 所示。将激光光束投射到待测物体表面后,漫反射光线 MN 和 BC 经过相机镜头中心 O,并在成像平面上成像。其中,物点 M 对应的成像点为点 N,物点 B 对应的成像点为点 C,待测物体表面法线与漫反射光线 BC 之间的夹角为 α ,漫反射光线 BC 与成像平面的夹角为 β 。

根据相似三角形原理,可以得出:

$$\frac{|MB| \times \sin \alpha}{|CN| \times \sin \beta} = \frac{|OB| - |MB| \times \cos \alpha}{|OC| + |CN| \times \cos \beta} \quad (2-1)$$

式中, $|MB|$ 表示待测物体表面的高度, $|CN|$ 表示物点 M 和物点 B 在成像平面的像点之间的距离, $|OB|$ 表示相机成像物距, $|OC|$ 表示相机成像像距。




图 2-1 垂直入射测量原理图

整理式(2-1)可得：

$$|MB| = \frac{|OC| \times |CN| \times \sin \beta}{|OB| \times \sin \alpha + |CN| \times \sin(\alpha + \beta)} \quad (2-2)$$

由于相机镜头的焦距 f 已知，则根据高斯成像原理可以得出以下关系：

$$\frac{1}{|OB|} + \frac{1}{|OC|} = \frac{1}{f} \quad (2-3)$$

联立式(2-2)和式(2-3)，则待测物体表面高度 $|MB|$ 与像点距离 $|CN|$ 之间的关系可以表示为：

$$|MB| = \frac{|OC| \times |CN| \times \sin \beta}{\frac{|OC| \times f}{|OC| - f} \times \sin \alpha + |CN| \times \sin(\alpha + \beta)} \quad (2-4)$$

2.1.2 斜入射测量

当激光器发射的激光光束不垂直于待测物体表面时，此时入射光线与反射光线遵循反射定律，即入射角等于反射角。这种测量模型被称为斜入射测量，如图 2-2 所示。其中，入射光线 LB 与反射光线 BC 之间的夹角为 α ，反射光线 BC 与成像平面的夹角为 β 。

根据相似三角形原理，可以得出：

$$\frac{\frac{|MA|}{\cos(\alpha/2)} \times \sin \alpha}{|CN| \times \sin \beta} = \frac{|OB| - |MB| \times \cos \alpha}{|OC| + |CN| \times \cos \beta} \quad (2-5)$$

式中， $|MA|$ 表示待测物体表面的高度， $|CN|$ 表示物点 M 和物点 B 在成像平面的像点之间的距离， $|OB|$ 表示相机成像物距， $|OC|$ 表示相机成像像距。




图 2-2 斜入射测量原理图

整理式(2-5)可得：

$$|MA| = \frac{|OC| \times |CN| \times \sin \beta \times \cos(\alpha / 2)}{|OB| \times \sin \alpha + |CN| \times \sin(\alpha + \beta)} \quad (2-6)$$

联立式(2-3)和式(2-6)，则待测物体表面高度 $|MA|$ 与像点距离 $|CN|$ 之间的关系可以表示为：

$$|MA| = \frac{|OC| \times |CN| \times \sin \beta \times \cos(\alpha / 2)}{\frac{|OC| \times f}{|OC| - f} \times \sin \alpha + |CN| \times \sin(\alpha + \beta)} \quad (2-7)$$

2.1.3 对比分析

在实际测量过程中，斜入射测量模型接收待测物体表面的反射光成像，能够通过改变入射角，从不同角度获取待测物体表面的几何特征，但是该测量模型容易受到光斑畸变、多角度数据配准等问题的影响，导致测量精度较低。而垂直入射测量模型接收待测物体表面的漫反射光成像，测量精度较高且测量结果稳定，同时对待测物体表面的高度变化更为敏感。综合上述分析，本文最终选用垂直入射测量模型开展焊缝表面缺陷检测方法研究。

2.2 线结构光中心线提取算法

在线结构光视觉测量系统中，相机所采集的激光条纹图像包含了被测焊缝表面的三维结构信息，是恢复焊缝表面三维坐标的重要依据^[31]。理论上投射至焊缝表面的线结构光条纹应当是无宽度的理想线条，但在实际获取的激光条纹图像中，线结构光条纹通常具有一定的宽度，因此需要对其进行中心线提取操作。线结构光中心线提取的精度直接影响到后续结构光传感器标定和焊缝表面三维重建的精度。常用的线结构光中心线提取算法有灰度重心法^[32]、Steger 算法^[33]等。

2.2.1 灰度重心法

灰度重心法是一种基于图像灰度特征的中心线提取算法，通过对激光条纹横

截面光强曲线的分析，逐列提取光条中心点。灰度重心法计算出的结构光条纹第 x 列的中心点坐标 (x_h, y_h) 可以表示为：

$$(x_h, y_h) = (x, \frac{\sum_{i=1}^N g(x, y_i) \times y_i}{\sum_{i=1}^N g(x, y_i)}) \quad (2-8)$$

式中， N 表示结构光条纹第 x 列的像素点个数， $g(x, y_i)$ 表示点 (x, y_i) 处的灰度值。可以看出，灰度重心法虽然计算简单，但只能提取出结构光中心点在单一方向上的亚像素坐标。

2.2.2 Steger 算法

Steger 算法利用 Hessian 矩阵和泰勒多项式展开来定位激光条纹在图像中的亚像素中心点。算法主要分为两个步骤：首先，通过 Hessian 矩阵确定光条中心的法线方向；然后，在法线方向上利用泰勒多项式展开计算出光条中心精确的亚像素坐标^[34,35]。Hessian 矩阵是一个二阶偏导数矩阵，用于描述函数在某点的局部曲率。在二维图像中，对于图像上的每一个点 (x, y) ，其 Hessian 矩阵可以表示为：

$$Hes(x, y) = \begin{Bmatrix} I_{xx} & I_{xy} \\ I_{xy} & I_{yy} \end{Bmatrix} \quad (2-9)$$

式中， I_{xx} 、 I_{xy} 、 I_{yy} 分别表示图像在点 (x, y) 处沿 x 、 y 方向的二阶偏导数。Hessian 矩阵特征值的大小反映了该特征值对应特征向量方向上光强分布函数的凹凸性，最大特征值对应的特征向量代表光强变化最剧烈的方向，即光条中心的法线方向。在确定了法线方向后，沿着该方向对光强分布函数进行泰勒多项式展开。设点 (x_0, y_0) 处法线方向的单位方向向量为 $e = [e_x, e_y]$ ，则在该方向上的光强分布函数可以表示为：

$$H(x_0 + t \cdot e_x, y_0 + t \cdot e_y) \approx g(x_0, y_0) + t \cdot e \cdot [I_x, I_y]^T + \frac{1}{2} t^2 \cdot e \cdot Hes(x_0, y_0) \cdot e^T \quad (2-10)$$

式中， t 表示激光条纹沿点 (x_0, y_0) 法线方向上的偏移量， $g(x_0, y_0)$ 表示点 (x_0, y_0) 处的灰度值， I_x 和 I_y 分别表示图像在点 (x_0, y_0) 处沿 x 方向和 y 方向的一阶偏导数。该式即为激光条纹在点 (x_0, y_0) 处的光强分布函数，使该式一阶导数为 0 的点就是光条沿点 (x_0, y_0) 法线方向上的光强极值点。

令 $\frac{\partial H}{\partial t} = 0$ 可得：

$$t = -\frac{e_x \cdot I_x + e_y \cdot I_y}{e_x^2 \cdot I_{xx} + 2e_x e_y I_{xy} + e_y^2 I_{yy}} \quad (2-11)$$

由于泰勒展开仅在很小的范围内适用,因此如果求出的 $t \cdot e_x$ 和 $t \cdot e_y$ 均小于0.5说明光强极值点处于当前像素内,光条中心坐标为 $(x_0 + t \cdot e_x, y_0 + t \cdot e_y)$ 。如果求出的 $t \cdot e_x$ 和 $t \cdot e_y$ 较大,则说明光强极值点不在当前像素内,需要跳过当前像素点继续扫描距离激光中心更近的点。然而,靠近光条中心的像素区域内通常存在大量亮度相近的像素点,在基于这些像素点提取中心点的过程中可能会将多个符合上述条件的邻近极值点标记为中心点;同时,传感器噪声、环境光干扰等也可能使光条边缘或中心区域的光强分布发生波动,导致标记出错误的中心点,从而降低中心线提取精度。

2.2.3 改进 Steger 线结构光中心精确提取方法

2.2.3.1 改进方法线结构光中心线提取流程

传统 Steger 算法在进行线结构光中心点提取的过程中,由于受灰度值饱和以及实际光强分布不一定满足高斯分布等因素的影响,导致该算法在光条亮度高以及包含较多像素点的区域进行中心点提取时,会标记出较多冗余点,如图 2-3 所示,冗余中心点的存在将直接影响后续线结构光中心线拟合、三维重建的精度。




图 2-3 原始 Steger 算法冗余中心点问题

针对此问题,本文提出一种改进方法,实现结构光中心线的精确提取。该方法首先对激光条纹图像进行阈值分割和滤波处理,抑制噪声干扰,从而有效截取激光条纹所在区域;在此基础上,使用 Steger 算法提取激光条纹初始中心点集;然后采用固定阈值法筛选包含冗余中心点的邻近点;最后通过对邻近中心点进行加权优化处理,获取精确的线结构光中心点像素坐标,中心线提取具体流程如图 2-4 所示。

第一步:对相机采集到的激光条纹图像进行预处理,预处理的内容包括灰度变换、阈值分割和滤波等。分割采用大津法确定分割阈值,将低于阈值的像素点灰度值设置为 0,确保中心点提取不会受到图像背景的干扰;滤波采用高斯滤波

方式，滤波核大小为 11×11 。第二步：通过 Steger 算法提取图像中结构光条纹的初始中心点集 S 。第三步：根据初始中心点集 S 确定筛选阈值 T 。第四步：使用固定阈值法筛选出冗余中心点集 P 。第五步：使用双线性插值法计算冗余中心点的灰度值。第六步：使用灰度值加权计算这些点的坐标的加权平均值，作为新的中心点 R_i 。第七步：使用新的中心点 R_i 替换点集 C 中被筛选出的冗余中心点，最终得到新的中心点集 R 。




图 2-4 改进算法线结构光中心线提取流程

2.2.3.2 邻近中心点加权优化算法

为滤除冗余中心点，本文提出一种邻近中心点加权优化算法，该算法以 Steger 算法提取的中心点作为初始中心点集，通过固定阈值法筛选出包含冗余中心点的邻近点，同时进行加权优化处理，从而得到更精确的中心点坐标，算法实现过程如下：

Step1: 对于图 2-5 所示激光条纹，在使用 Steger 算法进行初始结构光中心点提取时，采用逐行搜索的方式扫描像素点，并将提取到的中心点存储在点集 S 中。根据提取过程中冗余中心点之间的位置关系， x 方向上的距离远小于 y 方向上的距离的特点，将点集 S 中的中心点按照 y 坐标从大到小的顺序排列后存储到点集 C 当中。

Step2: 在 Steger 算法提取出初始中心点后，通过设置筛选阈值 T 从初始中心点中筛选出相邻的冗余中心点进行处理。根据不同实验环境下 Steger 算法所

