

中图分类号:

单位代号: 10280

密 级:

学 号: 19721486

上海大学



硕士学位论文

SHANGHAI UNIVERSITY
MASTER'S DISSERTATION

题 目	面向复杂材料图像的特征 信息处理方法研究
--------	-------------------------

作 者 张宏坤

学科专业 计算机应用技术

导 师 韩越兴

完成日期 2022.05.15

姓 名：张宏坤


学号：19721486


论文题目：面向复杂材料图像的特征信息处理方法研究

上海大学

本论文经答辩委员会全体委员审查，确认符合上海大学硕士学位论文质量要求。

答辩委员会签名：

主任： 

委员： 

导 师： 

答辩日期： 2022 年 6 月 19 日

姓 名：张宏坤

学号：19721486

论文题目：面向复杂材料图像的特征信息处理方法研究

原创性声明

本人声明：所呈交的论文是本人在导师指导下进行的研究工作。除了文中特别加以标注和致谢的地方外，论文中不包含其他人已发表或撰写过的研究成果。参与同一工作的其他同志对本研究所做的任何贡献均已在论文中作了明确的说明并表示了谢意。

签 名： 张宏坤 日期： 2022.6.19

本论文使用授权说明

本人完全了解上海大学有关保留、使用学位论文的规定，即：学校有权保留论文及送交论文复印件，允许论文被查阅和借阅；学校可以公布论文的全部或部分内容。

（保密的论文在解密后应遵守此规定）

签 名： 张宏坤 导师签名： 韩越兴 日期： 2022.6.19

上海大学工学硕士学位论文

面向复杂材料图像的特征信息处 理方法研究

姓 名：张宏坤

导 师：韩越兴

学科专业：计算机应用技术

上海大学计算机工程与科学学院

2022年05月

A Dissertation Submitted to Shanghai University for the Degree
of Master in Engineering

Research of Feature Information Processing Method for Complex Material Image

MA Candidate: Hongkun Zhang

Supervisor: Yuexing Han

Major: Computer Applications Technology

School of Computer Engineering and Science

Shanghai University

May, 2022

摘 要

材料图像处理对材料的性能预测、工艺优化、新材料研发等有重要的推动作用。而材料不同组织间存在多相黏连、组织交错等问题，使得材料的微观组织结构图像较为复杂，为材料图像处理带来了一定的难度。常见的传统图像处理技术特征信息处理速度较慢，对复杂纹理材料图像的处理效果较差；基于机器学习的特征信息处理方法需要人为定义特征，处理较为繁琐；基于深度学习的复杂材料图像处理技术尚不完善，仍处于起步阶段。此外，复杂材料图像之间差异较大，很难通过统一的方法来对材料图像进行处理，这增大了材料图像处理的难度。为了提高对于复杂材料图像的处理精度，提高分割识别效果，本论文针对陶瓷、钢铁以及钙钛矿等材料图像的特点，结合复杂网络、传统图像处理方法、机器学习和深度学习方法提出了三种处理复杂材料图像特征的方法。

本论文面对不同组织分布不均、重叠交错的复杂材料图像，提出了基于复杂网络理论的特征信息处理方法。该方法使用复杂网络中的社区结构描述材料中的不同组织，以网络构建过程中的距离阈值（ R ）和密度阈值（ T ）加速网络拓扑的动态演化过程，并提出了 RT -模块度对网络拓扑进行评价，完成图像处理。通过在陶瓷、共晶化合物以及钢铁等图像上进行分割实验，验证了本方法的有效性。面对具有多种特征的复杂纹理图片，本论文提出了一套基于传统图像处理技术的特征信息处理方法。该方法利用材料图像中特征的特点，设计了相应的特征信息处理算法，并且一改传统多特征融合的处理方式，利用提取到的形状特征对纹理特征的处理进行加速，大大降低了处理时间。通过在具有不规整形状和复杂纹理的薄膜图案上进行实验，验证了本方法的有效性。为了进一步提升处理速度，降低计算资源消耗，本论文面对上一方法中使用的具有复杂纹理材料图像提出了基于深度学习的特征信息处理方法。该方法首次将轻量级网络模型应用于纹理防伪研究中，通过协调注意力机制的引入和损失函数的设计，使得算法识别准确率得到保证。相比于其他利用深度学习进行纹理防伪的研究工作，该方法不仅降低了资源消耗，并且还在大量具有复杂纹理的材料图像数据库上进行了验证，证明了方法的有效性。

本论文使用多种材料图像进行实验，分别验证了三种方法的在复杂材料图像上的有效性和可靠性，为其他面向复杂材料图像的处理技术研究提供借鉴，推动材料的制备和应用进程。

关键词： 复杂材料图像处理，防伪检测，复杂网络，传统图像处理方法，深度学习

ABSTRACT

Material image processing plays a significant role in material performance prediction, process optimization, and new material development. The problems of multi-phase adhesion and interlacing between different microstructure of the material make the microstructure images of the material more complex, which brings some difficulty to the material image processing. The characteristic information processing speed of traditional image processing technology is slow, and the effect of complex texture material images is poor. The feature information processing method based on machine learning requires the artificial definition of features, which is cumbersome to process. Complex material image processing technology based on deep learning is still in its infancy. In addition, there are great differences between complex material images, so it is difficult to process the material images through a unified method, which increases the difficulty of material image processing. To improve the processing accuracy, segmentation, and recognition effect of complex material images, we propose three methods in this article. We use complex networks, traditional image processing methods, machine learning, and deep learning methods to process the image of ceramic, steel, and perovskite images.

This dissertation proposes a feature information processing method based on complex network theory in the face of complex material images with uneven distribution of different tissues. The method uses the community structure in complex networks to describe the different tissues in materials, accelerates the dynamic evolution process of network topology with distance threshold and density threshold during network construction, and proposes the RT-modularity to evaluate the network topology and complete the image processing. The effectiveness of this method was verified by performing segmentation experiments on images of ceramics, eutectic mixture, and steel. Then, facing the complex texture images with multiple features, this dissertation proposes a set of feature extraction methods based on traditional image

processing techniques. This method summarizes the feature information in material images, and designs corresponding feature processing algorithms for different feature information. This method changes the processing method of multi-feature fusion by using the shape features to accelerate the processing of texture features, which greatly reduces the processing time. The effectiveness of this method is verified by conducting experiments on thin film patterns with irregular shapes and complex textures. Finally, to further improve the processing speed and reduce the computational resource consumption, this dissertation proposes a deep learning-based feature information processing method in the face of the images with complex textured materials used in the previous task. This method applies the lightweight network model to texture anti-counterfeiting research for the first time. By introducing the coordinated attention mechanism and the design of the loss function, the algorithm achieves high accuracy. Compared with other studies on texture anti-counterfeiting using deep learning, this method reduces resource consumption and experiments on a large database of material images with complex textures, which proves its effectiveness.

In this dissertation, we use a variety of material images in experiments. And verify the validity and reliability of the three methods on complex material images. It can provide a reference for other research on complex material images and promote the process of material preparation and application.

Keywords: Complex Material Image Processing, Anti-counterfeiting Detection, Complex Network, Traditional Image Processing Methods, Deep Learning

目录

第一章 绪论	1
1.1 课题来源	1
1.2 课题背景概述	1
1.3 课题研究的目的和意义	2
1.4 国内外研究现状概况	3
1.4.1 基于复杂网络的图像特征信息处理算法研究现状	3
1.4.2 基于传统图像处理方法的复杂材料图像特征信息处理算法研究现状	5
1.4.3 基于学习方法的复杂材料图像特征信息处理算法研究现状	6
1.5 论文主要工作	8
1.6 论文组织结构	8
第二章 相关理论和方法概述	10
2.1 复杂网络理论概述	10
2.1.1 复杂网络理论发展和定义	10
2.1.2 邻接矩阵	11
2.1.3 节点的度	12
2.1.4 节点的强度	12
2.1.5 最短路径长度	13
2.1.6 模块度	13
2.2 传统图像处理方法概述	14
2.2.1 聚类	14
2.2.2 形状空间理论	14
2.2.3 ORB 算法	18
2.2.4 基于网格的运动统计算法	19
2.3 深度学习方法概述	20

2.3.1	经典深度学习网络结构	20
2.3.2	轻量级神经网络	24
2.4	评价指标概述	26
2.5	本章小结	28
第三章 基于复杂网络理论的复杂纹理特征处理方法		29
3.1	方法概述	30
3.1.1	图像预处理	30
3.1.2	网络拓扑构建	31
3.1.3	网络拓扑优化	33
3.1.4	图像分割与边界获取	36
3.2	实验分析	37
3.2.1	图像预处理与网络社区构建	37
3.2.2	模块度分析	38
3.2.3	相关方法对比	40
3.3	本章小结	43
第四章 基于传统方法的薄膜图案特征处理		44
4.1	方法概述	44
4.1.1	数据库构建方法	45
4.1.2	匹配验证方法	49
4.2	实验分析	52
4.2.1	数据准备	53
4.2.2	形状分类及纹理匹配阈值选取	53
4.2.3	编码容量计算以及相关算法对比	54
4.2.4	算法稳定性测试	56
4.3	本章小结	57

第五章 基于深度学习的薄膜图案特征处理	59
5.1 方法概述	59
5.1.1 模型框架	59
5.1.2 基于协调注意力的 MobileNetV3	61
5.1.3 基于类激活值的损失函数	63
5.2 实验分析	64
5.2.1 数据和实验设置	64
5.2.2 面向形状的轻量级网络选取对比实验	65
5.2.3 面向纹理的基于协调注意力的 MobileNetV3 验证实验	66
5.2.4 面向纹理的基于类激活值的损失函数验证实验	67
5.2.5 模型检测结果及性能分析	68
5.3 本章小结	69
第六章 总结与展望	70
6.1 结论	70
6.2 工作展望	71
参考文献	73
作者在攻读硕士学位期间公开发表的论文	86
致谢	87

第一章 绪论

1.1 课题来源

本课题来源科技部国家重点研发计划：“材料基因工程关键技术与支撑平台”专项中“材料基因工程专用数据库平台建设与示范应用”项目中课题“陶瓷涂层材料数据自动采集、整合与应用”中的子课题：“材料复杂显微结构高精度图像处理方法研究”（编号：2018YFB0704400）；科技部国家重点研发项目“材料基因工程关键技术与支撑平台”专项中“国家新材料数据库平台建设关键技术研究”项目中课题：“材料大数据技术研究”（编号：2020YFB0704500）；上海市自然科学基金面上项目：“小样本环境下物体自适应识别方法研究”（编号：20ZR1419000）；之江实验室科研攻关项目（编号：2021PE0AC02）资助。

1.2 课题背景概述

在材料科学研究中，材料制作工艺、微观结构以及宏观性能之间存在紧密的联系 [1, 2]，揭示这三者的关系有助于高性能新材料的研发，对工艺优化，材料的性能提升都有较大的帮助。而数据的处理大都依赖于计算机技术，这使得计算机技术在材料学中的应用不断增强，应用面也越来越广，并逐渐延伸到材料数据统计、材料图像数据挖掘以及宏观性能分析等方面 [3, 4]。

在材料图像研究领域，由于材料性质和制备工艺上的差异使得不同组织之间分布不均、形状各异，微观结构复杂，在图像中表现出组织粘连、目标交错的情况。当下的计算机方法很难直接应用于复杂的材料图像处理，一般需要根据材料的内在特征进行算法设计。因此，面向复杂材料图像的分割识别更是一项高难度的任务，这不仅要求研究人员掌握计算机相关知识，还需要对材料知识具有一定的了解 [5]，这为算法的设计带来了一定的难度。基于以上问题，研究人员开始根据图像的特征信息对图像进行处理，通过根据图像的颜色、纹理、形状等信息等设计特定的算法，最终完成复杂材料图像的处理。

因此，如何提取并处理复杂材料图像中的特征成了当下研究的一项重要任务，本论文围绕复杂材料图像展开研究，针对不同的复杂纹理信息进行图像特征信息提取与处理，为材料图像处理研究奠定基础。

1.3 课题研究的目的是和意义

随着计算机技术的快速发展，材料领域中的自动图像处理引起了越来越多的关注。一些具有清晰特征的材料图像，例如在具有差异较大的颜色、对比度的图像，或者具有规整的形状的图像上可以直接通过常用的图像处理算法进行处理。但是更多的材料图像纹理比较复杂，不同的材料图像差异巨大，这为复杂材料图像的处理带来了一定的困难。

当下的研究工作中，针对具有复杂纹理的图像，常见的处理方式仍然是基于颜色、纹理、形状等特征进行分析 [6-9]，或者采用多特征混合的方式进行处理 [10-12]，这样获得的特征简单易用但忽略了材料内在的组织关系。复杂网络的引入为这一问题带来了解决办法，使用复杂网络对图像进行网络拓扑构建以及社区划分可以在一定程度上解决这一问题。当下复杂网络应用在材料图像上的研究方法大多使用超像素进行节点的构建，利用模块度进行社区划分的度量时计算时间花费较大，并且这为复杂材料图像处理带来了一定的困难。

有些研究人员为了方便进行复杂材料图像处理，在材料中设计了一些较为明显的特征，来降低处理难度，提高材料图像的处理效率，例如利用材料设计特定花纹 [13]、图案 [14] 等。针对这部分图像，当下使用较多的是传统图像处理方法进行特征信息处理，这种方法受人工设计特征的影响较大，需要研究人员具备较高的专业素养以及知识储备。对于某些面向复杂材料图像处理的任务，由于特征利用不充分，很容易造成算法复杂、处理时间较长等问题。机器学习和深度学习的引入为复杂材料图像处理带来了一定的转机，凭借其自动的特征学习使得研究人员无需进行大量的试错即可达到令人满意的处理精度。只是大部分的研究仍处于初级阶段，模型使用的是较为成熟的大型神经网络，这在一定程度上增加了计算资源的消耗和时间花费。

综上所述，基于复杂网络的特征信息处理方法尚不完善，基于传统图像处理方法的特征信息处理方法处理速度较慢，机器学习方法需要利用大量人为定义的特征，深度学习在复杂材料图像处理方面处于起步阶段，尚且不能达到很高的准确率。本论文针对以上几类方法做了相应的修改与提升，为面向复杂材料图像的特征信息处理方法提供更多的解决思路。

1.4 国内外研究现状概况

本论文主要围绕复杂材料图像的特征信息处理方法进行研究，并采用复杂网络理论方法、传统图像处理技术、深度学习方法加以实现。因此本章介绍了以上算法在图像特征信息处理方面的研究现状，这些研究可以为本论文在复杂材料图像处理上提供一定的借鉴。

1.4.1 基于复杂网络的图像特征信息处理算法研究现状

近年来，复杂网络在生物医学 [15]，人文社会科学 [16]，物理学 [17] 和计算机视觉 [18–20] 等诸多领域引起了广泛的关注。由于复杂网络存在的小世界特性 [21] 以及聚类特性 [22] 等可以较好的描述图像中的结构信息，因此在图像处理中也引发了一波热潮。使用复杂网络理论方法可以建立图像特征信息之间的关系，通过复杂网络的动态演化，可以获得不同的网络拓扑结构。这些网络拓扑可以形象直观的表现出图像中的形状、颜色、纹理等信息，以此可以完成对图像的分类识别等任务。例如 Backes 等人利用物体轮廓边界上的离散点构建复杂网络模型，基于边权阈值对其动态演化，不同演化时刻下子网络的特征即可描述形状信息 [23]。但是这种形状描述是刚性变换下的不变量，对非刚性变化明显的物体的描述效果不理想。在此基础上，Backes 等人进一步利用复杂网络的分形特征来描述物体的形状，并分析了复杂网络特征对形状描述过程的影响 [24]。Scabini 等人使用图像不同颜色通道间和通道内的像素点作为节点，构建初始的复杂网络，通过阈值的动态演化进行图像特征信息的提取，最终完成图像的描述，完成分类任务 [25]。Zeynab 等人则认为仅仅从 RGB

图像中提取特征描述性较差，因此提出使用 RGB-D 传感器提取图像的深度和骨骼信息，在复杂网络上使用边缘权重直方图 (histogram of the edge weight, HEW) 和节点强度直方图 (histogram of the node strength, HNS) 进行评判，完成特征的描述，最终完成人像的匹配 [26]。这些研究为复杂网络在图像处理中的应用提供了很好的理论支持。

随着复杂网络中社区概念的提出，研究人员发现使用社区检测可以很好的描述图像中不同区域的关系，很多研究将社区概念引入到图像分割任务中。Abin 等人基于颜色信息的均值偏移分割结果构建了一个网络，网络的权重是两个区域的颜色相似度，最后通过社区检测算法完成图像分割 [27]。为了评估社区分割的质量，Newman 等人提出了模块度的概念 [28, 29]。模块度是通过计算社区中的总边数与网络中的总边数减去期望值的比值得到的。如果当前的复杂网络为随机网络时，由于缺乏社区的性质，节点之间随机连接，网络中的社区一般为一个。模块度描述了网络与随机网络的差异，如果差异越大，社区分割就越趋于合理。许多研究基于模块度进行图像处理，例如 Li 等人将模块度引入到图像分割中，这在当时是一个开创性的思想，为图像分割的发展找到了新的方向 [30, 31]；Linares 等人提出了一种基于模块度的快速社区检测的分割算法，通过超像素构建网络并计算 CIELAB 特征来判断两个节点是否可以连接，最后通过社区检测完成图像分割任务 [32]；Nguyen 等人为了解决社区检测容易发生过度分割的问题，在用复杂网络进行分割时考虑了颜色属性，使用更低维度的向量进行区域的特征描述来降低计算复杂度，使用余弦相似距离进行颜色的聚合，不仅降低了模块度计算的运算量还获得了更好的分割结果 [33, 34]；Gammoudi 等人则是使用随机森林和超像素对图像进行特征提取，将利用超像素得到的区域块进行复杂网络构建，用模块度评价社区划分，通过社区划分得到图像分割结果，这在医学图像上获得了不错的精度 [35]。以上的模块度检测算法都要经过不断的迭代计算，耗费时间较长，且应用场景较为简单，面向复杂材料图像的研究较少。

1.4.2 基于传统图像处理方法的复杂材料图像特征信息处理算法研究现状

传统的图像处理方法起源于 1964 年美国的喷气式推进实验室 (Jet Propulsion Laboratory, JPL), 为了可以处理太空飞船拍摄的月球表面图像, 实验室研究人员使用数字计算机对图像进行畸变校正处理, 并取得了不错的效果 [36]。这为图像处理的发展产生了深远的影响。随着技术的发展, 越来越多的图像处理方法应用在不同的领域, 材料图像处理便是其中之一。在材料图像中, 大致可以将其分为两类, 材料图像分割和材料图像识别。材料图像分割技术可以清晰精准的定位和分析不同物相的分布, 对物质中具有特定物理化学性质的相进行参数提取, 这对材料的设计、研发和制备优化等具有十分重要的作用。材料图像识别则是使计算机可以自动对不同的材料图像进行认知学习, 降低人工识别的难度, 减少因人工主观原因造成的精度不足的问题, 并且可以与材料的性能表现、计算和评价等进行关联, 实现端到端的自动处理, 加快材料图像处理分析速度和精度。

针对材料图像的处理方法当下使用较多的依旧是传统图像处理方法, 例如阈值法 [37], 区域生长法 [38], 分水岭法 [39], normalized cuts[40], 图割法 [41] 等等, 这些算法都能在简单场景中取得不错的效果。面向复杂材料图像进行处理时, 这些方法便显得有些捉襟见肘。为了进一步提升算法对复杂材料图像的处理能力, 研究人员开始挖掘材料图像的不同特征来进行处理。在当前工作中, 大致可以将处理方法分为两类: 基于区域特征的处理方法和基于边缘特征的处理方法。

