

分类号: TP391

密 级: 公开

学校代码: 10363

学 号: 2220320195



安徽工程大学

Anhui Polytechnic University

硕士学位论文

题 目

基于深度学习的混凝土结

合面粗糙度等级识别

论 文 作 者

卓文涛

校 内 导 师

汪石农

校 外 导 师

程志军

专业学位类别

电子信息

研究方向(领域)

人工智能

论文提交日期: 2025 年 5 月 12 日

分类号：TP391

单位代码：10363

密 级：公 开

学 号：2220320195

题 目 基于深度学习的混凝土结合面粗糙度等级识别

题 目 Identification of Roughness Grade of Concrete Joint Surface
Based on Deep Learning

学生姓名：卓文涛

校内导师：汪石农

校外导师：程志军

专业学位类别：电子信息

研究方向（领域）：人工智能

论文答辩日期：2025 年 5 月 8 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：卓文涛

日期：2025 年 5 月 12 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。

本学位论文属于

保密 ☐，在 ____ 年解密后适用本版权书。

不保密 ☒。

学位论文作者签名：卓文涛

日期：2022 年 5 月 15 日

指导教师签名：

日期：2022 年 5 月 15 日

基于深度学习的混凝土结合面粗糙度等级识别

摘 要

混凝土是一种由胶凝材料复合而成的集料结构，是当下最重要的建筑材料之一。它的用途也很广泛，不仅在土木行业中有所应用，还在船舶行业、机械制造业、军事国防等领域有所涉及。当今时代，人们对混凝土的使用率大幅提升，在此过程中，人们更加关注混凝土的质量对其物理性能的影响。混凝土结合面的物理性能是影响结构整体性和结构抗震性能的关键因素，而结合面的粗糙程度又影响着它的物理性能，因此结合面粗糙度的不同对混凝土的质量有着重要影响。本文通过视觉识别的图像处理方法，采用深度学习模型，针对多种类型的混凝土结合面，分别利用 Matlab 和 Visual Studio 软件完成粗糙度检测软件的设计、仿真和编程，主要完成的工作如下：

首先，通过奥比中光相机采集大量的混凝土结合面图片，对相机采集的结合面深度图提取深度信息，并将深度图映射为离散的点云。其次运用三角化法进行点云的三维重建，将离散的点云按照深度图相邻像素的位置，转为连续的点云。接着利用灌沙法原理和凹凸深度原理，使用连续的点云计算出结合面的粗糙度信息。由于相机本身的偏差以及点云的最高点误差和轮廓误差，此时结合面的粗糙度信息并不精确，需要进行消除误差处理。本文采用基准面修正法和 16 点修正法，分别对剪力键型结合面和骨料型结合面的粗糙度误差进行处理，之后获得了所有图片的粗糙度信息。根据粗糙度信息对结合面图片进

行等级分类，从而得到了训练深度学习模型的数据库。该数据库包含三个文件夹，在每个文件夹中，结合面图片的粗糙度等级是一致的。

由于三个粗糙度等级的图片数量不一致，为了确保特征学习的完整性和数据多样性，需要运用 Matlab 对数据库中的图片进行预处理。扩充了样本量少的图片，确保用于训练的样本量足够多、指标评估的有效性，避免过拟合问题。运用 Matlab 搭建 Resnet50 深度学习模型，通过更改学习率等参数，得到了能够识别粗糙度等级的深度学习模型；之后，在此模型的基础上加入了 CBAM 注意力机制，模型的识别准确度得到了提升，最终得到了改进的、能够识别混凝土结合面粗糙度等级的深度学习模型。

最后，将 Matlab 编写的代码通过 Matlab Coder 工具箱转换为 C++ 代码，并在 Visual Studio 开发环境中完成粗糙度算法的调试和优化。同时，在 MFC 框架下进行操作界面的设计，并实现语音提醒、相机参数调整、Excel 文件读写和结果展示与评价等功能，达到软件用户交互友好性的目的，完成在 Windows 平台上粗糙度检测算法的设计。接着通过软硬件结合的方式，实现了连接相机并采集图片、计算粗糙度和输出粗糙度的功能。最终组装了粗糙度检测仪，能够更加直观、更加系统性的完成粗糙度信息输出。

在建筑行业的实际应用场景中，该软件已经成功集成到粗糙度检测样机中，并在建筑材料表面质量粗糙度检测中得到了使用。在试用过程中，软件与样机的协同工作表现良好，系统运行流畅，未出现明显的故障或异常情况。通过长时间的连续运行测试，系统的稳定性和

可靠性得到了充分验证，为建筑行业提供了一种高效、精准的粗糙度检测解决方案，也为后续的优化和推广奠定了坚实的基础。

关键词：视觉识别，图像处理，深度图，点云，深度学习

Identification of the Roughness Grade of the Concrete Binding Surface Based on Deep Learning

Abstract

Concrete is a composite aggregate structure composed of cementitious material, which is one of the most important building materials at present. It is also very widely used, not only in the civil industry, but also in the shipbuilding industry, machinery manufacturing, military and defense and other fields. In today's era, people's utilization rate of concrete has greatly increased. In this process, people pay more attention to the influence of concrete quality on its physical properties. The physical performance of the concrete binding surface is the key factor affecting the structural integrity and seismic performance of the structure, and the roughness of the binding surface affects its physical performance, so the different roughness of the combined surface has an important influence on the quality of concrete. Through the image processing method of visual recognition, this paper adopts deep learning model, for various types of concrete binding surfaces, and uses Matlab and Visual Studio software to complete the design, simulation and programming of roughness detection software respectively. The main work is as follows:

First, a large number of concrete combined surface images are collected by the Obi medium light camera, and the depth information is extracted from the combined surface depth map collected by the camera, and the depth map is mapped into discrete point clouds. Secondly, the triangulation method is used to conduct 3 D reconstruction of point clouds, and the discrete point clouds are transformed into continuous point clouds according to the positions of adjacent pixels in the depth map. Then, the roughness of the binding surface was calculated by the use of continuous point cloud. Due to the deviation of the camera itself and the highest point error and contour error of the point cloud, the roughness information of the combined surface is not accurate at this time, and the error treatment needs to be eliminated. In this paper, we used the datum correction method and 16-point correction method, respectively, to treat the roughness error of shear bond bonding surface and aggregate binding surface, and then obtained the roughness information of all pictures. According to the roughness information, a database can train the deep learning model. The database contains three folders, in each of the roughness level of the combined face picture is consistent.

Due to the inconsistent number of pictures in the three roughness grades, in order to ensure the integrity of feature learning and data diversity, Matlab is needed to preprocess the pictures in the database. The picture with a small sample size is expanded to ensure enough sample

size for training, the effectiveness of index evaluation, and avoid the problem of overfitting. Using Matlab to build the Resnet50 deep learning model, the deep learning model was obtained by changing parameters such as the learning rate. Later, the CBAM attention mechanism was added on the basis of this model, improving the recognition accuracy of the model, and finally obtaining an improved deep learning model which can identify the roughness level of concrete combination surface.

Finally, the code written by Matlab is converted into C + + code through the Matlab Coder toolbox, and the debugging and optimizes the roughness algorithm in the Visual Studio development environment. At the same time, the operation interface is designed under the framework of MFC, and the functions such as voice reminder, camera parameter adjustment, Excel file reading and writing, and result display and evaluation are realized, so as to achieve the purpose of user interaction of the software and complete the design of roughness detection algorithm on the Windows platform. Then, through the combination of hardware and software, the function of connecting the camera and collecting pictures, calculating the roughness and output roughness. Finally, the roughness detector is assembled, which can complete the roughness information output more intuitively and systematically.

In the practical application scenarios in the construction industry, the software has been successfully integrated into the roughness detection

prototype, and was used in the surface quality roughness detection of building materials. In the trial process, the software and the prototype worked together well together, and the system ran smoothly, with no obvious fault or abnormal situation. Through a long time of continuous operation test, the stability and reliability of the system has been fully verified, providing an efficient and accurate roughness detection solution for the construction industry, and also laying a solid foundation for the subsequent optimization and promotion.

Zhuo Wentao(Electronic Information)

Supervised by Wang Shinong

KEY WORDS: visual recognition, image processing, depth map, point clouds, deep learning

目 录

摘 要	I
Abstract	IV
第 1 章 绪论	1
1.1 研究背景及意义	1
1.2 国内外研究现状	3
1.2.1 国内研究现状	3
1.2.2 国外研究现状	5
1.3 研究内容	8
1.4 技术路线	9
第 2 章 理论技术及所需设备介绍	10
2.1 卷积神经网络介绍	10
2.2 注意力机制概述	13
2.3 开发环境介绍	15
2.4 奥比中光 Deeyea 相机介绍	16
2.5 粗糙度检测仪样机介绍	17
2.6 本章小结	19
第 3 章 混凝土结合面粗糙度计算	20
3.1 粗糙度计算理论	20
3.2 数据采集	21
3.3 点云处理	22
3.3.1 点云的计算	22
3.3.2 点云的旋转	24
3.3.3 点云的三维重建	25
3.4 粗糙度处理	27
3.4.1 粗糙度计算	27
3.4.2 粗糙度误差处理	28
3.5 本章小结	30
第 4 章 深度学习下混凝土粗糙度等级识别	32

4.1 图像处理算法模型	32
4.1.1 Resnet50 模型	32
4.1.2 注意力机制模型	35
4.2 数据预处理与思路分析	36
4.2.1 样本扩充	36
4.2.2 注意力机制嵌入方式	37
4.3 仿真模型与结果分析	38
4.3.1 实验环境	38
4.3.2 消融实验	38
4.3.3 不同卷积神经网络准确率对比	39
4.3.4 学习率对模型准确度的影响	39
4.3.5 结果分析	40
4.4 本章小结	41
第 5 章 基于 Visual Studio 环境实现混凝土粗糙度等级识别	43
5.1 系统总体设计框架	43
5.2 相关库函数和 MFC 介绍	44
5.2.1 OpenCV 库	44
5.2.2 OpenNI 库	45
5.2.3 Eigen 库	46
5.3 系统功能模块与算法实现	46
5.3.1 功能模块	46
5.4 用户交互	48
5.5 本章小结	52
第 6 章 总结与展望	53
6.1 工作总结	53
6.2 展望	54
参考文献	55
致谢	64

第 1 章 绪论

1.1 研究背景及意义

在当今社会中，混凝土是生活中一种常见的建筑材料，它可以用来建造各种各样的住房，商业大楼，以及基础的公共设施^[1]。目前，混凝土在生产生活中的应用主要有：浇筑预制构件、浇筑钢筋混凝土结构以及用作外墙的装饰材料。图 1-1 展示了混凝土在日常生产、生活中的不同形态^[2]。在施工现场实施安装前，已经制作完成的装配式混凝土构件叫做浇筑预制构件，它是一种高效率、高效率的施工方法^[3]。而浇筑钢筋混凝土结构是一种常用的结构型式，其主要作用是将钢筋和混凝土连接起来，使其具有较强的承载力^[4]。另外，它还可以在外墙上涂上一层涂料，使建筑具有各种不同的外表效果。混凝土的持续革新与发展，为建筑业带来更多的可能。混凝土在居住、基建、绿化等各个方面的运用，既体现了现代建筑的美学特征，也给人们的生活带来了一种温馨和安全感。可以说，它是当代建筑的灵魂，也是人们追求更好生活的源泉。



图 1-1 混凝土在生产生活中的形态

建筑业作为国民经济的重要支柱，对国民经济的持续稳定发展具有重要的支持作用。但是，建筑行业的生产模式仍然是粗放式的，还没有达到高质量发展的要求。2020年，住房和城乡建设部、国家发展改革委、科技部等13个部门联合印发了《关于推进智能建造与建筑工业化协调发展的指导意见》。该文件明确指出，要以建筑产业化为核心载体，以数字化和智能化升级为驱动力，着力推动关键技术的创新与突破，加速智能建造技术在工程建设全生命周期的应用，构建一个涵盖科研、设计、生产加工、施工装配以及运营管理的完整产业链条^[5]。近年来，在外部经济下行压力不断增大的情况下，我国混凝土行业将继续面临“需求收缩，竞争加剧，均价下降，回款不佳，利润承压”的特征。我国规模以上的混凝土生产企业数量持续增长，行业集中度逐渐提升。然而，随着混凝土行业的盈利水平不断地下降，整个行业的毛利也在不断地降低。如今，混凝土行业面临最大的挑战就是财务资金问题，行业的竞争也在不断地加剧。从市场结构来看，整个行业都面临着转型问题，传统的混凝土产业也将走向数字化转型的道路。为了提高生产效率，降低成本，提高质量，对混凝土生产，运输，使用等各个环节实行智能化管理是一个必要的历程^[6]。

混凝土结合面的施工工艺、粗糙程度、界面剂种类、修补方位以及强度等级等因素均能影响新旧混凝土结合面的性能^[7]，例如抗剪性能、外观质量和使用寿命，其中表面粗糙程度是影响混凝土本身结构性能的一个重要因素^[12]。粗糙的结合面为混凝土之间提供了更多的机械咬合点，也有助于增加混凝土之间的化学粘结机会。此外，结合面的粗糙程度对结构整体性也有所贡献^[9]。在混凝土结构承受荷载时，结合面是应力传递的关键部位。粗糙的结合面能够使应力在新、旧混凝土之间更均匀、有效地传递。由于粗糙结合面能增强新、旧混凝土之间的协同工作能力，在结构受到外力作用而发生变形时，还能够有效减少新、旧混凝土之间的变形差异。在耐久性使用方面，粗糙的混凝土结合面可以提升抗渗性能，能够有效阻挡水分及有害物质（例如氯离子、硫酸根离子等）的渗透。因为在粗糙的表面，水分和有害物质需要沿着更加曲折的路径才能穿透结合面，这就增加了它们渗透的难度。还能抵抗环境的侵蚀，例如在恶劣的环境条件下，海洋环境中的混凝土结构（如码头、防波堤等）或者在化学腐蚀环境中的工业建筑，结合面粗糙度的作用更加明显。粗糙的结合面使得混凝土能够更好地抵抗海水的冲刷、

化学物质的侵蚀等。因此，在混凝土结构的设计、施工和维护中，为了保证工程结构的质量和安全性问题，方便评估现有结构状况和指导修复工作，必须对结合面进行表面粗糙度的测量与等级划分。随着我国建筑科学技术的发展，纵观市场的需求和政府的引导，对混凝土结合面粗糙度的测定应当往更加科学化、智能化、便捷化^[10]的方向进行研究。