提取初始中心点的离散程度差异，阈值 T 通常被设定在 0.6 到 1.0 的区间内。当提取出的初始中心点离散程度较大，即各中心点的空间分布较为分散时，为了有效去除提取出的冗余点，应当设置一个较高的阈值 T (0.8~1.0) 来进行进一步的筛选和处理；当提取出的初始中心点离散程度较小，即各中心点的空间分布相对集中时，则应当设置较低的阈值 T (0.6~0.8) 以保证数据的完整性，避免过度去除有效中心点。




图 2-5 激光条纹图像




图 2-6 冗余中心点筛选与加权处理流程

Step3: 从点集 C 中提取符合极差要求的中心点存储到点集 P 中，并对点集 P 中的点进行加权处理。具体流程如图 2-6 所示。

首先，从点集 C 中按顺序选取中心点 C_i ，计算点 C_i 和点集 P 中所有点 y 坐标的极差 D ：

$$D = y_{\max} - y_{\min} \leq T \quad (2-12)$$

式中， $y_{\max}$ 表示点集 P 内所有已存在的点与点 C_i 中 y 坐标的最大值， $y_{\min}$ 表示这些点中 y 坐标的最小值。

判断极差 D 是否超过设定阈值 T ，如果 $D \leq T$ ，则直接将点 C_i 添加到点集 P 中，并从点集 C 中取出下一个中心点 C_{i+1} 重新执行上述判断过程；如果 $D > T$ ，则停止向点集 P 中添加中心点，然后使用双线性插值法来计算点集 P 中每个中心点的灰度值 $g(x_j, y_j)$ ：

$$\begin{aligned} g(x_j, y_j) = & (1 - x_j + [x_j])(1 - y_j + [y_j])g([x_j], [y_j]) \\ & + (x_j - [x_j])(1 - y_j + [y_j])g([x_j] + 1, [y_j]) \\ & + (y_j - [y_j])(1 - x_j + [x_j])g([x_j], [y_j] + 1) \\ & + (x_j - [x_j])(y_j - [y_j])g([x_j] + 1, [y_j] + 1) \end{aligned} \quad (2-13)$$

式中， x_j 表示点集 P 中第 j 个点的列坐标； y_j 表示点集 P 中第 j 个点的行坐标； $[x_j]$ ， $[y_j]$ 分别表示取不大于 x_j ， y_j 的最大整数。

接着基于点集 P 中每个点的灰度值分配权重，通过计算点集 P 中所有点坐标的加权平均值，得到一个新的中心点坐标 (x_c, y_c) ，计算公式如下：

$$\begin{cases} x_c = \frac{\sum_{j=1}^n g(x_j, y_j) \cdot x_j}{\sum_{j=1}^n g(x_j, y_j)} \\ y_c = \frac{\sum_{j=1}^n g(x_j, y_j) \cdot y_j}{\sum_{j=1}^n g(x_j, y_j)} \end{cases} \quad (2-14)$$

式中， n 表示点集 P 中点的个数。完成加权计算后，将计算出的中心点坐标 (x_c, y_c) 作为点集 R 中的点添加到点集 R 中。在进行新一轮中心点优化前，将点集 P 中所有的点从点集 C 中删除，更新点集 C ，同时清空点集 P 。

Step4: 重复执行 step3 中的操作，直至点集 C 中的所有中心点都被遍历。此时，点集 R 中存储的点即为最终优化后的线结构光中心点。

如图 2-7(a)、图 2-7(c)和图 2-7(e)所示，当仅使用 Steger 算法进行结构光中心线提取时，在亮度较高且激光条纹较粗的区域会出现标记出多个冗余中心点的情况，且在端点处表现的更为明显。通过使用所提改进算法，提取到的激光条纹中心线如图 2-7(b)、图 2-7(d)和图 2-7(f)所示。对比 Steger 算法和所提方法的提

取结果可以看出本文提出的改进算法能够有效减少冗余中心点数量,提升中心点分布紧密度,显著提高线结构光中心线提取的质量。




图 2-7 线结构光中心线对比图

- (a) Steger 算法提取出的线结构光中心线 L_1 (b) 改进算法提取出的线结构光中心线 L_1'
(c) Steger 算法提取出的线结构光中心线 L_2 (d) 改进算法提取出的线结构光中心线 L_2'
(e) Steger 算法提取出的线结构光中心线 L_3 (f) 改进算法提取出的线结构光中心线 L_3'

为进一步验证所提方法在复杂环境下的提取性能,将激光条纹投射至一表面光滑的金属平面上并完成图像采集。相机所拍摄的激光条纹图像如图 2-8(a)所示,图中展示的激光条纹宽度分布不均匀,且部分区域存在明显反光。通过阈值分割、滤波等预处理操作抑制背景噪声干扰后,分别使用 Steger 算法和本文所提改进算法对该图像所包含的结构光中心线进行提取。

如图 2-8(b)所示,Steger 算法在激光条纹较细的区域能够有效提取出结构光中心线,但是在激光条纹较粗且存在反光的区域,其提取结果出现了明显的偏差。对比图 2-8(c)可以看出,本文所提算法不仅在 Steger 算法的基础上对冗余中心点坐标进行了校正,使其更接近光条的实际中心,而且在光条较粗、存在反光的区域同样能够有效地提取出结构光中心线,具有较好的稳定性。




图 2-8 金属表面线结构光中心线对比图

(a) 金属表面激光条纹图像

(b) Steger 算法提取出的线结构光中心线 L_4 (c) 改进算法提取出的线结构光中心线 L_4'

2.2.3.3 中心线提取精度分析

为评估所提方法中心线提取精度，针对前述获取的激光条纹图像提取到的结构光中心线，分别统计传统 Steger 算法与本文所提改进算法所提取的中心点的个数，计算 Steger 算法和改进算法所提取中心点距离拟合直线的平均距离与均方根误差，结果如表 2-1 所示。

表 2-1 Steger 算法和所提算法提取的线结构光中心点数量及精度结果

序号	提取中心点数量		距拟合直线平均距离 (pixel)		距拟合直线均方根误差 (pixel)	
	Steger	本文算法	Steger	本文算法	Steger	本文算法
1	884	791	0.623952	0.53575	0.86839	0.668339
2	1023	760	0.95473	0.625651	1.15692	0.78214
3	1174	606	0.630041	0.34931	0.76577	0.453524
4	1626	602	2.04981	0.817167	2.8699	1.33076

通过表 2-1 的数据可以看出，对于包含相同激光条纹的图像，相较于传统 Steger 算法，本文算法提取出的中心点数减少了 41.8%，滤除了大量冗余点。在精度方面，从表 2-1 中可以求出，传统 Steger 算法所有中心点距离拟合直线的平均距离为 1.18991 pixel，均方根差为 1.59691 pixel；改进算法所有中心点距离拟合直线的平均距离为 0.58097 pixel，均方根差为 0.79704 pixel。结果表明，所提出改进算法能够有效提升线结构光中心点提取精度。

2.3 线结构光视觉测量系统标定及三维重建

线结构光视觉测量系统主要由相机传感器和激光发射器两部分组成，为了获取焊缝表面的三维信息，首先需要对测量系统中的相机参数和光平面参数进行标定，然后在此基础上将结构光中心线提取算法计算得到的中心点像素坐标转换为三维空间坐标，最终得到焊缝表面的三维点云数据。本节将对线结构光视觉测量系统中的相机标定、光平面标定及三维重建方法进行论述。

2.3.1 相机标定

相机成像主要涉及到像素坐标系、图像坐标系、相机坐标系以及世界坐标系 4 个坐标系之间的坐标转换。

(1) 如图 2-9 所示，像素坐标系以图像左上角点 O 作为坐标原点，像素列方向为 u 轴，像素行方向为 v 轴；图像坐标系以相机光轴与图像平面的交点 O_n 为原点， X_n 轴平行于像素坐标系的 u 轴， Y_n 轴平行于像素坐标系的 v 轴。

假设点 O_n 的像素坐标为 (u_0, v_0) ，则图像平面中任意一点的像素坐标 (u, v) 与图像坐标 (x_n, y_n) 之间的转换关系可以表示为：

$$\begin{bmatrix} u \\ v \\ 1 \end{bmatrix} = \begin{bmatrix} \frac{1}{dx} & 0 & u_0 \\ 0 & \frac{1}{dy} & v_0 \\ 0 & 0 & 1 \end{bmatrix} \begin{bmatrix} x_n \\ y_n \\ 1 \end{bmatrix} \quad (2-15)$$

式中， dx 表示像素坐标系中单个像素在 X_n 轴方向上的物理尺寸， dy 表示像素坐标系中单个像素在 Y_n 轴方向上的物理尺寸。




图 2-9 像素坐标系和图像坐标系

(2) 相机坐标系以相机光心为原点 O_{cam} ，以相机光轴为 Z_{cam} 轴， X_{cam} 轴和 Y_{cam} 轴分别与图像坐标系中 X_n 轴和 Y_n 轴平行。像素坐标 (u, v) 到相机坐标 $(x_{cam}, y_{cam}, z_{cam})$ 的转换关系可以表示为：

$$\begin{bmatrix} x_{cam} \\ y_{cam} \\ z_{cam} \end{bmatrix} = z_{cam} M^{-1} \begin{bmatrix} u \\ v \\ 1 \end{bmatrix} = z_{cam} \begin{bmatrix} f_x & 0 & u_0 & 0 \\ 0 & f_y & v_0 & 0 \\ 0 & 0 & 1 & 0 \end{bmatrix}^{-1} \begin{bmatrix} u \\ v \\ 1 \end{bmatrix} \quad (2-16)$$

式中， M 被称为相机内参数， $f_x = f / dx$ ， $f_y = f / dy$ 。可以看出，由于 z_{cam} 的值是未知的，所以像素坐标系中的一个坐标对应相机坐标系中的多个物点。

(3) 相机坐标 $(x_{cam}, y_{cam}, z_{cam})$ 和世界坐标 (x_w, y_w, z_w) 之间属于刚体变换，可以通过旋转平移操作完成坐标之间的转换，二者之间的关系可以表示为：

$$\begin{bmatrix} x_{cam} \\ y_{cam} \\ z_{cam} \end{bmatrix} = R \begin{bmatrix} x_w \\ y_w \\ z_w \end{bmatrix} + T \quad (2-17)$$

式中, R 和 T 是世界坐标系相对于相机坐标系的旋转矩阵和平移向量, 被称为相机的外参数。相机标定的主要目的就是确定相机的内参和外参, 二者均可以通过张正友标定法使用棋盘格标定的方式计算得到。

2.3.2 光平面标定

通过相机标定计算出相机的内参和外参后, 由于比例因子 z_{cam} 的存在, 仍然无法直接将结构光中心线提取算法计算得到的中心点像素坐标转换为三维空间坐标。因此, 需要将结构光条纹投射到标定板平面上并以此确定光平面方程, 增加几何约束条件, 从而计算出焊缝表面的三维坐标。线结构光成像模型如图 2-10 所示。




图 2-10 线结构光成像模型

由式 (2-16) 和式 (2-17) 可以得到像素坐标和世界坐标之间的转换关系为:

$$z_{cam} \begin{bmatrix} u \\ v \\ 1 \end{bmatrix} = M \left\{ R \begin{bmatrix} x_w \\ y_w \\ z_w \end{bmatrix} + T \right\} \quad (2-18)$$