基于区域特征的处理方法, 最常用的是阈值法 [42], 这一类算法对于材料图像的要求较高, 如果图像对比度没有达到预期, 那么阈值法便很难得到较好的效果。研究人员也对这一方法进行了改进, 有的通过引入形态学方法进行处理, 使得特征处理更加方便 [43-45]; 有的通过引入边界细化算法使得提取的特征更好的描述分割边界 [46, 47]; 有的直接从颜色出发对图像进行处理 [48-50] 等等。阈值法需要手动设定阈值, 这极大程度上依赖于图像处理的经验, 并且在不同的图像上分割结果差异明显, 这使得分水岭算法开始逐渐发展起来。分水岭算法是一种基于种子生长的图像分割方法, 通过像素值上的相似度来连通不同的区域, 最终完成像素级特

征提取以及分割任务 [39, 51, 52]。但这种方法在高对比度图像中效果明显，对于具有复杂纹理的材料图像效果一般。此外，还存在一类比较特殊的算法，即通过对区域内的信息进行转换，将其描述为特征点，以此描述特征信息，例如 SIFT[53, 54]、SURF[55]、ORB[56] 等。这些特征处理方法可以清晰的提取出复杂材料图像中相应的纹理信息，无需训练和学习，即可对图像进行描述 [13, 57]，但是算法需要较多的专业知识指导，处理速度较慢。

基于边缘特征的处理算法的思想是将图像先转换为边缘图再进行相关处理，相比于基于区域的分割方式大大降低了图像处理的复杂度，加快了处理的速度。现有的边缘检测算法大都是依赖于较为成熟的边缘检测算子进行，但这些算子也存在一定的缺陷。例如 Sobel[58] 和 Prewitt 算子 [59] 都是一阶的边缘检测算子，其通过卷积运算识别出边缘。虽然这两个算子可以处理灰度渐变的低噪声图像，但是精度不是很高，当遇到具有复杂噪声的图像时，不容易取得好的分割结果；Log 滤波算子 [60] 是通过计算二阶导数零点的位置来确定边缘，但在滤波时容易受到噪声的影响，噪声去除越好，边缘精细度越低，这使得这一方法注定不会取得较细致的边缘；Canny 算子 [61] 使用两种不同的阈值分别检测强边缘和弱边缘，虽然可以检测出比较细致的边缘，但结果很零散。为此，研究人员另辟蹊径，提出了动态的轮廓检测方法，通过设计能量函数，构建模型来寻找能量函数最低点来动态的寻找图像的边界 [62]。近年很多研究大都通过结合多种分析方式来进行材料图像处理，例如 Wang 等人使用小波变换和多尺度边缘表示结合的方法对飞机夹层复合材料图像进行处理，发现可以很好的找到图像中的缺陷 [63]。基于边缘的分割方法在面对具有清晰边缘的情况下能取得较好的效果，而复杂材料图像边缘较为复杂，这使得处理难度大大增加。

1.4.3 基于学习方法的复杂材料图像特征信息处理算法研究现状

近年来由于机器学习的发展，越来越多的研究人员将机器学习引入到复杂材料图像的处理中，这类研究也逐渐发展成为热点。与经典的图像处理方法相比，机器学习能利用设计好的特征对数据内关系进行归纳总结，从而区分不同类别数据。例

如针对像素值的 FCM 算法, 设定了聚类中心来计算不同像素的特征与聚类中心的隶属度, 通过优化目标函数不断调整聚类中心最终使得目标函数达到极小值, 以划分出不同的类别 [64, 65]。支持向量机作为机器学习中具有代表性的算法也较早应用在了复杂材料图像处理中 [66, 67], 有些研究引入了不同特征信息, 例如结合材料原子参数 [68]、小波分解得到的材料纹理特征 [69] 等来训练支持向量机, 实验验证这种方式都能获得不错的分类效果。为解决不同场景问题, 支持向量机可以选取不同的核函数进行处理, Marconcini 等人提出了基于光谱和图像空间信息的混合核函数, 这使得算法在高光谱图像的光谱空间分类上取得了令人满意的效果 [70]。除此之外, 马尔可夫随机场 [71]、随机森林 [72]、高斯混合模型 [73] 等机器学习方法都在复杂材料图像处理中有了应用。传统机器学习方法大都是针对图像的特定特征进行处理的, 需要较强的专业知识、处理精度不高。

近年来, 研究人员引入了深度学习的方法来进行复杂材料图像的处理。深度学习可以自动进行特征的提取, 这极大降低了工作难度, 提升了处理速度。为了分割量化球墨铸铁图像和高温合金钢图像, 研究人员首次引入了人工神经网络并发现可以获得与人的观测极为相似的效果, 这为神经网络在复杂材料图像处理中的发展起到了积极的推动作用 [74, 75]。近年来, 越来越多的神经网络被用在复杂材料图像处理上。例如 Decost 等人使用深度神经网络, 利用不同尺度的特征信息对超高碳钢微观结构完成了分割任务 [76]; Azimi 等人使用全卷积神经网络对碳钢图像进行像素级特征信息处理, 获得了远超其他方法精度的分割效果 [77]; Yang 等人基于 GAN 方法, 对复杂材料图像进行了特征的设计, 通过对抗的方法训练两个网络, 即生成器和判别器, 获得了一个可以判别不同图像类别的分类器, 完成了真伪验证任务 [78]。随着研究的深入, 研究人员开始意识到更深层次的网络可以学习到更加高层的语义特征, 这也促生了很多深度神经网络的研究 [79–81]。此外, 为了增强模型对特征的提取能力, 研究人员引入了注意力机制来提升模型的学习效率, 提高了模型的处理能力 [82, 83]。但以上深度学习方法需要大量的数据和标注信息才能得到很好的效果, 在复杂材料图像处理领域仍旧处于初始阶段, 较多的研究仍然使用比较复杂的大型深度学习模型, 在处理速度和精度上尚不完善。

1.5 论文主要工作

为了解决复杂材料图像中特征信息处理问题，本文针对不同材料图像的特点，结合多种图像处理方法，实现了复杂材料图像的自动化处理。本文的主要工作和创新如下：

(1) 利用复杂网络和提出的 RT -模块度进行复杂材料图像分割。本论文使用复杂网络对材料图像中的纹理信息进行描述，利用网络构建过程中的 R 、 T 阈值设计了一个新的模块度，即 RT -模块度，对复杂网络社区构建结果进行度量，大大降低了模块度的计算难度。相比于其他方法，本方法在复杂材料图像处理中取得了更佳的分割效果。

(2) 设计了基于传统图像处理技术的钙钛矿晶体薄膜图案识别检测方法。针对具有复杂纹理的钙钛矿晶体薄膜图案，本方法结合形状空间理论、形状检测算法、特征点检测匹配算法等，使用形状特征识别结果加速纹理特征的检测，大大降低了处理时间，完成了薄膜图案的自动化检测处理。

(3) 设计了一套基于深度学习的钙钛矿晶体薄膜图案的识别检测方法。本方法首次使用轻量级神经网络完成纹理防伪任务，通过引入协调注意力机制增强模型的学习能力，设计损失函数指导模型训练，使得模型在较低资源占用下获得了较高的识别准确率。此外，本论文通过对特征向量各元素中的最大值进行区分，使得传统的分类模型可以处理单分类任务，拓展了基础模型的应用场景。

1.6 论文组织结构

本论文以本人攻读硕士学位期间承担的相关项目研究为基础，针对以上提出的问题和不同的复杂材料图像数据的特点，分别研究、设计了相应的复杂材料图像特征信息处理方法，以完成图像的分割识别任务，并通过实验验证了本论文提出方法的有效性。

本论文的其他各章内容安排如下：

第二章介绍了与本论文研究相关的理论和技术。首先，介绍了复杂网络理论方

法中的基本知识；然后，介绍了本论文中使用的聚类算法、形状空间理论、特征点匹配检测算法等传统图像处理技术；其次，对经典的深度学习模型进行了介绍，并描述了轻量级神经网络设计思路；最后，对本论文中使用的相关评价指标进行了解释。

第三章提出了一种基于复杂网络理论的特征信息处理方法。首先，介绍了图像预处理以及复杂网络节点的确定方式；然后，详细介绍了网络拓扑的构建方式及公式描述；接着，重点介绍了本论文提出的 *RT*-模块度和原理，以及图像分割和边界获取方法；最后，通过实验验证了本方法的有效性，并对结果进行了分析和讨论。

第四章提出了一种基于传统图像处理技术的复杂材料图像特征信息处理方法。本章首先介绍了钙钛矿晶体薄膜图案数据库的构建方法；接着，阐述了本方法使用特征信息进行形状纹理匹配的设计思路和算法流程；最后，介绍了本方法使用的数据，并对本章提出的方法进行了实验验证，同时对实验结果进行了分析说明。

第五章提出了一种基于深度学习的复杂材料图像特征信息处理方法。首先，阐述了本章提出模型的大体框架；接着，重点介绍了本论文设计的基于协调注意力的 MobileNetV3 模型结构和基于类激活值的损失函数；最后，通过在钙钛矿晶体薄膜图案数据上进行实验，验证了本论文所提方法的有效性。

第六章对全文进行了总结和回顾，并对未来的研究方向提出了一定的展望和设想。

第二章 相关理论和方法概述

计算机视觉一直是计算机领域的研究热点，近几年图像处理技术越发成熟，并且在各个领域都开始落地应用，为社会创造了极大的财富。材料图像处理是其中一个分支，经过了几十年的发展，基于图像的材料定量分析质量大大提升，计算机与材料研究越来越密不可分。本论文的研究目的是通过吸取当下方法中的优点，进一步探索新的图像处理技术在复杂材料图像处理领域的可能性。因此，本章回顾了与本论文相关的理论和技术，为后续章节的方法介绍提供铺垫。

2.1 复杂网络理论概述

2.1.1 复杂网络理论发展和定义

复杂网络的研究始于图论和拓扑学的发展，网络中很多的概念也源自于图论。1960年数学家 Erdos 和 Renyi 建立了随机图理论 [84, 85]，提出了随机网络的概念，说明了随机网络的两个节点之间连边是有一个概率决定的，这开启了复杂网络在数学领域研究的先河。这样的思想影响复杂网络的研究几十余年，1998年的 Watts 等人经过研究发现日常生活中的大部分网络不全是随机图，而是存在一定的小世界特性，也就是网络存在短的平均长度和高的聚类系数 [86]，进一步推动复杂网络的发展。1999年 Barabasi 等人提出了一种无尺度网络模型，描述了现实生活中存在的“富者更富”的现象，这样的描述更加贴近于真实的世界，为复杂网络的发展打下了坚实基础 [87]。由于复杂网络拥有巨大数量的节点，节点间关系错综复杂，节点间的连接和权重等也随着时间不断变化，这也构成了复杂网络极其复杂的网络拓扑结构。针对其拓补性质，研究人员利用图论、动力学方法等对其进行计算和仿真 [88]。

在计算机领域常用图论对网络进行描述，即利用一个图来表示一个网络，这可以精确的量化网络中的各参数。复杂网络在定义时一般使用 $G = (V, E)$ 表示，其中 V 为节点集合，节点集合的大小反映了网络规模； E 为网络中边的集合，为 $V \times V$ 的子集 [89]。如图2.1所示，复杂网络可以分为有向图、无向图、加权图等。如果节

点对 $V(i, j)$ 和 $V(j, i)$ 为同一条边, 那么该网络为无向图, 反之则为有向图。如果图中的每一条边都拥有相应的权重, 那么该网络的图为加权图。




图 2.1: 网络类型示意图

复杂网络中存在很多概念可以用来描述网络拓扑特性, 本论文使用了邻接矩阵、节点的度、节点的强度、最短路径长度、模块度等概念对网络进行研究和描述, 来完成特征信息的量化和分析。

2.1.2 邻接矩阵

邻接矩阵是常用的描述网络结构的数据结构, 其直接显示了网络节点的连接关系。对于节点集大小为 n 的网络, 其邻接矩阵为 $n \times n$ 的方阵 A , 使用公式描述如下 [90]:

$$A = (a_{ij})_{n \times n}, \quad (2.1)$$

如果考虑的为无向图, 那么其中边 a_{ij} 的定义如下:

$$a_{ij} = |e_k|, e_k = \langle v_i, v_j \rangle \in E. \quad (2.2)$$

如果考虑边的有向性, 那公式 (2.1) 中 a_{ij} 的描述如下:

$$a_{ij} = |e_k|, e_k = (v_i, v_j) \in E. \quad (2.3)$$

无向图的邻接矩阵具有一定的对称关系, 仅使用上三角或者下三角区域的数据即可描述网络, 仅占用 $n(n-1)/2$ 空间, 而有向图则需要保存整个邻接矩阵, 需要 n^2 的空间存储。

2.1.3 节点的度

节点的度描述了节点之间的连接关系，表示了与当前节点连接的边的数目，也即邻接节点的数目。对于无向图而言，节点 i 的度 K_i 的计算如下所示：

$$K_i = \sum_{j \in G} a_{ij}, \quad (2.4)$$

N 表示节点中所有的节点数目， a_{ij} 表示图中的边。对于有向图而言，节点的度分为入度 K_i^{in} 和出度 K_i^{out} ，入度表示所有指向该节点的边数，出度表示所有从当前节点出发的边数，两者的公式如下：

$$K_i^{in} = \sum_{j=1}^N b_{ji}, \quad (2.5)$$

$$K_i^{out} = \sum_{j=1}^N b_{ij}, \quad (2.6)$$

其中 N 表示图中节点数目， b_{ji} 表示所有指向节点 i 的边， b_{ij} 表示所有从节点 i 出去的边，节点的度表示为所有入度和出度的总和。通常情况下，节点的度越大，节点重要程度越高。由于在图像中，入度和出度没有较强的实际意义，因此本论文主要针对无向图进行研究。

2.1.4 节点的强度

节点的强度是描述的带权图中，所有与当前节点的连边的权重之和。节点的强度不仅描述了与当前节点连接的边的数目，还描述了节点间连接边的权重信息，节点 i 的强度 S_i 的公式描述如下：

$$S_i = \sum_{j \in G} w_{ij}, \quad (2.7)$$

其中 w_{ij} 表示节点 i 和节点 j 之间边的权重，权重越大，节点间约有可能存在更为密切的关联。

2.1.5 最短路径长度

复杂网络中的路径长度是指从网络的一个节点走到另一个节点过程中，途经边的数目。由于节点间的连接顺序不同，路径也千差万别，其中存在一条最短路径，可以完成从节点 i 到节点 j 的快速信息传输 [91]。在复杂网络中寻找此最短路径有很多种方法，本论文选取的最短路径检测算法是 Dijkstra 算法 [92]，其步骤如下：

算法 2.1: Dijkstra 算法伪代码

输入: 加权图 $G = (V, E, W)$, $V = \{v_1, v_2, \dots, v_n\}$, 源点 s

```

1 将源点  $s$  放入集合  $S$  中, 节点距离  $d[s, s] = 0$ ;
2 for  $v_i \in V - S$  do
3   | 将权重值  $w[s, v_i]$  赋值给  $dist[s, v_i]$  (如果  $v_i$  不在  $V$  中,  $dist[s, v_i] = \infty$ ) ;
4 end
5 while  $V - S \neq \phi$  do
6   | 从  $V - S$  集合中寻找  $\min_{v_j \in \{V - S\}} dist[s, v_j]$ ;
7   | 将距离最短的节点  $v_j$  放入集合  $S$  中;
8   | for  $v_i \in \{V - S\}$  do
9     |   | if  $dist[s, v_i] + w_{j,i} < dist[s, v_i]$  then
10    |   |   | 将  $dist[s, v_i] + w_{j,i}$  赋值给  $dist[s, v_i]$  更新;
11    |   | end
12 end

```

输出: 从源点 s 到所有 $v_i \in V$ 的最短路径

2.1.6 模块度

社区结构是复杂网络理论中最常用的属性，这揭示了复杂网络内部性质，社区内节点连接紧密，社区间连接稀疏。早期算法不能很好的确定社区划分是否是最优的，模块度的提出解决了这一问题，其公式描述如下：

$$Q = \frac{1}{2m} \sum_{ij} \left[A_{ij} - \frac{k_i k_j}{2m} \right] \delta(c_i, c_j), \quad (2.8)$$

其中 A_{ij} 表示两个节点 i 和 j 是否相连, 相连为 1, 否则为 0; m 表示整个网络中所有边的数目, 其公式 (2.9) 如所示; k_i 表示网络中所有与节点 i 相连的边的数目, k_j 同理; $\delta(c_i, c_j)$ 是狄利克雷函数, 用来判断节点 i 所在社区 c_i 和节点 j 所在社区 c_j 是否相同。

$$m = \frac{1}{2} \sum_{ij} A_{ij}. \quad (2.9)$$

模块度是基于节点的度来进行计算的, 每个节点在开始计算时都被认为是一个独立的社区, 接着通过合并相似节点来减少社区数目, 通过计算模块度的增益来判断当前社区是否被合理划分, 最终直到无论怎样合并节点都无法增加模块度时, 完成社区合并。

2.2 传统图像处理方法概述

2.2.1 聚类

聚类是一种无监督算法, 通过数据内的关系信息将其划分到不同的类别中, 使得相同类别的类内相似度高, 不同类别间相似度低。K-means 算法 [93] 是聚类算法中的杰出代表, 其基本思想是通过预先定义的聚类簇数目, 寻找当前数据中最优的划分方法, 使得设定的损失最小。在这里, 损失函数常用各个样本与簇中心的距离的平方和代替, 其公式如下所示:

$$J(c, \mu) = \sum_{i=1}^M \|x_i - \mu_{c_i}\|^2, \quad (2.10)$$

其中 M 是样本总数, x_i 表示第 i 个样本, c_i 是第 i 个样本所述的簇, μ_{c_i} 表示簇的中心点, 其主要流程如算法2.2所示。

2.2.2 形状空间理论

形状空间理论是 Kendall 等人提出了一套物体识别方法 [94–96]。此方法通过对二维图像进行地标点提取完成物体描述, 获取的一组地标点可以作为一个点投影到

算法 2.2: K-means 算法伪代码

输入: 样本集 $D = \{x_1, x_2, \dots, x_m\}$ 和聚类簇数 k

- 1 从 D 中随机选择 k 个样本作为初始均值向量 $\{\mu_1, \mu_2, \dots, \mu_k\}$
- 2 **while** 均值向量更新 **do**
- 3 令 $C_i = \phi(1 \leq i \leq k)$
- 4 **for** $j \in \{1, \dots, m\}$ **do**
- 5 计算样本 x_j 与各均值向量 $\mu_i(1 \leq i \leq k)$ 的距离: $d_{ji} = \|x_j - \mu_i\|^2$;
- 6 根据距离最近的均值向量确定 x_j 的簇标记: $\lambda_j = \arg \min_{i \in \{1, 2, \dots, k\}} d_{ji}$;
- 7 将样本 x 划入相应的簇: $C_{\lambda_j} \cup x_j$
- 8 **end**
- 9 **for** $i \in \{1, 2, \dots, k\}$ **do**
- 10 计算新均值向量: $\mu'_i = \frac{1}{|C_i|} \sum_{x \in C_i} x$;
- 11 **if** $\mu'_i \neq \mu_i$ **then**
- 12 将当前均值向量 μ_i 更新为 μ'_i
- 13 **else**
- 14 保持当前均值向量不变
- 15 **end**
- 16 **end**
- 17 **end**