1.2 国内外研究现状

1.2.1 国内研究现状

《混凝土结构设计规范》GB 50010-2010^[11]中对混凝土粘结面采用粗糙处理或键槽处理的方法进行了详细的阐述。《混凝土结构工程施工规范》GB 50666-2011^[12]对预制构件结合面的制作与加工提出了明确的要求，当设计中没有特别的要求时，可采取凿毛或者拉毛的方法，也可以使用露骨料。现行行业标准《装配式混凝土结构技术规程》JGJ 1-2014^[13]中，针对预制梁、板和后浇混凝土叠合层的结合面，有着关于粗糙面的明确规定。具体而言，预制梁的端面务必设置粗糙面，这是为了确保其与后浇混凝土结合时能形成良好的连接效果，提升整体结构的稳定性；预制剪力墙同样如此，其顶部和底部在与后浇混凝土相接的结合面处，粗糙面的设置不可或缺，侧面与后浇混凝土的结合面亦是这般要求，如此一来，能让剪力墙在装配过程中更好地与后浇部分融为一体，协同受力；此外，预制柱的底部也必须设置粗糙面，通过增加接触面的摩擦力与咬合力，为整个装配式混凝土结构的稳固性筑牢根基。但是，我国现行规范关于结合面粗糙处理的规定还显简略。虽然规范GB 50666-2011^[12]中阐述了拉毛、凿毛与露骨料工艺适用于处理混凝土结合面处理，但是没有给出相对具体的要求与做法。规范GB 50010-2010^[11]中规定了结合面的粗糙面积和凹凸深度，即粗糙面的面积占比应不低于结合面总面积的80%；预制板上的粗糙面凹凸深度需达到4mm及以上；对于预制梁端、预制柱端以及预制墙端，其粗糙面凹凸深度标准相应提高，须大于等于6mm。但是规范GB 50010-2010^[11]中并没有给出结合面的粗糙面凹凸深度的具体定义。目前有关的地方性标准大多将“凹凸深度”界定为沟槽或凹坑的凹陷深度，如上海、浙江和广东等地，将沟槽或凹坑内的几个点的平均值或最大深度作为其表面凹凸深度的表征。江苏地区采用灌砂方法，估算出拉毛结合面沟槽内的平均凹入深度。然而，这些参数都没有考虑凹槽和凹坑所占结合面的

面积比例。需要指出的是，在同一下凹深度条件下，因沟槽或凹穴所占区域的比例不同，结合面的粗糙度也会有很大的差异。为此，需要引入更为可靠的评估方法来评价结合面的粗糙程度。

20 世纪 90 年代，国内学者在研究不同结合面处理工艺对叠合板受力性能的影响^[14]，以及处理工艺、界面处理剂对结合面抗剪强度及抗渗性能的影响时^[15]，发现这些性能均会受到结合面粗糙度的影响。

随着科技的不断发展，我国对混凝土结合面粗糙度的检测方法越来越多，应用范围更加广泛，检测的新技术和新方法已日趋成熟。进入到 21 世纪，我国对混凝土表面粗糙度的检测方法主要有大类：一是定性检测，二是定量检测。定性检测主要是通过目测、手工触摸等方式来评价混凝土的外观品质及平整度。定量检测是利用仪器对混凝土表面的高、低差异进行测量，并将其数值化表达出来。定性检测中最典型的测量方法是触感测量法，通常指用手在混凝土表面上的触觉来评价其表面的粗糙程度。定量检测的方法包括光学测量法和机械测量法。光学测量法是一种非接触式的测量方法，该方法可有效地避免人为因素对测定结果的影响。常见的光学检测装置有激光扫描仪和平面激光测量仪，这些装置通过产生 3D 曲面模型，求出待测结合面的均方根粗糙度。机械测量法是一种接触式的测量方法，是利用机器设备与混凝土表面进行直接接触，从而获得其表面的粗糙度。通常使用的仪器有表面粗糙度计，金属刮板，触针式测量仪等。图 1-2 为混凝土接触式和非接触式测量混凝土结合面的工具，其中图 1-2 (a) 是激光扫描仪外观图，图 1-2 (b) 是平面激光测量仪外观图，图 1-2 (c) 是机械测量混凝土结合面粗糙度的图片。



(a) 激光扫描仪图片 (b) 平面激光测量仪外观图 (c) 机械测量粗糙度图片

图 1-2 定量检测结合面粗糙度图

2003 年，郭进军^[16]等自行设计出一种测量混凝土表面粗糙度的仪器，该仪器具有快速、方便的特点。另外，他们还还对表面拟合和实测数据平均值两种测试

方法进行了阐述，对其与灌砂法进行了对比，并对其优缺点进行了分析。

2013 年，张雄^[17]等提出了一种基于激光三角测距理论的方法，该方法可以提取混凝土粗糙面空间形貌特征，采用覆盖法获得用于表征粗糙度的分形维数，并对其进行量化分析，揭示其对应的分形特征。研究表明，用分形维数 D 可表征混凝土的粗糙度，分形维数 D 与新旧混凝土的抗折强度成正比。

2017 年，田稳苓^[18]等通过图像处理的方式，测量出了混凝土结合面的粗糙度。作者通过量化结合面像素值的方式，建立粗糙面分数维值与灌砂平均深度、平均构造深度之间关系，得出了平均构造深度与结合面粗糙度之间的换算公式，并且讨论了结合面粗糙度对新老混凝土结合面抗剪性能的影响，最后证实了该方法检测新老混凝土结合面粗糙度的可行性。

2019 年，黄选明^[19]等提出用灌砂法测量混凝土表面的粗糙度，但有一定的局限性，该方法只能表征出粗糙面的总面积，具有单一性，无法科学的测量出结合面的粗糙度。

2020 年，张渤钰^[20]等在仿真堆砂方法的工作原理上，开展了基于三维激光扫描技术的混凝土构件表面粗糙度测量方法的研究。采用三维激光扫描与堆沙试验相结合的方法，对三种不同类型的混凝土试件进行了测试，并对测试结果进行了比较分析。结果表明，该方法可以基本满足粗糙度检测的要求。

2020 年，胡淑婷^[21]等提出一种新的三维形貌测量方法，该方法可以有效地克服现有测量方法表达不完整、受环境影响大、测量精度不高等不足。实验通过设计 12 块粗糙度不同的混凝土试样，建立相应的镜面模型，利用三维扫描技术对其 3D 形貌进行测量，并对其误差进行分析。研究发现，镜像模型与混凝土试样的三维粗糙度指数之间的误差均小于 30%，采用镜面模型方法可以实现复杂曲面的三维粗糙度测量，有助于提高隐蔽关键节点的完整性。

1.2.2 国外研究现状

国外在对混凝土材料的研究方面进行了大量的研究。国际混凝土修复协会（ICRI）的 CSP 等级标准定义，根据不同的混凝土表面粗糙程度处理方法和工程要求，定义了 10 种粗糙度 CSP 等级，并配有一组粗糙度比对模板 CSP1~10，便于通过目测和触摸确定粗糙度等级。CSP 模板大小约为 16 平方英寸，由灰色柔韧的橡胶材料制成，内含 10 个不同粗糙度的拓植样板。但使这种方法有相应

的局限性，虽然在实际工程中得到了广泛应用，但它是一种定性的评估方法，需要依赖个体判断，不同的检验人员可能会得出略有差异的结果。欧洲 *Shear at the interface of precast and in-situ concrete*^[22]提出，新老混凝土结合面应该是干净的，没有浮浆，应该经过粗糙化处理之后，露出粗集料，保证在浇注新混凝土前，裸露的集料不会受到干扰。美国的规范 *ACI 318-19*^[23]规定，混凝土接缝处的结合面也必须是干净的，没有浮浆的，而且要特别地粗化处理，表面的凹凸度要在 6 毫米以上。近年来，高性能混凝土、自修复混凝土、纳米混凝土等一系列新材料相继问世。这些新材料既可改善其力学性能，又可扩大混凝土的使用范围。不仅如此，国外对混凝土的施工工艺也进行了大量的研究与应用。通过施工工艺的改进，进而改变混凝土的粗糙度，可以提高混凝土的施工质量，也可以减少对环境的影响。常见的混凝土结合面施工工艺如图 1-3 所示。




图 1-3 常见混凝土结合面施工工艺

20 世纪末到 21 世纪初，国外学者着重研究混凝土结合面的抗剪性能与其表面粗糙度的关系。1994 年，武井一夫^[24]通过设计多组混凝土剪切强度试验，发

现评估结合面粗糙度方法不同,得到的评估值也不同。但是结合面的凹凸深度、面积、附着力、凹凸角的斜率均是影响其抗剪强度的关键因素,从而会影响到结合面的粗糙度。

1996 年,牛垣和正等^[25]通过研究粗糙度与抗剪强度之间的关系,发现粗糙度与剪力和轴力比值呈正相关,但误差较大。

1998 年,香取庆一^[26]等研究表明,结合面粗糙度、混凝土强度同抗剪强度的相关系数超过 0.7。

2018 年,高瀬裕也^[27]发现结合面粗糙处理后加设施工锚时的抗剪强度比单纯施工锚的情况高,并且拥有更大的受压抵抗面积。阿部隆英^[28]等人研究表明,粗糙面面积比(粗糙化部的水平投影面积与结合面面积的比)在 0.3 时,抗剪强度最大。

进入 21 世纪,国外学者开始运用图像处理技术以及 3D 激光扫描技术等研究混凝土结合面的粗糙度和粗糙度各异性的关系。2007 年, Pedro MDS^[29]等采用数字图像处理技术,获得结合面的粗糙度轮廓,并对结合面粗糙度进行量化评估,分析了评估参数与粘结强度之间的相关性关系,说明了粗糙度与粘接强度有相关性。

2009 年, Tatone BSA^[30]等通过一系列的混凝土断裂面数字化,证明了三维表面测量能够评估表面粗糙度和粗糙度各向异性。

2013 年, Pedro MDS^[31]等通过对前人研究的粗糙度评价方法总结后指出,结合面的处理方法对不同龄期浇筑的混凝土层间粘结强度具有明显影响,同时指出 2D 扫描具有便利性,3D 扫描更加准确。

2015 年, Hoła J^[32]等人的研究表明,利用三维激光扫描技术获得的粗糙度参数信息可以无损表征混凝土结合面的拉脱附着力。Grigoriadis K^[33]在研究电动凿锤和远程机器人水力腐蚀对混凝土表面粗糙度的影响时,发现基于条纹的激光干涉测量法能够更准确地测量和表征混凝土基板表面粗糙度。

2018 年, Bentz DP^[34]等在研究混凝土基材水分状态和粗糙度对混凝土结合面微观结构和粘结强度的影响时,发现材料的流动性、基材粗糙度及湿度状态均能影响结合面的粘合性能。

2019 年, Sarker M^[35]等利用单个摄像机,解决了点云重建和曲面点滤波的问

题,在降低计算量的同时,也降低了结合面的粗糙度采集误差。武者右京^[36]等人,在 3D 扫描技术评价粗糙度的基础上,提出了剪切抵抗力的计算公式,并验证了公式的准确性。

1.3 研究内容

目前,国内外已开展了大量的试验和理论研究,主要集中在评估混凝土结合面力学性能试验、粗糙度测量与评价、粘结机制等方面。然而,在实际应用中,缺乏系统性的质量控制方法,且缺乏与之相适应的实用评价指标,更缺乏一套完善的结合面粗糙度评价方法,用于叠合构件的工作性能评价和工程质量验收。

本文针对混凝土结合面粗糙度等级识别中存在的问题展开研究,研究内容主要包括以下几个方面:

(1) 采集多种工艺的结合面图片,对图片进行预处理及算法处理。使用奥比中光相机采集结合面图片,得到深度图和彩色图,并对深度图提取深度信息,绘制成三维重建后的点云,计算粗糙度信息,并按照粗糙度等级分类。之后,要确保数据集的均衡性,保证模型的训练和性能不受到影响。为此,本文采取平衡数据集的方法对图片的数量进行处理,保证后续的深度学习进程不受到样本数量的制约,最终得到了可以用于深度学习训练的数据库。

(2) 接下来,使用 Matlab 2023a 的深度学习工具箱,构建深度学习模型。之后,将结合面粗糙度等级信息作为标签,用于训练深度学习模型。接着,通过训练常用的深度学习模型,观察不同模型识别的精确度后,选择准确度较大的 Resnet50 作为主干网络。之后,对 Resnet50 进行改进,加入 CBAM 注意力机制,识别预处理后的图片,最终获得能够识别结合面粗糙度等级的深度识别模型。

(3) 构建了混凝土结合面粗糙等级检测系统,并嵌入粗糙度检测仪中,形成了结合面粗糙等级检测技术。本文在 Windows 平台上进行结合面的粗糙度等级识别,加强了检测方法的多样性和可操作性。首先,将可识别粗糙度等级的 Matlab 程序通过 Matlab Coder 工具箱转换为 C++ 代码,在 Visual Studio 开发环境中调试。其次,把调试好的 C++ 程序移植到组装的粗糙度检测仪中,将电脑和粗糙度检测仪通过数据线连接,最终实现结合面图片的采集与粗糙度等级的系统性识别。

1.4 技术路线

本文的技术路线如图 1-4 所示。




图 1-4 技术路线

首先基于 Matlab 进行粗糙度算法编写，包括图片采集、数据处理、点云重建和粗糙度计算。通过奥比中光相机采集混凝土表面的图片，得到大量的、不同类型的结合面图片，输出的图片有彩色图和深度图两种。根据结合面图片的几何特征，对采集到的图片进行粗糙度计算，其中涉及到了数据变换、点云转换、三维重建以及粗糙度计算这几个步骤。

其次，以划分粗糙度等级的结合面图片为基础，运用深度学习模型进行深度学习，根据识别准确度对模型优化处理，得到优化后的深度学习模型，该模型可以直接检测混凝土结合面的粗糙度等级。

最后，将 Matlab 开发环境下的代码转换成 C++ 代码，并在 Visual Studio 开发环境中调试。同时在 Visual Studio 环境中制作 MFC 界面，用户可通过 MFC 界面实现人机交互，实现获取深度信息和输出粗糙度信息的功能。最终完成了粗糙测量方法嵌入检测设备中的工作，形成了完整的粗糙度检测技术。

第 2 章 理论技术及所需设备介绍

传统的混凝土结合面粗糙度检测通常采用接触式和非接触式的方法,这种检测方法通常精确度不够高,并且浪费时间。以深度学习为基础的检测方法可以实现粗糙度等级的智能化检测,从而提高检测的效率和准确性。通过训练大规模的混凝土结合面的图像数据集,深度学习模型通过学习相关特征,识别各种类型的结合面粗糙度等级,这些结合面类型包括拉毛、花纹钢板、小键槽、泡泡膜、露骨料等。本文运用到的卷积神经网络,它作为深度学习模型中的一种,在进行图像分割和目标检测任务时取得了较好的效果^[37]。本文也运用到了 C++ 语言对结合面粗糙度信息进行处理,并将检测技术移植到粗糙度检测设备中,实现了软硬件结合的方式,提升了检测便捷性。本章将介绍卷积神经网络相关内容,以及使用到的奥比中光 Deeyea 相机、组装的粗糙度检测仪设备、开发环境等,为后续的工作安排提供理论基础。

2.1 卷积神经网络介绍

卷积神经网络(Convolutional Neural Network, CNN)是深度学习领域中一种在计算机视觉任务中表现卓越的模型。它们的设计灵感来自于生物学中的视觉系统,旨在模拟人类视觉处理的方式^[38]。在过去的几年中, CNN 已经在图像识别、目标检测、图像生成和许多其他领域取得了显著的进展,成为了计算机视觉和深度学习研究的重要组成部分^[39]。在卷积神经网络中,卷积操作是指将一个可移动的小窗口(称为数据窗口)与图像进行逐元素相乘然后相加的操作。这个小窗口其实是一组固定的权重,它可以被看作是一个特定的滤波器或卷积核^[40]。这个操作的名称“卷积”,源自于这种元素级相乘和求和的过程。这一操作是卷积神经网络名字的来源。