在光平面标定过程中, 世界坐标系通常是在相机标定所使用的标定板图像中的角点基础上建立的, 因此可知 $z_w = 0$, 则可以得到:

$$Z_{cam} R^{-1} M^{-1} \begin{bmatrix} u \\ v \\ 1 \end{bmatrix} = \begin{bmatrix} x_w \\ y_w \\ 0 \end{bmatrix} + R^{-1} T \quad (2-19)$$

记 $R^{-1} M^{-1} \begin{bmatrix} u \\ v \\ 1 \end{bmatrix} = \begin{bmatrix} a \\ b \\ c \end{bmatrix}$, $R^{-1} T = \begin{bmatrix} t_1 \\ t_2 \\ t_3 \end{bmatrix}$, 得:

$$Z_{cam} \begin{bmatrix} a \\ b \\ c \end{bmatrix} = \begin{bmatrix} x_w \\ y_w \\ 0 \end{bmatrix} + \begin{bmatrix} t_1 \\ t_2 \\ t_3 \end{bmatrix} \quad (2-20)$$

由式 (2-20) 最后一行可以计算出 z_{cam} 的值为:

$$z_{cam} = \frac{t_3}{c} \quad (2-21)$$

由此可得, 标定板平面上某一点的世界坐标可以表示为:

$$\begin{bmatrix} x_w \\ y_w \\ 0 \end{bmatrix} = \frac{t_3}{c} \begin{bmatrix} a \\ b \\ c \end{bmatrix} - \begin{bmatrix} t_1 \\ t_2 \\ t_3 \end{bmatrix} \quad (2-22)$$

至此就可以实现投射到标定板上的结构光条纹中心点的像素坐标 (u, v) 与世界坐标 $(x_w, y_w, 0)$ 之间的转换。

但仅仅使用一张包含结构光条纹的标定板图像还无法拟合出光平面方程, 在至少改变一次标定板位姿的情况下再拍摄一张或多张带有结构光条纹的标定板图像并通过上述步骤计算出结构光中心点的世界坐标。由于在线结构光视觉测量系统中, 相机与激光发射器之间的位置关系保持不变, 所以将所有结构光中心点的世界坐标 (x_w, y_w, z_w) 通过式 (2-17) 统一转换到相机坐标系中, 然后使用最小二乘法拟合出光平面方程, 完成光平面标定:

$$Ax_{cam} + By_{cam} + Cz_{cam} + D = 0 \quad (2-23)$$

2.3.3 三维重建

在完成相机标定和光平面标定后, 通过联立式 (2-16) 和式 (2-23) 就可以得到投射至焊缝表面的线结构光中心线上任意一点的像素坐标 (u, v) 与相机坐标 $(x_{cam}, y_{cam}, z_{cam})$ 之间的转换关系为:

$$z_{cam} \begin{bmatrix} u \\ v \\ 1 \\ 0 \end{bmatrix} = \begin{bmatrix} f_x & 0 & u_0 & 0 \\ 0 & f_y & v_0 & 0 \\ 0 & 0 & 1 & 0 \\ A & B & C & D \end{bmatrix} \begin{bmatrix} x_{cam} \\ y_{cam} \\ z_{cam} \\ 1 \end{bmatrix} \quad (2-24)$$

整理式 (2-24), 可得:

$$\begin{bmatrix} \frac{x_{cam}}{z_{cam}} \\ \frac{y_{cam}}{z_{cam}} \\ 1 \\ 1 \\ \frac{1}{z_{cam}} \end{bmatrix} = \begin{bmatrix} f_x & 0 & u_0 & 0 \\ 0 & f_y & v_0 & 0 \\ 0 & 0 & 1 & 0 \\ A & B & C & D \end{bmatrix}^{-1} \begin{bmatrix} u \\ v \\ 1 \\ 0 \end{bmatrix} \quad (2-25)$$

根据上述三维重建原理，对 2.2.3 节中传统 Steger 算法和改进 Steger 算法提取出的线结构光中心点数据进行三维重建，结果如图 2-11 所示。由图可以看出本文提出的线结构光中心线精确提取方法能够有效滤除传统 Steger 算法提取时存在的冗余点，进而提升结构光三维重建的质量。




图 2-11 三维重建对比图

由于线结构光视觉测量每次只能获取单条结构光条纹中所包含的焊缝表面三维信息，因此，需要将线结构光视觉传感器装配在一维运动平台上，通过控制该运动平台等间距移动并同步进行数据采集，最终实现对整个焊缝表面的三维重建。

假设一维运动平台每次移动操作在相机坐标系下所产生的运动向量为 $[x_d, y_d, z_d]^T$ ，线结构光视觉测量系统获取到的焊缝表面在当前相机坐标系下的坐标为 $(x_{cam}, y_{cam}, z_{cam})$ ，则以第一次进行数据采集时的相机坐标系为基准坐标系，

最终得到的焊缝表面的三维坐标 (x_m, y_m, z_m) 可以表示为:

$$\begin{bmatrix} x_m \\ y_m \\ z_m \end{bmatrix} = \begin{bmatrix} x_{cam} \\ y_{cam} \\ z_{cam} \end{bmatrix} + m \begin{bmatrix} x_d \\ y_d \\ z_d \end{bmatrix} \quad (2-26)$$

式中, m 表示一维运动平台的移动次数。

2.4 本章小结

本章首先阐述了线结构光视觉测量中垂直入射测量和斜入射测量两种三角测量模型的基本原理, 并对两种模型进行了对比分析; 然后概述了常用的线结构光中心线提取算法, 提出了一种基于改进 Steger 算法的线结构光中心线精确提取方法, 并对其提取精度进行评估; 最后对线结构光视觉测量中的相机标定、光平面标定以及三维重建方法进行了论述与分析。

第 3 章 焊缝表面点云数据获取及数据集构建

获取焊缝表面点云数据是进行焊缝表面缺陷检测工作的首要前提。本章节基于第二章所介绍的结构光视觉测量系统获取了实际焊缝表面的三维点云数据，并对这些点云数据进行相应的预处理操作，以提高焊缝表面点云质量并提升后期点云数据的处理速度，然后基于预处理后的点云数据，构建了基于语义分割的焊缝表面点云数据集，为后续研究基于深度学习网络模型的焊缝表面缺陷检测方法提供了数据支持，具体流程如图 3-1 所示。




图 3-1 焊缝表面点云数据集构建流程

3.1 焊缝点云数据获取

在焊接作业过程中，焊缝表面常因焊接工艺、焊接材料、人工操作等因素的影响，产生各种类型的缺陷或瑕疵。常见的焊接表面缺陷包括焊瘤、凹陷、气孔、咬边等。本文主要研究焊瘤、凹陷和气孔这三种焊缝表面缺陷的检测方法。鉴于在平板对接焊缝上能够高效地提取以上三种缺陷的三维特征，本文以平板对接焊缝作为研究对象，将第二章所介绍的结构光视觉传感器装配在三自由度机器人运动平台上，获取实际焊缝表面的三维点云数据。在数据获取过程中，结构光视觉测量系统中相机坐标系的 Y_{cam} 轴与机器人运动平台的 Y 轴保持平行，且机器人运动平台采用步进式位移，沿运动平台的 Y 轴正方向以 1mm 的步距进行移动。如图 3-2 所示，获取到的焊缝表面点云数据为 txt 格式文件，包含了焊缝表面的三维空间坐标。点云可视化结果如图 3-3 所示。

```
//X Y Z  
-125.22899628 10.00000000 25.10000038  
-125.05999756 10.00000000 25.06080055  
-124.89099884 10.00000000 25.02720070  
-124.72200012 10.00000000 25.06640053  
-124.55300140 10.00000000 25.16160011  
-124.38400269 10.00000000 25.13920021  
-124.21499634 10.00000000 25.05520058  
-124.04599762 10.00000000 25.08320045  
-123.87699890 10.00000000 25.19519997  
-123.70800018 10.00000000 25.28479958  
-123.53900146 10.00000000 25.25119972
```

图 3-2 txt 点云文件




图 3-3 点云可视化结果图


3.2 焊缝表面形貌特征分析

3.2.1 正常焊缝

如图 3-4 所示，正常焊缝的表面平整光滑，纹理规整且均匀，且没有明显的凹凸缺陷。使用结构光视觉传感器所获取的正常焊缝表面的点云通常较为完整和紧密，无异常的点云缺失与高度变化现象。



(a) 正常焊缝表面



(b) 焊缝表面点云

图 3-4 正常焊缝表面示意图

3.2.2 焊瘤

焊瘤缺陷是在焊接过程中，由于熔化的液态金属流出焊缝外部并凝固形成的金属瘤。其形成的原因主要是焊接时电流过大，导致熔池温度升高，使得熔池体积增大，液态金属在自重作用下下坠并形成焊瘤。此外，焊接操作不当或焊接人

员经验不足也是焊瘤产生的常见原因。焊瘤缺陷的存在不仅会影响焊接结构的外观，还可能导致应力集中，降低结构的强度，进而引发安全隐患。



(a) 焊瘤焊缝表面

(b) 焊缝表面点云

图 3-5 焊瘤缺陷表面示意图

如图 3-5 所示，焊瘤缺陷区域呈现为焊接部位表面凸起的团状或球状金属瘤。与焊缝的其他区域相比，焊瘤部位的母材堆积较为集中，缺陷区域明显高于其他焊缝区域。此外，焊瘤缺陷通常具备较好的连通性，不存在明显的断裂或断点。由于焊瘤缺陷的凸起形态，使用结构光视觉传感器所获取的焊瘤缺陷区域的点云分布通常更为紧密，能够准确反映焊瘤的形态与位置。但是，焊瘤缺陷下方与靠近焊接母板的点云可能会受到焊瘤缺陷遮挡的影响，进而导致部分点云数据的丢失。

3.2.3 凹陷

凹陷缺陷的形成主要由以下原因引起：一是由于焊接功率或保护气体压力过高导致烧穿或严重的熔体飞溅，并且缺乏足够的焊丝进行填充，进而形成凹陷；二是由于熔池中熔体的公差较小，同样造成熔体飞溅后形成凹陷。凹陷缺陷会导致焊接接头的强度下降，影响结构的承载能力，增加发生断裂的风险。



(a) 凹陷焊缝表面


(b) 焊缝表面点云

图 3-6 凹陷缺陷表面示意图

如图 3-6 所示，凹陷缺陷区域主要表现为焊接部位未能完全熔合，形成了明显的洼陷形貌，外观上通常呈现为椭圆形状，并且具有不连续、游离或错位的特点。使用结构光视觉传感器所获取的凹陷缺陷区域的空间点高度低于正常焊缝表面，且点云分布通常较为稀疏，呈现出明显的几何特征。

3.2.4 气孔

气孔缺陷是在焊接过程中熔池中未能及时排出的气泡在焊缝金属内部形成的空洞区域。焊接速度过快或电流较小而造成熔池温度过低，无法有效排出气体是气孔缺陷产生的主要原因。气孔缺陷的存在会导致焊接部位的横截面积减小，降低焊接结构的强度与密封性，进而在后续的使用过程中引发严重的安全隐患。