输出: 最终簇划分 $C = \{C_1, C_2, \dots, C_k\}$

预形状空间上, 通过计算预形状空间上两个物体的测地距离 (如图2.2所示) 即可完成物体的识别匹配。

首先, 在待识别的图像中可以获得一组二维欧几里德空间里的地标点 P ,

$$P = \{p_1(x_1, y_1), p_2(x_2, y_2), \dots, p_n(x_n, y_n)\}, \quad (2.11)$$

其中 n 表示地标点的数目, p_i 表示第 i 个地标点。 P 点处于 R^{2n} 维度空间内, 为了移除位置等信息对地标点的影响, 将其每个坐标都做了去均值处理得到 P' :

$$P' = \{p'_1(x_1 - \bar{x}, y_1 - \bar{y}), p'_2(x_2 - \bar{x}, y_2 - \bar{y}), \dots, p'_n(x_n - \bar{x}, y_n - \bar{y})\}, \quad (2.12)$$

其中 \bar{x} 和 \bar{y} 为 $\{x_i\}$ 和 $\{y_i\}$ 的均值。通过以上方式去除了平移对特征点的影响, 这




图 2.2: 测地距离示意图 [97]。图中两个点 τ_1 和 τ_2 表示预形状空间内的两个预形状，两点之间的直线距离是欧几里德距离 (ED)，沿着球体表面的距离表示测地距离 (GD)。

也使得 P' 变为 $(2n - 2)$ 维空间内的一点。接着通过公式 (2.13) 所示方式去除缩放对数据的影响，可以获得预形状 τ 。

$$\tau = \frac{P'}{\|P'\|} \quad (2.13)$$

其中， $\|\cdot\|$ 表示欧几里德范数，且假定 $\|\cdot\| > 0$ 。经过以上处理，使得具有 n 个地标点的所有预形状嵌入在 R^{2n} 空间内的 $(2n - 2)$ 维线性子空间内。如图2.3所示，形状空间即为所述 R^{2n} 空间，空间内的一点即为相同数目地标点组成的所有形状，是 $(2n - 2)$ 维线性子空间，图像中将其表现为一个超球。由于 $\|\tau\| = 1$ ，因此针对一种形状而言，其不同变化所得的形状皆处于 $(2n - 3)$ 维的空间内。在图像中表现为超球表面的一个轨道，轨道中包含了一种形状的所有可能变化（在欧几里德空间内表现为经过位置偏移、缩放以及旋转等获得不同形状），在这里将其描述为 S_*^{2n-3} 。

如果想要计算两个形状的相似性，那么需要定义距离计算公式。在形状空间上，两个形状 $O(\tau_1)$ 和 $O(\tau_2)$ 的距离可以通过以下公式计算 [94]：

$$d_p[O(\tau_1), O(\tau_2)] = \inf[d(A, B) : A \in O(\tau_1), B \in O(\tau_2)], \quad (2.14)$$

$d(A, B)$ 表示两个预形状 τ_1 和 τ_2 在预形状空间的 S_*^{2n-3} 轨道上的测地距离，其计




图 2.3: 形状空间理论示意图 [98]。(A) 表示预形状空间, 在欧几里德空间内位置、缩放和旋转不同的物体的预形状都位于 S_*^{2n-3} 的同一个大圆(虚线)上。(B) 表示形状空间, 空间中一个点包含了所有具有相同数目地标点的形状。

算公式如下:

$$d(\tau_1, \tau_2) = \cos^{-1}(\langle \tau_1, \tau_2 \rangle), \quad (2.15)$$

$\langle \tau_1, \tau_2 \rangle$ 是 τ_1 和 τ_2 的内积。通过将公式 (2.15) 带入公式 (2.14) 中可获得如下公式:

$$d_p[O(\tau_1), O(\tau_2)] = \inf[\cos^{-1}(\langle A, B \rangle) : A \in O(\tau_1), B \in O(\tau_2)], \quad (2.16)$$

其中 $\inf(*)$ 表示集合的下确界, $\cos^{-1}(\langle A, B \rangle)$ 表示 A 点和 B 点在 S_*^{2n-3} 空间内的测地距离, 因此两个形状之间的相似度可以通过计算预形状空间轨道之间的最短距离获得。

但是此公式的计算较为困难, 因此 Small 等人 [96] 引入了复数空间来对公式进行推导, 最终获得如下公式:

$$d_p[O(\tau_1), O(\tau_2)] = \cos^{-1} \left(\left| \sum_{j=1}^p \tau_{1j} \tau_{2j}^* \right| \right). \quad (2.17)$$

其中 τ_{1j} 和 τ_{2j} 是 τ_1 和 τ_2 的第 j 个复坐标 (complex coordinates), τ_{2j}^* 是 τ_{2j} 的共轭复数。这个函数度量是著名的富比尼-施图迪度量 (Fubini-Study metric), 其中两个形状之间的距离度量不会受 $O(\tau_1)$ 和 $O(\tau_2)$ 这两个预形状空间上轨道内距离的影响。如果测地距离小, 那么两个形状更有可能是一种类型的物体。

2.2.3 ORB 算法

ORB 算法 [56] 主要分为两个部分：特征点提取和特征点描述。特征点提取使用的是带方向的 FAST 算法 [99]。首先以像素点 O 为圆心，以设定的长度作半径，获取的圆周上像素点；之后通过设置阈值 h 将圆周上的像素点值 I_x 分为三类： $I_x \geq I_O + h$ ， $I_x \leq I_O - h$ ， $I_O - h < I_x < I_O + h$ ，其中 I_* 表示像素点的灰度值；最后比较圆周上连续的一半像素点是否都属于同一类，如果是，那么将此点 O 认为是特征点。但是此类特征点比较容易在图像上物体的边缘处产生，对角点关注较低。为了使得算法能较好的对图像中的角点具有较强的识别能力，算法使用了 Harris 角点度量 [100] 来对获取到的特征点进行排序，特征点选取时根据排序结果从前至后选定。为了描述特征点的方向，ORB 算法引入了图像的矩，其如公式 (2.18) 所示：

$$m_{pq} = \sum_{x,y} x^p y^q I(x,y), \quad (2.18)$$

其中 p 和 q 表示自变量，不同值代表了不同类型的矩， x 表示像素点在 x 轴上的投影值， y 表示像素点在 y 轴上的投影值， $I(x,y)$ 表示在 (x,y) 坐标处像素点的灰度值。由公式 (2.19) 可以求出强度质心 C ：

$$C = \left(\frac{m_{10}}{m_{00}}, \frac{m_{01}}{m_{00}} \right), \quad (2.19)$$

其中 m_{00} 是零阶矩， m_{10} 、 m_{01} 表示一阶矩，这都通过公式 (2.18) 计算得来。特征点的方向 θ 用中心像素点 O 与强度质心 C 的连线 \overrightarrow{OC} 表示，其公式 (2.20) 如下：

$$\theta = f_{at}(m_{01}, m_{10}), \quad (2.20)$$

其中 $f_{at}(*)$ 表示可以确定象限的反正切函数。通过以上方法获取到特征点的方向信息，以便于后续的特征点匹配验证。

对特征点的纹理描述是通过 BRIEF 算法 [101] 完成的。其处理步骤如下：首先，对特征点区域使用高斯模糊消除噪音，降低因为随机噪声带来的影响；其次，以一定的随机算法寻找随机点对 (X_i, Y_i) ，如果 X_i 灰度值小于 Y_i ，那么此点对记为 1，

反之为 0，公式描述如下：

$$\varsigma(X_i, Y_i) = \begin{cases} 1, & \text{if } I(X_i) < I(Y_i) \\ 0, & \text{otherwise} \end{cases}, \quad (2.21)$$

其中 $I(X_i)$ 和 $I(Y_i)$ 分别表示点 X_i 和点 Y_i 的像素值。重复上一步骤 n 次，得到长度为 n 的二进制编码，即特征点的特征描述子 $f_n(O)$ ，其公式描述如下：

$$f_n(O) = \sum_{i=1}^n 2^{i-1} \varsigma(X_i, Y_i), \quad (2.22)$$

其中 $\varsigma(X_i, Y_i)$ 由公式 (2.21) 获得，表示一对像素点的对比结果。在匹配验证时，所有的特征点都以相同的随机算法进行处理，使得每个特征点可以获得一串固定像素点顺序的特征向量。

BRIEF 特征可以描述出特征点附近的灰度变化等信息，将原本的图像变换为向量，大大降低了处理时间。此外，由于在处理前进行了高斯模糊处理，这降低了图像噪声点带来的影响。在进行两个特征点的匹配时，使用汉明距离 [102] 即可完成对二值描述子的度量。

2.2.4 基于网格的运动统计算法

基于网格的运动统计 (Grid-based Motion Statistics, GMS) 算法是 Bian 等人提出的一种实时特征点匹配算法 [103]，其基本思想是使用周围网格的特征点数目对匹配特征点的可信度进行支撑。如图2.4所示，为了增强网格内特征点的匹配效果，此算法使用了九个格子进行特征点的匹配支撑。一对特征点 i 和 j 是否匹配需要依赖于匹配分数 $S_{i,j}$ 的计算，匹配分数使用特征点 i 和 j 所处方格的周围 9 个方格的匹配点总数的总和描述，即公式 (2.23) 所示：

$$S_{i,j} = \sum_{k=1}^{k=9} |X_{i^k j^k}|, \quad (2.23)$$

$|X_{i^k j^k}|$ 表示 i^k 和 j^k 方格的匹配点数目，也就是图中相应格子匹配点的数目。那么两个点是否匹配就可以使用公式 (2.24) 进行描述：

$$pair_{i,j} \in \begin{cases} T, & \text{if } S_{ij} > \alpha\sqrt{n_i} \\ F, & \text{otherwise} \end{cases}, \quad (2.24)$$

其中 $\alpha\sqrt{n_i}$ 表示匹配阈值， α 为系数， n_i 表示网格划分完后第 i 个格子里的特征数目均值。如果当前这对匹配点的匹配分数大于此阈值，则匹配点保留，反之不保留。

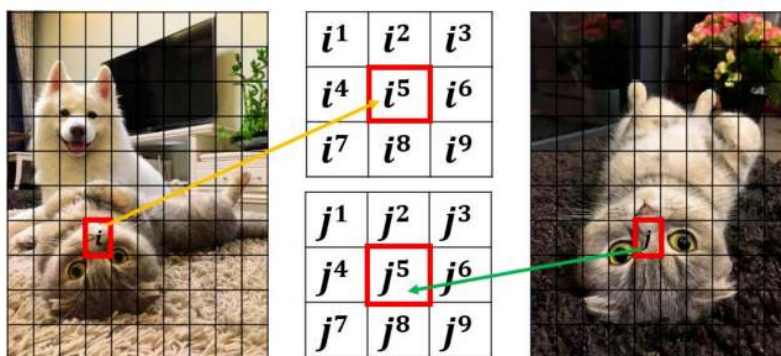


图 2.4: GMS 算法匹配示意图 [103]

2.3 深度学习方法概述

近年来随着深度学习的发展，研究人员发现使用深度学习模型在处理高维数据中的复杂结构时能获得令人满意的效果。大量神经网络模型不断涌现，在图像处理领域出现了如 AlexNet[104]、VGG[105]、ResNet[106]、SegNet[107]、MobileNet[108–110] 等的网络模型。本节详细介绍了经典的卷积神经网络 (convolutional neural networks, CNN) 模型，并对与本论文相关的 MobileNet 网络模型进行了介绍。

2.3.1 经典深度学习网络结构

在图像处理领域，CNN 是最常用的深度学习模型。1980 年，Kunihiko 提出了一种名为“NeoCognitron”的模式识别机制，将人体细胞间的信息传递方式进行了

总结和应用：高阶细胞通常更倾向于选择性的对刺激作出反应，具有更大的“感受野”，并且对刺激位置不敏感 [111]。这是 CNN 的最初灵感来源 [112]。但是由于不能解决“异或”问题，神经网络经历了一段时间的消沉期，1986 年 BP 算法的提出使得 CNN 重获新生 [113]。之后随着 AlexNet 在 ImageNet 大赛上夺冠，掀起了一股 CNN 研究热潮。卷积神经网络与普通神经网络的区别在卷积层和池化层，通过卷积和池化操作使得模型复杂度大大降低，降低了训练的难度和资源占用。

卷积层通过滤波操作对输入的图像进行处理，以提取图像的局部特征 [114]。由于内部执行过程是离散卷积操作，卷积层由此得名。其处理过程如图 2.5 所示，使用卷积核以滑动的方式在图像上计算内积，一次滑动计算得到一个像素点值，将其按处理顺序排放得到了下一层的特征图。卷积层具有两个重要的特性：局部连接和权值共享。局部连接是指在卷积操作时，卷积核常常将相邻区域的信息整合到当前区域上，这使得模型可以学习到更加抽象的高维特征，特征间的位置信息也得以保留。权值共享是指在进行卷积操作时，卷积核内的权值并不会发生改变，并且会与输入图像的所有通道进行卷积计算。这保证了图像中每个像素都有一个权重系数，并且可以不用单独为每一个像素设置参数，这大大降低了模型的参数量。




图 2.5: 卷积层操作示意图 [115]

池化层的作用是将相似的语义特征进行合并 [114]。如图 2.6 所示，经典的池化操作分为最大池化和平均池化两种。最大池化是将特征图中池化窗口中的最大值填入输出特征图的相应位置，通过以设定的步长遍历整张特征图得到处理结果。另一种常见的池化操作是平均池化，与最大池化的不同之处在于处理时是将池化窗口内所有值的平均值填入输出特征图的相应位置。通过池化操作可以大幅降低特征图的

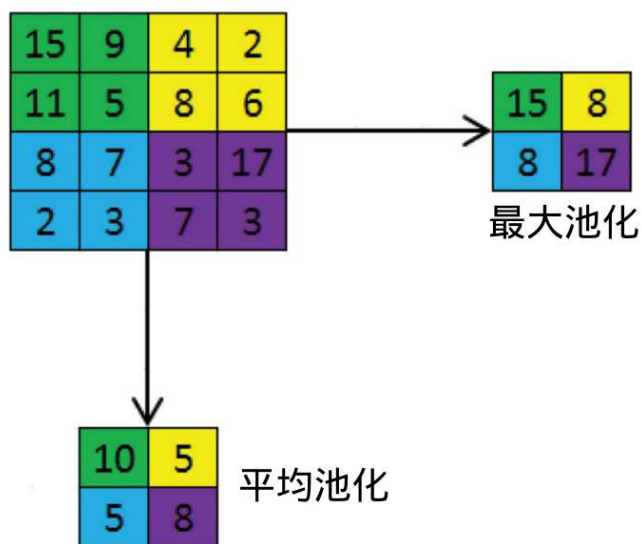




图 2.6: 池化层操作示意图 [115]

维度，提取高层语义信息。




Tanh

$$\text{Tanh}(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}$$




ReLU

$$\text{ReLU}(x) = \max(0, x)$$



ReLU6

$$\text{ReLU6}(x) = \min(6, \max(0, x))$$



h-swish

$$\text{h-swish}(x) = x \frac{\text{ReLU6}(x + 3)}{6}$$

图 2.7: 激活函数示意图

激活层是为了增强网络的非线性拟合能力 [116]。单纯使用卷积池化等操作相当于仅通过线性拟合完成图像或者数据的描述，但真实情况中数据间容易存在非线性的特征排布关系，这就需要引入激活函数完成模型的非线性操作。如图2.7所示，常见的激活函数有 $Tanh$ 、 $ReLU$ 、 $ReLU6$ 、 $h-swish$ 等。 $Tanh$ 函数将输入映射到了 $[-1, 1]$ 区间，在输入趋近于 0 时变化明显，在输入值较大或者较小的时候函数不敏感，并且此函数容易带来梯度消失问题。 $ReLU$ 等函数的出现大大改善了这一问题，在输入大于零时梯度恒定不变，输入小于零时神经元死亡增大网络的稀疏性，通过这种方式大大缓解了梯度消失问题。但在移动端的低精度场景中，由于 $ReLU$ 函数对输出并未有限制，这使得当输入极大时输出可能极大导致无法被描述，使精度损失， $ReLU6$ 的出现解决了这一问题。与 $ReLU$ 相比， $ReLU6$ 增加了限制，函数的最大值被限制在 6 处，即便输入再大输出也可被描述，这避免了精度消失问题。 $h-swish$ 函数是在 $swish$ 函数基础上改进而来， $swish$ 函数与 $ReLU$ 相比更加平滑，在深度学习模型上性能更优，但是在应用在移动端时较为不便，而使用 $ReLU6$ 实现的 $h-swish$ 函数进一步解决了这一问题，大大降低了计算开销。




图 2.8: 全连接层示意图 [115]

全连接层通常位于 CNN 的后几层，作为分类器对前几步获取的特征进行空间映射和处理。其结构如图2.8所示，池化层得到的特征图直接与第一个全连接层中所

有的神经元进行连接，通过多层神经元的计算，输出特征向量，完成对图像类别信息的描述。

2.3.2 轻量级神经网络

MobileNetV3 是谷歌在 2019 年提出的轻量级网络模型 [110]，其使用架构搜索技术完成模型的设计，在基础数据集上获得了较为优秀的分类表现。网络结构结合了 MobileNetV1[108] 的深度可分离卷积 (depthwise separable convolutions)、MobileNetV2[109] 的具有线性瓶颈的逆残差结构 (the inverted residual with linear bottleneck) 以及基于 Squeeze-and-Excitation 结构 [117] 的轻量级注意力模块进行设计，并在一些模块内引入 h -swish 激活函数行设计，最终得到了轻量高效的网络模型。

模型中深度可分离卷积分为深度卷积 (depthwise convolution) 和逐点卷积 (pointwise convolution) 两部分，处理流程如图2.9所示。其中深度卷积是对每一个特征图通道只使用一个卷积核处理，通过拼接所有卷积核的输出得到最终结果。逐点卷积可以使得模型对输出通道的数量进行把控，通过使用与特征图相同通道的 1×1 卷积融合了通道信息，卷积核的数目决定了输出特征图通道数，经过处理得到最终的特征图。这一结构使得卷积核的数目大大降低，相比于常见的卷积操作，大大降低了模型的参数量和计算成本。

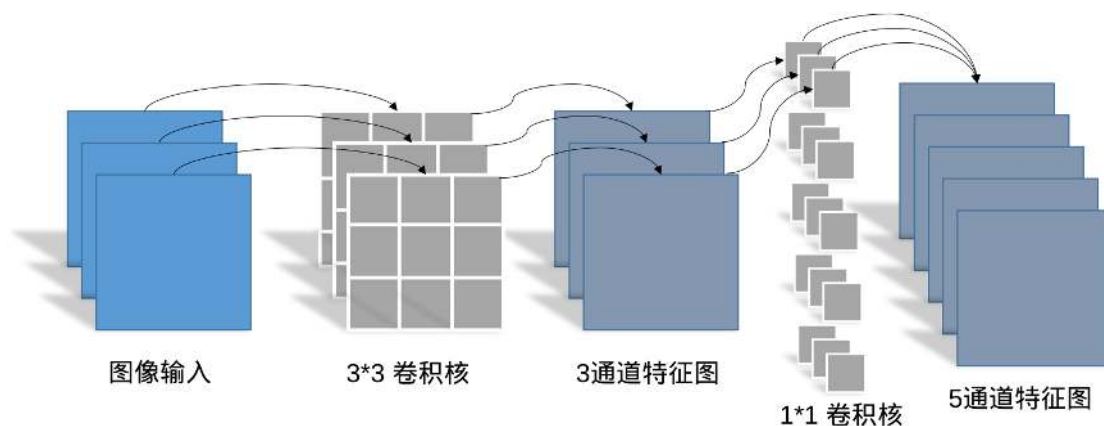


图 2.9: 深度可分离卷积模块示意图

线性瓶颈的逆残差结构如图2.10所示。首先，模型使用 1×1 卷积实现升维，利用 3×3 的深度卷积提取特征，最后通过 1×1 的卷积结构实现降维，这使得模型可以在高维空间提取更多的信息。残差结构的引入确保了信息的完整性。线性瓶颈结构则是在最后的 1×1 卷积结构中使用线性激活函数进行处理，使得特征在降维时尽可能保留特征信息。相比于常见的深度学习模型，该结构的引入使得模型并没有产生较大的中间张量，大大降低了模型的内存占用。