当使用全连接神经网络^[41]处理大尺寸图像时,存在以下三个显著问题:(1)图像被展开为向量时,会丢失其空间结构信息;(2)网络参数过多,导致计算效率低下且训练过程复杂;(3)过多的参数还容易引发过拟合现象。这些全连接神经网络所面临的问题都能被 CNN 有效解决。与传统神经网络不同,卷积神经网络中的神经元以三维结构排列,即宽度、高度和深度。在输入层中,宽度

和高度对应于输入图像的尺寸，而深度则表示图像的通道数，例如，对于 RGB 图像有 R、G、B 三个通道，深度为 3；而对于灰度图像只有一个通道，深度为 1。对于中间层来说，宽度和高度指的是特征图的宽和高^[42]，通常由卷积运算和池化操作的相关参数决定；深度指的是特征图的通道数，通常由卷积核的个数决定^[43]。

通常情况下，一维和二维卷积可以处理一维数据和二维图像数据，而三维卷积用来处理三维图像或者立体影像任务^[44]。

(1) 一维卷积运算。一维卷积是一种在一维数据上应用滑动窗口的数学运算，用于提取有用的特征^[45]。与二维卷积不同，一维卷积核只能左右滑动，适合处理具有连续顺序特征的一维数据。一维卷积分为 full 卷积、same 卷积和 valid 卷积，计算过程涉及卷积核与输入数据相乘并求和^[46]。其中 full 卷积包含了 same 卷积和 valid 卷积，same 卷积包含了 valid 卷积，三种卷积过程均是卷积核沿着一维张量移动，不同的是 full 卷积从卷积核的第一个位置就开始与张量的第一个位置相乘，而在 Same 卷积和 Valid 卷积中，卷积核与输入张量的相乘操作分别从卷积核的前两个位置和前三个位置开始，并与张量的对应位置进行逐元素相乘。在卷积核滑动的最后一步中，其位置与初始滑动位置呈对称关系。以长度为 5 的一维张量和长度为 3 的卷积核为例，图 2-1 展示了这三种卷积方式的输出结果，具体展示了每种卷积操作的计算过程及其最终得到的结果。




图 2-1 一维卷积运算

(2) 二维卷积运算。在对图像进行处理的时候，卷积层通过卷积核对输入图像进行运算，这个卷积核也可被称为滤波器，从而获得图像的相关特征。在二维卷积层中，输入数据通常是一个多通道的二维数组，例如彩色图像的 R、G、B 三个通道。卷积核也具有相应的通道数，每个通道有一个二维数组。在卷积

运算中，每个通道的输入数据与对应通道的卷积核进行互相关运算，然后将所有通道的结果相加，得到最终的输出^[47]。二维卷积运算的公式如式（2-1），即将卷积核与输入图像的对应区域元素逐个相乘再求和，最终遍历整个输入图像。

$$f * g(n) = \int_{-\infty}^{+\infty} f(\tau)g(n - \tau)d(\tau) \quad (2-1)$$

二维卷积运算如图 2-2 所示，输入的矩阵与核的相对对应位置相乘，得到输出的矩阵。




图 2-2 二维卷积运算

（3）三维卷积运算。二维卷积对图像的操作是在单通道上进行的，其输入是一个二维矩阵，包括了宽度和高度。而三维卷积在输入中增加了深度这一维度，输入是具有高度、宽度和深度的三维矩阵^[48]。图 2-3 就是三维卷积过程，其滤波器的深度小于输入层的深度（即滤波器的尺寸小于输入通道的大小）。因此，三维滤波器能够在图像的三个维度（高度、宽度和通道）上进行移动^[49]。在每个滑动位置，卷积操作通过逐元素的乘法和加法计算出一个数值。由于滤波器在三维空间（图像的高度、宽度和通道）中滑动，因此输出的数值也按照三维结构排列，形成一个三维数据。三维卷积广泛应用于视频分类、三维医学图像分割等场景^[50]。




图 2-3 三维卷积过程

ResNet50 主要应用于图像分类、目标检测、图像分割等计算机视觉任务，

这些任务的输入数据通常是二维的图像^[51]。例如在图像分类任务中，输入的是具有一定尺寸的二维图像，ResNet50 通过一系列的二维卷积操作和残差连接，逐步提取图像的特征，并最终输出图像所属的类别概率。ResNet50 是二维卷积神经网络，主要由一系列的卷积层、残差块、批量归一化层、激活函数以及全连接层等组成^[52]。其中，卷积层是其重要组成部分，在 ResNet50 中使用的卷积核是在二维平面上进行滑动操作的，对输入图像的二维矩阵数据进行特征提取。例如，对于常见的彩色图像数据，其具有高度和宽度两个维度，卷积层通过不同大小的卷积核在图像的二维平面上移动，提取出不同层次的特征，如边缘、纹理等，这体现了其二维卷积神经网络的特性。ResNet50 中的核心结构是残差块^[53]，以 Bottleneck 结构的残差块为例，它包含了三个卷积层。第一个卷积层采用了 1×1 的卷积核，其主要功能是降低输入数据的通道维度。通过这种方式，可以在减少计算量的同时，尽可能保留关键信息；第二个卷积层采用 3×3 的卷积核，用于在二维平面上提取数据的特征，从而捕捉图像的局部空间信息；第三个卷积层再使用 1×1 的卷积核将通道数恢复到与 shortcut 连接匹配的维度，以便进行残差相加操作。这些卷积层都是在二维图像数据上进行操作的，进一步说明了 ResNet50 是二维卷积神经网络。本文需要对二维结合面图像进行处理，并进行粗糙度等级识别，故采用 Resnet50 为主网络，对混凝土结合面的粗糙度等级进行识别。

2.2 注意力机制概述

人在观察事物时会有选择性的关注较为重要的信息，称其为注意力^[54]。通过持续关注这一关键位置以获得更多的信息，而忽略其他的无用信息，这种视觉注意力机制显著提升了我们在信息处理中的效率和准确性^[55]。通俗的说，深度学习中的注意力机制 (Attention Mechanism) 和人类视觉的注意力机制类似，就是在更多信息中把注意力集中放在重要的点上，选出关键信息，而忽略其他不重要的信息，图 2-4 展示了注意力机制的通俗理解方法，即注意力机制是对需要关注的像素位置进行重点关注^[56]。注意力机制是一种在机器学习中广泛使用的数据处理方法，它被应用于自然语言处理、图像识别、语音识别等多种类型的机器学习任务中^[57]，它对不同信息的关注程度由权值来体现，可以视为查询矩阵(Query)、键(Key)以及加权平均值构成了多层感知机(Multilayer Perceptron, MLP)。它的思想，

类似于寻址，假设目标图像中的某个元素查询矩阵已经得知，通过计算，可以获得查询矩阵和各个键的之间的关联程度，从而得到每个键对应值的权重系数，然后对这些关联性大的值进行加权求和，就可以得到最终的注意力数值。总之，查询矩阵和键是计算相关值的权重系数的工具，注意力机制其实是对源图像中着重关注的元素值进行加权求和。




图 2-4 注意力机制关注的像素位置图

常用的注意力机制包括以下几种：

SE 注意力机制^[58]主要包括压缩和激励两个部分，其中压缩部分是全局池化，对特征进行压缩；激励部分是通过两层全连接结构得到特征图中每个通道的权值，并将加权后的特征图作为下一层网络的输入。

CA 注意力机制^[59]是对宽度和高度两个方向分别全局平均池化，分别获得在宽度和高度两个方向的特征图，然后将两个方向的特征图 `concat`，然后送入共享卷积降维，再通过批量归一化处理 and 激活函数后得到特征图。

ECA 注意力机制^[60]首先对输入的特征图进行全局平均池化操作，将每个通道的二维特征图压缩成一个具有全局信息的数值。其次根据输入特征图的通道数自适应地计算一维卷积的核大小。接着使用计算得到的卷积核大小，对全局平均池化后的特征张量进行一维卷积操作。之后使用 `Sigmoid` 激活函数，对一维卷积的输出结果进行 0 到 1 之间的映射，就可以得到基于各个通道的注意力权重。然后将输入特征图与注意力权重与相乘，通过广播机制将注意力权重扩展到与输入特征图相同的维度，并执行逐元素乘法，得到特征图。

GAM 注意力机制^[61]分为两个模块：通道注意和空间注意，通道注意是学习不同通道的权值，并用权值对不同通道进行多重划分，空间注意关注目标在图像

上的位置信息，并通过空间特征的加权选择性的聚焦每个空间的特征。

本文采用在深度学习网络中嵌入 CBAM 注意力机制的方式，来提高模型识别结合面粗糙度等级。CBAM 注意力机制^[62]分为通道注意力和空间注意力两部分^[62]，通道注意力和 SE 注意力机制的结构相同，只是加了一个最大池化，中间共享一个 MLP，最后将两部分的输出相加经过激活层。将通道注意力模块得到的通道权重乘以原始的输入特征图，调整每个通道的重要性，得到一个经过通道注意力调整后的特征图。空间注意力使用平均池化和最大池化对输入特征层进行通道压缩，再使用卷积操作。最后，将通道注意力机制的特征图输入到空间注意力模块，将空间注意力模块得到的空间权重乘以经过通道注意力机制调整后的特征图，得到最终的输出结果，即经过 CBAM 注意力机制处理后的特征图，该特征图在通道和空间维度上都进行了有效的特征选择和增强，能够更好地用于后续的任务，如分类、检测等^[63]。

2.3 开发环境介绍

Matlab 是一款广泛应用于科学计算、工程设计、数据分析等众多领域的高级编程语言和交互式开发环境^[64]，它的主要组成部分包括命令窗口、编辑器、工作区、当前文件夹等^[65]。本文需要用到编辑器对输入的图像数据进行预处理，包括对输入的图像进行翻转、裁剪、平移，以及对深度数据进行点云的转化，从而计算出图片的粗糙度，并按照粗糙度等级分类在不同的文件夹中。本文还需用到其中的深度学习工具箱，以训练出可以识别混凝土结合面粗糙度等级的深度学习模型。

Visual Studio 是一款由微软公司开发的集成开发环境，用于开发各种类型的应用程序，如桌面应用程序、Web 应用程序、移动应用程序等^[66]。Visual Studio 支持多种编程语言，如 C++、C#、Visual Basic 等^[67]，还提供了丰富的工具和功能，如代码编辑器、调试器、图形化界面设计器、版本控制等，方便开发者进行应用程序开发和管理^[68]。本文用到该软件编写 C++ 程序、制作 MFC 界面，可以直观地检测、输出粗糙度信息。C++ 是一种高级编程语言，它是在 C 语言的基础上发展而来的。C++ 保留了 C 语言面向过程的编程特性。在面向过程编程中，程序是由一系列的函数和数据结构组成的。C++ 的重要特征之一是面向对象编程，在面向对象编程中，程序是由对象组成的，对象是类的实例，类定义了

对象的属性（数据成员）和行为（成员函数）。MFC（Microsoft Foundation Classes）是微软基础类库，它是一套 C++ 类库，用于开发 Windows 应用程序。MFC 对应用程序编程接口（Windows API）进行了封装，使得开发人员可以更加方便、高效地创建具有 Windows 图形用户界面（GUI）的应用程序。它提供了一系列的类来处理窗口、对话框、菜单、控件等常见的 Windows 编程元素。本文基于 Visual Studio，使用 C++ 语言编写程序，设计 MFC 界面，实现混凝土结合面粗糙度的检测。

2.4 奥比中光 Deeyea 相机介绍

本文选用奥比中光 Deeyea 相机采集结合面数据，该相机具有低功耗、小体积、高分辨率的特点，适用于智慧办公、体感游戏、手势交互等室内、半室内场景^[69]。相机的外观如图 2-5 所示，该相机是一款基于 3D 结构光技术的单目摄像机，主要由一个彩色摄像头、一个红外摄像头、一个激光投影仪以及内置处理器组成。使用时，需从奥比中光官方网站或其他可靠来源下载并安装相机的驱动程序和相关软件，这些软件通常包括相机的控制界面、图像采集和处理工具等。安装完成后，打开相机的控制界面。在控制界面上可以设置相机的参数，如分辨率、帧率、曝光时间等，根据具体需求进行相应的设置。本文设置的相机参数如表 2-1 所示。




图 2-5 奥比中光 Deeyea 相机

表 2-1 奥比中光 Deeyea 相机参数

技术参数	描述	技术参数	描述
测量范围	0.25~1.5m	使用场景	室内、半户外
精度	1m 处 $\pm 5\text{mm}$	环境温度	10°C~40°C
操作系统	Windows	数据接口	USB3.0
深度图分辨率	640*400@30FPS	深度视场角	H/V/D:67.9°/45.3°/78°
彩色图分辨率	1280@960@30FPS	彩色视场角	H/V/D:71.5°/56.7°/87°

奥比中光 Deeyea 相机成像原理是通过激光投影仪向被测物体表面投射可

控制的光点、光条或激光散斑，然后由相机的图像传感器接收这些结构光的反射或散射信息，通过彩色相机采集彩色图，红外相机采集带有激光散斑的红外图并转化为深度图，输出深度信息，从而获取被测物体的三维信息^[70]。相机的成像原理如图 2-6 所示。




图 2-6 相机成像原理

在相机的控制界面中，点击“开始采集”按钮，相机将开始采集图像，可以通过控制界面实时查看采集到的图像，并进行相应的处理和分析。如果想要保存采集到的图像数据，可以在控制界面中选择“保存”或“导出”选项，将图像数据保存到本地硬盘或其他存储设备中。本文采集到的结合面图像分为深度图和彩色图两种。奥比中光相机采集图片的实例如图 2-7 所示，包括彩色图和深度图。




图 2-7 相机采集图片实例

2.5 粗糙度检测仪样机介绍

本项目需组装混凝土结合面粗糙度检测设备，以规范地检测混凝土结合面的粗糙度信息。初步的粗糙度检测仪样机设计图如图 2-8 所示。该装置包含：遮光外壳、刚性框架、内部光源、电池组、开发板、奥比中光相机、触摸屏。




图 2-8 结合面粗糙质量检测设备结构设计图

图 2-8 中，各部分的具体功能如下：

（1）奥比中光相机用来采集混凝土结合面图片，使用该相机可以获得两种图片，其中彩色相机采集结合面的彩色图，红外相机采集激光散斑投影图（简称红外图），相机内置处理器会自动处理红外图并输出深度图。并且奥比中光相机的焦距是固定的。

（2）开发板是对数据进行处理的处理模块，主要涉及到深度数据到点云的转换、点云粗糙度的处理和对检测结果的评价。

（3）本系统的显示屏以触控的方式，显示结合面粗糙度等相关信息的检测结果，并提供人机互动界面。

（4）本系统的电池组用来提供设备所需的电能。

（5）内部光源配合遮光外壳，为整个系统提供了稳定的照明环境。由于奥比中光相机适用于室内、半室内使用场景，不适用于室外紫外线强的场景，因此通过隔绝外部环境光，同时提供内部稳定光照的方式，来提高奥比中光相机的适用性。因此内部光源起到了“定光照”的作用。