(a) 气孔焊缝表面

(b) 焊缝表面点云

图 3-7 气孔缺陷表面示意图

如图 3-7 所示，气孔缺陷区域主要表现为焊接区域内出现的小型圆状空洞结构，这些空洞的直径和深度受焊接工艺及焊接金属材料特性的影响，且缺陷区域可能包含单个或者多个气孔。使用结构光视觉传感器所获取的气孔缺陷区域的空间点数量通常较少，且常伴随点云缺失现象。

3.3 点云预处理

在获取焊缝表面点云数据的过程中，由于受到采集设备精度、人工操作以及工况环境等因素的影响，所获取的焊缝原始点云数据中往往会存在一些偏离主体点云的噪声点。为解决这一问题，需要使用点云滤波算法滤除空间中的噪声点。然而，经过滤波处理后的点云数据依然保持着庞大的数据量，不仅需要占用大量的存储空间，而且在实验过程中可能会消耗过多的计算资源，从而降低实验整体的时效性，为提升后续点云数据的处理速度，引入点云降采样操作对焊缝点云数据进行精简化处理。此外，焊缝点云中的焊接母板区域与焊缝缺陷检测任务关联较少，为了排除焊接母板点云对后续焊缝表面缺陷检测工作的干扰，在点云预处理阶段使用点云去除地面点算法实现焊道点云的提取。

3.3.1 点云滤波

常用的点云滤波算法包括直通滤波、统计滤波、半径滤波等^[36]：

(1) 直通滤波：直通点云滤波是一种通过对点云数据的空间范围进行约束来筛选有效数据的方法。其原理是通过设定点云中每个点在 X 、 Y 和 Z 坐标轴上的最大值和最小值，来定义一个空间范围，只有处于这个空间范围内的点才会被保留下来，超出范围的点会被滤除。当噪声点与目标点之间有较大间隔或噪声点大面积存在时，直通滤波能够通过简单的坐标范围限制，滤除掉这些不相关的噪

声点。

(2) 统计滤波：统计点云滤波是一种基于点云数据局部邻域的统计特征进行噪声点去除的方法。其原理是通过计算每个点在指定邻域范围内的点的统计特征（如均值、方差、标准差等），并根据这些统计量来判断该点是否为噪声点。当点云中的某个点的邻域内的点分布较为稀疏或该点与邻近点之间的距离过大时，该点将被视为噪声点并被剔除。而当该点邻域内的点分布较为密集且符合一定的统计特征时，则将其保留。统计滤波主要适用于去除较为明显的小规模噪声点，但该方法计算量较大，且对预先设置的参数过于敏感，难以保证滤波效果。

(3) 半径滤波：半径点云滤波是一种基于点云数据中每个点的局部邻域内点云密度来去除噪声点的技术。其基本原理是对于点云中每个点，设定一个固定的半径范围，然后计算该点在该半径范围内邻近点的数量。如果邻近点的数量小于预设的阈值，则认为该点为噪声点，将其剔除；如果邻近点的数量大于预设的阈值，则认为该点是有效点，将其保留。半径滤波算法计算简单，滤波速度较快，广泛应用于边缘点检测和离群点去除等场景。

通过将采集到的焊缝点云数据可视化，可以看出在焊缝主体点云附近存在部分离群的稀疏噪声点，因此本文选择使用半径滤波算法去除焊缝点云中存在的噪声点，滤波前后的焊缝点云如图 3-8 所示。



图 3-8 半径滤波效果图

3.3.2 点云降采样

在实际采集焊缝表面点云数据的过程中，获取到的焊缝点云数据量通常较为庞大。本文通过引入点云降采样方法对焊缝点云进行处理，在保留焊缝点云几何特征的前提下缩小数据规模，降低后续点云处理算法的计算成本。

常见的点云降采样方法包括最远点采样法、八叉树法、体素降采样法和随机降采样法等^[37-39]。本文选择使用体素降采样方法对焊缝点云进行降采样处理，体素降采样方法能够确保在向下采样的同时不破坏焊缝点云自身的几何结构，其原理如图 3-9 所示。





图 3-9 体素降采样原理图


体素降采样方法首先在焊缝点云外围形成立方体包围盒，在此基础上沿着坐标轴将包围盒均匀划分为多个体素小方格，形成三维体素栅格。接着，计算每一个体素栅格内部的质心点，用栅格的质心点替代栅格中的其他点，从而达到简化焊缝点云数据的目的，具体计算公式可以表示为：

$$\begin{cases} VGX_v = \sum_{i=1}^{n_v} X_{v_i} / n_v \\ VGY_v = \sum_{i=1}^{n_v} Y_{v_i} / n_v \\ VGZ_v = \sum_{i=1}^{n_v} Z_{v_i} / n_v \end{cases} \quad (3-1)$$

式中， X_{v_i} 、 Y_{v_i} 、 Z_{v_i} 表示第 v 个体素栅格中第 i 个空间点的三维坐标， n_v 表示第 v 个体素栅格内空间点的总数。体素格降采样前后的焊缝点云如图 3-10 所示。



(a) 降采样前点云



(b) 降采样后点云

图 3-10 体素降采样效果图

3.3.3 焊道点云提取

在对焊缝点云进行滤波和降采样处理后，焊缝点云数据中仍然存在大量与焊缝无关的空间点，例如焊接母板点云。焊接母板点云的存在不仅会增加后续焊缝缺陷几何特征提取的难度，还可能影响最终焊缝缺陷检测的结果。针对上述问题，本文在点云预处理阶段引入点云去除地面点算法以实现焊道点云提取，排除焊接母板点云对后续焊缝缺陷检测的干扰。

常见的点云去除地面点算法包括随机采样一致性算法、坡度滤波算法和布料滤波算法等^[40-42]。

(1) 随机采样一致性算法是一种基于数学模型参数估算的迭代方法，广泛

应用于激光雷达点云和三维重建等领域。使用随机采样一致性算法去除焊接母板点云的基本原理是首先从焊缝点云中随机选取若干点，并假设这些点属于需要去除的焊缝母板。接着，通过这些点拟合出一个平面模型来描述母板点云的几何特征。然后，计算焊缝点云中其他点与该平面的距离，如果其中某一点到平面的距离小于预先设定的阈值，则认为该点属于焊缝母板。通过多次迭代，随机采样一致性算法能够筛选出最佳的焊缝母板几何模型，进而去除焊接母板点云，具体步骤如下所示：

- 1) 确定随机样本数 num_p ，距离阈值 d_T ，内点阈值 inp_T 和抽样迭代次数 num_r 的取值；
- 2) 计算焊缝点云中空间点的总数 num_{cloud} ，并随机选取 num_p ($num_p \geq 3$) 个点拟合空间平面；
- 3) 计算焊缝点云中其他空间点与该拟合平面之间的距离 d_i ；
- 4) 如果 $d_i < d_T$ ，则将该点视为焊接母板点云的内点；反之，则将其视为外点；
- 5) 计算当前迭代周期中内点的总数 num_{in} 。如果 $num_{in} / num_{cloud} > inp_T$ ，则提前结束迭代，并将所有内点从焊缝点云中删除；反之，则进行下一次抽样迭代。
- 6) 重复上述步骤直至完成 num_r 次抽样迭代，将拟合出的包含内点数量最多的空间平面作为最佳的焊缝母板几何模型，并将对应的内点从焊缝点云中删除。




图 3-11 随机采样一致性算法原理示意图

(2) 布料滤波算法是一种基于物理模拟原理的点云地面点去除方法。该方法首先对焊缝点云进行翻转。然后，假设焊缝点云上方存在一块质量分布均匀的布料在重力作用逐渐下落并覆盖在焊缝点云表面。最终，布料中的点会被拉伸并逐渐适应焊缝点云表面的几何形态，从而将离地面较远的焊道点云排除在外。通过上述步骤，布料滤波算法能够识别焊缝点云中与地面平行的焊接母板点云并将其去除，实现焊道点云提取。




图 3-12 布料滤波算法原理示意图

(3) 坡度滤波算法是一种基于坡度理论的点云滤波算法，主要用于高效去除点云数据中的平坦区域或背景噪声。使用坡度滤波算法去除焊接母板点云的核心原理是首先通过投影将焊缝点云划分为多个二维格网，并在每个格网内记录最低点的高度，进而构建高程网格。接着遍历所有格网，计算出每个格网的坡度值。最后根据设定的坡度阈值，判断坡度网格中每个格网的坡度值是否符合条件，若坡度小于阈值，则将对应该格网内的点视为焊接母板并去除；若坡度大于阈值，则保留这些点。具体步骤如下所示：

- 1) 确定格网边长 L_s 和坡度阈值 S_T 的取值；
- 2) 将焊缝点云数据沿 Z 轴方向投影至二维平面，并记录每个点的高度值；
- 3) 沿 X 轴方向和 Y 轴方向，以 L_s 为格网边长建立高程网格，并将每个格网内最低点的高度值作为该格网的高程值；

E_1	E_2	E_3
E_4	E_l	E_5
E_6	E_7	E_8

图 3-13 8 邻域网格结构示意图

- 4) 计算每个格网的坡度值。如图 3-13 所示，本文采用 8 邻域网格结构，则格网 E_l 的坡度值 S_l 可以表示为：

$$S_l = \frac{1}{8} \sum_{i=1}^8 \frac{h_{il}}{L_s} \quad (3-2)$$

式中， h_{il} 表示格网 E_i 和格网 E_l 之间的高程差的绝对值；

- 5) 将每个格网的坡度值 S_l 与坡度阈值 S_T 进行比较。如果 $S_l < S_T$ ，则将格网 E_l 内的空间点视为焊缝母板点云并删除；如果 $S_l \geq S_T$ ，则保留这些点。

以上三种算法中，随机采样一致性算法的提取精度较差，且计算时间长。布料滤波算法虽然在提取精度上略高于坡度滤波算法，但是计算成本高，处理速度较慢。通过分析所获取的焊缝点云数据，可以看出焊缝点云中包含的焊接母板表

面平整，结构较为简单。因此，本文选择使用处理速度较快的坡度滤波算法滤除焊缝点云中的焊接母板部分以实现焊道点云提取。提取结果如图 3-14 所示。




图 3-14 焊道点云提取效果图

3.4 基于语义分割的焊缝表面点云数据集构建

数据集在深度学习中至关重要，它为网络模型提供了学习的基础，并直接影响训练效果。一个高质量的数据集应当满足以下两个关键要求：

(1) 准确性：数据的准确性直接决定了网络模型的训练效果。标注错误或数据本身的偏差会导致网络模型学习到错误的信息，从而影响预测结果的精度和可靠性。

(2) 多样性：数据集中数据的多样性能够确保网络模型学习到广泛的数据特征，避免过拟合或偏向某些特定的类别或模式。如果数据集中的数据过于单一或缺乏代表性，网络模型在面对实际应用中的新样本时，可能会表现出较差的性能。

3.4.1 数据准备及语义标注

为了构建焊缝表面点云数据集，本文使用第二章介绍的结构光视觉测量系统共采集了 40 余条焊缝表面的点云数据。在对点云数据进行滤波、降采样以及焊道提取相关预处理操作后，为提升数据集规模，进一步将焊缝表面点云按照 30mm 为单位进行切割，最终经过筛选得到了 90 段焊缝点云数据。部分点云可视化结果如图 3-15 所示。