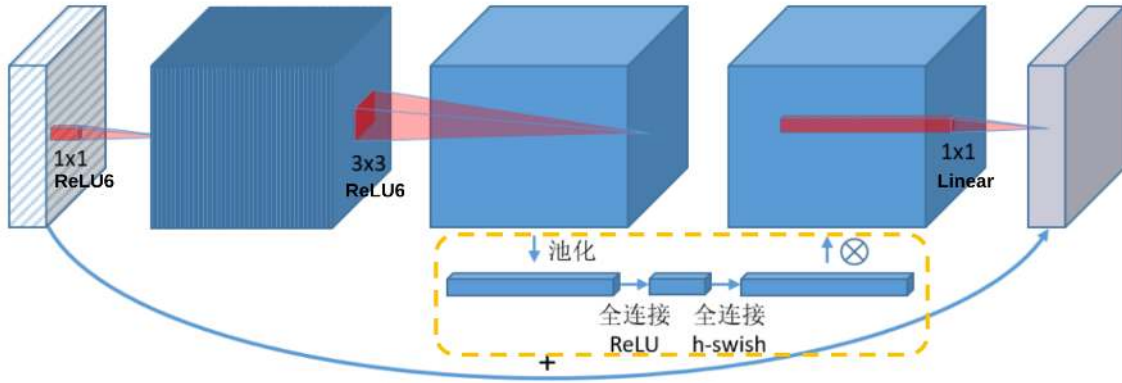


图 2.10: MobileNetV3 的基础模块示意图

Squeeze-and-Excitation (SE) 结构是 Hu 等人提出的一个轻量级注意力模块 [117]，用在图2.10中的橙框部分。此模块通过考虑特征图不同通道间的关系来增强模型的学习能力。模块内分为压缩和激励两个步骤，来完成全局信息的嵌入和通道关系自适应学习。压缩的过程如公式 (2.25) 所示：

$$z_c = \frac{1}{H \times W} \sum_{i=1}^H \sum_{j=1}^W x_c(i, j), \quad (2.25)$$

其中 x_c 表示输入特征的第 c 个通道特征图， H 和 W 表示一个通道的特征图长宽， z_c 表示每个通道的一个全局信息。激励过程如公式 (2.26) 所示，

$$\hat{X} = X \cdot \sigma(F_2(\text{ReLU}(F_1(z)))), \quad (2.26)$$

公式中 F_1 和 F_2 表示全连接层， ReLU 和 σ 表示激活函数， z 表示提取出的整个特征图所有通道经过压缩过程得到的特征向量，即所有通道的 z_c 组成的向量，得到的 \hat{X} 包含了通道间关系信息。

2.4 评价指标概述

针对二分类模型，可以使用 N 和 P 表示实际结果和预测结果，使用 T 和 F 表示预测正确和错误。将其两两组合可以获得如表2.1所示的混淆矩阵。

表 2.1: 二分类问题存在的四种情况混淆矩阵

	标签为真	标签为假
预测为真	TP	TN
预测为假	FP	FN

基于以上混淆矩阵，常用的评价指标有重叠度 (IOU)、精确率 (precision)、召回率 (recall)、F1 分数 (F1-score)、准确率 (accuracy) 等。其描述如下：

(1) 重叠度:

$$IOU = \frac{TP}{FP + TP + FN}, \quad (2.27)$$

重叠度是分割问题的常用度量指标，其测量给出了图像中目标对象的预测区域和真实区域之间的相似性。

(2) 精确率:

$$precision = \frac{TP}{TP + FP}, \quad (2.28)$$

精确率是针对预测结果而言的，其显示了预测结果中准确预测部分的比例，其值越高，模型性能越好。

(3) 召回率:

$$recall = \frac{TP}{TP + FN}, \quad (2.29)$$

召回率是针对原样本而言的，其显示了所有样本中正例被预测正确的比例，值越高模型性能越好。

(4) F1 分数:

$$F1 - score = \frac{2 * precision * recall}{precision + recall}, \quad (2.30)$$

一般希望精确率和召回率两者都尽可能很高，但事实并非如此，两者总是相互影响，此消彼长。F1 分数通过结合两个评价指标，提供了一个更加综合性的判断。

(5) 准确率:

$$accuracy = \frac{TP + TN}{TP + FN + FP + TN}, \quad (2.31)$$

准确率显示了预测正确的结果占所有样本的比例。

此外，本论文还使用了一些其他的评价指标，如编码容量，每秒浮点运算次数，模型参数量，模型内存占用等。其描述如下:

(1) 编码容量:

编码容量是度量防伪标签中信息的一种方式，是防伪标签检测中较为重要的一项指标。该计算方式由 Carro-Temboury 等人 [118] 提出，公式描述如下:

$$Capacity = \left[C(1 + L(\frac{1}{\sqrt{D}} - 1))^2 + 1 \right]^{D \frac{R^2}{L^2}}, \quad (2.32)$$

其中 C 表示除去背景部分的颜色层级， L 表示标签的像素长度， R 表示标签部分在实际环境中的长度， D 表示标签图案在图像中的密度。通过本公式可以计算出防伪标签的信息承载量。

(2) 每秒浮点运算次数:

在深度学习模型中，卷积、池化、激活函数等操作都需要消耗算力，本论文使用每秒浮点运算次数 (floating-point operations per second, FLOPs) 进行计算量的度量，这可以很好的衡量算法或者模型的复杂度。

(3) 模型参数量以及内存占用:

神经网络的参数量直接决定了模型的大小，直接影响模型推断时间和性能。内存占用是指模型运行时，所占用的内存或显存的大小。这两项性能影响到模型是否实用，关乎算法的落地。在相同准确率下，如果模型参数量越小，内存占用越低，那模型效果越好。

2.5 本章小结

本章首先介绍了复杂网络理论,同时对复杂网络理论中的相关特性进行了解释。接着对本论文中使用的聚类算法、形状空间理论、ORB 算法以及 GMS 算法等传统图像处理方法进行了介绍,并详细阐述了其原理和实现步骤。然后对经典的深度学习模型进行了介绍,并对本论文中使用的轻量级神经网络进行了回顾,并详细介绍了网络中的不同模块以及模型轻量化的原因。最后对本论文中使用的相关评价指标进行了描述。

第三章 基于复杂网络理论的复杂纹理特征处理方法

近年来，伴随着复杂网络研究的热潮，复杂网络理论在处理图像中所体现出来的优势逐渐显现。研究人员发现利用复杂网络可以结合图像局部性质和整体性质，为图像处理提供更加全面的信息，这一研究被应用在轮廓识别、纹理分析等方面。此外，复杂网络中的社区结构是重要的拓扑结构属性之一，它揭示了复杂网络中隐藏的规律和行为特征。社团内部节点之间的联系非常紧密，而社区之间的联系则相对比较稀疏。这与复杂材料图像中不同物相的分布相类似，将其与图像分割相关联、利用社区信息对复杂材料图像进行处理能取得意想不到的效果。为此本章利用复杂网络思想来对图像进行特征信息处理，通过设置网络的参数来对复杂网络进行动态演化，最后通过社区结构来描述复杂图像的不同物相分布，以完成对复杂纹理图像的分割任务。

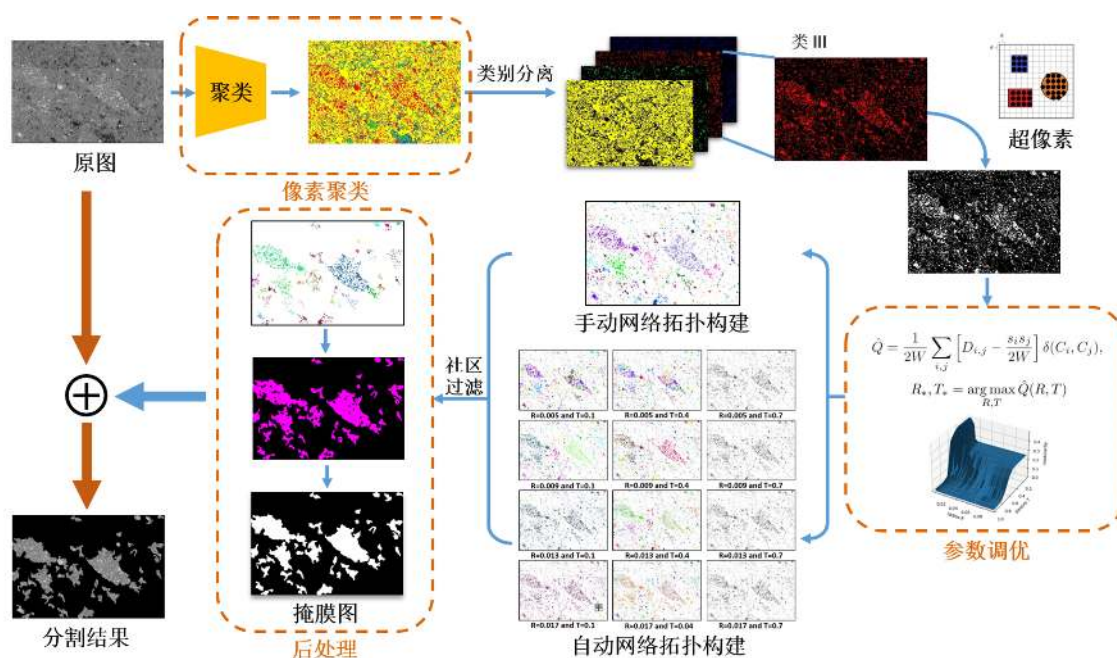


图 3.1: 方法流程图

3.1 方法概述

本方法分为预处理、网络拓扑构建、网络拓扑优化和图像分割四个部分，如图3.1所示。首先，利用像素聚类获取图像的粗粒度分割结果，并通过类别分离完成物相的初步分离；其次，利用网格划分超像素，以此构建复杂网络节点，基于节点的连接方式设置距离阈值 R 和密度阈值 T 两个参数，构建网络拓扑；然后，利用 RT -模块度函数对社区进行评价，划分社区结构，其中模块度参数 R 和 T 可以手动或自动选择；最后，将得到的社区结构覆盖在原始图像中，经过处理得到最终的分割结果。

3.1.1 图像预处理

本章的材料图像预处理包括两个步骤：聚类和网络节点构建。聚类是一种无监督的学习方法，它可以根据像素值的分布进行处理，常用的聚类方法有 K-means[119]、DBSCAN[120]、Meanshift[121]。在这里，采用简单高效的 K-means 算法对复杂图像中不同的像素进行提取，获得粗粒度分割结果。如图3.2所示本论文利用 K-means 方法对微观结构图像中的四个类别簇进行了提取。

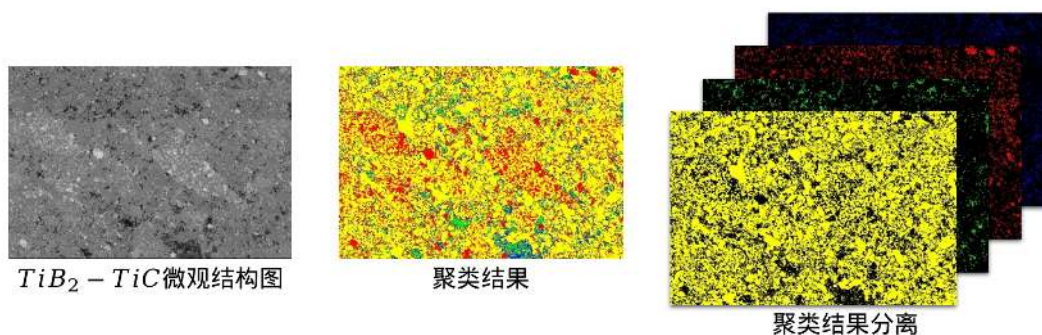


图 3.2: 聚类结果示意图。显微结构包含 4 种相，分别为白色、灰白色、深灰色、黑色，通过聚类可对其进行分离。

定义网络节点的目的是为了为了更好的构建网络拓扑结构。常用的节点构建方法是将每个像素定义为一个节点，但这样得到的节点的数量较大，无法有效构建复杂网络的结构。特别是对于高分辨率的图像，这种构建方式在网络计算时需要较大的计

算量、执行时间以及内存存储。例如， 512×512 像素的图像包含 262144 个节点，构造邻接矩阵时计算量为数百亿。为了降低执行成本，从图像中提取超像素来替换聚类结果图像中的像素，这样复杂纹理的图像可以使用超像素构建的网络进行描述。网络上的一个单元即为一个超像素，也就是网络的一个节点。具体处理步骤如下：

- 1) 在聚类结果图像中划分网格。网格上单元的大小为 $d \times d$ ， d 的值取决于图像分割的要求，它决定了图像分割的精确度。 d 越小，精确度越高。如果 $d = 1$ ，则超像素退化成一个基本像素。
- 2) 利用阈值确定网格单元是否可以作为网络节点。一个单元可能包含不同物相的像素，它是否可以被标记为一个节点取决于单元中感兴趣区域的像素数量。本论文设置一个阈值系数 ε 来决定这个单元是否是一个节点，如果感兴趣区域的像素数量大于 $\varepsilon(d \times d)$ ，则该单元被标记为一个节点。
- 3) 使用网格单元确定节点信息。将单元中心点像素的坐标 (x_i, y_i) 视为节点的坐标，节点定义为 v_i 。

3.1.2 网络拓扑构建

复杂网络的结构被描述为一个图 $G = (V, E)$ ，包括两类元素： V 和 E 。 $V = \{v_1, v_2, \dots, v_n\}$ ，其中 v_i 是一个节点，它是通过上一节所述方法获得的超像素单元。 $E = \{e_{v_i, v_j}, \dots\}$ 表示节点 V 之间的边。本论文参考 Machado 等人 [122] 所述的网络构建方法，利用节点间的欧几里德距离和节点的强度信息构建网络拓扑。因为节点 V 在欧几里德空间中，所以采用欧几里德距离来计算 E 。节点 v_i 和 v_j 之间的欧几里德距离计算如下：

$$d_{v_i, v_j} = \sqrt{(x_i - x_j)^2 + (y_i - y_j)^2}. \quad (3.1)$$

为了消除不同图像指标的量纲之间的影响，在这里对距离进行归一化处理，将 d_{v_i, v_j} 归一化到区间 $[0, 1]$ 内，其公式描述如下：

$$\hat{d}_{v_i, v_j} = \frac{d_{v_i, v_j}}{\Delta}, v_i, v_j \in V, \quad (3.2)$$

其中 Δ 是 V 中节点间距离的最大值, 即 $\Delta = \max(d_{v_i, v_j}), v_i, v_j \in V$ 。

并不是所有的 E 都参与了网络的构建, 根据欧几里德距离只选择了其中的一部分。欧几里德距离越近, 对应的两节点就越有可能在一个社区中。相反, 如果距离较远, 则两个节点可能被划分为两个不同的社区。基于此, 本论文定义了一个参数 R 作为阈值来区分这些欧几里德距离。如果节点 v_i 和 v_j 之间的归一化距离不大于 R , 那么 v_i 和 v_j 是连通的; 否则, v_i 和 v_j 不连通。通过以上方式, 本论文计算两个节点 v_i 和 v_j 之间的权重 e_{v_i, v_j} 以估计两个节点的相似度, 定义如下:

$$e_{v_i, v_j} = \begin{cases} R - \hat{d}_{v_i, v_j}, & \text{if } \hat{d}_{v_i, v_j} \leq R \\ 0, & \text{otherwise} \end{cases}. \quad (3.3)$$

显然, 权重 e_{v_i, v_j} 与 \hat{d}_{v_i, v_j} 成反比。固定 R , \hat{d}_{v_i, v_j} 越大, e_{v_i, v_j} 越小。如果 \hat{d}_{v_i, v_j} 大于 R , 则 v_i, v_j 两个节点之间没有边连接。通过这种方式, 构建了初始网络拓扑结构。

e_{v_i, v_j} 描述了两个节点 v_i 和 v_j 之间的相似性, 但不能描述社区的节点聚集信息。对于网络中密度不同的两个社区, 紧凑社区中节点的相似性大于松散社区中的节点。为了衡量复杂网络中整个社区的紧凑性, 本论文基于 e_{v_i, v_j} 定义了节点的密度 $d_e(*)$, 其公式计算如下:

$$d_e(v_i) = \frac{s(v_i)}{k(v_i)}, \forall v_i \in V, \quad (3.4)$$

其中

$$k(v_i) = \sum_{v_j \in V} \begin{cases} 1, & \text{if } e_{v_i, v_j} \in E \\ 0, & \text{otherwise} \end{cases}, \quad (3.5)$$

$$s(v_i) = \sum_{v_j \in V} \begin{cases} e_{v_i, v_j}, & \text{if } e_{v_i, v_j} \in E \\ 0, & \text{otherwise} \end{cases}, \quad (3.6)$$

$k(v_i)$ 和 $s(v_i)$ 分别是节点 v_i 的度和强度。换句话说, $k(v_i)$ 表示 v_i 邻居节点的数量, $s(v_i)$ 是所有与节点 v_i 连接边的权重之和。 $d_e(v_i)$ 越大, 节点越密集, 越有可能在同一个社区中。在实验所用的陶瓷图像中, $d_e(v_i)$ 在 0 至 0.007 之间波动, 大部分节

点的密度集中在 0.003 左右。为了简化计算，在这里将密度归一化到区间 $[0, 1]$ 内，其公式如下所示：

$$\hat{d}_e(v_i) = \frac{d_e(v_i)}{D_e}, \forall v_i \in V, \quad (3.7)$$

其中 D_e 是节点密度的最大值，即 $D_e = \max(d_e(v_i)), v_i \in V$ 。 $\hat{d}_e(v_i)$ 可以衡量 v_i 与其邻居之间的紧凑性，通过连接紧凑的节点得到紧密连接的网络拓扑。为了优化网络拓扑，本论文引入了密度阈值 T ，网络权重进一步优化，最终的权重计算如下公式所示：

$$\hat{e}_{v_i, v_j} = \begin{cases} e_{v_i, v_j}, & \text{if } \hat{d}_e(v_i) \geq T \text{ and } \hat{d}_e(v_j) \geq T \\ 0, & \text{otherwise} \end{cases}. \quad (3.8)$$

通过以上方式对网络内的结构进行设计，使得 \hat{e}_{v_i, v_j} 不仅受节点距离阈值 R 的影响，还受节点密度阈值 T 的影响。通过 \hat{e}_{v_i, v_j} 构建的网络拓扑可以描述两个节点是否在同一个社区中，即如果两个节点间存在通路，那么两节点在一个社区中。此外，社区的部分边界也可以用 \hat{e}_{v_i, v_j} 来计算。如果一个节点的密度高而相邻节点的密度低，那么高密度的节点就有可能在边界上。这样就可能找到高密度区域的部分轮廓，如图3.3中黄色点所示。此外，如果两个节点都是低密度的，那么它们是离散点或噪声，即它们不是连通的。图3.3中描述了三种连接类型。