（6）刚性框架是用来固定奥比中光相机、开发板和内部光源的，与遮光外壳共同作用，固定了奥比中光相机的摄影角度（与探测面垂直）、探测距离和探测范围。由于在检测图片数据时，靠近奥比中光像机的区域，其密集度高于远离像机的区域，为了防止结合面点云数据在不同位置上疏密分布不均，需将奥比中光相机的拍摄角度固定为 90° 。将奥比中光相机固定在平行于结合面的刚性框架上，做到了固定 90° 拍摄角度的要求，该做法起到了“定角度”的作用。其次，为了更具代表性地拍摄出结合面的凹凸程度信息，需要固定粗糙度检测仪的检测

范围，最终确定结合面的检测范围不小于 $100\text{mm} \times 100\text{mm}$ 。这就需要固定相机的焦距以及相机距离结合面的检测距离。根据表 2-1 中相机的视场角均不小于 45° ，工作距离不小于 0.25m ，当检测角度为 90° 、遮光外壳拍摄范围为 $60\text{mm} \times 60\text{mm}$ 时，可检测到结合面范围大于 $100\text{mm} \times 100\text{mm}$ ，满足检测要求。该做法起到了“定范围”的作用。

2.6 本章小结

(1) 本章首先介绍了卷积神经网络、注意力机制的相关理论，主要运用到深度学习模型识别结合面的粗糙度，这种方法可以更高效的实现混凝土结合面的粗糙度等级识别。

(2) 其次，本章介绍了系统的开发环境，包含 Matlab 和 Visual Studio 两个软件，主要在 Matlab 上进行粗糙度等级的识别、在 Visual Studio 上进行界面的编辑并将代码嵌入粗糙度检测仪中，实现软硬件结合的粗糙度等级识别，更加具有可操作性。

(3) 同时，本章介绍了粗糙度检测仪样机的初步设计，样机上包含了奥比中光相机、开发板、显示屏等等。介绍了奥比中光相机的外观、成像原理以及拍摄的实物图；介绍了奥比中光相机的相关参数，约束了粗糙度检测仪样机的相关细节设计。

第3章 混凝土结合面粗糙度计算

本章叙述了在 Matlab 环境下的混凝土结合面粗糙度计算方法，包括数据的采集、深度图到点云的转换、点云的旋转与变换、计算粗糙度、消除粗糙度误差。粗糙度计算流程如图 3-1 所示。粗糙度信息可以反映出结合面的力学性能，后续工作会根据粗糙度信息，对结合面的粗糙度等级分类，为深度学习模型的训练提供数据库。




图 3-1 粗糙度计算流程

3.1 粗糙度计算理论

为了更好地评价混凝土结合面的粗糙度，学者们引入了一些能够表征结合面粗糙度的公式和方法。混凝土结合面粗糙度是指混凝土施工缝、新老混凝土结合面等表面的粗糙程度^[7]。它对于混凝土结构的整体性和力学性能有着重要的影响。评价粗糙度的参数可划分为线性参数和表面参数两类。线性参数是由多个轮廓线所求出的二维参量，面参数指的是通过整个或部分的粗糙表面得到的三维参数，包括灌沙深度、三维平均粗糙度、三维分形维数等。由于线参数主要是基于轮廓线进行计算，它描述的是沿着某一方向的表面轮廓特征。而面参数是在一个二维平面区域内，对整个表面的高度分布等特性进行衡量。从计算角度看，面参数的计算可以看作是对线参数计算的一种扩展。故本文首先采取面参数来表征混凝土结合面的粗糙度。灌沙深度 H_s 是目前研究中一个常用的粗糙度表征参数，通常是在使用灌沙法测量某些物理量（如上述提到的混凝土结合面粗糙度）或在土工试验（如测量土壤压实度）等过程中涉及的一个概念。它是指在试验过程中，沙子从容器灌入到被测物体表面凹陷处的垂直深度。通常根据灌沙的体积 V 和灌沙区域的面积 S 来计算灌沙深度。已知灌沙体积和灌沙区域面积，则灌沙深度的计算公式如下：

$$H_s = \frac{V}{S} \quad (3-1)$$

另外，由于我国已有不少将凹凸深度作为粗糙度的评价标准，所以本文也使

用了基于凹凸深度的粗糙度测量方法。本文拟参照上海市地方标准 DG/TJ 08-2252-2018《装配整体式混凝土建筑检测技术标准》^[71]对混凝土结合面进行粗糙度检测。在此规范中，凸凹深度是由 10 个凹面上的点与基准面之间的平均间距决定的。其中，基准面大致是结合面最高点所处的水平面。而凹面 10 点的选择，是在结合面的下凹形表面上随机选择 16 点，然后将 3 个最高点和 3 个最低点去掉，就可以获得有效点。也就是在结合面的数字化 3D 模型上，最高点高度 $H_{\max}$ 和平均最低高度 $H_{\min}$ 之间的差值：

$$D_H = H_{\max} - H_{\min} \quad (3-2)$$

3.2 数据采集

使用粗糙度检测仪采集混凝土结合面图片，采集到的原始图像数据如图 3-2 所示。相机内部包括彩色相机和红外相机两部分，因此采集的图片有彩色图和深度图两种。这两种图片同时输出，仅输出格式不同，但都反映了结合面的粗糙程度。由于奥比中光相机采集到的图片不仅包含了结合面图片，还包含了检测仪的遮光外壳内壁，这影响到了后续图片的粗糙度计算等问题，因此需要对采集到的图片进行裁剪处理。根据所采集的图像，设定裁剪出能够代表 $100\text{mm} \times 100\text{mm}$ 像素点的结合面图像即可。裁剪后的结合面深度图示例如图 3-3 所示，其中， u_0 、 v_0 表示裁剪区域的左上角像素坐标， d_u 和 d_v 表示裁剪区域尺寸。将 u_0 、 v_0 的坐标设置为 (85, 105)， d_u 和 d_v 设置为 205mm 和 205mm，这样裁剪出的深度图的大小为 $120\text{mm} \times 100\text{mm}$ ，可以代表结合面的深度信息。




图 3-2 原始图像




图 3-3 深度图裁剪示例

3.3 点云处理

3.3.1 点云的计算

由奥比中光相机采集图片转换成深度图的原理如下：由于理想的相机模型涉及到四个坐标系之间的转换问题，也就是首先将世界坐标系转换成相机坐标系，接着将相机坐标系转换成图像坐标系，最后将图像坐标系转换成像素坐标系，像素坐标系中的像素点构成了深度图，完成了将世界坐标系中的每一个点转换成像素坐标系中的像素点所构成的深度图的目标。

各个坐标系之间的位置关系如图 3-4 所示，世界坐标系到相机坐标系的转换需要经过平移和旋转，相机坐标系与图像坐标系之间是缩放的关系，图像坐标系到像素坐标系的转换需要平移完成。然而，实际的相机输出深度信息是有畸变的，包括由透镜存在缺陷导致的径向畸变、由多个光学镜头的光轴没有完全共线导致的离心畸变以及由镜头设计制造存在缺陷和加工安装存在误差导致的薄棱镜畸变。但由于奥比中光相机的深度图畸变校正已在厂家完成，故可以直接采用理想的相机模型将输出的深度图映射成点云。




图 3-4 各个坐标系之间的位置关系

点云不仅可以反映结合面的三维形貌,而且可以根据点云计算结合面的粗糙度,因此本文需要将深度图处理成点云。深度图到点云的映射公式如下:

$$\begin{cases} x = \frac{z(u-u_o)d_x}{f} \\ y = \frac{z(v-v_o)d_y}{f} \\ z = z \end{cases} \quad (3-3)$$

公式(3-3)中, (x, y, z) 表示红外相机坐标系下点 P 的坐标, (u, v) 表示像素坐标系下深度图中点 p 的坐标, (u_o, v_o) 为图像坐标系的原点在像素坐标系下的坐标, z 为像素点 p 的值。根据公式(3-3), 可以将深度图一一映射为点云, 图 3-5 为原始彩色图和映射后的点云。




图 3-5 原始彩色图 and 对应点云

图 3-5 中, 选取拉毛和键槽作为转换点云的实例, 它们的尺寸均为 $120\text{mm} \times 100\text{mm}$ 。将点云的凹凸效果与原始彩色图的凹凸效果做对比, 可以看出点云能够很好的反映出原始图片的凹凸程度, 并且点云的整体尺寸和原始图片的基本情况相吻合。这说明本文使用的奥比中光相机能够很好的获取混凝土结合面的三维信息, 能够满足结合面图片采集并计算粗糙度的需求。使用根据图 3-5 (b) 与图 3-5 (d), 发现点云密集区域的点对应原始图片的起伏相对平缓, 而点云稀疏区域的点对应原始图片的凹凸起伏较大。

3.3.2 点云的旋转

如图 3-6 所示，设备获得的点云与整体的坐标轴之间存在夹角，而利用灌沙法测量粗糙度时需要将结合面水平放置，因此需要将点云进行旋转，使点云的整体法向与结合面垂直。




图 3-6 点云的旋转

本文采用主成分分析法（PCA）进行点云的整体旋转。PCA 是一种常用的多元统计分析方法^[72]。其主要目的是通过线性变换的方法，将原始数据转换到一个新的坐标系中，使得在这个新坐标系下，数据的方差在某些方向上达到最大（这些方向被称为主成分），从而可以对高维数据进行降维和特征提取。在点云数据处理中，PCA 可以用于确定点云的主方向。点云是由许多三维空间中的点组成的集合，通过 PCA 分析点云数据的协方差矩阵，可以得到代表点云主方向的特征向量。这些主方向通常与点云的几何形状和分布有关。例如，对于一个类似长方体形状的点云，PCA 可以找到这个长方体的长、宽、高三个方向对应的向量，这些向量就是点云的主方向。

点云实际上是一种 n 行 3 列的矩阵，记为 A_{pc} ，点云旋转的数学步骤如下：

（1）计算协方差矩阵 M 。计算协方差矩阵的公式如式（3-4）所示，其中， X ， Y ， Z 分别为点云矩阵 A_{pc} 的第一列、第二列、第三列，协方差矩阵 cov 的计算公式如式（3-5）所示。

$$M = \begin{bmatrix} cov(X,X) & cov(X,Y) & cov(X,Z) \\ cov(Y,X) & cov(Y,Y) & cov(Y,Z) \\ cov(Z,X) & cov(Z,Y) & cov(Z,Z) \end{bmatrix} \quad (3-4)$$

$$cov(X,Y) = E[(X - E(X))(Y - E(Y))] \quad (3-5)$$

（2）计算协方差矩阵的特征值 λ_1 、 λ_2 、 λ_3 和对应的特征向量 e_1 、 e_2 、 e_3 。

特征值表示在对应特征向量方向上数据的方差大小,特征向量则确定了主成分的方向。其中,特征值 λ_1 最大,则对应的特征向量 e_1 在点云方向投影的离散性也最大;特征值 λ_2 次大,则对应的特征向量 e_2 在点云方向投影的离散性也次大;特征值 λ_3 最小,则对应的特征向量 e_3 在点云方向投影的离散性也最小。

(3) 由于结合面的宽度与长度相较于结合面的深度大得多,因此长与宽所对应的结合面平面内的数据离散性要大得多,并且远大于结合面深度方向的离散性。故得到最小特征值 λ_3 对应的特征向量 e_3 为点云的整体法向的结论。根据特征向量 e_3 构建点云旋转矩阵,使点云的整体法向和结合面垂直,最终得到的旋转后点云如图 3-6 (b) 所示。

本文使用 Matlab 对点云进行旋转操作。首先将点云数据存储在矩阵 A_{pc} 中,接着可以使用 cov 函数来计算协方差矩阵、使用 eig 函数来求解特征值和特征向量,并根据求得特征向量构建旋转矩阵。为了实现将点云的主方向与坐标轴对齐的旋转,我们需要对特征向量进行适当的排列来构建旋转矩阵。一般的做法是,将特征向量按照我们期望的坐标轴对齐方式依次排列到旋转矩阵的列中。有了旋转矩阵后,利用矩阵乘法对点云进行旋转,并用旋转矩阵乘以点云各点的坐标,获得点云最终的坐标。最后,为了直观地查看点云旋转前后的效果,可以使用 Matlab 的点云可视化函数,如 pcshow 等,将旋转前后的点云在同一坐标系或不同坐标系中展示出来。

3.3.3 点云的三维重建

点云的三维重建应用领域广泛,工程建筑领域、制造业、医学领域、自动驾驶与机器人领域、文化遗产保护领域、地理信息系统与地质勘探领域均有应用^[73]。进行点云的三维重建具有多方面的重要意义,首先,点云的三维重建可以精准还原与可视化呈现,精确还原物体形态的同时,还可以只管可视化展示。其次,点云的三维重建可以高效测量并获取数据,在对于精密机械零件的检测和逆向工程上,可以确保产品的质量和精度,实现快速数据采集和处理。再次,点云的三维重建还可以实现非接触式测量和保护,可以在避免物体损伤和保持物体原始状态的情况下实现高精度的测量。最重要的一点,点云的三维重建可以实现多维度信

息融合和深度信息挖掘与分析。点云数据不仅包含物体的三维坐标信息，还可以携带颜色、纹理、法线等多种属性信息，通过三维重建，可以将这些多维度的信息融合到一个统一的模型中，使重建后的模型更加丰富、逼真，为后续的分析 and 应用提供更全面的数据支持，例如在虚拟现实、增强现实等领域，可以创建出更加真实感强烈的虚拟环境和交互体验。基于三维重建后的模型，可以进行各种深度的信息挖掘和分析，如物体的体积、表面积、重心等几何属性的计算，物体之间的空间关系分析，以及基于模型的模拟、仿真等。在工程设计中，可以进行结构强度分析、流体力学模拟等；在医学领域，可以进行手术规划、病理分析等，为各领域的专业研究和应用提供有力的工具。

为了实现多维度信息融合和深度信息挖掘与分析，本文需要对点云进行三维重建，也就是将离散的点云转换为连续的点云，方便后续的粗糙度计算。由于上述获取的点云非常密集，故可以采用直接连接相邻点来进行三维重建，三维重建的方法亦称为三角化法，图 3-7 为三角化后的点云效果。




图 3-7 点云的三维重建

传统三角化法主要是指在计算机图形学和几何处理领域中，将给定的一组点连接成三角形网格的方法，这些点通常是在二维平面或三维空间中。其基本思想是利用点之间的几何关系，构建三角形来近似表示一个物体的表面或一个区域的形状，例如 Delaunay 三角化、贪心三角化。本文采用基于深度图的三角化法，相比于计算复杂度高的传统三角化方法，基于深度图的三角化方法数据获取将对容易、精度较高、适用于多种场景。运用深度图法采集结合面深度图时，要保证奥比中光相机距离结合面的距离不能过远，这样才能使点云的密集度高。如图 3-8 中所示，由奥比中光相机采集的点云中的每个点都与深度图上的每一个像素

点相对应，故点云中的点云也存在着类似像素点之间的位置关系。




图 3-8 基于深度图的三角化法

例如图 3-8 中，点云中的数据点 P1、P2、P3、P4 是相邻的，对应的深度图中的像素点 p1、p2、p3、p4 也是相邻的，且点云中各点的布置为阵列式。这样，就可以将相应点云数据点连接起来，并按照其邻近点之间的邻接关系，进行三角形划分。与传统的三角化法相比，该方法具有测量精度高、运算效率高等优点。