本文使用 CloudCompare 软件完成焊缝表面点云数据集的语义标注工作，主要标注内容包括正常焊缝的焊缝表面点云、焊瘤缺陷的焊缝表面点云、凹陷缺陷的焊缝表面点云以及气孔缺陷的焊缝表面点云，分别对应数据集中的 1、2、3、4 号标签，部分完成语义标注后的焊缝点云可视化图像如图 3-16 所示，图中绿色点代表正常焊缝点云，红色点代表焊瘤缺陷，蓝色点代表凹陷缺陷点云，紫色点代表气孔缺陷点云。




图 3-15 部分焊缝点云可视化示意图




图 3-16 完成语义标注后的焊缝点云可视化示意图

3.4.2 数据增强

在获取焊缝点云数据的过程中,由于成本限制以及焊接缺陷产生的随机性等因素,较难大规模获取具有代表性的焊接缺陷样本。针对深度学习网络模型训练对大量焊缝缺陷样本的需求,本文通过数据增强的方式,在现有的真实焊缝缺陷样本基础上对焊缝表面点云数据集进行扩充。

数据增强作为机器学习和深度学习中常用的数据扩充手段,能够通过生成与原有数据集相似的样本,有效增加数据量。在图像处理领域,常用的数据增强手段包括旋转、镜像、缩放等^[43],而在三维点云领域常用的方法有旋转、下采样、引入随机噪声以及对点云不同程度的遮挡等。

为了快速扩充数据集,本文选择在 CloudCompare 开源软件中对现有焊缝点

云数据进行处理，通过围绕 X 、 Y 、 Z 三个轴分别旋转 30° 、 60° 、 90° 来生成扩充样本数据。最终完成数据增强后的焊缝表面点云数据集共包含 360 组焊缝表面点云数据，为了便于后续训练深度学习网络模型，将数据集按照 6:1:3 的比例划分为训练集、验证集和测试集，具体缺陷分布如表 3-1 所示。

表 3-1 焊缝表面点云数据集缺陷分布表

缺陷类型	焊瘤	凹陷	气孔	无缺陷
训练集	69	60	91	55
验证集	12	10	15	10
测试集	31	30	42	27

3.5 本章小结

本章主要完成了实际焊缝表面的点云数据获取、点云数据预处理以及焊缝表面点云数据集构建三项关键工作。首先，对获取到的实际焊缝表面点云数据进行了简单描述；其次，针对原始焊缝表面点云数据的特点，采用半径滤波算法、体素降采样算法以及坡度滤波算法对焊缝点云进行预处理操作；最后，使用 CloudCompare 开源软件完成语义标注与数据增强的工作，构建了基于语义分割的焊缝表面点云数据集，为后续研究基于深度学习网络模型的焊缝表面缺陷检测方法提供了重要的数据支持。

第4章 基于深度学习的焊缝表面缺陷检测

基于点云的焊缝表面缺陷检测方法主要可以分为传统机器学习方法和深度学习方法。传统机器学习方法往往需要先从焊缝点云中提取出可能存在缺陷的区域，再通过分类器构建相应的分类模型对包含缺陷的点云进行分类，很大程度上依赖分类模型自身的特征设定以及使用者的先验知识，泛化性与迁移应用的能力较弱^[44]。

随着深度学习的不断发展，越来越多的学者将深度学习应用在点云领域，其中代表性的点云神经网络包括 PointNet^[45]和 PointNet++^[46]。相较于传统机器学习方法，基于深度学习的焊缝表面缺陷检测方法无需人工设计复杂的特征提取规则，能够通过构建特征提取结构自动且高效地提取焊缝点云的局部与全局特征，在此基础上对焊缝点云中的每一个点进行分割，可以更准确全面地检测焊缝表面存在的缺陷。因此，本文选择首先使用 PointNet++算法对焊缝点云进行分割，然后根据焊缝缺陷检测的实际需求，通过 DBSCAN 聚类算法将分割出的缺陷点云实例化为独立的焊缝缺陷对象，从而实现焊缝缺陷检测，具体流程如图 4-1 所示。




图 4-1 焊缝表面缺陷检测流程

4.1 点云深度学习基础理论

(1) 感知机

感知机 (Perceptron) 作为一种最基础的人工神经元模型，通常用于二分类问题，其核心思想是模仿生物神经元信息传递的工作原理，通过输入层接收数据，计算加权和，然后通过激活函数进行处理，最终输出分类结果。该方法最早由美国科学家 Frank Rosenblatt 于 1957 年提出，并被广泛应用于解决线性可分的二分类问题。

如图 4-2 所示，与神经元结构类似，感知机主要由输入层、激活函数以及输出层三个部分组成。在感知机模型中，输入数据首先通过输入层进入，每个输入的值都与对应的权重相关联。然后计算输入数据的加权和，并将计算结果传递给

激活函数进行处理，最终经过激活函数的判断后，通过输出层将数据输出。




图 4-2 感知机结构示意图

感知机的训练过程依赖于监督学习的方式，通过比较模型的预测值和真实标签来更新权重和偏置。如果感知机发生分类错误，模型会通过调整权重和偏置来减少误差。这种调整过程是通过梯度下降或权重更新规则来实现的。简单来说，权重 w 和偏置 b 的更新过程可以表示为：

$$w = w + \eta(y_{true} - y_{pred}) \cdot x, b = b + \eta(y_{true} - y_{pred}) \quad (4-1)$$

式中， η 表示学习率， y_{true} 表示真实标签， y_{pred} 表示预测标签， x 表示输入的特征值。

总的来说，感知机是深度学习的基础概念之一，尽管感知机的功能主要局限于处理线性问题，但其简洁的结构和实现方式在深度学习的初期阶段发挥了重要作用，为日后多层神经网络和深度学习的发展奠定了基础。

(2) 神经网络

神经网络是深度学习的基础，由大量的神经元相互连接而成。每个神经元接收来自其他神经元的输出信号，并根据其权重和激活函数产生输出信号。神经网络通过调整神经元之间的连接权重来预测输出，让输出结果更加贴近真实值，从而实现对数据的表示、学习和推断。

神经网络基于架构可区分不同类型，目前，主流的基本网络架构有多层感知机 (Multilayer Perceptron, MLP)，循环神经网络 (Recurrent Neural Network, RNN)，生成对抗网络 (Generative Adversarial Network, GAN) 和卷积神经网络 (Convolutional Neural Network, CNN) 等。其中，MLP 具备强大的非线性建模能力与自动特征学习能力，广泛应用于缺陷检测等领域。多层感知机网络结构由单层感知机扩展而成，通常包括输入层、一个或多个隐藏层以及输出层三个部分，

每个神经元接收来自上一层的输出，作为本层的输入，其网络结构如图 4-3 所示。




图 4-3 多层感知机网络结构示意图

上图所示的多层感知机网络共包含 t 个隐藏层，每个隐藏层由 P_t 个神经元成， $N_{P_t(t)}$ 表示第 t 个隐藏层的第 P_t 个神经元。

4.2 基于 PointNet++与 DBSCAN 聚类算法的焊缝缺陷检测

PointNet^[47]是一种基于神经网络的端到端的点云特征提取算法，该算法首先通过多层感知机提升点云的特征维度，然后利用最大池化函数提取整个点云的全局特征，进而实现点云分类、点云分割等任务。但是，PointNet 只关注了点云的整体特征，缺乏提取点云局部特征的能力。

本文使用的 PointNet++算法^[48]是 PointNet 的扩展与改进版本，其核心思路是首先将焊缝点云划分为一系列重叠的局部区域，然后通过 PointNet 提取这些局部区域内点云的全局特征，从而捕获来自小邻域的精细几何结构。接着将这些局部区域进一步聚合到更大的区域中继续进行处理，生成更高层次的特征表示。重复此过程直到最终获得整个焊缝点云的特征。相较于 PointNet 算法，PointNet++算法的多层次特征提取结构能够更有效地提取点云的局部与全局特征，显著提升了模型在复杂场景中的分析能力，目前被广泛应用在工程领域中^[49-52]。

4.2.1 PointNet++网络架构

PointNet++网络模型包括分类网络与分割网络两个分支，前者对整个点云进行分类，而后者则针对点云中的每一个点进行分类。根据焊缝表面缺陷的检测需求，本文选择 PointNet++分割网络完成焊缝表面缺陷检测任务。其网络结构如图 4-4 所示。

(1) 集合抽象模块

PointNet++分割网络属于编码-解码网络，网络的编码部分通过多个集合抽象模块（Set Abstraction, SA）实现多层下采样，从而逐步提取点云数据特征以生成

不同规模的特征点。其中集合抽象模块由采样层（Sampling layer）、分组层（Grouping layer）和 PointNet 层三部分组成。该模块首先使用采样层和分组层将输入的点云划分为多个相互重叠的局部点集，然后通过 PointNet 层提取每个局部区域内的全局特征进而生成特征点。集合抽象模块的特征提取过程如图 4-5 所示。




图 4-4 PointNet++分割网络结构简图




图 4-5 集合抽象模块特征提取过程

①采样层

采样层使用最远点采样法（Farthest Point Sampling, FPS）对输入的点云数据进行采样。首先在输入的点云中随机选取一个点作为初始点并将其加入采样点集中，然后计算剩余点与采集点集中的各点之间的欧氏距离，并选择距离最远的点加入采样点集，最后重复此过程达到所需采样点数。相较于随机采样，最远点采样法能够确保采样点最大限度地覆盖整个点云。以图 4-5（a）展示的包含 16 个空间点的点云为例，其中橙色点为最远点采样算法从点云中选取的采样点。

②分组层

分组层通过球状邻域查询算法 (Ball query) 在以采样层所选取的每个采样点为球心、半径为 r 的球状邻域范围内搜索空间点, 选取至多 K 个点作为该邻域的成员, 从而将输入的整个点云划分为一系列重叠的局部点集, 便于后续提取多层次的点云特征。以图 4-5 (b) 所示, 分组层以采样层所选取的 5 个采样点为球心, 将原始点云分割成 5 个相互重叠的球状邻域, 且每个邻域内所包含的空间点数量不一定相同。

③PointNet 层

PointNet 层的作用是接收采样层和分组层处理后得到的多个局部点集, 并将其输入到小型 PointNet 网络中以提取每个局部点集的全局特征, 并将这些信息传递给下一层。如图 4-5 (c) 所示, 经过 PointNet 层的处理, 每个局部点集由一个特征点抽象表示, 特征点的坐标仍为原先的球心坐标, 同时该特征点聚合了整个局部点集的点云数据特征。PointNet 层网络结构如图 4-6 所示。




图 4-6 PointNet 层结构图

针对每一个局部点集, PointNet 层首先通过共享的多层感知机网络将点集中的每个点的坐标及其原有特征映射为高维特征表示。鉴于点云数据的无序特性, PointNet 层采用最大池化函数作为对称函数, 通过对每个点的特征进行逐元素的最大值计算, 生成一个能够代表该局部点集的全局特征向量, 这一过程确保了全局特征的计算不受点云输入顺序的影响。最终通过串联多个集合抽象模块, PointNet++ 能够将低层次的局部特征逐步聚合到更高层次的表示中, 实现点云数据的多层次特征提取。