由公式 (3.2) 到 (3.8) 可以对具有复杂纹理的图像构建网络拓扑。其中变量 R 和 T 是构建最优网络的两个关键参数。本论文将在下一节详细讨论它们。

3.1.3 网络拓扑优化

网络拓扑的构建直接取决于两个阈值 R 和 T ， R 控制节点的连接域， T 衡量节点与邻居之间的紧凑性。对于一个节点 R 距离内的节点，如果它们的密度大于 T ，那么它们就连接到该节点。考虑极端的特殊情况，如果 R 小而 T 大，则所有节点都是孤立的，网络中不存在边；如果 R 大而 T 小，则网络变成完全连通图。随着 R 和 T 的变换，网络结构从孤立的节点图变为全连通的图。不同 R 和 T 的值可以构建不同的网络拓扑。在一个好的网络拓扑中，社区内的连接是紧密的，而社区之间的连接是稀疏的。本论文认为同一个社区的节点是相互连通的，不同社区的节点




图 3.3: 网络中节点之间存在三种类型的连接。(a) 代表节点密度高的社区;(b) 代表节点密度低的社区。红色部分为孤立节点,黄色部分为边界节点,蓝色部分为社区内其他节点。图中虚线表示两个节点之间没有连接。如果两个节点的密度很高,那么它们将紧密相连,如图中实线所示,实线连接的节点形成社区。

可能是不连通的,由此来划分社区。当参数发生变化时,会得到不同的社区分割结果。本论文可以手动调整 R 和 T 来找到合适的网络结构,但这对于大量图像的处理是十分困难的。为了可以更好的进行自动化图像处理,本论文提出了新的模块度函数来自动的计算最优社区结构,从而获得最佳的网络拓扑。

对一张图像而言,可能存在的网络拓扑结构数量是巨大的,这是一个以节点数目为指数的数。模块度可以评估网络拓扑中社区划分的质量,但计算过程需要不断地合并社区,以寻找最优社区划分结果,这个计算的过程是多项式复杂程度的非确定性问题,即 NP-hard 问题 [123]。为了减少计算量,本论文在公式 (3.3) 和公式 (3.8) 引入欧几里德距离阈值 R 和节点密度阈值 T , 得到 e_{v_i, v_j} 和 \hat{e}_{v_i, v_j} , 以此提出了一个新的模块度来获取最优的分割结果,如公式 (3.9) 所示,本论文称之为 RT -模块度。其中 R 用于构造初始网络拓扑, T 通过引入密度信息来进一步优化网络拓扑,最终的模块度函数 \hat{Q} 利用经过 R 和 T 共同优化的社区网络来进行计算,其定

义如下:

$$\hat{Q} = \frac{1}{2W} \sum_{i,j} \left[D_{i,j} - \frac{s_i s_j}{2W} \right] \delta(C_i, C_j), \quad (3.9)$$

其中 C_* 表示社区。 W 表示网络中所有边的权重之和, 定义如下:

$$W = \frac{1}{2} \sum_{i \in N} \sum_{j \in N} w_{v_i, v_j}, \quad (3.10)$$

w_{v_i, v_j} 是初始网络拓扑中两个节点之间的权重, 描述如下:

$$w_{v_i, v_j} = \frac{e_{v_i, v_j} - \min(e_{v_i, v_j})}{\max(e_{v_i, v_j}) - \min(e_{v_i, v_j})}. \quad (3.11)$$

公式 (3.9) 中的 $D_{i,j}$ 利用初始网络拓扑中的权重矩阵计算:

$$D_{i,j} = \begin{cases} w_{v_i, v_j}, & \text{if } e_{v_i, v_j} > 0 \\ 0, & \text{otherwise} \end{cases}. \quad (3.12)$$

公式 (3.9) 中的 s_i 表示初始网络拓扑中 v_i 的所有连接边的权重之和, 定义如下:

$$s_i = \sum_{j \in N} w_{v_i, v_j}. \quad (3.13)$$

公式 (3.9) 中 $(s_i s_j)/2W$ 表示初始网络中节点 v_i 和 v_j 之间权重的期望值。 $\delta(C_i, C_j)$ 是狄利克雷函数, 定义如下:

$$\delta(C_i, C_j) = \begin{cases} 1, & \text{if } \hat{e}_{v_i, v_j} > 0 \\ 0, & \text{otherwise} \end{cases}, \quad (3.14)$$

其中 \hat{e}_{v_i, v_j} 表示经过 R 和 T 过滤的合理的边。如果 \hat{e}_{v_i, v_j} 大于 0, 则证明节点 v_i 和 v_j 属于同一个社区。

当前社区结构与初始网络结构之间的差异可以用公式 (3.9) 计算, 随着 R 和 T 的变化, 模块度的值也在不断变化。通过公式 (3.15) 搜索 \hat{Q} 的最大值可以计算出最优参数 R_* 和 T_* :

$$R_*, T_* = \arg \max_{R, T} \hat{Q}(R, T). \quad (3.15)$$

不同 R 和 T 值的选取, 可以获得不同的社区结构, 使得 \hat{Q} 的值也存在一定的差异。因此, \hat{Q} 可以量化社区划分的好坏, \hat{Q} 越大, 也就是自变量越接近 R_* 和 T_* 处, 社区分割最为合理。




图 3.4: 后处理流程图。(a) 按区域面积筛选小社区；(b) 通过计算节点间的欧氏距离和最短路径重构网络拓扑结构；(c) 通过轮廓检测和孔洞填充算法获取掩膜图片；(d) 通过边界检测直接从拓扑得到轮廓；(e) 将掩膜图像叠加在原图像上获得分割结果；(f) 将轮廓叠加在原始图像上获得轮廓描述。

3.1.4 图像分割与边界获取

图像中物体的轮廓包含很多信息，可以用来分析物体的属性。例如，轮廓可以间接表示不同材料的聚集状态。通过上一节本论文可以获取最佳的网络拓扑结构，那么材料的物相轮廓可通过如图3.4所示步骤进行分割。首先，去除可能被认为是噪声的小社区结构；然后，利用节点间的欧几里德距离和网络内的最短路径 [92] 两个值来重构社区结构；最终边界从重构的网络结构中获得。如果两个节点之间的欧几里德距离（橙线）小于阈值 D_s ，并且两个节点之间的最短路径（蓝线）步数小于阈值 P_s ，则同一社区中的两个节点直接相连。分割时，将节点间的新边输入到网络结构中，构建更准确合理的网络结构，网络拓扑结构的最外层轮廓即为物相边界，如图中红线所示。本论文将最终的社区拓扑结构作为掩膜图像覆盖在原始图像上，得到

图像分割结果，其数学描述如公式 (3.16) 所示，

$$I(i, j) = \begin{cases} I(i, j), & \text{if } I_m(i, j) = 1 \\ 0, & \text{otherwise} \end{cases}, \quad (3.16)$$

其中 $I(i, j)$ 表示原始图像中点 (i, j) 处的像素值，0 表示此像素为背景， $I_m(i, j)$ 表示了掩膜图像的前景，即原始图像中的待分割目标区域。

3.2 实验分析

为了方便展示，本论文选择 $TiB_2 - TiC$ 复相陶瓷的图像来测试和验证所提出的方法。二硼化钛 (TiB_2) 是超高温陶瓷材料，由于其具有高熔点、高硬度、低密度等优点而常常被用在装甲材料、耐磨元件、导电涂料中 [124]。单项的 TiB_2 具有抗氧化性差、易断裂等缺陷，而多项材料复合的方式为这一材料带来新的生机，通过研究发现通过向其中掺杂一定的 TiC 可以增强其韧性和抗氧化性，有助于提升 TiB_2 材料的力学性能 [125]。而不同材料间的掺杂由于工艺、环境等因素的影响，往往使得材料性能不能尽如人意。因此从材料中获取图像，对各物相进行分割，进而优化制备工艺是及其有价值的一项研究。

本章使用复杂网络对此类具有复杂纹理材料图像进行特征信息处理，通过动态演化方式寻找最佳特征描述的网络拓扑结构，以此验证所提方法在材料图像分割上的性能。所有实验均在 Intel(R) Core(TM) i7-10700 CPU 2.9GHz*16 和 32G RAM 的计算机上执行。

3.2.1 图像预处理与网络社区构建

如图3.5中 $TiB_2 - TiC$ 复相陶瓷微观结构图所示，深灰色表示 TiB_2 的相位区域，而灰白表示 TiC 的相位区域。任何一个小区域几乎都包括深灰色和灰白色区域，两者在不同区域分布不均。本论文使用如下方法进行图像的预处理和网络构建：首先，根据领域知识，采用3.1.1节中提到的方法将聚类参数设置为 4，获得粗粒度像素聚类结果；其次，针对粗粒度像素聚类结果的 TiC 的相位区域确定网络节点，

网格大小设为 $d = 3$ ，节点选取阈值为 $\varepsilon = 2/3$ ；然后，使用3.1.2节中的方法构建网络拓扑；最后，通过调整参数 R 和 T 得到不同的社区划分。如图3.5所示，在社区划分图中不同的颜色代表不同社区。如果 T 固定， R 增加，则网络拓扑的范围变大；如果 R 固定， T 增加，则网络拓扑的连接变得分散。




图 3.5: 网络拓扑构建效果示意图

3.2.2 模块度分析

为了可以描述 R 和 T 参数与模块度 \hat{Q} 之间的关系，本章使用公式(3.15)进行模块度的计算，绘制出曲面如图3.6所示。 \hat{Q} 曲面上最大值的自变量，即 R_{max} 和 T_{max} ，被认为是最优参数。 R 和 T 的范围分别根据经验设置 $[0.001, 0.099]$ 和 $[0.1, 1.0]$ ，最终计算出的模块度的所有点都分布在一个曲面上。本章选择了六个点来描述在不同的 R 和 T 时的分割结果。当模块度较小时，如 $R = 0.003$, $T = 0.9$; $R = 0.047$, $T = 0.9$; $R = 0.041$, $T = 0.2$ 和 $R = 0.073$, $T = 0.6$ ，由于 R 过小或者 T 过大导致社区不是最优状态，致使分割结果很差。当 $R = 0.008$, $T = 0.3$ 时，模块度值高，社区划分合理，分割结果较优。当 $R = 0.003$ 和 $T = 0.1$ 时，虽然取得了较高的模块度值，但 R 较小，密度大的节点汇聚成了较小的社区，这使得算法的感受野变小，不能展现图像中物相的全局分布，最后通过后处理发现这样对图像的分割效果不是很好。

为此，本章验证了最佳的 R 区间，尝试寻找适用于不同图像的参数范围。通过实验发现，如果 R 太小，社区会被划分为更小的社区，社区划分无法根据模块度的标准进行评判。为了寻找最优适用区间，本论文选取不同的材料图像（如 TiB_2-TiC 复相陶瓷和钢 [126]）进行处理，通过分析发现在 R 大于 0.008 时，模块度可以用

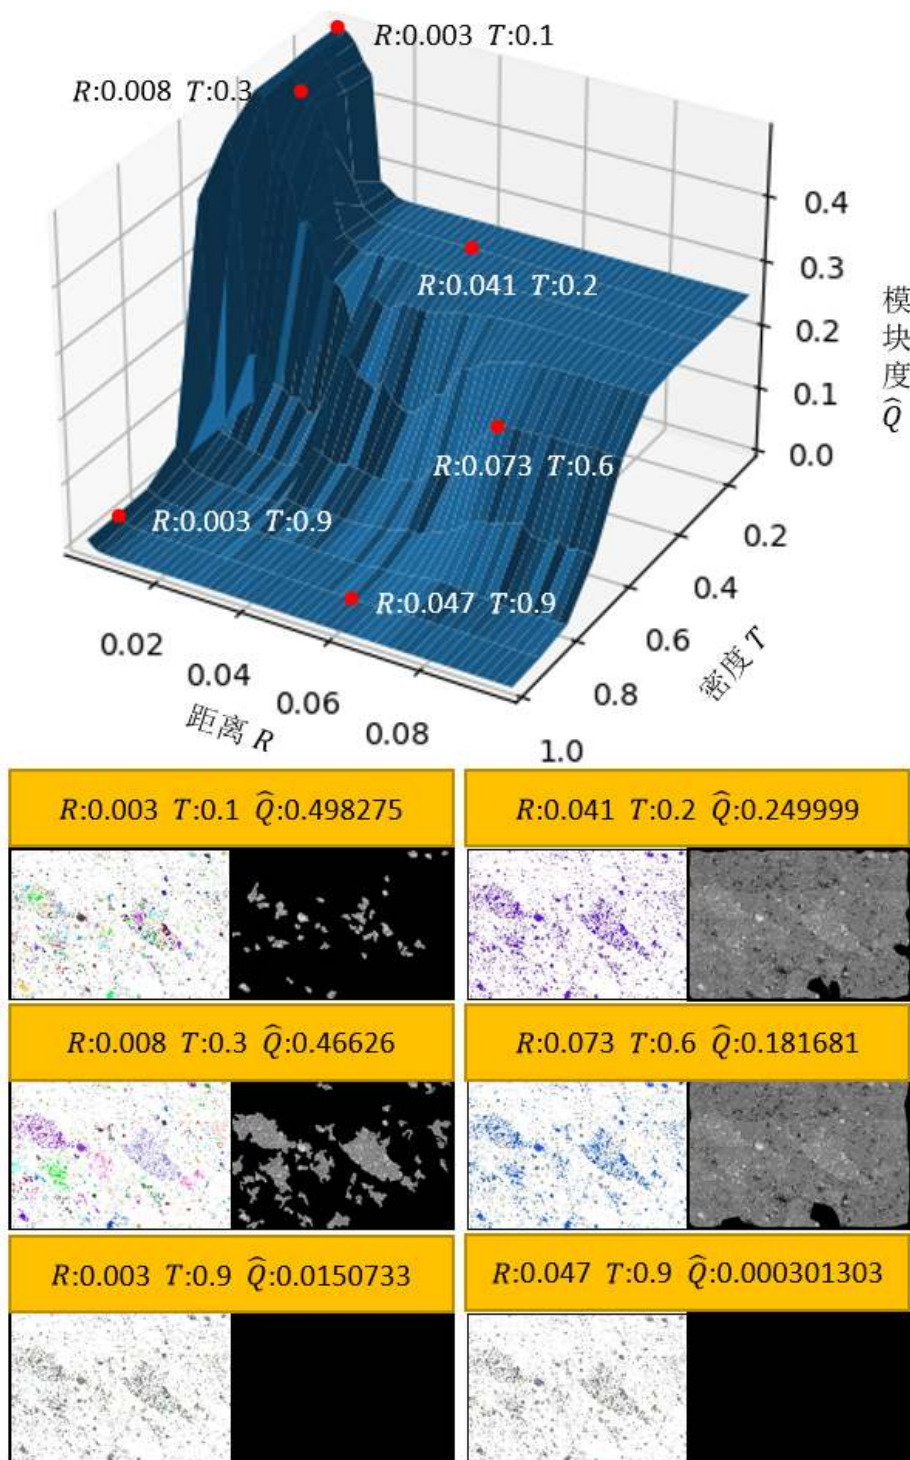


图 3.6: 不同 R, T 值对模块度和分割结果的影响示意图。上部的曲面图展示了不同 R, T 与模块度 \hat{Q} 之间的关系, 本论文截取了六个点进行了展示, 每个点的处理结果在下部进行了展示, 左侧为社区划分图, 右侧为分割结果图。

来作为图像的分割好坏的评价指标。如图3.7所示，以 T 为常数 0.3 为例，橙色标记的区间，也就是 R 处于 $[0.008, 0.03]$ 时社区划分可以带来较好的分割结果。当模块度值落在区间内时，模块度可以满足值越大，分割结果越好的趋势。通过对本图的实验发现，适用于当前图片的最优参数是 $R = 0.008$ ， $T = 0.3$ 。

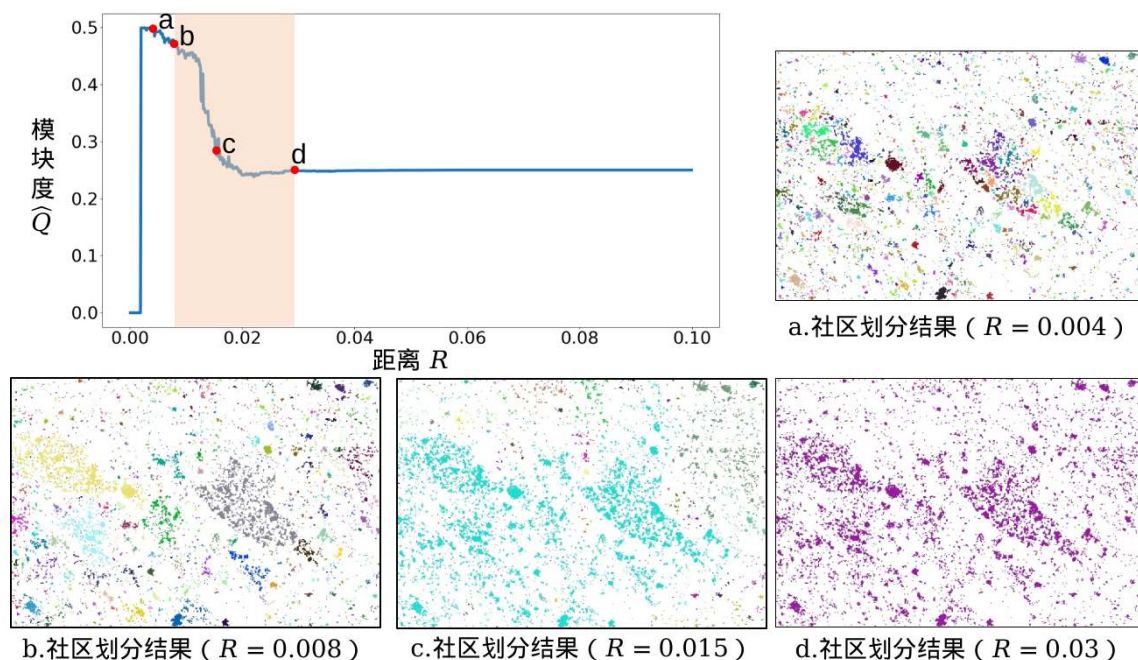


图 3.7: 社区分割结果以及 R 方向模块度切片图。其中 T 固定为 0.3，社区划分结果中不同颜色表示不同社区。

3.2.3 相关方法对比

在材料图像中，不同物相之间关系影响到材料的力学性能，准确对其进行分割可以为新材料的研发带来一定的推动作用。本论文选取了几类材料图像进行处理，如图3.8所示，其中包括陶瓷、共晶化合物和钢铁图像，第一张显示了对 TiB_2-TiC 复相陶瓷图像的分割结果，第二、三、四张图像显示了不同方法对共晶化合物 HfB_2-B_4C 图像中缺损组织的分割效果，后四张显示了不同方法对钢数据 [126] 中网状碳化物的分割效果。

为了说明本方法分割的有效性，本节将本论文的方法与 FCM 方法 [127]、基于图的方法 [41]、Han 等人的方法 [10]、FCN 方法 [128]、UNet++ 方法 [129]、R2U-Net