3.4 粗糙度处理

3.4.1 粗糙度计算

通过结合面的数据采集、深度图到点云的转换、点云旋转和三维重建之后，便可以通过三维重建后的点云模型计算结合面的粗糙度，也可划分粗糙度等级。灌沙深度评价粗糙度的公式如式（3-6）所示，可以通过此公式计算剪力键型结合面的粗糙度。

$$H_s = h_{\max} - h_{\text{mid}} = h_{\max} - \frac{V}{S} = h_{\max} - \frac{\sum_{i=1}^n V_i}{S} \quad (3-6)$$

公式（3-6）中，灌沙深度 H_s 为填充粗糙面沙子的体积 V 与沙子所覆盖的结合面投影面积 S 的比值，也就是三维重建后的点云上面最高点高度 $h_{\max}$ 与其平均高度 h_{mid} 的差值。由于结合面的凹凸性和不连续性， n 为点云三维重建后的三角面个数， V_i 为点云三维重建后的一个三角面到结合面最低点所在水平面的体积。如图 3-9 所示，可将 V_i 所在三角面到最低点水平面近似看作一个六边形，将六边形分解为三个四角锥，通过计算三个四角锥体积之和便可得到该六边形的体积。




图 3-9 计算结合面体积原理图

图 3-9 中，选取某一三角面作为例子，将该三角面对应的六边形单独呈现，将六边形各个顶点进行标注，清晰可见分解后得到的三个四角锥的顶点与原六边形顶点是一一对应的关系。

凹凸深度评价粗糙度的公式如式（3-7）所示，可以通过此公式计算骨料型结合面的粗糙度。显然，由于测点选取的随机性，根据公式（3-2）得到的凹凸深度并不唯一。为确保凹凸深度测量的稳定性，进一步将凹凸深度定义为结合面上高度最低的 $0.1S$ 区域到结合面最高点所在水平面的平均距离，其中， $V_{\min}$ 为结合面上高度最低的 $0.1S$ 区域到其最低点所在水平面的体积， S 为结合面在水平面的投影面积， V_i 为结合面数字化三维模型上一个三角面到结合面最低点所在水平面的体积， $n_{\min}$ 为结合面数字化三维模型 $V_{\min}$ 对应的三角面个数。

$$D_H = H_{\max} - H_{\min} = H_{\max} - \frac{V_{\min}}{0.1S} = H_{\max} - \frac{\sum_{i=1}^{n_{\min}} V_i}{0.1S} \quad (3-7)$$

3.4.2 粗糙度误差处理

由于奥比中光相机采集的三维点云数据存在 $\pm 0.6\text{mm}$ 范围内的误差，因此需要进行粗糙度误差处理。点云数据的误差主要体现在轮廓误差和最高点误差上，这是由于测量点与真实点不一致造成的。轮廓误差是由采集的点云数据误差而造成的体积误差，最高点误差是由采集的点云数据误差而造成的最高点高度值误差。由于在采集结合面点云时，结合面点云具有很充足的数据点，这些数据点的分布

随机且均匀，或高于真实位置亦或低于实际位置，故可以忽略由采集的结合面轮廓信息带来的体积误差（轮廓误差）。根据公式（3-6）可知，由于最高点误差所带来的误差是不能忽略的，在导致 $h_{\max}$ 值变大的同时，也会导致平均高度 h_{mid} 的值与真实值有所差距，所计算出的粗糙度值不够精确，因此有必要对最高点误差进行误差修正处理。

1、基准面修正法

以拉毛为代表的剪力键型结合面，其基准面上的数据点占比最大。若是最高点误差出现在基准面的测量值上，则会造成基准面的测量高度比实际基准面高度大，最大差值为 0.6 mm，且最高点误差只会是正误差，基准面上的点可取 $h_{\max}$ 到 $h_{\max} - 2t$ 之间的点。如图 3-10 所示，随着拉毛表面高度 h 的增加，基准面附近的点云密度会有所不同，由于基准面的投影面积最大、数据点占比最大，因此它的点云密度最大，只需要寻找点云密度最大的投影面所对应的高度即可。本文提出基准面修正法，对剪力键型结合面的粗糙度误差进行修正，具体的修正步骤如下：

（1）根据公式（3-6），计算结合面的平均深度 h_{mid} 。注意，计算出的 h_{mid} 并非真实的结合面平均深度，带有一定的误差。

（2）计算 $h_i - t$ 到 $h_i + t$ 高度之间的点云数 n_i ， n_i 最大的值所对应的高度 h_i 就是基准面的高度值近似值，该近似值记为 h_0 。其中， h_i 大于 h_{mid} 且小于 $h_{\max}$ ，且按照 0.1 mm 取步长， t 为数据误差阈值 0.6。

（3）计算最终的基准面高度 h_{mid}' ，则 h_{mid}' 为近似基准面高度阈值内（即 $h_0 - t$ 到 $h_0 + t$ 内）的所有数据点高度的均值。

（4）最终的结合面误差为： $d_{\text{H1}} = h_{\max} - h_{\text{mid}}'$ ，最终的结合面粗糙度为：

$$H_s = h_{\max} - d_{\text{H1}} - h_{\text{mid}}。$$




图 3-10 剪力键型基准面误差示意图

2、16 点修正法

以露骨料为代表的骨料型结合面，与剪力键型结合面相类似，轮廓误差可以忽略不计，但最高点误差不可忽略不计。由于骨料型结合面的基准面上只有一个点，相较于剪力键型结合面基准面上大量的数据点，奥比中光相机采集单个点时出现误差几率很小，采集最高点的高度往往就是实际点的高度，因此该误差可以忽略不计。但是得考虑奥比中光相机本身的偏差，如图 3-11 所示，该偏差会导致测量值与真实值存在 0.6 mm 的偏差，故要消除此偏差。本文提出 16 点修正法对骨料型结合面粗糙度误差进行修正。由于奥比中光相机的内部误差呈正态分布，标准差 σ 为 0.23 mm，且骨料型结合面最高点误差的分布与奥比中光相机内部的误差分布同步，故将测得的最髙点直接减去 1.645σ ，便可得到骨料型结合面的粗糙度误差为： $d_{H2} = 1.645\sigma$ ，最终的结合面粗糙度为： $H_s = h_{\max} - d_{H2} - h_{\text{mid}}$ 。




图 3-11 骨料型基准面误差示意图

3.5 本章小结

针对结合面粗糙度计算方法的问题，本章研究内容如下：

(1) 数据采集。数据的采集主要是采集混凝土结合面的深度图，文中讲述了获取深度图的原理，即世界坐标系到像素坐标系的转换，首先通过世界坐标系

转换为相机坐标系，再将相机坐标系转换为图像坐标系，最后将图像坐标系转换为像素坐标系下的深度图。

(2) 数据变换。数据变换就是将深度图根据坐标关系映射为点云，此时的点云是离散的。

(3) 点云旋转。点云的旋转是将点云的法相旋转成与结合面垂直的效果，这是由于设备本身的偏差造成的，点云旋转运用到了 PCA 方法(主成分分析法)。

(4) 三维重建。三维重建是将离散的点云转换成连续的点云，其中运用到了基于深度图的三角化法。

(5) 粗糙度计算。粗糙度计算运用的是灌沙法和凹凸深度计算方法。根据灌沙深度原理，选取三维重建后点云的一个三角面，将其对应的六边形分解为三个四锥体，从而计算出剪力键型结合面的粗糙度。根据凹凸深度原理，可计算出骨料型结合面的粗糙度。

(6) 粗糙度误差处理。粗糙度误差主要是由最高点误差引起，文中阐述了两种结合面粗糙度误差的消除方法。

第4章 深度学习下混凝土粗糙度等级识别

利用深度学习模型对结合面图像的粗糙度等级进行识别,能够自动从图像中提取复杂的特性,可以减少人工干预,也可以处理大规模的数据。本章将介绍 Resnet50 模型的网络结构、如何进行数据预处理、粗糙度等级分类的具体做法、训练 Resnet50 模型以及在模型中嵌入 CBAM 注意力机制以提高模型的识别性能等。本章通过深度学习的粗糙度检测方法,可以更快速、更准确地识别出结合面的粗糙的等级。

4.1 图像处理算法模型

接下来对常见的几种算法模型进行介绍。其中, LeNet-5 模型^[74]是早期较为成功的 CNN 模型之一,由卷积层、池化层和全连接层构成。它在手写数字识别任务上表现出色,为后续 CNN 的发展奠定了基础。AlexNet 模型^[75]在 2012 年 ImageNet 图像识别大赛中夺冠,极大推动了 CNN 在计算机视觉领域的应用。它采用了更深的网络结构、更多的卷积核以及 ReLU 激活函数等,提升了图像识别的准确率。VGG 模型^[76]以其简洁统一的网络结构和较好的泛化能力著称,通过堆叠多个小卷积核的卷积层来增加网络深度,能够有效提取图像的特征,在图像分类、目标检测等任务中都有不错的表现。Inception^[77]的核心思想是通过多个不同大小的卷积核并行卷积操作,能够同时捕捉不同尺度的图像特征,提高了网络对图像特征的提取能力,在图像分类和目标检测等任务中取得了优异成绩。ResNet 模型^[78]通过引入残差连接解决了随网络深度增加而出现的梯度消失问题,使得训练极深的网络成为可能,在图像分类、目标检测、图像分割等多个计算机视觉任务上均取得了重大突破,大大提升了模型的性能。GoogLeNet 模型^[79]是由 2014 年 ILSVRC 竞赛冠军谷歌提出,它的主要方法是将多个池化或卷积操作连接成一个网络模块,再将多个网络模块连接成 GoogLeNet。因此,GoogLeNet 的结构具有模块化的特征。

4.1.1 Resnet50 模型

ResNet50 能够学习到更具代表性的特征,使得模型在面对不同的数据集和任务时具有更好的泛化能力。它可以适应各种图像的变化,如光照、尺度、旋转

等，从而在实际应用中表现出较高的稳定性和可靠性。本文运用 Resnet50 深度学习模型训练并识别结合面粗糙度等级，Resnet50 是由微软研究院的研究人员在 2015 年提出。如 2.1 节所述，Resnet50 是一种二维卷积神经网络，由 50 层的卷积神经网络组成，其中包含了 1 个全连接层和 49 个卷积层。Resnet50 的本质属于深度残差网络，通过残差连接，使得信息能够更直接地在网络中传播，避免了在深层网络中梯度逐渐变小甚至消失的问题，从而可以训练非常深的网络，更好地提取图像的复杂特征。和一般的卷积神经网络一样，ResNet50 的卷积层具有权重共享的特性，即同一卷积核在整个输入数据上滑动时，其权重参数是共享的，大大减少了模型的参数数量，降低了计算成本，同时也能够提取出位置不变的特征。相比一些较浅的网络，如 ResNet18，ResNet50 具有更多的层和参数，模型复杂度更高。这使得它在训练时能够更好地学习数据中的复杂模式和特征，对于具有复杂结构和特征的数据集，即使数据量相对较少，也能够更好地拟合训练数据，提高泛化能力。

Resnet50 的结构如图 4-1 所示，其中，二、三、四、五部分包含了残差块。该模型经过前五个部分的卷积计算，到达池化层后会将结果转换为向量的形式，最后经过分类器对向量进行分类。在对数据集进行训练之后，Resnet50 能够在精度和速度上都表现出优于其他深度神经网络的性能，在图像分类、物体检测和计算机视觉问题中都得到了广泛的应用。




图 4-1 Resnet50 模型

Resnet50 的网络结构由三个大的部分组成，分别是卷积层与池化层部分、残差模块部分和全连接层部分^[80]。

卷积层对输入图像进行卷积操作，之后通常会接一个池化层，用于减少数据量和提取主要特征。卷积层是卷积神经网络的核心组成部分。如章节 2.1 中所述，它主要通过卷积核在输入数据上进行滑动操作来提取特征。池化层是卷积神经网络中的重要组成部分，主要作用是对卷积层输出的特征图进行下采样，以减少数据量和计算量，同时保留重要的特征信息，并且在一定程度上增强模型的鲁棒性。

和泛化能力。池化层的操作通常分为最大池化和平均池化，最大池化是选择池化窗口内的最大像素值进行输出，而平均池化是对池化窗口内的像素值求平均并输出。池化层的运算结果如图 4-2 所示。




图 4-2 池化层运算

残差模块是 ResNet50 的核心结构，包含 4 个残差模块，每个残差模块由多个残差块组成。残差块的结构是先经过一个卷积层，接着通过一个激活函数（ResNet50 的激活函数是 Relu 函数，函数如图 4-3 所示），再经过一个卷积层，然后将输出与输入进行相加，得到残差块的最终输出。这种残差连接的方式解决了深度神经网络中梯度消失的问题，使得网络能够更好地学习深层次的特征，即使网络层数很深时也能有效地进行训练。模型的残差结构如图 4-4 所示，其特有的多层残差结构可以解决梯度消失问题。图 4-4 的输入为特征矩阵，直线顺序依次经过了卷积核为 1×1 、 3×3 、 1×1 的卷积层，起到了降维（通道变少）和升维（通道变多）的作用。经过卷积后的特征矩阵和原特征矩阵相加，最后再经过激活层。Resnet50 在较浅的网络深度、较少的参数数量以及相对较低的参数复杂度下，所需的训练时间和计算成本都要比其他深度神经网络低得多。




图 4-3 Relu 函数




图 4-4 Resnet50 的残差结构

全连接层位于整体网络结构的最后一层，用于分类任务，将前面提取的特征映射到最终的输出类别空间，输出对应各个类别的概率分布。

4.1.2 注意力机制模型

Resnet50 虽然堆叠了很多的层，可以提取更多的特征，处理复杂的图像分类任务和识别任务，但是它的残差网络中存在着大量的冗余，在训练的过程中需要更多的计算资源，并且大量的参数也会导致过拟合现象。为了解决这些问题，将 CBAM 注意力机制、CBAM 空间注意力机制、CBAM 通道注意力机制分别嵌入 Resnet50 中，通过比较三种方式的准确率，找到更好的网络模型。这样不仅结合了卷积和注意力机制，还实现了从空间和通道上对图像进行关注，提升了原本网络模型的性能。

CBAM 是一种轻量级的注意力模块，在识别物体上更加敏感，可以在通道和空间维度上实现相应的功能。实现 CBAM 注意力机制的流程图如图 4-5 所示。从图中可以看出，CBAM 包括两个相互独立的功能模块，即空间注意模块和通道注意力模块，可以从空间和通道上实现相应的关注。




图 4-5 CBAM 注意力机制流程图

CBAM 的输入为中间特征图 F ，与通道注意机制输出的特征图 $M_c(F)$ 相乘得到 F' ，与空间注意机制输出的特征图 $M_s(F')$ 相乘得到最终的注意机制特征图 F'' 。计算过程如下：

$$F' = M_c(F) \otimes F, F'' = M_s(F') \otimes F' \quad (4-1)$$

空间注意机制利用特征图的内在联系，生成空间关注特性图。与通道注意机制不同的是，空间注意机制更多地考虑了特征图上的有效信息的位置，相对于通道注意机制，该方法更侧重于多个局部特征的关联，从而获取更为完整的信息。图 4-6 显示了该注意力机制的计算流程图。首先，对输入的特性图执行平均池化和最大池化，此过程在通道维度上进行；随后拼接平均池化和最大池化后的特征，再将此特征送入卷积层，得到最后的空间注意力特征图。