(2) 特征传播模块

可以看出, 原始点云经过集合抽象模块的处理, 点云中点的数量是不断减少的。而点云分割任务的最终目标是得到输入点云中的每一个点的预测分类, 即输出网络的点云数量必须与输入网络的点云数量保持一致。因此, PointNet++ 引入了特征传播模块 (Feature Propagation, FP), 将集合抽象模块提取出的高层次特征信息传播给集合抽象模块下采样过程中丢失的点, 从而恢复原始点云结构。特征传播模块由图 4-4 所示的插值层 (interpolate)、跳连拼接以及 unit pointnet 三部分组成, 特征传播过程如下:

①插值层: 对于集合抽象模块下采样过程中丢失的待插值点 x , 特征传播模

块采用基于 K 近邻的反向距离加权平均插值方式计算该点的特征 $f(x)$ ：

$$f(x) = \frac{\sum_{i=1}^k w_i(x) f_i}{\sum_{i=1}^k w_i(x)} \quad \text{where } w_i(x) = \frac{1}{d(x, x_i)} \quad (4-2)$$

式中, k 为预先设定的近邻点个数, f_i 表示第 i 个近邻点 x_i (已知特征点) 的特征, $d(x, x_i)$ 表示点 x 与点 x_i 之间的欧式距离。

②跳连拼接：将计算出的插值特征 $f(x)$ 与该点未经集合抽象模块处理的特征进行拼接。

③unit pointnet：通过 MLP 和 ReLU 激活函数更新丢失点 x 拼接后的特征。

重复上述操作直到恢复原始点云分辨率。最终 PointNet++ 通过重复 PointNet 单元 (1×1 卷积网络) 得到输入点云中每个点的预测分类。

4.2.2 基于 DBSCAN 聚类算法的缺陷点云实例化方法

在通过 PointNet++ 分割网络得到焊缝点云中每个点的预测分类结果后, 针对不同焊缝缺陷点云之间存在一定间隙的特点, 本文采用 DBSCAN 聚类算法对 PointNet++ 预测为焊缝缺陷的三维点云进行实例化处理, 将计算得到的每一个聚类点集视为一个独立的焊缝缺陷对象, 最终输出焊缝点云中包含的缺陷类型以及对应的缺陷数量, 以更好地满足工业场景下焊缝缺陷检测的实际需求。

DBSCAN (Density-Based Spatial Clustering of Applications with Noise) 聚类算法是一种基于密度可达关系的聚类方法, 其核心思想是选择点云中的核心点作为“种子”, 再由此出发找出其密度可达的数据点生成聚类点集, 直到所有的核心点都被访问过^[53]。该算法能够识别出点云中形状不规则且具有不同密度的点云簇, 同时有效地处理含有噪声的数据, 适用于处理复杂的点云数据和焊缝缺陷检测等应用场景。DBSCAN 聚类算法涉及到的基本概念如下：

(1) ε 邻域：以给定点云中的某一点 p 为中心, 半径为 ε 的区域称为点 p 的 ε 邻域；

(2) $MinPts$ ：将给定点云中某一点视为核心点时, 该点的 ε 邻域内需要包含的最小点数；

(3) 核心点：如果给定点云中某一点 p 的 ε 邻域内的点数大于或等于 $MinPts$, 则称点 p 为核心点；

(4) 直接密度可达：对于给定点云中的两个数据点 p 和点 q , 如果点 q 在点 p 的 ε 邻域内, 且 p 为核心点, 则称点 q 从点 p 直接密度可达；

(5) 密度可达：如果给定点云中存在一系列数据点 $p_1, p_2, \dots, p_n$ ，满足其中每个点 p_{i+1} 从点 p_i 均直接密度可达，则称点 p_n 从点 p_1 密度可达，密度可达关系具有传递性和非对称性；

(6) 密度相连：如果给定点云中存在某一核心点 o ，能够满足点 p 和点 q 都从点 o 密度可达，则称点 p 和点 q 为密度相连，密度相连具有对称性；

(7) 聚类点集：在给定点云中，任意一个核心点与其密度可达的所有点构成一个聚类点集；

(8) 无效点：在给定点云中，无法从任意一个核心点密度可达的点被称为无效点。

对于 PointNet++ 分割网络输出的点云分割结果，首先通过去除焊缝点云中被分类为正常焊缝的空间点，从而提取出缺陷点云 DF 。如果缺陷点云 DF 为空，则将该焊缝点云视为无缺陷焊缝；如果缺陷点云 DF 不为空，则使用 DBSCAN 聚类算法对提取出的缺陷点云 DF 进行聚类处理，具体流程如图 4-7 所示。

Step1：通过 k-distance 函数确定 DBSCAN 聚类参数 ε 和 $MinPts$ 的取值。k-distance 函数是一种用于衡量数据点与其邻近点之间距离的方法，常用于聚类算法和密度估计中。在使用 k-distance 函数时，通常需要根据数据的密度、分布以及应用场景来决定 k 的取值。一般情况下， k 的取值可以参考以下公式：

$$k = 2 \cdot dim - 1 \quad (4-3)$$

式中， dim 表示缺陷点云 DF 中空间点的特征维度，在本文中 $dim = 3$ ，即 $k = 5$ 。然后计算缺陷点云 DF 中每个空间点到距其第 k 近的点的距离，并将这些距离值按照升序排列后绘制点云分布关系图。

如图 4-8 所示，首先通过最小二乘法对点云分布关系图中的离散数据点进行多项式拟合。为提升拟合精度，本文将多项式拟合的阶数设定为 15，则拟合得到的曲线方程 $f(x)$ 可以表示为：

$$f(x) = \gamma_0 + \gamma_1 x + \gamma_2 x^2 + \dots + \gamma_{15} x^{15} \quad (4-4)$$

式中， $\gamma_0, \gamma_1, \dots, \gamma_{15}$ 表示多项式方程的各项系数。然后计算拟合曲线上曲率最大的点，该点即为拟合曲线的拐点^[54,55]。其中，曲率 ka 的计算公式如下：

$$ka(x) = \frac{|f''(x)|}{[(1 + (f'(x))^2)]^{\frac{3}{2}}} \quad (4-5)$$

式中， $f'(x)$ 表示拟合曲线对 x 的一阶导数， $f''(x)$ 表示拟合曲线对 x 的二阶导数。拐点位置对应的距离值即为 ε 的值， $MinPts$ 的值通常选择 k 值加 1。




图 4-7 焊缝缺陷点云实例化流程图

Step2: 计算缺陷点云 DF 中每个点的 ε 邻域内的空间点数量 N_ε 。如果 $N_\varepsilon \geq MinPts$ ，则将该点视为核心点，并添加到核心点集 CP 中。

Step3: 从核心点集 CP 中随机选取一个核心点 CP_i ，为其建立一个新的缺陷聚类点集 DP_j ，将缺陷点云 DF 中所有从点 CP_i 密度可达的空间点添加到缺陷聚类点集 DP_j 中，同时将缺陷聚类点集 DP_j 中包含的所有核心点添加到当前聚类核心点集 CN_j 中。

Step4: 统计各种焊缝缺陷类型的空间点在缺陷聚类点集 DP_j 中所占的比例，以占比最多的缺陷类型作为整个缺陷聚类点集 DP_j 代表的缺陷类型 f_j 。此时，该缺陷聚类点集已经构建成功，将点集 CN_j 中的点从点集 CP 中删除，同时将聚类点集 DP_j 中的点从缺陷点云 DF 中删除。

Step5: 重复 step3 和 step4 的操作直至核心点集 CP 为空。此时，缺陷点云 DF 中剩余的点被视为无效点删除。最终，输出焊缝缺陷点云聚类结果 $DP_1, \dots, DP_j$

以及各缺陷聚类点集代表的焊缝缺陷类型 $f_1, \dots, f_j$ 。




图 4-8 点云分布关系示意图

通过上述步骤，本文所提焊缝缺陷检测方法最终能够识别焊缝表面存在的缺陷类型以及对应的缺陷数量，实现焊缝表面缺陷检测。

4.3 焊缝缺陷检测方法效果评价

对于点云分割任务，常使用交并比 IoU (Intersection over Union) 和平均交并比 MIoU (Mean Intersection over Union) 对分割性能进行评价；对于缺陷检测任务，通常使用准确率 (Accuracy) 作为评价指标。

(1) 交并比

交并比 IoU 是用于分割问题的标准评价指标，主要计算实际分割与模型预测的分割之间的交并比，表达式为：

$$IoU_i = \frac{PN_{ii}}{X_i + Y_i - PN_{ii}} \quad (4-6)$$

式中， i 表示空间点的分类类别， X_i 表示真实标签为 i 类的点的数量， Y_i 表示在模型中被预测为 i 类的点的数量， PN_{ii} 表示原本属于 i 类并预测为 i 类的点的数量。

(2) 平均交并比

平均交并比 MIoU 是将每一种分类类别计算得到的交并比进行求平均得到的指标，同时考虑了分割失误以及遗漏点的情况，由于 MIoU 在语义分割评价上具有代表性并表达较为简洁明了，成为了点云语义分割评价准确性的指标中最常用的一种指标，其表达式为：

$$MIoU = \frac{1}{S} \sum_{i=1}^S IoU_i \quad (4-7)$$

式中， S 表示总分类类别数量。

(3) 准确率

准确率 $Accuracy$ 是评估分类模型性能的基础指标，用于表示模型正确预测的样本数占总样本数的比例，其计算公式为：

$$Accuracy = \frac{N_{true}}{N_{all}} \quad (4-8)$$

式中， N_{true} 表示正确预测的样本数； N_{all} 表示总样本数。

4.4 本章小结

本章围绕焊缝缺陷检测开展研究，首先概述了点云深度学习的基本理论；接着，从理论层面出发，详细阐述了通过 $PointNet++$ 分割网络模型处理焊缝点云，获取焊缝点云中每个点的预测分类结果的具体流程，论述了采用 DBSCAN 聚类算法将分割出的缺陷点云实例化为独立的焊缝缺陷对象的基本原理，提出了一种基于 $PointNet++$ 网络模型和 DBSCAN 聚类算法的焊缝缺陷检测方法；最后总结了点云分割任务和缺陷检测任务常用的评价指标。

第5章 焊缝缺陷检测实验与结果分析

本章概述了焊缝缺陷检测实验平台的硬件组成,结合第三章所构建的焊缝表面点云数据集设计了焊缝点云分割实验和缺陷点云实例化实验,以验证本文所提的焊缝缺陷检测方法的有效性与检测结果的准确性,并对所提方法的检测性能进行评估。

5.1 实验平台

为了便于采集焊缝表面点云数据以进行焊缝缺陷检测方法研究,本文搭建了如图 5-1 所示的焊缝缺陷检测实验平台,该实验平台由四部分组成:(1)线结构光视觉传感器;(2)控制结构光视觉传感器步进式移动的机器人运动平台;(3)用于接收测量数据并进行三维重建的计算机;(4)待测量的真实焊缝。




图 5-1 焊缝缺陷检测实验平台示意图

5.2 焊缝缺陷检测实验


5.2.1 焊缝点云分割实验

本文通过 Anaconda 构建虚拟开发环境,结合 Pycharm 开发工具和 Pytorch 深度学习框架部署 PointNet++网络模型。实验采用第三章所构建的焊缝表面点云数据集对 PointNet++网络模型进行训练,通过训练集优化模型参数,并利用验证集对模型性能进行评估,以筛选出表现最佳的网络模型,具体训练参数如表 5-1 所示。