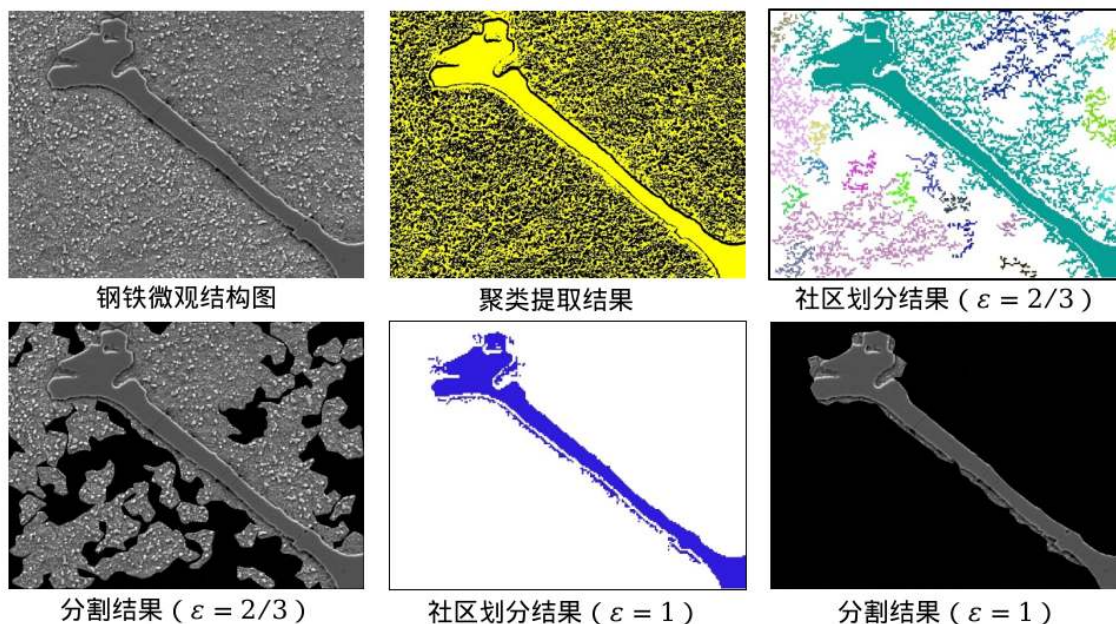
图 3.8: 在陶瓷图像、共晶化合物和钢铁数据中与其他方法的比较结果。第一行是原始图像；第二行是手工标注的图像；第三到第十行是 FCM 方法、图割法、Han 等人的方法、FCN 方法、UNet++ 方法、R2U-Net 方法、SegNet 方法和 LPCN 方法的结果；第十一行是本论文方法的实验结果。

方法 [130]、SegNet 方法 [107] 和 LPCN 方法 [131] 进行了比较。实验结果如图3.8和表3.1所示，从图中可以看出，由于社区构建和过滤，分割结果中存在着更少的噪声点。此外，从表中可以看出本论文的方法在重叠度、召回率、F1 分数和准确率等评价指标上表现更好。面对小样本数据，深度学习方法很难学习到高质量的样本的特征，这使得预测结果偏向于利用低阶特征进行处理和分割，例如颜色、灰度等。如表中 FCN 和 UNet++ 的结果所示，这降低了样本预测出错的概率，可以达到更高

的精度，但也带来了相应的缺陷，即召回率低使得其他参数表现平平。LPCN 是基于手动划线和图的分割方法，对于标注的正例样本具有较好的鲁棒性，但结果中存在较多的假正例，这使得召回率虽高但其他评价指标一般。综合以上来看，本论文的方法可以获得更平衡的效果。

表 3.1: 各方法平均评价结果的比较

	重叠度	精确率	召回率	F1 分数	准确率
FCM	0.2452	0.2698	0.7899	0.3797	0.6781
图割法	0.5384	0.7117	0.6913	0.6842	0.9146
Han 等人的方法	0.1694	0.2373	0.6489	0.2699	0.5344
FCN	0.5734	0.8001	0.7178	0.6891	0.8718
UNet++	0.5545	0.8312	0.6423	0.6839	0.9078
R2U-Net	0.4291	0.7040	0.6092	0.5816	0.8785
SegNet	0.4010	0.6248	0.6317	0.5314	0.8240
LPCN	0.6113	0.6377	0.9427	0.7469	0.9286
本文方法	0.6675	0.7536	0.8666	0.8130	0.9334

图 3.9: 节点选取参数 ϵ 对社区划分和分割结果的影响

此外, 在3.1.1节提到的超像素节点构建阈值参数 ε 也会影响分割结果, 其大小影响到复杂网络的节点的确定。图3.9中显示了不同取值对社区划分结果和分割结果的影响。由于每个区域内都分布有较多的超像素节点, 构建出的网络拓扑结构很难对材料内各物相进行描述。因此使用之前的 $2/3$ 阈值得到的分割结果中存在较多的社区, 这也导致最后的分割结果效果较差。为了解决这类问题, 本方法将 ε 从 $2/3$ 调整到 1 , 以减少超像素节点的数量, 得到结果如图3.9中 $\varepsilon = 1$ 的图像所示, 可以明显看到分割精度的提升。

3.3 本章小结

本章针对具有复杂纹理的材料图像, 提出了一种基于复杂网络的图像处理方法。本方法分四个步骤: 第一步对图像进行初步处理, 获取超像素以构建复杂网络的节点; 第二步, 利用两个参数 R 和 T 构建网络拓扑; 第三步, 通过复杂网络的动态演化获取不同的网络拓扑结构, 利用 RT -模块度函数对复杂网络进行社区评价, 选取最佳网络拓扑; 第四步, 通过处理社区信息和网络拓扑信息获取最终分割结果。本章所提出的方法有如下三方面的贡献: 首先, 本方法利用复杂网络帮助发现复杂纹理的图像的内在属性, 以检测材料图像中的不同物相; 其次, 本方法提出了一种新的模块度函数 (RT -模块度) 来评价复杂网络中的社区构建; 最后, 本方法优化了最优社区划分的计算过程, 将模块度计算的 NP-hard 问题转化为两个参数优化的问题, 减少了处理时间, 有助于更准确地分割目标区域。

通过实验验证发现, 该方法可以描述不同类型纹理的更准确边界, 对具有复杂纹理的材料图像十分有效。但是在此方法中最优参数只能通过网格遍历获取, 较为笨重繁琐, 且处理时间较长。此外, 所提方法没有利用图像的像素语义信息来帮助图像处理。这是未来工作中需要解决的问题。

第四章 基于传统方法的薄膜图案特征处理

针对复杂材料图像的处理，除了利用复杂网络特性进行图像的特征描述和处理外，当下最常用的依旧是利用传统图像处理方法进行处理。基于传统图像处理技术的方法没有复杂网络方法中的网络拓扑构建和动态演化等步骤，这可以大大加速特征的提取速度，基于像素的处理方式也使得处理精度可以到更高的水平。近些年，钙钛矿材料的强度高、热膨胀系数小、成本低廉、高荧光量子产率等优点，吸引了大量研究人员关注 [132]。其随机结晶的方式使得材料表面存在复杂的纹理，这使得研究人员可以利用其制备具有复杂纹理的薄膜图案，并将其应用到了一个全新的防伪检测领域 [133]。此类任务基于材料的复杂纹理信息制备防伪标签，这样每个标签便携带了全世界独一无二的信息，免去防伪标签设计的繁杂步骤。但这对识别检测算法要求较高，算法不仅需要具有极高的准确率，还要尽可能降低时间花销，使用上一章的复杂网络方法便很难处理此类任务。基于此本论文针对钙钛矿晶体薄膜图案的可控形状特征和复杂纹理特征，设计了一套基于传统图像处理方法的防伪标签检测算法。本算法根据钙钛矿晶体薄膜图案进行检测，利用形状信息加速防伪验证速度，使用薄膜图案的不可复制复制纹理特征信息进行精准匹配，最终可以获得较高的防伪检测准确率。本章所述方法已在《Small》期刊发表。

4.1 方法概述

使用本方法进行防伪处理的整体流程如图4.1所示，总体可分为两个步骤：一个是数据库的建立，一个是薄膜图案的匹配识别。本方法可以从带有防伪标签的产品中提取防伪信息，经过入库操作将防伪信息存入数据库。用户在进行验证时便可以直接使用手机以及便携式摄像头进行拍摄，将获取到的防伪薄膜图案信息传入验证软件进行防伪验证。通过以上两步验证，如果在数据库内找到了相应的数据，那么图像就验证成功，如果找不到与之相匹配的数据，则验证失败。




图 4.1: 防伪检测整体流程图。厂家生产产品后将防伪标签的形状纹理信息放入数据库存储, 用户验证时仅使用手机拍摄并进行上传即可完成真伪校验。

4.1.1 数据库构建方法

在实际应用中, 防伪标签往往是大批量生产, 建立一个大数据量的数据库作为检测可靠性的依据是必须的。常规的建库方法是将薄膜图案文件全部存储到一个库中, 检测时一一匹配, 这使得时间花销随着库文件数目的增多而呈现线性增长趋势。本论文利用钙钛矿晶体薄膜图案中存在的形状信息和纹理信息对图像进行描述。薄膜图案在设计时具有一定的形状, 通过形状的预分类可以大大加速纹理的精准匹配。因此本论文的薄膜图案数据库分成了形状数据库和纹理数据库两部分。

为了更好的提取薄膜图案的形状信息和纹理信息, 本方法图像处理过程分为图像预处理、形状信息提取和纹理特征提取三步完成。

A. 图像预处理

图像预处理是为了获得较为规整的图像, 这可直接将拍摄的图像处理成同等规格的图像, 便于后续的形状识别和纹理识别。而钙钛矿晶体薄膜图案在制备过程中存在一定的缺陷, 有些图像内部过于暗淡, 如图4.2所示, 这容易妨碍图像的分割提取, 本方法在处理时进行了孔洞填充, 只留下薄膜图案的外部轮廓, 以方便后续的

处理。




图 4.2: 存在孔洞的图片示意




图 4.3: 图像预处理

预处理的整体流程如图4.3所示，首先使用形态学的方法对原图进行的处理，获取图像的二值图，通过孔洞填充方式获得薄膜图案的轮廓。之后为了更好的将图案分割出来，本方法使用最小外接圆的方法进行薄膜图案的寻找，由于单个薄膜图案的尺寸是相近的，所以进行图案筛选时可以通过比较最小外接圆的面积来进行筛选。本方法设置筛选阈值为最大图案外接圆面积的 40%，通过筛选可以将图中的细碎的点以及不完整的图形进行去除，留下完整的图形进行接下来的处理。由于拍摄的原始图片像素不统一且尺寸过大，不方便统一处理，所以对图案进行了归一化处理，设置形状归一化为 240×240 ，纹理图归一化为 960×960 。这样既可以从小尺寸的图片中轻易获取形状信息，又能保留较多的纹理信息便于纹理特征信息处理。

B. 形状信息提取

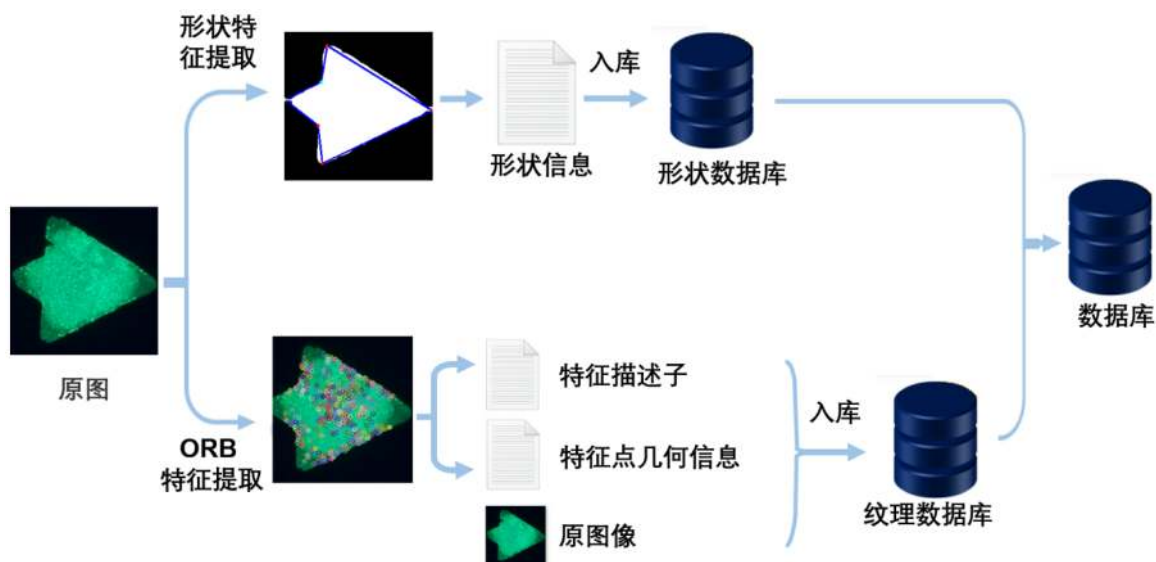


图 4.4: 数据库构建

形状特征和纹理特征的提取和入库的流程如图4.4所示。在进行形状检测时，为了获得比较好的检测结果，本方法根据拍摄的图像归纳总结出一些形状来进行识别。形状信息可以由轮廓上的特征点来描述，本方法使用了 Han 等人提出的 CNL 方法 (the controlling number of landmarks) 进行形状特征信息的提取 [97, 98]。其算法流程如图4.5所示，第一步，以轮廓图中最远的两个点作为初始地标点，连接两点获得初始连线；第二步，寻找轮廓上距离连线最远的点作为新的地标点，连接其在轮廓点顺序上的前后两个地标点组成新的连线；第三步，重复之前两步操作，直到地标点与连线之间距离小于设定的阈值停止。图像中的形状信息即可通过 10 个地标点进行描述，其包含了薄膜图案的轮廓中最远点以及垂线等信息。这些点都集中在了图形的角点等位置，可以很好的表现出图形的形状。本方法将其转换成文件形式存储在形状数据库中。

C. 纹理信息提取

纹理提取现在已经有很多成熟的方法，例如 SIFT[54]，SURF[134]，ORB[56]，CNN[104] 等。其中 ORB 算法相较于其他算法提取方式更快，能满足实时性的需要。ORB 算法包含带方向的 FAST 算法和可旋转的 BRIEF 算法。如图4.6(a)(b)，本方法使用算法中的 FAST 算法选取特征点，其中阈值 h 设置为 0，这样像素点只会被




图 4.5: 基于 CNL 的形状点获取示意图

分为两类，即像素值大于中心像素值和像素值小于中心像素值两类。对于像素点 O 而言，通过比较圆周上像素点与圆心像素点灰度值的大小，将其划分为两类。如果其中一半连续的像素点同属于一类，那么此像素点 O 被选为特征点。本方法为了检测速度考虑将特征点数目设置为 1500 个，这可在保证速度的同时尽可能获得更多的图像纹理描述信息。特征点的信息描述使用 BRIEF 算法，如图 4.6(c) 所示，在特征点像素周围随机选取 256 对像素，通过公式 (2.21) 和公式 (2.22) 所示方式获得特征点的 256 维二进制特征向量。此向量即为特征点的特征描述子，此描述子可以较好的描述特征点附近的纹理信息。




图 4.6: 特征点纹理信息提取示意图。(a) 使用算法获取的特征点示意图；(b) 特征点选取示意图；(c) 特征点描述子获取示意图。

最终本方法将特征点的纹理信息提取为两个文件，分别保存薄膜图案特征点信息和特征描述子信息。其中薄膜图案特征点信息文件保留了检测出特征点的位置、大小等信息；特征点描述子信息文件保留了特征点处的明暗、对比度等纹理信息。

4.1.2 匹配验证方法

从获取拍摄图像到最终得到验证结果，整体处理流程如图4.7所示。便携式设备获取薄膜图案，经过预处理得到物理不可克隆功能标签（physical unclonable functions, PUF）；使用形状识别算法获取薄膜图案的形状信息，通过改进的霍夫圆检测算法和在形状空间上的距离度量完成形状匹配；通过形状检测信息寻找到适合的形状纹理库，最后使用 GMS 算法在识别到的形状内对纹理进行匹配验证，最终验证薄膜图案真伪。本论文将识别过程分为三个部分来进行描述：图像预处理、形状判断和纹理识别与判断。

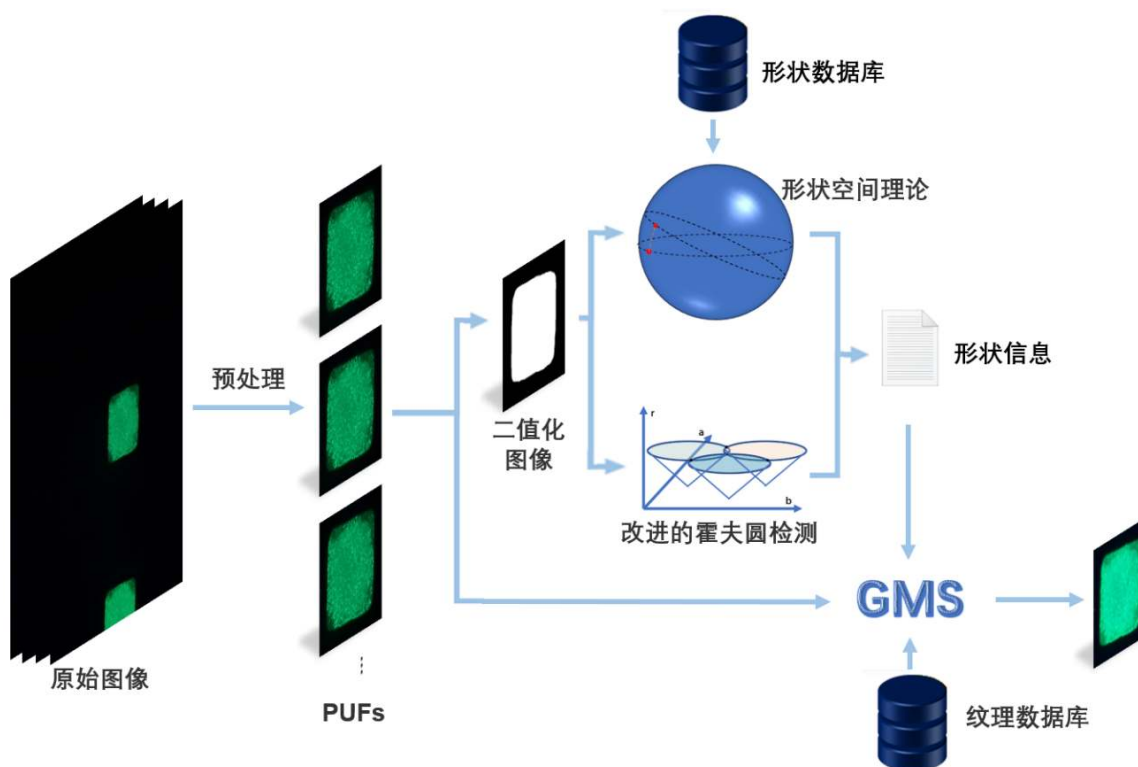


图 4.7: 匹配验证流程图。原始图像经过预处理获得归一化的标签图片，此图片经过形态学处理成为二值化图像，用来进行形状检测，即通过形状空间理论和改进的霍夫圆检测方式获得形状信息；形状信息和标签图片会通过 GMS 算法获得薄膜图案的纹理信息，完成防伪验证。图中两个数据库为4.1.1节所述形状数据库和纹理数据库。

A. 图像预处理

本节的图像预处理与第4.1.1节的图像预处理操作相类似，通过形态学处理和最小外接圆算法来对传入的图像数据进行剪裁切割，以获得完整、易识别的单个薄膜

图案图像。

B. 形状判断

为了快速进行形状检测，降低时间花销，本方法采用 CNL 方法对形状进行识别，通过形状空间理论 [97, 98] 对获取的地标点信息和形状库内的形状信息进行距离度量。为了可以计算两个形状的测地距离，本方法将提取到的形状信息与形状数据库中相同数目地标点的形状信息进行空间映射，将其共同映射到预形状空间。再通过公式2.17找到测地距离最近的形状，即为当前图形最匹配的形状，以此完成形状的匹配。这种计算方式可以降低因形状的细小差别而带来的影响，如果两个形状都是处于预形状空间上的一个圆形轨道上，也就是说两个形状都是一样的形状，那么两个形状之间的距离计算出来就是很小的。通过这种方式可以区分出两个形状是否是同一个形状，达到形状检测识别的目的。