图 4-6 空间注意力机制流程图

通道注意力机制作为 CBAM 的一个子模块，旨在压缩特征图的空间维度，同时通过最大池化和平均池化两种方式对特征图进行空间维度的压缩，从而更多地关注通道上的信息。将这两种池化后的特征同时送到由多个卷积层构成的共享感知机制中，形成最终的通道注意力特征图。由于其中的多个全连接层会造成空间信息损失过多，因此对通道注意力机制进行改进。在激活函数后加入一层 3*3 的平均池化层，并去掉由多个全连接层构成的共享多层感知机制，重新训练。实验表明，该方式可以减小模型的计算量，在保留整体特征的同时还不容易过拟合。图 4-7 为改进后的通道注意力机制。




图 4-7 改进后的通道注意力机制流程图

4.2 数据预处理与思路分析

4.2.1 样本扩充

进行深度学习之前，要确保数据集的均衡性，保证模型的训练和性能不受到影响。为此，本文采取平衡数据集的方法对图片的数量进行处理，保证后续的深度学习进程不受到样本数量的制约。

首先，对采集到的深度图做算法处理，将不同粗糙度等级的图片分类在不同的文件夹中。其次，在对粗糙度等级进行分类的过程中，发现粗糙度为“光滑”

的图片远多于粗糙度为“较光滑”和“粗糙”的图片，因此通过裁剪、旋转等方法对采集的图片数量进行处理，使不同粗糙度等级的图片数量相当。将粗糙度等级为“光滑”的图片设置为“等级 1”，“较光滑”的图片设置为“等级 2”，“粗糙”的图片设置为“等级 3”。按照 7: 1: 2 的比例，将数据集分成训练集、验证集和测试集三个部分，经过数据扩充以及数据划分后的图片数量如表 4-1 所示。

表 4-1 数据划分后的图片数量

粗糙等级	训练集	验证集	测试集	总数
等级 1	1085	155	311	1551
等级 2	1142	163	327	1632
等级 3	1146	163	392	1638

4.2.2 注意力机制嵌入方式

考虑到 CBAM 注意力机制由通道和空间注意力机制两种组成，因此分别采用三种方式将注意力机制插在 Resnet50 第一个卷积层之后，之后再将三种方法得到的精确度作比较，可得到最佳的组合方式。

三种注意力机制插入的方案为：方式一将通道注意力机制和空间注意力机制串联起来，嵌入第一个卷积层之后；方式二单独将改进的通道注意力机制嵌入第一个卷积层之后；方式三单独将空间注意力机制嵌入在第一个卷积层之后。三种注意力机制与 Resnet50 结合的方式如图 4-8 所示。




图 4-8 CBAM 与 Resnet50 结合方式

在不改变原始主网络的情况下，在 Resnet50 的第一个卷积层后面分别嵌入三种注意力机制。其中，通道和空间注意力机制能够更精准地识别结合面的特征，减少经过神经网络流动的信息冗余；同时，该方法也能解决计算量大的负载问题，缩短网络训练的时间，提高原网络模型的识别效率。

4.3 仿真模型与结果分析

4.3.1 实验环境

研究以英特尔 Corei7-8565U 为基础，进行实验。CPU 为酷睿 i7 8 代系列，GPU 为 MX250，主频为 1.8 GHz，运行内存为 8 GB。软件环境是基于 Windows 11 系统，MATLAB 2023a 版本。

在训练模型时采用的训练参数为：批大小（Mini Batch Size）是 96，最大训练次数（Max Epochs）为 6，采用 sgdm 梯度下降法，验证频次（Validation Frequency）为 30，初始学习率（Initial Learn Rate）为 0.001，学习率下降因子（Learn Rate Drop Factor）为 0.8。

4.3.2 消融实验

为了评估不同模型的性能，需要对三种网络进行消融实验，找出最佳的网络模型，量化以 Resnet50 主干网络为基础的识别效果。在实验的过程中，要保证数据集和主网络及其参数均一致，只改变注意力机制的种类，确保只有这一个变量影响到模型的整体性能，最终以验证集的准确率为最终的模型准确率。实验的结果如表 4-2 所示。

表 4-2 三种网络模型训练结果

注意力机制插入方式	验证集准确率
方式一	60.27%
方式二	93.84%
方式三	91.78%

由表 4-2 可知，方式一将通道注意力机制和空间注意力机制串联起来，嵌入第一个卷积层之后的准确率最低，低于不加入任何注意力机制的主网络，说明方式一不能有效地关注图片的显著特征，反而降低了原本网络的性能。相较于方式三单独将空间注意力机制嵌入在第一个卷积层之后，方式二单独将改进的通道注意力机制嵌入第一个卷积层之后的验证集准确率最高，强化了对图片显著特征的关注，验证集准确率能够达到 93.84%。这说明在 Resnet50 的基础上，加入改进的 CBAM 通道注意力机制，可以提高混凝土结合面粗糙度等级的识别准确率，图 4-9 为 CBAM 通道注意力机制与 Resnet50 结合的模型图（简称 Resnet50_CBAM_C）。




图 4-9 Resnet50_CBAM_C

4.3.3 不同卷积神经网络准确率对比

将 Resnet50_CBAM_C 与其他网络作对比，可以直观验证该网络的识别准确率。如图 4-10 所示，R+CC 代表加入 CBAM 通道注意力机制的 Resnet50，R+CS 代表加入 CBAM 空间注意力机制的 Resnet50，R 代表 Resnet50，R+C 代表加入 CBAM 注意力机制的 Resnet50，A 代表 Alexnet，G 代表 GoogLenet。




图 4-10 各卷积神经网络准确率

从图 4-10 可以看出，相比于 Alexnet 和 GoogLenet 网络，Resnet50 准确率较高。在 Resnet50 基础上分别加入 CBAM 注意力机制、CBAM 通道注意力机制和 CBAM 空间注意力机制，结果表明，加入 CBAM 通道注意力机制的 Resnet50 准确度最高。

4.3.4 学习率对模型准确度的影响

学习率通过影响损失函数进而影响是否能找到全局的最优点，学习率过大

或过小都会影响网络模型的最佳性能。通过设置四个不同的学习率，分别是 0.01、0.001、0.0001、0.00001，来观察模型的准确度情况。

图 4-11 为不同学习率下 Resnet50_CBAM_C 的准确度。从图 4-11 可以看出，学习率大小对模型性能有显著影响。当学习率为 0.001 时，准确度最高，在此基础上学习率增大或减小，准确度都会下降。因此选用 0.001 作为最终使用的学习率。




图 4-11 不同学习率下的 Resnet50_CBAM_C 的准确度

4.3.5 结果分析

为了进一步说明添加 CBAM 通道注意力机制后的 Resnet50 能有效识别混凝土结合面粗糙度等级，现计算测试集的混淆矩阵。混淆矩阵由真实结果和预测结果组成，同时通过混淆矩阵可以计算出精确率、准确率和召回率。

准确率是真正类和真负类在总样本中所占的比例，准确率越高，说明该网络模型的效果越好，计算公式如下：

$$\zeta_{\text{accuracy}} = \frac{N_{\text{TP}} + N_{\text{TN}}}{N_{\text{TP}} + N_{\text{FN}} + N_{\text{FP}} + N_{\text{TN}}} \quad (4-2)$$

精确率是真正类在真正类和假正类样本中所占的比例，精确率越高，说明网络模型的效果越好，计算公式如下：

$$\zeta_{\text{precision}} = \frac{N_{\text{TP}}}{N_{\text{TP}} + N_{\text{FP}}} \quad (4-3)$$

召回率是真正类在真正类和假负类中所占的比例，召回率的值越大，说明网络模型的效果越好，计算公式如下：

$$\zeta_{\text{recall}} = \frac{N_{\text{TP}}}{N_{\text{TP}} + N_{\text{FN}}} \quad (4-4)$$

其中，真正类（ N_{TP} ）指的是样本的实际类为正类，模型的辨识结果也为正

类；真负类（ N_{TN} ）指的是样本的真实类为负类，并且被模型判定为负类；假正类（ N_{FP} ）指的是样本的真实类别是负类，而模型却把它作为一个正类来鉴别；假负类（ N_{FN} ）指的是样本的真实类别是正类，而被模型判定为负类。

图 4-12 中，每行数据总和代表这个分类中的真实样本数目，而每列数据之和则代表这个分类中被预测为该类别的样本数目。




图 4-12 混淆矩阵

根据图 4-12，可计算出该模型的准确率为 93.10%。等级 1 的精确率为 92.23%，召回率为 93.75%；等级 2 的精确率为 93.77%，召回率为 92.05%；等级 3 的精确率为 94.71%，召回率为 92.03%；通过混淆矩阵可以看出，Resnet50_CBAM 通道注意力机制能对测试集图片的粗糙度等级有效划分。

4.4 本章小结

（1）介绍了常见的图像处理算法模型和注意力机制模型，介绍了 Resnet50 模型的大体结构和优点，为后续模型训练等实验奠定基础。

（2）提出了一种基于深度学习模型的混凝土结合面粗糙度检测方法。通过对样本扩充，可以达到增强数据的效果。通过对 CBAM 通道注意力机制进行改进，去掉其中的多层感知机制，可以避免空间信息损失过多的问题。经过仿真可知，加入 CBAM 通道注意力机制的 Resnet50 模型能够更好地识别结合面的粗糙度等级。

（3）将 Resnet50_CBAM_C 同时与五种网络模型做对比，发现此网络模型可以很好地提高识别准确率，识别准确率能达到 93.84%。相比于 Resnet50、

Resnet50_CBAM 注意力机制、Resnet50_CBAM 空间注意力机制、GoogLenet 和 Alexnet, Resnet50_CBAM_C 识别准确度分别提高了 6.85%、33.57%、2.06%、10.96%、10.28%。因此,该模型能对混凝土结合面粗糙度等级有效识别和分类,在混凝土合面粗糙度的检测行业中有一定的应用价值。

第5章 基于 Visual Studio 环境实现混凝土粗糙度等级识别

第4章已经在 MATLAB 环境中，实现了混凝土结合面图片粗糙度等级分类、以及使用深度学习模型进行粗糙度等级划分的功能。接下来将在 Visual Studio 开发环境中实现用户交互功能，将粗糙度检测方法移植到检测仪样机中，实现图片采集、粗糙度识别一体化的功能，并最终返回检测数据。

5.1 系统总体设计框架

使用 Visual Studio 与粗糙度检测仪实现混凝土结合面粗糙度检测时，主要包含三个框架，一是获取结合面图片，二是软件检测功能的实现，三是系统的硬件组装与实现。系统的框架结构如图 5-1 所示。




图 5-1 系统框架

图 5-1 描述了系统的主体框架，其特征为软硬件结合。图中包含了采集结合

面图片、编写粗糙度检测代码、烧录程序到开发板、开发板与相机组装成粗糙度检测仪硬件等操作，整体操作可以更加直观地检测结合面的粗糙度。系统首先要采集混凝土结合面图片，该过程中需要固定光源，已于第 2 章 2.5 节中叙述。软件中涉及到的工作是 MFC 界面的制作和粗糙度检测代码的编写，该过程采用 C++ 程序完成编写，主要运用类的方式进行封装。奥比中光相机和开发板组装并构成粗糙度检测仪，即硬件模块。

5.2 相关库函数和 MFC 介绍

5.2.1 OpenCV 库

OpenCV (Open Source Computer Vision Library) 是一个用于计算机视觉任务的开源库^[81]。它由 Intel 公司在 1999 年发起并开发，后来得到了广泛的开发者社区的支持。其初衷是为计算机视觉应用提供一个通用的基础设施，帮助研究人员和开发者更高效地实现各种视觉算法。它的功能特点包括图像处理功能和计算机视觉算法。该库可以图像滤波、图像变换和色彩空间转换对图像进行处理，也可以通过特征提取与匹配、目标检测、立体视觉与深度估计实现计算机视觉相关算法。广泛应用于安防监控、自动驾驶和工业检测领域。

通过 OpenCV 可以支持多种编程语言，如 C++、Python 等。在引用 OpenCV 库时，首先要配置 Visual Studio 的环境，包括从官网下载 OpenCV 库、添加头文件路径、添加库文件路径、添加库文件名。之后便可以在代码中引用此库。如图 5-2 所示，编程引用了以下四个头文件。

```
#include<opencv2/opencv.hpp>
#include<opencv2/core/Utils/logger.hpp>
#include <opencv2/imgproc/types_c.h>
#include<opencv2/highgui/highgui_c.h>
```

5-2 引用 OpenCV 的头文件

其中，“#include <opencv2/opencv.hpp>”使得程序可以使用 OpenCV 的各种功能；“#include<opencv2/core/Utils/logger.hpp>”是在使用 OpenCV 库时用于引入日志相关功能的头文件；“#include <opencv2/imgproc/types_c.h>”是 OpenCV 库中用于图像处理相关的一个头文件，这个头文件主要定义了一些与图像处理相关的基本数据类型和常量等内容，在进行图像的各种操作（比如滤波、形态学处理、颜色空间转换等）时，往往需要依赖这些预先定义好的数据类型和常量来准确地传递参数、表示图像数据的格式以及界定不同操作的相关范围等；“#include

<opencv2/highgui/highgui_c.h>”是 OpenCV 库中与高层图形用户界面（GUI）及图像输入、输出相关的头文件，它对应的是 C 语言风格的接口。

OpenCV 中的各类类、函数、枚举等元素都被定义在 `cv` 这个命名空间下，可以直接通过指令“`using namespace cv;`”在 C++ 中使用命名空间。如果不使用“`using namespace cv;`”指令，那么每当要使用 OpenCV 中的某个元素时，就需要带上完整的命名空间限定，比如“`cv::Mat`”（`Mat` 类用于表示图像等数据结构）、“`cv::imread`”（用于读取图像的函数）等。而使用了“`using namespace cv;`”后，就可以直接写“`Mat`”和“`imread`”等，省略了前面的“`cv::`”限定部分，能让代码看起来更加简洁，书写起来也更方便，尤其在频繁使用 OpenCV 相关元素的代码中，可以减少代码的冗长程度。

5.2.2 OpenNI 库

OpenNI（Open Natural Interaction）是一个开源的、跨平台的框架，主要用于开发自然交互应用^[82]。它提供了统一的接口，使开发者能够方便地访问各种深度传感器所获取的数据，包括深度图像、彩色图像和红外图像等。通过这些数据，开发者可以实现多种计算机视觉相关的应用，如人体姿态识别、手势识别、环境感知等。它的主要功能模块有：设备访问与管理、视频流处理、数据转换与校准。OpenNI 和 OpenCV 可以相互配合，发挥各自的优势。OpenNI 负责获取深度和彩色图像等原始数据，而 OpenCV 则提供了丰富的图像处理和计算机视觉算法。例如，本文通过 OpenNI 获取深度图像后，可以使用 OpenCV 的滤波算法对深度图像进行处理，去除噪声。