由图 5-2 可以看出,随着网络模型的不训练,焊缝点云分割的准确率逐渐提升,并在训练进行至 120 次左右以后趋于平稳,最终得到的模型训练准确率为 85.67%。

表 5-1 PointNet++网络模型训练参数表

训练参数	参数设置
初始学习率	0.001
学习率衰减率	0.5
权重衰减系数	1e-4
损失函数	Cross-Entropy
优化器	Adam
批次大小	16
采样点数	2048
最大训练轮次	150



(a) 准确率曲线



(b) 损失曲线


图 5-2 PointNet++网络模型训练结果曲线

训练完成后，以 4.3 节中介绍的交并比 IoU 为评价指标，使用测试集中的数据验证网络模型的点云分割性能，测试集中共包含 31 个焊瘤缺陷样本、30 个凹陷缺陷样本、42 个气孔缺陷以及 27 个无缺陷焊缝样本，结果如表 5-2 所示。此


外，部分焊缝点云分割结果可视化图像如图 5-3 所示。

表 5-2 焊缝点云分割结果


	正常焊缝	焊瘤	凹陷	气孔
IoU	92.4%	83.5%	86.1%	70.4%




(a) 焊缝表面点云样本 H_1




(b) 点云分割结果 H_1'




(c) 焊缝表面点云样本 H_2




(d) 点云分割结果 H_2'




(e) 焊缝表面点云样本 H_3



(f) 点云分割结果 H_3'



(g) 焊缝表面点云样本 H_4



(h) 点云分割结果 H_4'

图 5-3 部分焊缝点云分割可视化结果图

由表 5-2 和图 5-3 可以看出，PointNet++网络模型能够有效地识别出焊缝点云中各个空间点所属的形貌类型。该模型在分割正常焊缝、焊瘤和凹陷这三种焊缝表面形貌的空间点时分割精度较高，而对于气孔这一类焊缝表面形貌，由于其包含的空间点数量较少且常伴随点云缺失，分割精度相对较低，最终全类别平均焊缝点云分割精度 MIoU 为 83.1%。

5.2.2 缺陷点云实例化实验

基于上述焊缝点云分割结果，首先通过去除被分类为正常焊缝的空间点，提取出焊缝点云所包含的缺陷点云，并将不包含焊缝缺陷空间点的焊缝点云分类为无缺陷焊缝。提取出的部分缺陷点云可视化图像如图 5-4 所示。




图 5-4 缺陷点云可视化示意图

完成缺陷点云提取之后，为确定 DBSCAN 算法的聚类参数，采用 k-distance 函数绘制缺陷点云的点云分布关系图，并计算图像中的拐点坐标，如图 5-5、图 5-6 和图 5-7 所示。然后使用 DBSCAN 聚类算法将提取出的缺陷点云实例化为一组独立的焊缝缺陷对象。最终得到的缺陷点云实例化结果如表 5-3 所示。




图 5-5 焊瘤+凹陷缺陷点云分布关系图




图 5-6 凹陷缺陷点云分布关系图




图 5-7 气孔缺陷点云分布关系图

由表 5-3 可以看出,本文所提焊缝缺陷检测方法的总体检测准确率为 91.5%。其中,无缺陷焊缝样本的检测结果与真实结果完全一致;焊瘤缺陷与凹陷缺陷的深度特征较为明显,检测准确率较高,分别达到了 93.5%和 90.0%;气孔缺陷由于其分布较为密集,容易将相邻的多个气孔缺陷识别成一个整体,导致检测准确率相对较低,为 85.7%。综上所述,本文所提焊缝缺陷检测方法能够有效检测焊缝表面存在的缺陷。

表 5-3 缺陷点云实例化结果

缺陷类型	总数量/个	成功检测/个	误漏检数/个	准确率/%
焊瘤	31	29	2	93.5
凹陷	30	27	3	90.0
气孔	42	36	6	85.7
无缺陷	27	27	0	100.0
总计	130	119	11	91.5

5.3 本章小结

本章围绕焊缝表面缺陷检测工作,概述了焊缝缺陷检测实验平台的硬件组成,结合第三章所构建的焊缝表面点云数据集设计了焊缝点云分割实验与缺陷点云实例化实验,验证了本文所提出的焊缝缺陷检测方法的有效性以及检测结果的准确性。实验结果表明,本文提出的焊缝缺陷检测方法能够有效检测焊缝表面存在的缺陷。

第 6 章 总结与展望

6.1 总 结

焊接作为一种重要的金属连接工艺，广泛应用于工业制造领域。焊接结构的质量直接影响焊接产品的强度、耐用性与安全性。然而，在实际焊接作业过程中，由于受焊接工艺、焊接材料、人工操作等因素的影响，焊缝表面可能会出现各种难以预测的缺陷，如焊瘤、凹陷和气孔等。这些缺陷不仅会影响焊缝外观，还可能导致焊接结构失效，严重时甚至会引发安全事故。因此，在焊接过程中及焊后进行焊缝缺陷检测是保证焊接产品质量不可或缺的重要工序。

当前，焊缝缺陷检测方法主要依赖人工目视检查或 2D 视觉检测。然而，人工检测效率低、成本高；2D 视觉检测技术在实际焊接作业环境中易受弧光、火花等环境因素的干扰，且在检测焊瘤、气孔等具有明显深度特征的缺陷时效果不够理想。为了解决这些问题，本文采用具有高穿透性和高抗干扰性的结构光视觉传感器获取焊缝表面的三维点云数据，然后通过滤波、降采样等方法对点云数据进行预处理，最后结合深度学习网络模型与聚类算法实现焊缝缺陷检测。本文的主要工作如下：

(1) 调研了现有的焊缝缺陷检测技术，系统地分析了基于 2D 视觉和 3D 视觉的焊缝缺陷检测方法的研究现状，并进一步论证了本研究课题的合理性与可行性。

(2) 阐述了线结构光视觉测量中垂直入射测量和斜入射测量两种三角测量模型的基本原理，并对这两种模型进行了对比分析；详细论述了线结构光视觉测量系统中的相机标定、线结构光中心线提取、光平面标定以及三维重建过程，并提出了一种基于改进 Steger 算法的线结构光中心线精确提取方法。实验结果表明，相较于传统 Steger 算法，所提方法在对相同激光条纹进行中心点提取时，中心点数量减少了 41.8%；提取中心点距离拟合中心线的均方根误差降低 50.1%，所提方法能够有效滤除冗余点，提升中心线提取精度和稳定性，更好地满足后续结构光传感器高精度标定和三维重建的需求。

(3) 围绕焊缝缺陷检测任务，总结分析了正常焊缝、焊瘤、凹陷和气孔四种焊缝表面形貌的几何特征。以平板对接焊缝为研究对象，通过结构光视觉测量系统获取焊缝表面的点云数据，采用半径滤波算法、体素降采样算法以及坡度滤波算法对焊缝点云进行预处理。此外，使用 CloudCompare 开源软件完成焊缝点云数据语义标注与数据增强工作，建立了基于语义分割的焊缝表面点云数据集，并将数据集按照 6:1:3 的比例划分为训练集、验证集和测试集，为后续的缺陷检测工作提供数据基础。

(4) 阐述了点云深度学习的基本理论，详细描述了 PointNet++ 分割算法与

DBSCAN 聚类算法的基本原理，提出了一种基于 PointNet++ 网络模型和 DBSCAN 聚类算法的焊缝缺陷检测方法。总结了点云分割任务与缺陷检测任务常用的评价指标，以便后续对所提焊缝缺陷检测方法的性能进行评估。

(5) 概述了本文搭建的焊缝缺陷检测平台的硬件组成，使用焊缝表面点云数据集对 PointNet++ 网络模型进行训练，通过训练集优化模型参数，并利用验证集对模型性能进行评估，以筛选出表现最佳的网络模型，最终结合 DBSCAN 聚类算法实现了焊缝缺陷检测。结合测试集设计了焊缝点云分割实验与缺陷点云实例化实验对所提方法的检测性能进行评估。实验结果表明，本文所提焊缝缺陷检测方法的全类别平均焊缝点云分割精度为 83.1%，缺陷点云实例化总体准确率为 91.5%，所提方法能够有效检测焊缝表面存在的缺陷。

6.2 展望

针对现有焊缝缺陷检测方法的不足，本文通过 3D 结构光视觉获取焊缝表面的三维点云数据，结合滤波、降采样等点云预处理方法，提出了基于深度学习网络模型和聚类算法的焊缝缺陷检测方法并进行实验验证。实验结果表明，本文所提方法能够有效检测焊缝表面缺陷。

然而，由于时间、实验条件和个人能力的不足，部分研究工作尚未得到完善，具体内容如下：

(1) 在研究过程中，本文以平板对接焊缝为研究对象，构建了包含焊瘤、凹陷和气孔三种常见焊缝缺陷类型的焊缝表面点云数据集。然而，在实际的焊接作业过程中，焊缝类型与焊缝缺陷的种类繁多。因此，后续研究应当获取更多类型的焊缝表面点云数据，进一步增强数据集中数据的多样性，以提升所提焊缝缺陷检测方法的检测性能与普适性。

(2) 本文在缺陷点云实例化过程中使用的 DBSCAN 聚类算法对于相关参数的设定较为敏感，特别是在检测多个紧密相连的焊缝缺陷时，可能导致误检或漏检的情况发生。因此，后续研究应针对 DBSCAN 聚类算法的聚类策略进行优化，例如引入自适应参数调整机制或改进距离度量方法，以提升算法在复杂焊缝缺陷检测中的准确性。此外，也可以探索其他聚类算法或采用多种算法的结合，以进一步提升检测性能。