图 4.8: 霍夫圆检测失败样例示意图 [135]

形状空间理论能够找到两个形状在预形状空间上的测地距离，完成形状验证，从而帮助纹理特征的匹配检测。但这一方法有一个重要的缺陷，就是很难确定两个圆上特征点的对应关系。这就会导致两个相同的圆形可能计算出的距离较大，从而被认为是两种形状。为了可以对薄膜图案中圆形形状的检测，本方法引入了一种传统的霍夫圆检测算法进行检测识别 [136]。传统的霍夫圆检测算法是常用的圆形检测方法，其基于投票的方法选定圆心和半径。如果存在圆弧状图形，即如图4.8所示图形时，容易将此图形检测为圆形。本论文在原本霍夫圆检测的基础上增添了阈值筛选，可以筛选如图所示的形状，以此来保证形状检测的准确性。

首先对图像进行轮廓检测来寻找所有的轮廓点，通过公式 (4.1) 计算轮廓上每

个点 $p_{i,j}$ 到中心点 p_O 的距离 $d_{i,j}$:

$$d_{i,j} = p_{i,j} - p_O, \quad (4.1)$$

接着通过比较 $d_{i,j}$ 与霍夫圆检测半径 R_h 的大小可以获得轮廓上的异常点, 如果这些异常点的数目 C_n 小于 ηN , 便认为这个形状 S 不是圆形, 其公式描述如 (4.2) 所示:

$$S = \begin{cases} 1, & \text{if } C_n < \eta N \\ 0, & \text{otherwise} \end{cases}, \quad (4.2)$$

公式中 1 表示形状 S 是圆形, 0 表示不是圆形, N 表示轮廓上像素点的总数, η 是一个常数, 在这里取 0.2。异常点数目 C_n 使用以下公式描述:

$$C_n = \sum_{i=0}^N K_i, \quad (4.3)$$

其中 K_i 表示轮廓上的第 i 个坐标点是否异常, 公式描述如 (4.4) 所示:

$$K_i = \begin{cases} 1, & \text{if } d_{i,j} \geq \mu R_h \\ 0, & \text{otherwise} \end{cases} \quad (4.4)$$

其中 μ 为一个系数, 本论文取 7/5。通过以上方式, 改进霍夫圆检测算法, 可以解决图4.8中形状识别错误的问题。

C. 纹理识别与判断

经过上述步骤可以获得薄膜图案的形状信息, 筛选掉了大量的样本。接着需要对图片的纹理信息进行识别与判断, 完成最终真伪样本检测。由于图像中存在较为复杂的纹理, 并且纹理图片大都相似, 仅可通过细小边缘或者内部纹理进行图片比对, 传统的特征点匹配方法很难取得较为优秀的匹配效果。在实际拍摄时由于拍摄习惯、拍摄设备不同等因素的影响, 使得获取的图片存在一定的差异, 这增加了纹理匹配验证的难度。

本论文使用 ORB 算法对选取的特征点进行匹配, 由于 FAST 算法在计算时降低了类别的数目, 这使得此步骤得到了大量的匹配特征点。但仅通过 ORB 算法匹配的特征点容易存在较多的错误匹配, 因此本论文选取了 GMS 算法对 ORB 算法

获取得到的特征点进行进一步筛选，这不仅可以复用 ORB 算法提取的特征点以及特征描述子信息，还能获得更加准确的匹配特征点。GMS 算法匹配示意如图 4.9 所示，如果一个网格（如图中红色方框内所示）内存在多个匹配的特征点，那么这个网格内的其他特征点更有可能也是匹配的（黄色线所连接的特征点），如果两个网格内仅有一个特征点匹配（如图中紫色连线所示），但所处网格位置差异明显，那这一对便极有可能是错误匹配的特征点。算法以公式 (2.23) 的计算两个匹配点的匹配分数，通过将匹配分数和设定阈值进行比较，即公式 (2.24) 所示方式可以判定节点是否匹配。最终通过对整幅图像进行遍历，可以获得所有精确匹配的特征点，完成匹配特征点的筛选。




图 4.9: GMS 算法匹配示意图

4.2 实验分析

本论文使用传统图像处理方式对钙钛矿晶体薄膜图案进行形状和纹理提取，并通过手机拍摄的图片进行验证。所有实验均在 Intel(R) Core(TM) i7-10700 CPU

2.9GHz*16 和 32G RAM 的计算机上执行。

4.2.1 数据准备

使用数据为激光刻蚀的薄膜图案，数据中包含 4000 张不同的薄膜图案图像。如图4.10所示，除了 60 个常规的形状之外，本论文还把一些复杂的形状来作为第 61 类形状，增强数据库的完备性。一些由于制备而产生的损坏形状的薄膜图案也被放到了复杂形状中，这可使得数据被尽可能利用。每个形状下包含 60 至 70 张纹理图片，每张纹理都具有其独特性，都是独一无二的。

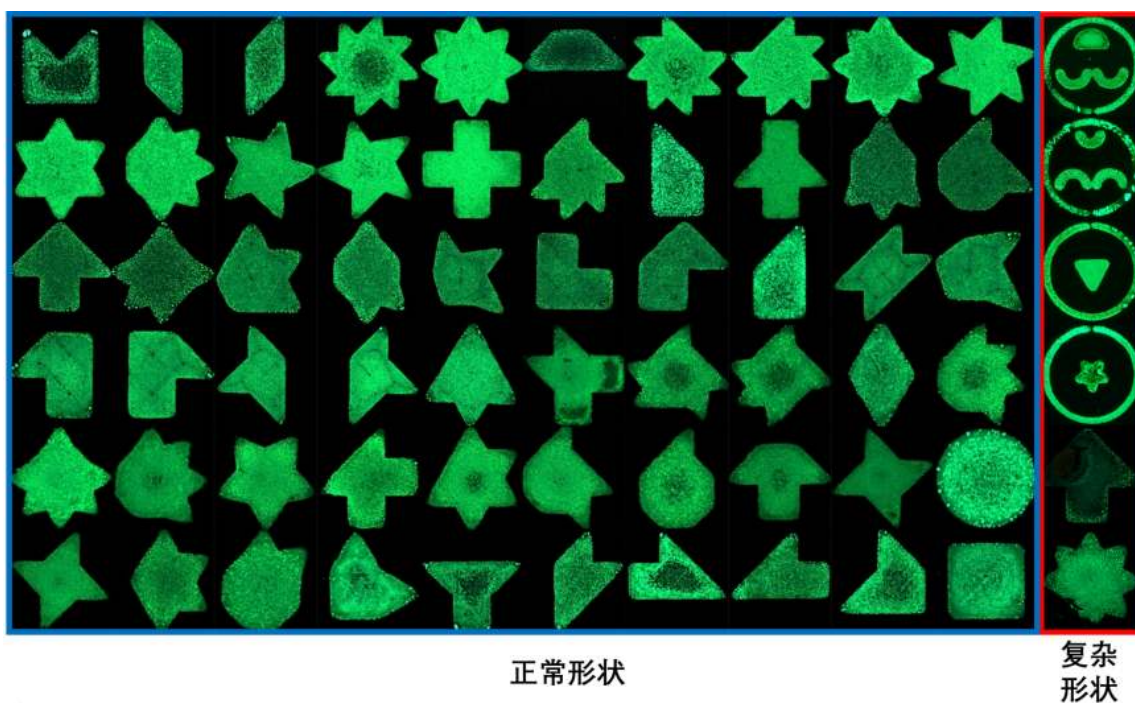


图 4.10: 所有薄膜图案形状示意图。本论文归纳形状分为正常形状和复杂形状，正常形状如左侧 60 种形状所示，复杂形状如右侧红框内所示，其中包含圆环嵌套形状以及制备残缺形状等。

4.2.2 形状分类及纹理匹配阈值选取

为了验证形状数目对于匹配速度的影响，本章将数据库的所有图片进行了重新划分，分别设计了七组实验进行验证，其中包括不分类直接进行验证、分 11 类验证、分 21 类验证、分 31 类验证、分 41 类验证、分 51 类验证以及当前本论文设置

的分 61 类进行验证，所有数据都是平均划分的。本论文随机选取 12 张图片进行验证，结果如图4.11（左）所示，其中假样本的验证时间比真样本检测时间多一倍左右。这是因为真样本检测时遇到匹配成功的样本会立即返回检测结果，而假样本是需要检测当前形状下的所有纹理图像以及复杂纹理库中的所有样本，这使得两者具有一定的差异。通过图中趋势看出随着类别数目的增多，匹配时间不断降低，最终逐渐趋于平稳，总体看平均匹配时间可从一开始不使用形状分类时的 54.18s 逐渐降低到最终的 2.69s。具体匹配时间如表4.2所示。

表 4.1: 分类数目与检测时间对比结果

	1 类	11 类	21 类	31 类	41 类	51 类	61 类 (本方法)
真样本平均匹配时间/s	34.98	4.46	2.59	2.45	2.54	2.03	1.91
假样本平均匹配时间/s	73.39	9.07	5.62	4.62	4.07	3.76	3.47
平均检测时间/s	54.18	6.76	4.11	3.54	3.30	2.90	2.69

在验证时为了可以区分真假样本，本方法通过设置阈值来对真伪样本进行区分，当验证图片与数据库中图片的匹配特征点数大于阈值 φ 时，此样本被判定为真样本，反之为伪造样本。为了验证最佳的匹配阈值本论文随机选取了 74 个薄膜图案，使不同人利用不同的便携式设备获得待验证的薄膜图案图像，其中包括 47 张真样本和 27 张伪造样本，利用本论文设计的算法进行防伪验证。实验结果如表4.2和图4.11（右）所示，最终发现当阈值设置为 200-300 时可以达到最佳的匹配效果，尤其是在设置 200 阈值时真样本验证准确率到达 97.87%，对于伪造样本可以达到 100% 的检测准确率，为此本论文将 200 作为最终的特征点匹配检测阈值。

4.2.3 编码容量计算以及相关算法对比

为了评估防伪标签的信息承载量，本节对本论文使用的防伪标签进行编码容量的计算。防伪标签如图4.12所示，本方法使用的纹理提取算法基于图像灰度值进行，所以公式2.32中 C 取 255。本方法以特征点作为基本的单位进行计算， p 和 p' 是否可以作为特征点取决于周围 7×7 像素的灰度值，所以根据特征点大小 L 设置为 7。




图 4.11: 不同形状数目对匹配时间的影响示意图 (左) 和不同匹配阈值设置对准确率的影响示意图 (右)

表 4.2: 阈值选取匹配数据结果

	匹配特征点阈值	100	200	300	400	500	600
真样本 (47 张)	验证成功样本数	47	46	39	36	32	25
	验证失败样本数	0	1	8	11	15	22
	验证准确率	100%	97.87%	82.98%	76.6%	68.09%	53.19%
假样本 (27 张)	验证成功样本数	25	27	27	27	27	27
	验证失败样本数	2	0	0	0	0	0
	验证准确率	92.59%	100%	100%	100%	100%	100%

根据拍摄时的相机参数等信息进行计算, 本论文取 R 为 137, D 为 0.436。通过将以上参数带入公式 2.32 计算得到编码容量为 2.119×10^{623} 。




图 4.12: 本论文薄膜图案的特征点区域选取示意图 [135]

为了验证算法的优越性，本论文在编码容量、验证时间和数据库大小上对比了当下几种实用的防伪标签验证方法的性能，详情如表4.3所示。通过分析可知本方法使用的防伪标签图案具有较高的编码容量和较快的检测时间。这使得从拍摄到最后验证成功仅需要 12 秒即可完成，相对于其他的传统防伪处理方案有着较为明显的性能提升。并且本论文在更为大量的样本上进行了验证，为应用于实际生产带来更高的可信度。

表 4.3: 防伪验证方法对比

	Carro-Temboury 等人 [118]	Gu 等人 [137]	Liu 等人 [138]	Jing 等人 [139]	本方法
编码能力	6×10^{104}	3×10^{15051}	4.7×10^{202}	1×10^{144494}	2.1×10^{623}
总体处理时间	5min	20min	Seconds-minutes	3.5min	12.17s
数据库大小	-	100	-	1760	4000

4.2.4 算法稳定性测试




图 4.13: 用于稳定性测试的薄膜图案

钙钛矿晶体薄膜图案由于材料性质的原因，无法长久保存。为了应对不同环境，在保证薄膜图案材料稳定的同时，也需要本方法具有极好的鲁棒性。本论文使用不




图 4.14: 温度和光照变化对阈值的影响。红线表示本方法设定的纹理匹配阈值, 匹配点数目大于此阈值即为验证成功。

同环境下的薄膜图案进行验证, 其中包括对薄膜图案进行光照测试和热稳定性测试, 最终得到的效果如图4.14所示, 通过对如图4.13所示的六个薄膜图案进行跟踪检测发现六个图案的匹配点数均可以保持在阈值(200)以上, 这也说明了本方法在图片出现轻微的变化时仍然具有较好的识别准确率。

4.3 本章小结

本章使用传统图像处理方法对具有可控形状和复杂纹理的钙钛矿晶体防伪标签薄膜图案进行特征信息处理, 完成了防伪标签数据库构建和检测识别任务。数据库中包含薄膜图案的形状信息和纹理信息, 形状信息使用形状空间理论中的 CNL 方法进行地标点的提取, 纹理信息使用 ORB 算法进行提取。验证过程也分两步进行, 使用形状空间理论和改进的霍夫圆检测算法进行形状检测, 使用 ORB 和 GMS 算法完成纹理信息检测, 利用形状信息加速纹理检测速度, 最终识别出防伪标签真伪。

本方法为基于钙钛矿晶体薄膜图案的防伪检测任务提供了新的思路, 使用形状信息提高了匹配检测速度, 并且在 4000 张图片的数据库中进行实验, 验证了算法的有效性。但方法设计较为复杂, 并且由于形状的不规整使得形状检测处理较为困

难，容易发生错判的情况。此外在相同形状内，纹理检测使用一一匹配的方法进行，这在一定程度上降低了匹配速度。

第五章 基于深度学习的薄膜图案特征处理

在上一章，本论文基于传统图像处理方法提出了一套面向复杂纹理薄膜图案的处理方法，可以有效的提取薄膜图案的形状信息和纹理信息，以完成整套的防伪检测任务。然而该方法需要研究人员具有较强的专业知识，形状检测算法在面对不规整图像时存在一定的识别误差，纹理检测的过程稍显简单，时间消耗较长。为了降低处理难度，降低时间花费，选择具有较好学习能力且处理速度较快的算法是十分有必要的。随着人工智能的快速发展，深度学习凭借其自主学习特征、鲁棒性强、准确率高的优点而受到了研究人员的广泛关注 [82, 138, 139]。目前，在复杂材料图像处理领域，基于深度学习的处理方法仍处在初始阶段，所使用的神经网络大都为基础模型，模型较为冗杂，这需要消耗大量的计算资源和存储资源，这在一定程度上增加了各种成本。而轻量级网络的发展，为这一问题提供了解决方案。基础的轻量级网络模型虽然可以在传统场景数据（如 ImageNet 数据集）中获得较为不错的分类表现，但是面对具有复杂纹理的材料图像时，依然很难取得较高的准确率。为解决以上问题，本章基于 MobileNetV3 结构，提出了一种面向复杂纹理薄膜图案的轻量级网络结构。通过低成本、高精度、不可克隆的钙钛矿晶体薄膜图案作为测试数据进行实验，验证了本方法在低资源占用下的防伪标签识别检测的有效性。本章内容已被上海大学学报（自然科学版）接收。

5.1 方法概述

5.1.1 模型框架

本方法设计了两步验证的防伪标签识别架构，整体流程如图5.1所示。首先，通过训练一个形状分类模型识别出薄膜图案的可控特征；接着，利用形状信息，从数据库中寻找形状对应的纹理模型，进行薄膜图案的不可复制纹理特征的识别，这降低了纹理识别的难度，减少了纹理识别的时间花销；最后，通过对比纹理识别模型输出的特征向量各元素中的最大值与预设值的差异，来判断薄膜图案的真伪。

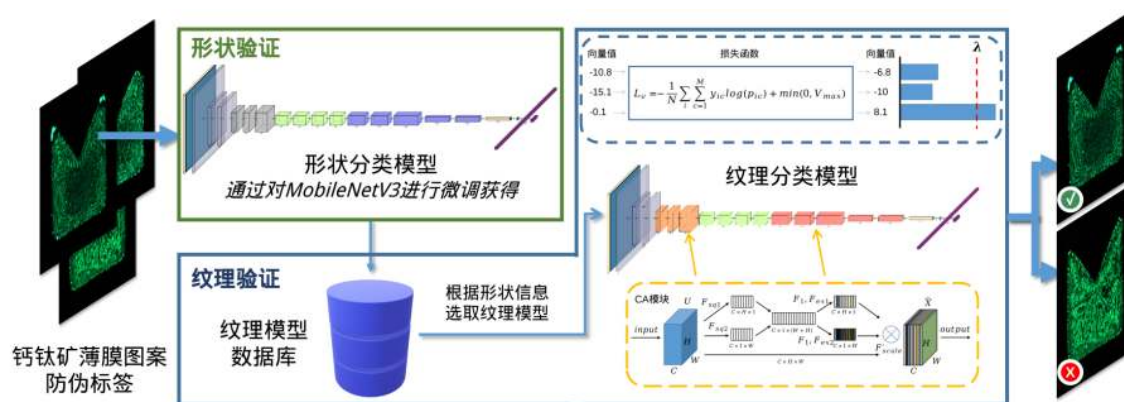


图 5.1: 模型整体流程示意图

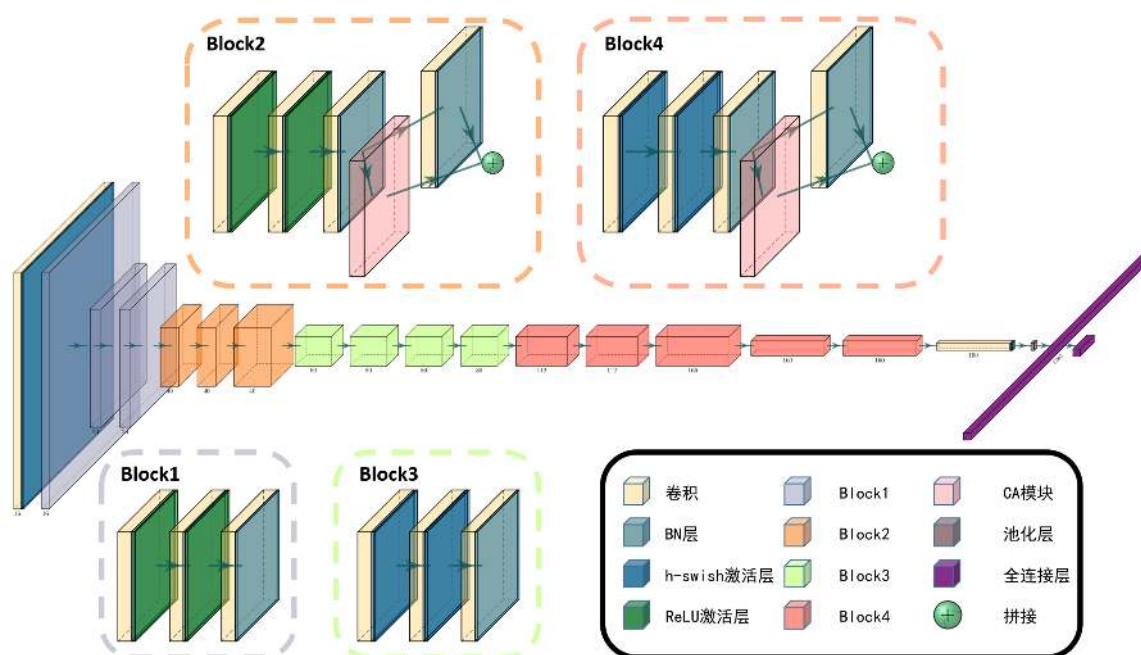


图 5.2: 基于协调注意力的 MobileNetV3 模型架构图

为了尽可能降低资源消耗，本方法选取轻量级网络中的经典的 MobileNetV3[110] 作为基础网络框架，其架构与大部分 CNN 模型类似：首先通过卷积块的卷积操作来完成特征提取，接着使用全局平均池化层对数据进行降维并去除冗余信息，最后使用全连接层对图像进行分类识别。