编程使用了“`#include "OpenNI.h"`”这个头文件，“`#include "OpenNI.h"`”是在 C++ 程序中引入 OpenNI 库相关定义的头文件语句，通过在代码中添加 `#include "OpenNI.h"`，就能让程序识别并使用 OpenNI 库中提供的各种元素，从而进行诸如设备连接、视频流管理、数据处理等操作。

“`using namespace openni;`”是一条在 C++ 编程中使用 OpenNI 库时常用的语句，实验中使用“`using namespace openni;`”语句后，在后续代码中再去引用 OpenNI 库内的这些元素时，就可以直接写元素名称，无需再带上“`openni::`”这样的命名空间前缀了，能够让代码看起来更加简洁明了，书写起来也更为便捷。尤其是在频繁使用 OpenNI 库相关功能的代码段里，这样可以有效减少代码的

冗长程度，提高代码的可读性。

5.2.3 Eigen 库

Eigen 是一款为线性代数操作设计的 C++ 模板库。它提供了高效的实现方式，支持多种矩阵分解、线性方程组求解等操作^[83]。Eigen 的设计目标是提供高性能、易用性和灵活性，并且可以在多种平台上使用。它的功能特点包括矩阵和向量操作、线性代数运算、高效的实现和优化，广泛应用于计算机图形学、机器人学、机器学习和数据分析领域。

图 5-3 是编程使用到的 Eigen 头文件，其中，“#include <Eigen/Core>”是在使用 Eigen 库时非常关键的一个头文件引入语句，Eigen 库作为专注于线性代数运算的 C++ 模板库，Eigen/Core 头文件中定义了诸多基础且核心的类型以及相关功能，是后续进行各种线性代数操作的基石。“#include <Eigen/Eigenvalues>”是 Eigen 库中用于处理矩阵特征值、特征向量相关计算的重要头文件。在数学和诸多应用领域（比如物理学、工程学、数据分析等），矩阵的特征值和特征向量有着极为关键的作用，它们可以帮助分析矩阵所代表的线性变换的性质，在诸如主成分分析（PCA）、振动系统分析、图像压缩等具体应用场景中不可或缺。本文运用到了主成分分析法（PCA 法），因此需要用到该头文件。

```
#include<Eigen/Core>
#include<Eigen/Eigenvalues>>
```

图 5-3 引用 Eigen 的头文件

“using namespace Eigen;”是在 C++ 程序中使用 Eigen 库时常用的一条语句，本文在代码中使用“using namespace Eigen;”语句后，后续再去引用 Eigen 库内的相关元素时，就能够直接书写元素名称，而无需再添加“Eigen::”这样的命名空间前缀了。

5.3 系统功能模块与算法实现

5.3.1 功能模块

基于 C++ 的混凝土粗糙度检测系统以类的方式将各部件的功能代码封装起来，以构建各功能模块间的关联关系，从而实现对被测样品的图像重建与分析预测。处理系统主要由基于 MFC 的对话框、设置对话框窗口的相关操作即自定义系统粗糙度检测功能、构建用户界面并实现与用户的交互操作组成。功能模块

如图 5-4 所示。




图 5-4 功能模块

(1) 当应用程序主窗口不是对话框时，框架将自动执行设置对话框图标的操作，包括实现界面功能包括添加最小化按钮、获取光标、列出控件和空间的自适应。

(2) 创建图像显示窗口时需要嵌套 OpenCV 窗口，可以自动加载为特定处理器优化的库。

(3) “粗糙度检测功能”首先要顺利打开相机，并依次打开彩色相机和红外相机，保证能够成功采集图片。

(4) 使用奥比中光相机采集的图片包括彩色图像和深度图像，这两种图像将会在界面窗口中显示。

(5) 计算粗糙度时，通过计算有效点数来获取深度数据，根据第三章粗糙度计算方法，并使用类的方式封装各个功能，从而计算出结合面图的粗糙度。

(6) 输出的粗糙度信息可以在界面上直接显示，同时以 Excel 表格的形式返回。

(7) 最终关闭相机设备，停止获取深度信息，并销毁深度数据内存。

(8) 用户输入功能包括输入检测的地点、项目，以及输入相机的参数和曝光时间等。

(9) 用户可以通过界面或者 Excel 表格获得直观的结合面粗糙度信息。

5.4 用户交互

为了更加简洁明了地实现粗糙度检测功能，系统主界面的设计是至关重要的，这关系到人机交互的友好性。Visual Studio 提供了资源编辑器来设计 MFC 应用程序的界面。该软件基于 MFC 可视化编程，主要功能是对已装配好的混凝土构件进行表面粗糙度的测量，并通过两种方法得到的粗糙度的大小，从而得到相应的粗糙度。用户交互软件完成后，将程序烧录到开发板中，并与相机共同组装成粗糙度检测仪，完成系统的粗糙度检测。检测仪组装细节已于第二章的 2.5 节中介绍，实物如图 5-5 所示。



图 5-5 粗糙度检测仪实物

检测结合面粗糙度时，将待测混凝土结合面装入测试设备中，通过触摸屏幕上对应的按键，即可得知零件的表面粗糙程度。因此，本软件操作简便，测试结果客观，克服了人为的主观因素。软件的使用步骤如下：

（1）基本信息输入

该软件打开后的相应的操作界面如图 5-6 所示。当软件运行时，该界面会在显示屏上显示。



图 5-6 操作界面

首先，在“地点/项目”编辑框里输入结合面的检测地点为“安徽省芜湖市”，之后，点击“确认”按钮，此时其它按钮无法点击，并呈灰色，创建目录成功后如图 5-7 所示。




图 5-7 创建目录

图 5-8 表明目录已经创建好，用户交互软件的所有信息都在“C:\data”的目

录下。若是目录创建不成功，也会给出相应的提示信息，便于操作员根据提示重新创建目录。如果检测的地点和项目不发生改变，则之后所有的检测信息都在“C:\data\安徽省芜湖市”目录下。




图 5-8 目录路径

(2) 打开相机与参数调整

成功创建目录后，此时“打开相机”按钮处于可点击状态，不呈灰色。点击此按钮后，会提示相机能否成功被打开的信息，如图 5-9 所示，相机被成功打开。



图5-9 打开相机提示图

在进行打开相机操作之前，一定要确保正确安装驱动程序、相机通过 USB 线准确连接PC端。相机驱动程序被正确安装后，设备管理器的界面如图5-10所示：



图5-10 设备管理器

当相机被正确打开后，“参数调整”按钮不成呈灰色，处于可点击状态。点击“参数调整”按钮后，软件根据检测仪的环境由算法自动对参数进行调整，调整的时间一般在5~10秒左右。当参数正确调整好后，操作界面给出图5-11的提示。如果参数调整不成功，也会给出提示信息，此时可以调整检测仪的光线，或根据

提示减小“有效点数占比”的数值。




图5-11 参数调整

(3) 粗糙度检测：调整好相机参数后，便可以进行结合面的粗糙度检测。将结合面构件正确放入检测仪中，点击界面的“开始检测”按钮进行粗糙度检测。检测结果如图5-12所示。界面左边给出两种算法下结合面的粗糙度数值，右边显示出结合面的彩色图像与深度图像。当检测某个混凝土构件时，在两种不同算法下，检测粗糙度的数值分别是3.093和0.750。根据粗糙度数值，之后也可以进行结合面粗糙度等级的划分。




图5-12 粗糙度检测

此时被测结合面的粗糙度信息会以 Excel 形式储存在“C:\data\安徽省芜湖市”目录下。如图5-13所示，该表格显示出了被检测结合面的所有粗糙度信息。

A	B	C	D	E	F
地点/项目	时间	彩色图	深度图	16点修正法	基准面修正法
安徽省芜湖市	2024/12/22	160519-1. jpg	160519-1. png	3. 093	0. 750

图5-13 Excel信息

5.5 本章小结

本章详细阐述了基于 Visual Studio 环境下的混凝土结合面粗糙度检测，介绍了软件平台的框架以及整体思路。采用 C++ 语言编写程序，介绍了过程中运用到的头文件及其作用；同时利用 MFC 界面制作人机交互软件，将程序移植到开发板中；之后与奥比中光相机共同组装成了粗糙度检测仪，该检测仪可以更加直观地检测混凝土结合面粗糙度，最后输出粗糙度信息。

第 6 章 总结与展望

6.1 工作总结

混凝土结合面粗糙度的研究对其本身的工程和应用价值有非常重要的意义。工程中,通过获取混凝土结合面的粗糙度,可以得知混凝土的力学性能、耐久性能,从而判断混凝土的施工质量和经济性的影响。结合面的粗糙程度适中,构件的安全性能越好,从而保障了构件的耐久性能和经济性能。混凝土的原材料均会影响其本身的粗糙程度,本文在讨论混凝土结合面粗糙度时,也讨论了不同原材料下的粗糙度评判标准。

本文主要的工作及研究内容如下:

(1) 本文采用点云的三维重建将离散的点云连续化,计算粗糙度信息。剪力键型结合面的粗糙度计算方法采用灌沙法原理,表面粗糙度可以表征为结合面上最高点高度与平均高度的差值。本文将平均高度设置为结合面上所有三角面的体积与结合面面积的比值。骨料型结合面的粗糙度计算方法采用凹凸深度原理,表面粗糙度可以表征为结合面最高点高度与平均最低高度的差值。本文将平均最低高度设置为所有结合面上高度最低的三角面体积与 0.1 倍结合面面积的比值。此外,本文也采用了基准面修正法与 16 点修正法,分别对剪力键型结合面和骨料型结合面的粗糙度误差进行修正处理。

(2) 本文采用了深度学习相关理论,对划分好粗糙度等级的结合面进行深度学习,采用了卷积神经网络和注意力机制相结合的方式,对结合面的粗糙度等级进行识别,得到了可以识别混凝土结合面粗糙度等级的深度识别模型——Resnet50_CBAM_C。该模型采用 Resnet50 和改进的 CBAM 通道注意机制结合的方式,进行粗糙度等级识别。通过消融实验、设置最佳学习率、对比其他模型准确度的方式,得到了 Resnet50_CBAM_C 模型识别准确度最佳的结论。Resnet50_CBAM_C 模型的识别准确度可以达到 93.84%,明显优于原网络模型和其他网络模型。

(3) 本文采用 Visual Studio 开发环境进行粗糙度程序的编写,通过 MFC 设计人机交互界面,将程序移植到组装的粗糙度检测仪。经过检测仪中奥比中光相机采集结合面图片,可以更加直观的获得混凝土结合面的粗糙度信息,实现了软硬件结合的方式,体现了人机交互的友好性。

6.2 展望

本文采用软硬件结合的方式，对混凝土的粗糙度进行了系统的检测与评估。此过程中，软件涉及到 Matlab 和 Visual Studio 开发环境，硬件涉及到粗糙度检测仪的组装。

（1）论文中提到的基于深度学习的混凝土结合面粗糙度检测方法准确度较高，但是后续需要继续改进，可以进一步提高检测的准确度。

（2）论文中的粗糙度算法仍有不足之处，基于灌沙法的粗糙度检测方法在计算时，将某一三角面作了近似六边形处理，后续可以改进这个处理方式，找到更加适合的处理方法。基于凹凸深度的粗糙度处理方法中，可以尝试改变结合面的面积比例取值，从而更精确的计算出粗糙度。

（3）在制作人机交互界面时，可以将界面制作的更加美观，便于操作员更方便地使用粗糙度检测仪进行后续操作。

参考文献

- [1] 李鑫,杜晨阳.城市公路交通建设用复合纤维混凝土综合性能研究[J].合成材料老化与应用,2024,53(06):80-82.
- [2] Rahul R, K. Darabi MK, Abu ARRK, et al. A general overview of concrete at high temperatures[J]. Asian Journal of Multidimensional Research,2021,10(12):675-680.
- [3] Yuan ZM, Wang HN, Yang Y, et al. Improving the construction accuracy of precast components in prefabricated buildings by analyzing relevant factors from the perspective of supply chain: a system dynamics model[J]. Architectural Engineering and Design Management,2024,20(2):230-248.
- [4] Jinwon K, Kyungkoo L, Daehee K. Structural performance evaluation of thin-walled concrete filled steel tube column to reinforced concrete wide beam connection[J]. ce/papers,2023,6(3-4):90-94.
- [5] 张颖. 住建部等 9 部门印发意见加快新型建筑工业化发展[J]. 中国勘察设计, 2020, (09): 6-6.
- [6] 李银,王明阳.渠道边坡薄壁混凝土衬砌面板智能化养护技术[J].四川水力发电,2024,43(05):24-27.
- [7] 孟苗苗,李亚红,刘沙沙.建筑混凝土裂缝的主要影响因素及处理技术探讨[J].中国设备工程,2024,(24):12-14.
- [8] Kailash KS, Mohd AK, Visalakshi T, et al. Expansion in low calcium fly ash-based geopolymer concrete: chemical factors influenced by silica fume and NaOH concentration[J]. Journal of Sustainable Cement-Based Materials,2025,14(1):74-88.
- [9] 万伟伟.水工结构混凝土水砂磨损率影响因素研究[J].水利技术监督,2024,(12):276-279.
- [10] Yu LY, Wu DY, Su HJ, et al. Influences of interface roughness and loading direction on tensile behavior of rock-concrete bimaterials under brazilian test conditions[J]. Rock Mechanics and Rock Engineering,2023,56(8):5861-5883.
- [11] GB 50010-2010 混凝土结构设计规范[S]. 北京: 中国建筑工业出版社, 2010.