(3) 本文尚未深入分析所提焊缝缺陷检测方法的实时性能，后续可以围绕 PointNet++ 网络模型的轻量化改进展开进一步研究，以提升所提方法的检测效率。

参考文献

- [1] Malikov A, Orishich A, Vitoshkin I, et al. Effect of post-heat treatment on microstructure and mechanical properties of laser welded Al-Cu-Mg alloy[J]. Journal of Manufacturing Processes, 2021, 64: 620-632.
- [2] 方涛. 焊接技术中常见的缺陷、检验及其解决措施分析[J]. 舰船科学技术, 2021, 43 (18): 211-213.
- [3] 沙经伟, 范孟豹, 曹丙花, 等. 金属构件硬度的无损检测研究进展与展望[J]. 机械工程学报, 2023, 59(24): 1-17.
- [4] 刘涵, 郭润元. 基于 X 射线图像和卷积神经网络的石油钢管焊缝缺陷检测与识别[J]. 仪器仪表学报, 2018, 39(04): 247-256.
- [5] 胡宏伟, 张婕, 彭刚, 等. 基于 LBP-KPCA 特征提取的焊缝超声检测缺陷分类方法[J]. 焊接学报, 2019, 40(06): 34-39+162.
- [6] 王博正, 董丽虹, 王海斗, 等. 激光红外热成像技术在材料缺陷检测中的研究和应用现状[J]. 材料导报, 2020, 34(05): 5127-5132.
- [7] 余佳杰, 周建平, 薛瑞雷, 等. 基于结构光视觉和光照模型的焊缝表面质量检测[J]. 中国激光, 2022, 49(16): 170-178.
- [8] Kumar G S, Natarajan U, Ananthan S S. Vision inspection system for the identification and classification of defects in MIG welding joints[J]. The International Journal of Advanced Manufacturing Technology, 2012, 61: 923-933.
- [9] Ranjan R, Khan A R, Parikh C, et al. Classification and identification of surface defects in friction stir welding: An image processing approach[J]. Journal of Manufacturing Processes, 2016, 22: 237-253.
- [10] Vasan V, Sridharan N V, Balasundaram R J, et al. Ensemble-based deep learning model for welding defect detection and classification[J]. Engineering Applications of Artificial Intelligence, 2024, 136: 108961.
- [11] Tripicchio P, Camacho-Gonzalez G, D'Avella S. Welding defect detection: coping with artifacts in the production line[J]. The International Journal of Advanced Manufacturing Technology, 2020, 111(05): 1659-1669.
- [12] Girshick R, Donahue J, Darrell T, et al. Rich feature hierarchies for accurate object detection and semantic segmentation[C]. Proceedings of the IEEE conference on computer vision and pattern recognition. IEEE, 2014: 580-587.
- [13] 张鹏贤, 王延升, 张国强. 焊缝表面缺陷的视觉图像表征[J]. 兰州理工大学学报, 2016, 42(01): 17-21.
- [14] 罗莉. 小波分析在焊缝缺陷识别中的应用[D]. 兰州理工大学, 2004.
- [15] 李尚仁, 王春明, 米高阳. 基于机器视觉的焊缝表面下塌缺陷实时检测系统[J]. 焊接技术, 2019, 48(11): 85-88+6.
- [16] 王宸, 张秀峰, 刘超, 等. 改进 YOLOv3 的轮毂焊缝缺陷检测[J]. 光学精密工程, 2021, 29(08): 1942-1954.
- [17] Zhou Y, Chang B, Zou H, et al. Online visual monitoring method for liquid rocket engine nozzle welding based on a multi-task deep learning model[J]. Journal of Manufacturing Systems, 2023, 68: 1-11.
- [18] 迟大钊, 李孙珏, 孙昌立, 等. 基于双目视觉的缺陷深度测量方法[J]. 焊接学报, 2016,

- 37(11): 7-10+129.
- [19] 马骥骥, 杨新文, 张昭, 等. 基于结构光视觉的钢轨波磨检测与定位方法研究[J]. 机械工程学报, 2022, 58(22): 140-147.
- [20] 苏育挺, 景梦瑶, 井佩光, 等. 基于光度立体和深度学习的电池缺陷检测方法[J]. 吉林大学学报(工学版), 2024, 54(12): 3653-3659.
- [21] Neill A M, Steele J P. Modeling and simulation of three dimensional weld pool reconstruction by stereo vision[C]. 2016 IEEE international conference on advanced intelligent mechatronics (AIM). IEEE, 2016: 542-547.
- [22] Boillot J P, Uota K, Berthiaume E, et al. Tracking and inspection for laser welding[C]. First International Symposium on High-Power Laser Macroprocessing. SPIE, 2003: 165-170.
- [23] Nguyen H C, Lee B R. Laser-vision-based quality inspection system for small-bead laser welding[J]. International journal of precision engineering and manufacturing, 2014, 15: 415-423.
- [24] Lee K, Hwang I, Kim Y M, et al. Real-time weld quality prediction using a laser vision sensor in a lap fillet joint during gas metal arc welding[J]. Sensors, 2020, 20(06): 1625.
- [25] Bestard G A, Sampaio R C, Vargas J A R, et al. Sensor fusion to estimate the depth and width of the weld bead in real time in GMAW processes[J]. Sensors, 2018, 18(04): 962.
- [26] 齐天宇. 基于双目立体视觉的焊缝缺陷检测技术研究[D]. 济南大学, 2024.
- [27] 王荣浩, 张文昌, 伍昕忠, 等. 基于激光视觉的焊缝表面质量检测方法研究[J]. 机电产品开发与创新, 2018, 31(05): 11-13.
- [28] Chu H H, Wang Z Y. A vision-based system for post-welding quality measurement and defect detection[J]. The International Journal of Advanced Manufacturing Technology, 2016, 86: 3007-3014.
- [29] Jiang S, Li X X, Xing Y F. Repair method of data loss in weld surface defect detection based on light intensity and 3D geometry[J]. IEEE Access, 2020, 8: 205814-205820.
- [30] 韦逍遥, 刘文渊, 王龄裕, 等. 基于光度立体视觉的钢轨焊缝打磨表面缺陷检测[J]. 机械工程学报, 2024, 60(24): 11-24.
- [31] 刘振, 李声, 冯常. 基于互相关算法的激光条纹中心提取[J]. 中国激光, 2013, 40(05): 202-207.
- [32] LI S S, GAO X, XIE Z X. Underwater Structured Light Stripe Center Extraction with Normalized Grayscale Gravity Method[J]. Sensors, 2023, 23(24): 9839.
- [33] QI L, ZHANG Y X, ZHANG X P, et al. Statistical behavior analysis and precision optimization for the laser stripe center detector based on Steger's algorithm[J]. Optics express, 2013, 21(11): 13442-13449.
- [34] NAN F, LI D H, GAO Q, et al. Implementation of adaptive light stripe center extraction of improved Steger algorithm[J]. Laser Journal, 2018, 39(01): 85-88.
- [35] 曾凯, 刘贺飞, 何茜, 等. 基于改进 Steger 算法的线结构光中心提取[J]. 华北理工大学学报(自然科学版), 2021, 43(01): 101-107.
- [36] 杨旭. 激光雷达点云数据的滤波和分割处理[D]. 哈尔滨工业大学, 2020.
- [37] 伟利国, 李广瑞, 董鑫, 等. 基于激光 SLAM 的小麦点云采集系统与冠层高度提取方法[J]. 农业机械学报, 2024, 55(S2): 263-276.
- [38] 李鑫. 基于机器视觉的焊缝表面缺陷检测方法研究[D]. 长春工业大学, 2024.
- [39] 赵畅. 基于点云数据的钢板表面缺陷三维检测方法研究[D]. 北京化工大学, 2020.

- [40] Sithole G, Vosselman G. Filtering of laser altimetry data using a slope adaptive filter[J]. International Archives of Photogrammetry Remote Sensing and Spatial Information Sciences, 2001, 34: 203-210.
- [41] Filin S. Surface clustering from airborne laser scanning data[J]. International Archives of Photogrammetry Remote Sensing and Spatial Information Sciences, 2002, 34: 119-124.
- [42] Hackel T, Wegner J D, Schindler K. Joint classification and contour extraction of large 3D point clouds[J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2017, 130: 231-245.
- [43] 王时丽, 刘桂华. 基于机器视觉的钢轨表面缺陷三维检测方法[J]. 微型机与应用, 2015, 34(19): 10-13.
- [44] 麦海锋. 基于深度相机与点云深度学习的散乱堆叠轴承圈抓取[D]. 华南理工大学, 2023.
- [45] Qi C R, Su H, Mo K, et al. Pointnet: Deep learning on point sets for 3d classification and segmentation[C]. Proceedings of the IEEE conference on computer vision and pattern recognition. IEEE, 2017: 652-660.
- [46] Qi C R, Yi L, Su H, et al. Pointnet++: Deep hierarchical feature learning on point sets in a metric space[J]. Advances in neural information processing systems, 2017, 30: 5099-5108.
- [47] 赵中阳, 程英蕾, 释小松, 等. 基于多尺度特征和 PointNet 的 LiDAR 点云地物分类方法[J]. 激光与光电子学进展, 2019, 56(05): 251-258.
- [48] 徐婕, 刘慧, 沈跃, 等. 基于改进 PointNet++模型的苗圃树木点云分类与分割[J]. 中国激光, 2024, 51(08): 193-203.
- [49] 王浩云, 肖海鸿, 马仕航, 等. 基于 MRE-PointNet+AE 的绿萝叶片外形参数估测算法[J]. 农业机械学报, 2021, 52(01): 146-153.
- [50] 周颖, 赵晓哲, 逯超. 基于多尺度特征聚类算法的不确定目标检测[J]. 火力与指挥控制, 2019, 44(04): 164-168.
- [51] Guo Z, Huang Z, Gong W, et al. Wave-PCT: Wavelet point cloud transformer for point cloud quality assessment[J]. Expert Systems with Applications, 2024, 257: 125039.
- [52] Wang J, Wang G, Li H, et al. Intelligent Construction Activity Identification for All-Weather Site Monitoring Using 4D Millimeter-Wave Technology[J]. Journal of Construction Engineering and Management, 2024, 150(11): 04024150.
- [53] 唐相猛. 基于和声搜索优化的激光点云聚类算法研究[D]. 哈尔滨工程大学, 2022.
- [54] 胡洪涛. 基于 K-dist 图的自适应参数改进的 DBSCAN 算法的研究与应用[D]. 大连交通大学, 2023.
- [55] 周治平, 王杰锋, 朱书伟, 等. 一种改进的自适应快速 AF-DBSCAN 聚类算法[J]. 智能系统学报, 2016, 11(01): 93-98.

攻读硕士期间的主要成果

- [1] 蔡磊, 吴路路, 俞伟锋, 等. 基于改进 Steger 算法线结构光中心精确提取方法
[J]. 安徽工程大学学报 (已录用, 第一作者)

致谢

时光荏苒，岁月如梭，转眼间我的硕士生涯即将画上句号。回首这段求学之路，我深感幸运与感激。这篇论文的完成，离不开许多人的支持与帮助，在此，我向他们致以最诚挚的谢意。

首先，我要衷心感谢我的导师吴路路老师。感谢您在学术上的悉心指导与耐心教诲，从论文的选题、框架设计到最终的修改与完善，您始终以严谨的治学态度对我进行指导。尽管您工作繁忙，但对于我学术上遇到的问题，您总是耐心解答我的疑问，并给予我宝贵的建议。在学术之外，您也时刻关心我的生活与成长，您的关怀与鼓励让我在求学之路上倍感温暖。承蒙您的教诲，学生心存感激。

此外，我要感谢我的同门与同学们。感谢你们在学术上对我的帮助，在生活中的关心与陪伴。与你们的相识和陪伴让我的硕士生涯充满了乐趣，无论是实验室里的学术讨论，还是闲暇时的畅谈，都为我的生活增添了许多色彩。这段共同奋斗的时光，将成为我人生中最美好的记忆之一。

最后，我要特别感谢我的家人们，尤其是我的父母。感谢你们一直以来无条件的支持与理解，每当我遇到困难时，你们的关怀与鼓励总能让我重拾信心；每当我取得进步时，你们的笑容是我最大的动力。你们的默默付出与无私奉献，让我能够专心致志地投入学业中。我深知，今天的点滴成就，离不开你们的支持与陪伴。

“我相信在秋天俯身采种子的人，来年会拥有整个春天。”西伯利亚的海鸥沿南抵达春城，你和我从来不说再见。谨以这段稚嫩的文字，献给所有照亮我求学之路的星辰。

尚德敏学 唯实惟新