- [12]GB 50666-2011 混凝土结构工程施工规范[S]. 北京: 中国建筑工业出版社, 2012.
- [13]JGJ 1-2014 装配式混凝土结构技术规程[S]. 北京: 中国建筑工业出版社, 2014.
- [14]侯建国,贺采旭.预应力混凝土叠合板的叠合面受力性能研究[J].武汉水利电力大学学报,1993(03): 307-316.
- [15]管大庆,陈章洪,石韞珠.界面处理对新老混凝土粘结性能的影响[J].混凝土,1994(05):16-22.
- [16]郭进军,张雷顺,蔺新艳.混凝土表面粗糙度评测新方法[J].工业建筑,2003(06): 52-54.
- [17]张雄,张蕾.新老混凝土粘结面人造粗糙度表征及性能研究[J].同济大学学报(自然科学版),2013,41(05):753-758.
- [18]田稳苓,宋昭,肖成志,等.基于数字图像法的新老混凝土粘结面粗糙度研究[J].河北工业大学学报,2017,46(05):74-79.
- [19]黄选明,张新江,刘昊,等.预制混凝土构件叠合面劈裂抗拉性能试验[J].建筑科学,2019,35(03):70-76.
- [20]张渤钰,沈岐平,赵勇,等.基于3D激光扫描的预制混凝土构件结合面粗糙度检测技术研究[J].建筑科学,2020,36(01):111-116.
- [21]胡淑婷,黄方成,胡康俊,等.基于3D扫描技术的现场混凝土三维粗糙度检测方法[J].低温建筑技术,2020,42(09):30-33.
- [22]Shear at the interface of precast and in-situ concrete[R]. Wexham Spring: Cement and Concrete Association, 1982.
- [23]ACI 318-19 Building code requirements for structural concrete[S]. Farmington Hills:American Concrete Institute, 2019.
- [24]武井一夫.コンクリート打継ぎ面の界面粗さの評価方法:界面粗さの形状とせん断伝達[J].日本建築学会構造系論文集,1994(455):7-16.
- [25]牛垣和正,香取慶一,林静雄.コンクリート接合面における表面粗さの評価とせん断伝達に関する実験研究(その1-2)[J].日本建築学会大会学術講演梗概集, 1996: 837-840.
- [26]香取慶一,林静雄.コンクリート接合面の表面粗さ評価値を用いた接合面載

- 荷せん断力の推定の限界に関する研究[J].学術講演梗概集.C-2,構造 IV,鉄筋コンクリート構造,プレストレストコンクリート構造,壁構造・組積構造,1998(19): 753-754.
- [27]高瀬裕也,樋渡健,阿部隆英.既存コンクリート目荒らし面にあと施工アンカーを併用した場合の力学挙動に関する研究 その 2 目荒らしとあと施工アンカーを併用した試験体における実験結果[J].日本建築学会技術報告集,2018,24:125-126.
- [28]阿部隆英,樋渡健,坂本啓太.既存コンクリート目荒らし面にあと施工アンカーを併用した場合の力学挙動に関する研究(その 3)目荒らしとあと施工アンカーを併用した試験体における実験結果[J].日本建築学会技術報告集,2018,24:127-128.
- [29]Pedro MDS, Eduardo N.B.S. Júlio, Vítor D. Silva. Correlation between concrete-to-concrete bond strength and the roughness of the substrate surface[J]. Construction and Building Materials,2007,21(08):1688-1695.
- [30]Tatone BSA, Grasselli G. A method to evaluate the three-dimensional roughness of fracture surfaces in brittle geomaterials[J]. Review of Scientific Instruments,2009,80(12):181-196.
- [31]Pedro MDS, Eduardo NBSJ. A state-of-the-art review on roughness quantification methods for concrete surfaces[J]. Construction & Building Materials,2013,38(01):912-923.
- [32]Hoła J, Sadowski Ł, Reiner J, Stach S et al. Usefulness of 3D surface roughness parameters for nondestructive evaluation of pull-off adhesion of concrete layers[J]. Construction and Building Materials,2015,84:111-120.
- [33]Grigoriadis K. Use of laser interferometry for measuring concrete substrate roughness in patch repairs[J]. Automation in Construction,2016,64:27-35.
- [34]Bentz DP, Varga IDL, Jose F. et al. Influence of substrate moisture state and roughness on interface microstructure and bond strength: slant shear vs. pull-off testing[J]. Cement & Concrete Composites,2018,87:63-72.
- [35]Sarker M, Dias-Da-Costa D, Hadigheh SA. Multi-scale 3d roughness

- quantification of concrete interfaces and pavement surfaces with a single-camera set-up[J]. *Construction and Building Materials*,2019,222(10):511-521.
- [36]武者右京,高瀬裕也,阿部隆英.既存コンクリート目荒らし面における 3D スキャナを用いた形状座標値によるせん断耐力式[J].日本建筑学会技术报告集, 2019,25(59):55-60.
- [37]Yuan JH, Zhang Q, Zhang JQ, et al. Image representation of vibration signals and its application on fault diagnosis of rotating machinery with convolutional neural network: A benchmark study[J]. *Proceedings of the Institution of Mechanical Engineers*,2025,239(2):532-564.
- [38]黄海新,蔡明启,王钰瑶.基于图卷积神经网络的点云语义分割综述[J].*计算机科学*,2024,51(S1):43-49.
- [39]王博雅,杨小春,卢升荣,等.基于图卷积神经网络的多维度节点重要性评估方法[J].*物理学报*,2024,73(22):190-203.
- [40]Qi X, Johar MGM, Khatibi A, et al. Dq-YOLOF: An effective improvement with deformable convolution and sample quality optimization based on the YOLOF Detector[J].*Electronics*,2024,13(21):4204-4204.
- [41]王尔申,刘依凡,于腾丽,等.基于全连接神经网络的 GNSS/INS 组合定位方法[J].*沈阳航空航天大学学报*,2024,41(05):54-61.
- [42]Yu Z, Du C, Liu S, et al. Improved textile-vamp punching points location using CNN and priori regional template matching in the footwear industry[J].*The Journal of The Textile Institute*,2025,116(1):62-70.
- [43]Ai D, Mo F. Prediction of unknown compressive stress/damage in concrete structure using 3D convolutional neural network-based deep learning of raw electromechanical admittance signals[J].*Journal of Intelligent Material Systems and Structures*,2025,36(1):29-52.
- [44]Chen R, Hu P, Gui X, et al. An on-line weld inspection method for underwater offshore structure based on an improved deep convolutional network[J].*Nondestructive Testing and Evaluation*,2025,40(1):289-308.
- [45]Mengarelli A, Tigrini A, Scattolini M, et al. Myoelectric-based estimation of vertical ground reaction force during unconstrained walking by a stacked

- one-dimensional convolutional long short-term memory
Model[J].Sensors,2024,24(23):7768-7768.
- [46]Sun J, Ding H, Li N, et al. Intelligent fault diagnosis of hydraulic system based on multiscale one-dimensional convolutional neural networks with multiattention mechanism[J].Sensors,2024,24(22):7267-7267.
- [47]崔守毅.基于二维卷积的连续血压预测算法及系统研究[D].杭州电子科技大学,2024.
- [48]Lin C, Yu D, Lin S. Three-dimensional CKANs: UUV noncooperative target state estimation approach based on 3D convolutional Kolmogorov-arnold networks[J].Journal of Marine Science and Engineering,2024,12(11):2040-2040.
- [49]Liu J, Yang L, Cheng H, et al. Three-dimensional convolutional vehicle black smoke detection model with fused temporal features[J].Applied Sciences,2024,14(18):8173-8173.
- [50]吴国盼,王蒙蒙,李辛莹,等.基于三维卷积神经网络的遥感影像变化检测[J].遥感信息,2024,39(04):61-67.
- [51]Rath A, Mishra PSB, Bagal KD. ResNet50-based deep learning model for accurate brain tumor detection in MRI scans[J].Next Research,2025,2(1):100104.
- [52]滕贷宇,南柄飞.工作面液压支架丢架状态视觉自动检测方法[J].工矿自动化,2024,50(11):99-108.
- [53]韩素敏,余悦伟,郭宇.基于改进 GAF-SE-ResNet 的光伏逆变器开路故障诊断[J].太阳能学报,2024,45(10):336-344.
- [54]Zhu J, Zhou D, Lu R, et al. C2DEM-YOLO: improved YOLOv8 for defect detection of photovoltaic cell modules in electroluminescence image[J].Nondestructive Testing and Evaluation,2025,40(1):309-331.
- [55]Junaid IM, Madarapu S, Ari S. Human gait recognition using attention based convolutional network with sequential learning[J].Signal, Image and Video Processing,2024,19(1):157-157.
- [56]Gao R, Jin H, Chang J, et al. A fast gangue detection algorithm based on multi-head self-attention mechanism and anchor frame optimization strategy[J].International Journal of Coal Preparation and

- Utilization,2025,45(1):196-212.
- [57]王理丽,李子彬,李军,等.基于声纹识别的油浸式变压器局部放电故障诊断研究[J].青海电力,2024,43(04):36-41.
- [58]朱振宇,江文斌,袁嫣红.基于改进 YOLOv5s 的缫丝机绪下茧粒数检测[J].轻工机械,2024,42(06):73-81.
- [59]Hu D, Zheng Z, Liu Y, et al. Axial-UNet++ power line detection network based on gated axial attention mechanism[J].Remote Sensing,2024,16(23):4585-4585.
- [60]崔丽群,李万欣.融合高效通道注意力的复杂场景违禁品检测[J].辽宁工程技术大学学报(自然科学版),2024,43(04):494-505.
- [61]张志涵,于红,程志澳,等.融合全局注意力机制和时空特征的 ARPA 雷达海上目标分类方法[J/OL].现代雷达,1-13.
- [62]孙逊,祝美宁,宋金玲,等.基于 CBAM 和 Unet 的遥感影像水体识别[J].环境科学导刊,2024,43(05):91-96.
- [63]Zhao D, Zhang W, Wang Y. Research on personnel image segmentation based on mobilenetv2 h-swish CBAM PSPNet in search and rescue scenarios[J].Applied Sciences,2024,14(22):10675-10675.
- [64]钟世英,刘长飞,时文浩.MATLAB 工具箱自动识别探地雷达空洞图像技术[J].计算机辅助工程,2024,33(04):8-14.
- [65]Zhang S, Li J, Zhao L, et al. gCMEbox: A MATLAB toolbox for extracting and analyzing common-mode errors from GNSS time series[J].Advances in Space Research,2025,75(1):497-514.
- [66]王长云,管晓虎,时谦.基于 Visual Studio 的方向性电流保护仿真实验设计[J].工业控制计算机,2024,37(12):127-129.
- [67]李祺玥.基于 Visual Studio 的农村配电网无功补偿设计与研究[J].科技与创新,2024,(24):117-119.
- [68]Ali K, Amani T, Al HE. Computing density profile and square end to end distance of protein using MS Visual Studio C++[J].Journal of Applied Sciences,2012,12(9):809-821.
- [69]谭晓影.奥比中光: 打造“机器之眼”[J].经理人,2022,(08):36-38.

- [70]王雷生,金羽泽.奥比中光:争夺手机巨头[J].中国企业家,2018,(13):77-81.
- [71]DG/TJ 08-2252-2018 装配整体式混凝土建筑检测技术标准[S]. 上海: 同济大学出版社, 2018.
- [72]陆施佳.基于主成分分析法的北京市城市生态系统健康评价研究[J].智能城市,2023,9(02):53-57.
- [73]Mandeep S, K.S.N. Improved 3D laser point cloud reconstruction for autonomous mobile robot applications by using SVM-R technique[J].International Journal of Intelligent Unmanned Systems,2024,12(4):491-506.
- [74]Babu RP, Srikrishna A, Gera R V. Diagnosis of tomato leaf disease using OTSU multi-threshold image segmentation-based chimp optimization algorithm and LeNet-5 classifier[J].Journal of Plant Diseases and Protection,2024,131(6):2221-2236.
- [75]Devi GK, Kishore B, Senthilkumar C. Feature analysis and classification of maize crop diseases employing AlexNet-inception network[J]. Multimedia Tools and Applications,2023,83(9):26971-26999.
- [76]Tong S, Li S. Design of VGG structured U-Net model for remote sensing green space information extraction[J].Journal of Geovisualization and Spatial Analysis,2024,9(1):5-5.
- [77]Fu L, Lv X, Wu Q, et al. Field Weed Recognition Based on an Improved VGG With Inception Module[J]. International Journal of Agricultural and Environmental Information Systems (IJAEIS),2020,11(2):1-13.
- [78]Srivastava R, Kumar N, Sandhan T. Binary classification of laryngeal images utilising ResNet-50 CNN architecture[J]. Indian Journal of Otolaryngology and Head & Neck Surgery,2024,(prepublish):1-8.
- [79]徐岸峰,黄学彬,王波.改进 GoogLeNet 的自然场景图像多标记分类仿真[J].计算机仿真,2024,41(11):258-261.
- [80]Hao D, Wei W, Xuerao W, et al. Scene image recognition with knowledge transfer for drone navigation[J]. Journal of Systems Engineering and Electronics,2023,34(05):1309-1318.

- [81]熊晖,齐元胜,来永爱,等.基于 OpenCV+Dll 图像识别处理的印刷车间疲劳预测系统设计[J].印刷与数字媒体技术研究,2024,(06):67-73.
- [82]Li SG. The Application Research Based on Arduino and Kinect[J].Applied Mechanics and Materials,2014,3485(635-637):1742-1745.
- [83]舒畅,秦肖臻.基于 Eigen 和 OpenCV 的图像算法加速[J].微型机与应用,2017,36(24):40-43.

攻读硕士学位期间的研究成果

1 发表学术论文

- [1] 卓文涛,汪石农,程志军.深度学习下混凝土结合面粗糙度等级识别[J/OL].重庆工商大学学报(自然科学版),1-8[2025-02-19].<http://kns.cnki.net/kcms/detail/50.1155.N.20240508.1029.002.html>.
- [2] Zhuo W, Wang S, Zhao J. Concrete Roughness Grade Identification Based on the Improved AlexNet[C]. 2024 7th International Conference on Robotics,Control and Automation Engineering (RCAE).IEEE,2024:563-569.

2 参加比赛

安徽工程大学第二届“贝斯柯杯”研究生人工智能创新大赛二等奖

致谢

时光荏苒，我的三年研究生生涯即将画上句号。在这段充满挑战与收获的旅程中，我受到了很多人的关心和支持，正是他们的关心和引导，我才能成功地完成自己的学业，才能在学术之路上继续前进。在这里，我要真诚地感谢所有对我提供帮助的人们。

首先，我要向我的导师汪石农老师致以最崇高的敬意和最诚挚的感谢。在过去的几年里，汪石农老师不仅在学术研究上给予我悉心指导，帮助我攻克了一个又一个难题，更在生活中给予我无微不至的关怀与鼓励。他的严谨治学态度、渊博学识和高尚品德，将永远激励我在未来的学术道路上不断探索与追求。在接下来的学习和工作里，导师就是我心中的标杆。他积极乐观的生活态度，让我懂得在面对困难时要始终保持微笑；他科学严谨的做事风格，教会我对待任何事情都要一丝不苟。我会把导师当作榜样，踏踏实实地用积极乐观、科学严谨的态度去对待学习和工作，一步一个脚印地前进。

其次，我要感谢我的同门和师兄们。在实验室的日夜相伴中，我们共同讨论问题、分享经验，每一次思想的碰撞都让我受益匪浅。感谢你们在困难时刻给予我的支持与鼓励，让我感受到团队的力量与温暖。在和同门共同参加的人工智能大赛上，我们每个人都积极做好手头任务，共同商讨大赛的内容，互帮互助，这也为我们团队获奖打下了良好的基础。

在我漫长的求学之旅中，家，宛如一座温暖且坚固的港湾，而家人，便是我最最坚实的后盾，给予我无尽的力量与勇气。那些在学业海洋中奋力划桨的日子里，难题似汹涌波涛，压力如沉重迷雾，每一步都充满了未知与挑战。但每当我被挫折撞得遍体鳞伤时，家人总会用他们温柔却又坚定的目光注视着我，用最温暖的话语鼓励我。在此，我要深深地感谢我的家人。这份感激，如同陈酿的美酒，越品越香；又似悠扬的乐章，永远在我心中奏响。我会带着他们的爱与期望，继续勇敢地走下去，用优异的成绩回报他们的付出与厚爱。

最后，我要感谢所有在学习和生活中给予我帮助的老师、同学和朋友。你们的每一份支持都如同一束光，照亮了我前行的道路。研究生生活是我人生中宝贵的财富，这段经历让我成长了许多。未来，我将以更加饱满的热情和坚定的信念，继续在学术道路上探索前行，不辜负每一位帮助过我的人。