在形状识别处理过程中，由于形状较为规整、特征明显，本方法直接对模型进行微调即可达到较高的准确率。但在纹理识别上，仅使用基础架构无法达到预期的效果，因此本方法对原本的 MobileNetV3 进行修改，得到如图5.2所示网络结构。为

增强模型的学习能力，本方法微调了全局池化层大小，并在 Block2 和 Block4 中引入协调注意力 (coordinate attention, CA) 模块 [140]，从而提出基于协调注意力的 MobileNetV3 结构；为了使模型更好地辨别真伪样本，本方法通过修改模型的损失函数，提出使用基于类激活值的损失函数来指导模型的训练。

5.1.2 基于协调注意力的 MobileNetV3

近年来轻量级网络的发展较为迅速，常见的轻量级网络有 ShuffleNet[141]，EfficientNet[142]，MobileNet[110] 等。MobileNetV3 网络凭借其更小的体积和计算量，更高的精度而受到了广泛关注。如2.3.2节所述，模型利用了 SE 模块来增强模型的学习能力，其结构如图5.3(a) 所示。SE 模块学习到了特征图通道间关系信息，使得模型在基础数据集上取得了不错的效果，但在本论文的纹理检测任务中效果欠佳。本方法引入了如图5.3(b) 所示 CA 模块来对模型进行修改，使得模型可以关注到特征图上空间信息，增强了模型的学习能力。

CA 模块思想与 SE 模块相似，也分为压缩和激活两个步骤。不过该模块保留了通道与特征图高度和宽度之间的关系，将特征图压缩成两个二维向量，这使得模型不仅可以捕捉到沿着空间方向的长程依赖，还可以保存特征的精确位置信息。其压缩过程如公式 (5.1) 和公式 (5.2) 所示， $z_c^h(h)$ 和 $z_c^w(w)$ 表示在每个通道内获得的在高度和宽度方向的统计信息，

$$z_c^h(h) = \frac{1}{W} \sum_{0 \leq i < W} x_c(h, i), \quad (5.1)$$

$$z_c^w(w) = \frac{1}{H} \sum_{0 \leq j < H} x_c(j, w). \quad (5.2)$$

为了可以获取到全局特征和精确的位置信息，在激励过程之前，模块使用全连接层对上述两个方向的特征进行拼接与处理，如公式 (5.3) 所示，

$$f = \delta(F_1([z^h, z^w])), \quad (5.3)$$

F_1 表示全连接层， δ 表示激活函数， $[z^h, z^w]$ 表示对两个方向的特征图直接拼接得到的新的特征图。为了可以将上述特征累加到特征图上，这里对原本拼接的特征进行

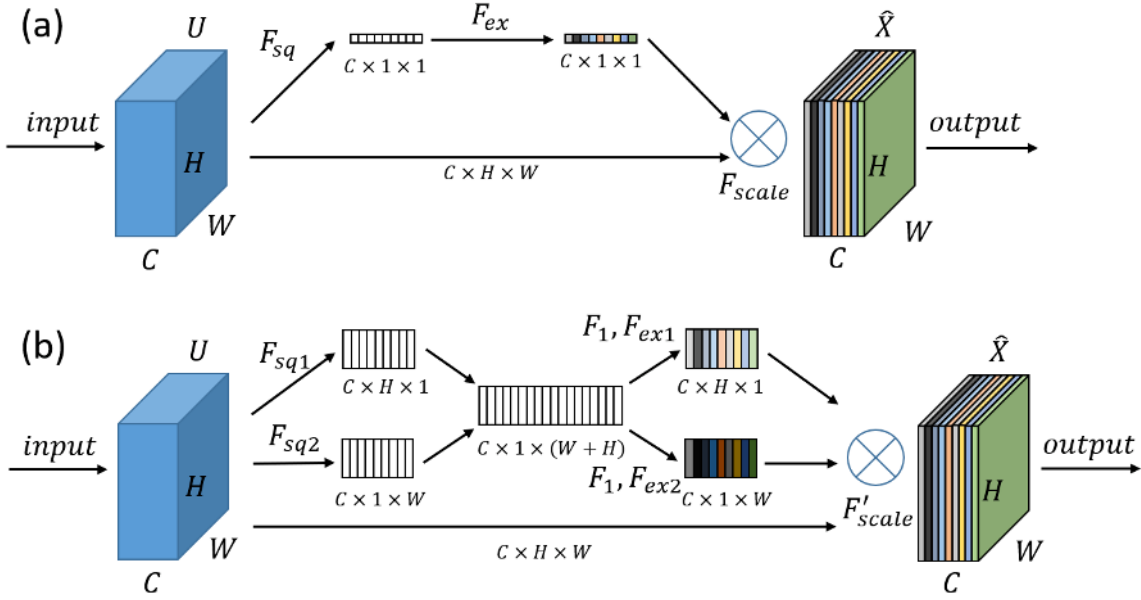


图 5.3: 注意力模块示意图。(a) SE 模块结构示意图; (b) CA 模块结构示意图。在 SE 模块中, 特征图经过压缩操作 F_{sq} 获得一维特征向量, 激活操作 F_{ex} 得到融合了通道间关系的特征图权重向量。最终, 通过将此向量与原本特征图混合完成通道间信息描述。而在 CA 模块中, 特征图的处理被 F_{sq1} 和 F_{sq2} 操作拆分为两个二维向量, 这两个二维向量将特征图的高度和宽度与通道建立了连接。接着将两个向量进行拼接和学习 (利用全连接层 F_1) 学习了通道间关系。最后通过激活操作 F_{ex1} 和 F_{ex2} 获得特征图在高度和宽度上的注意力权重, 将其与原特征图融合获得 \hat{X} 以完成空间位置以及通道关系描述。

分离, 使用全连接进行特征维度变换, 其描述如公式 (5.4) 和公式 (5.5) 所示,

$$g^h = \sigma(F_h(f^h)), \quad (5.4)$$

$$g^w = \sigma(F_w(f^w)), \quad (5.5)$$

其中 F_h 和 F_w 表示全连接层, σ 表示激活函数, f^h 和 f^w 表示将 f 分离得到的特征权重。得到的 g^h 和 g^w 表示在高度 H 方向和宽度 W 方向的注意力权重。将其与原本输入的特征图进行相乘, 便可获得携带更多信息的特征图, 其公式如 (5.6) 所示,

$$y_c(i, j) = x_c(i, j) \times g_c^h(i) \times g_c^w(j), \quad (5.6)$$

其中 $y_c(i, j)$ 表示的就是结合了通道间的位置关系以及特征图上空间关系后的 c 通道的特征图, $x_c(i, j)$ 表示上一层的特征图, $g_c^h(i)$ 和 $g_c^w(j)$ 表示经过注意力模块获取到的特征权重。

5.1.3 基于类激活值的损失函数

为了使得模型可以识别防伪标签的真伪，大量数据训练是必不可少的。然而本任务中所有的伪造图像不能穷举，模型只能在正样本上对图像进行识别训练。换句话说，本方法需要使神经网络对已经训练的图像进行记忆，使神经网络过拟合。为此本方法除了增加训练轮次外，还对图像进行了数据增强，但收效甚微。本节希望从损失函数入手，通过指导网络模型的学习过程，使得模型在仅有正样本的情况下依旧可以辨别样本的真伪性。

在常见的分类任务中，交叉熵是较为常见的损失函数，其描述如公式 (5.7) 所示：

$$L = -\frac{1}{N} \sum_i \sum_{c=1}^M y_{ic} \log(p_{ic}), \quad (5.7)$$

其中 M 表示类别数量， y_{ic} 表示类别预测结果，如果样本 i 属于类别 c 那么当前值被设置为 1，反之为 0， p_{ic} 表示观测样本 i 属于类别 c 的概率。经实验发现仅使用交叉熵损失函数进行训练模型时，很难对新样本进行真伪验证。为此，本方法在损失函数中增加了一个类激活损失，使得模型可以通过最后的特征向量中的各元素最大值来对真伪样本进行区分，其描述如公式 (5.8) 所示：

$$L_R = -\frac{1}{N} \sum_i \sum_{c=1}^M y_{ic} \log(p_{ic}) + \min(0, V_{max}), \quad (5.8)$$

其中 V_{max} 表示模型输出的特征向量中各元素的最大值。当 V_{max} 大于 0 时，损失为 0，当 V_{max} 小于 0 时，损失函数开始统计，其值越小，损失值越大。通过这种方式训练神经网络，可以使得真样本收缩到一个特定空间，也就是说，对于已经训练的样本，输入模型后输出的特征向量中的各元素最大值大于 0。当有伪样本传入时，网络模型并没有对其特征进行学习，得到的预测特征向量中的各元素最大值小于 0。而真样本已经经过训练，特征都被记录在模型中，这使得模型预测得到的特征向量中的各元素最大值大于 0 并且会相对较高，通过这种方法可以区分两类样本。本方法为了进一步降低因训练波动带来的误差，设置了固定阈值 λ 来对其进行筛选，如果输出特征向量中的各元素最大值大于 λ 为真样本，否则为伪样本，以此完成对薄膜图案的真伪验证。

5.2 实验分析

5.2.1 数据和实验设置

本论文使用的图片为 Lin 等人 [135] 数据集中的部分图案。数据共包含薄膜图案形状 10 种，每种形状包含约 66 张图片，总共 659 张图片。每一张图片都具有独一无二的纹理，图片的分辨率为 960×960 像素。训练数据以 6:4 进行划分，在形状识别任务中，390 张图片被划分为训练集，剩下的 269 张作为测试集验证形状分类模型，在纹理识别任务中，每个形状内 39 张被划分为训练集，剩下的作为测试集验证纹理分类模型。在进行训练时每张图片都进行数据增强来保证模型的鲁棒性。




图 5.4: 薄膜图案形状及部分纹理图

本论文使用的计算机配置为 Intel(R) Xeon(R) Silver 4210R CPU @ 2.40GHz, NVIDIA GeForce 3090 GPU, 操作系统为 Ubuntu18.04 实验基于 PyTorch 框架进行模型的搭建, 在形状分类实验中设置训练 batch size 为 4, 训练轮次为 200, 初始学习率为 0.001, 衰减策略为每 20 步衰减 0.5; 在纹理分类实验中设置训练 batch size 为 4, 训练轮次为 100, 初始学习率为 0.001, 衰减策略为每 20 步衰减 0.5。

5.2.2 面向形状的轻量级网络选取对比实验

钙钛矿晶体薄膜图案的形状验证较为简单, 形状间具有较大的区分度, 本节使用形状验证来对轻量级网络进行选取。实验选取当前几种较为成熟的轻量级网络, 使用十个形状 of 的薄膜图案对模型进行训练, 表5.1展示了不同的模型在测试集上的准确率、复杂度、参数量以及内存占用等。

表 5.1: 轻量级网络对比

	预训练	准确率/%	FLOPs	参数量	内存占用
MobileNet-V3	Yes	99.763	4.11GFlops	5,483,032	884.59MB
MobileNet-V3	No	96.982	4.11GFlops	5,483,032	884.59MB
EfficientNet-V1	Yes	99.527	7.3GFlops	5,288,548	1390.44MB
EfficientNet-V1	No	95.503	7.3GFlops	5,288,548	1390.44MB
ShuffleNet-V2	Yes	99.053	783.89MFlops	1,366,792	206.33MB
ShuffleNet-V2	No	97.811	783.89MFlops	1,366,792	206.33MB
MobileNet-V3-s	No	99.988	4.81GFlops	22,387,916	828.51MB

通过表格可见使用预训练模型可以提高网络识别的准确率, 对于基础模型, 即表格中的前 6 行所示, 相对而言 ShuffleNet 可以获得较高的准确率。对于同一种模型来讲结构越简单、参数量越小, 模型的学习能力越差, 反之, 结构越复杂模型越有可能学习到足够的信息, 例如同为 ShuffleNet, 使用正常的模块堆叠相比于使用 0.5 倍的模块堆叠, 在形状识别上可以获得更高的准确率。此外, 模型在池化时会按区域将局部特征图转化为特征值表示, 这虽然降低了参数量, 但也降低了模型精度。本方法对 MobileNetV3 最后的全局池化层进行了修改, 降低池化层过滤器的大

小，并在全连接层使用更多的神经元来进行连接，经实验验证这是提高模型识别效果的一种简单有效的方式。结果如表5.1的最后一行所示，通过微调后，在形状识别上，虽然增加了参数量，但可以获得更高的精度。最终模型在从头训练的情况下相较于原本使用了预训练模型的 MobileNetV3 仍提高了 0.23% 的准确率，本论文将此模型作为形状识别任务的最终模型来使用。

5.2.3 面向纹理的基于协调注意力的 MobileNetV3 验证实验

对于纹理识别，由于使用图片与形状检测相同，且依旧是分类任务，本节选取了在形状分类中表现最好轻量级模型进行实验。与形状识别不同的是，同一个形状下的不同纹理图案之间具有较高的相似性，这使得识别效果大打折扣，为此本节使用5.1.2节所述方法对模型进行修改，通过提升注意力机制的学习能力来提高模型的准确率。实验结果如表5.2所示，通过引入 CA 模块可以在其他资源占用基本不变的情况下，提升了 3.44% 的识别准确率。由于 CA 模块压缩过程中降低了神经元的数量，所以也降低了模型的参数量，使得模型可在占用更少资源的情况下获得识别准确率的提升。

表 5.2: 基于空间的 MobileNet 验证实验

	准确率/%	FLOPs	参数量	内存
MobileNet-V3-s	86.245	4.81GFlops	22,387,916	828.51MB
MobileNet-V3-t1	89.692	4.81GFlops	22,354,128	829.33MB

深度学习网络模型是黑盒模型，很难直接从参数中可视化的感受到模型的关注区域。为此研究人员将网络最后的输出的特征向量映射并还原到各个层上，将其覆盖在原图上就得到了热图，即网络关注区域的可视化图像。本论文使用此类方法中的 Grad-cam++ 方法 [143] 对模型关注的区域行可视化，更加直观的展现出注意力机制替换对模型识别效果的提升。结果如图5.5所示，其中越偏向于红色，模型对此处关注度越强，越偏向于蓝色，模型对此处关注度越弱。从图中可以清晰看出，在使用 CA 模块后，模型对纹理图片的区分会更加依赖于大块的明显特征，其中包括

薄膜图案边角处大面积亮点的形状、排布，以及内部独特纹理等。




图 5.5: 注意力可视化结果

5.2.4 面向纹理的基于类激活值的损失函数验证实验

损失函数的设计是为了解决纹理检测时无法区分真伪样本的问题，本节对比了中心损失函数、原始交叉熵损失函数、基于类激活值的损失函数的效果，并对真伪阈值进行了对比实验。实验使用每个形状内的 60% 的纹理图进行训练，验证时分别从已经训练的数据以及未训练数据（剩余 40%）中，随机抽取 200 张经过随机旋转和不同亮暗变化的图片进行测试，以模拟真实情况中可能发生的旋转以及光线变化的情况下获取的数据，以此检测模型鲁棒性。本论文使用如图 5.4 所示的十个形状的纹理图片分别训练十个模型，统计出各项指标如表 5.3 所示。结果中第一行是使用中心损失函数 [144] 对模型进行训练，使用 $\log_softmax$ 处理输出的特征向量，以此进行真假区分，第二行是仅使用交叉熵损失函数来对模型进行训练，第三行是使用本论文提出的损失函数训练模型，后两个实验皆使用 $\lambda = 0$ 作为真伪区分阈值。从数据中可见，相较于前两种损失函数进行纹理识别模型的训练，本论文使用的损失函数在准确率、召回率、F1 分数上都有提升。

由于薄膜图案纹理较为相似且模型在训练时可能存在一定的训练误差，这使得

表 5.3: 基于类激活值的损失函数验证效果 ($\lambda = 0$)

	准确率/%	精确率/%	召回率/%	F1 分数/%
中心损失	69.5	68.833	73.75	70.510
交叉熵	89.692	96.786	82.322	88.539
本文方法	92.45	87.519	99.167	92.955

一些伪样本的某些特征位于真样本的解空间内，导致伪样本在验证时容易被错分为真样本。如果使用损失函数中设置的阈值 0 来进行区分，可能无法获得比较满意的结果。为此本论文选取多个 λ 值来进行实验，以寻找最优的阈值。结果如表5.4所示，随着阈值增大，假正例减少，假反例增多，这使得精确率逐渐增大而召回率不断减小，为了使模型达到最佳效果，本方法使用阈值 $\lambda = 8$ 进行验证实验。

表 5.4: 不同阈值设定对比结果

λ	准确率/%	精确率/%	召回率/%	F1 分数/%
0	92.45	87.52	99.17	92.95
2	93.8	89.74	99	94.13
4	94.48	91.53	98.09	94.68
6	95.15	93.18	97.5	95.27
8	95.68	95.26	96.2	95.69
10	95.55	96.17	94.95	94.89
12	95.03	96.93	93.1	94.89

5.2.5 模型检测结果及性能分析

模型整体准确率由形状识别和纹理识别共同决定，检测结果如表5.5所示，总体识别率约为 95.67%。与此同时，验证的时间花费也是防伪检测中较为关注的要点，这影响到用户的使用体验。为此在本节中增加了对模型预测时间的统计对比，结果如表5.5所示，大部分时间花费在纹理模型的加载过程中。本方法相对于使用相同数据的 Lin 等人的方法 [135]，一张图片的形状检测和纹理检测时间都被大大缩减。

表 5.5: 准确率及单张图片检测时间对比结果

	准确率/%	形状检测时间/s	纹理检测模型加载时间/s	纹理检测时间/s	总时间/s
Lin 等 [135]	97.9	0.49	-	2.2	2.69
本文方法	95.67	0.1305	0.441	0.065	0.6365

5.3 本章小结

本章针对钙钛矿晶体薄膜图案防伪标签，设计了一种基于轻量级网络的防伪检测识别方法。在形状检测任务中通过微调基础模型提高了形状识别准确率，在纹理检测任务中通过引入 CA 模块增加了网络对特征图上位置信息的关注，并通过设计损失函数增强模型对真伪样本的区分度，提升模型纹理检测准确率。实验结果表明，本方法能在低资源消耗、低存储占用的前提下，完成对具有不规整形状和复杂纹理的钙钛矿晶体薄膜图案的处理，且能达到较高的识别准确率。

本方法是轻量级网络在防伪检测任务上的探索，有很多不足之处需要改进。虽然模型相比于现有算法在速度和性能上有所提升，但识别准确率与传统图像处理方法之间仍然存在一定的差距，具有较大的改进空间。

第六章 总结与展望

6.1 结论

材料中复杂的微观结构导致其图像处理难度较大，传统的图像处理方法很难取得较为优秀的处理结果，也无法准确提取出材料中的各组织参数。因此，有效的复杂材料图像处理方法研究，有助于促进材料的进一步研究。本论文针对几种具有复杂纹理材料图像，提出不同的方法，对其进行处理，即：

- (1) 面向复杂纹理材料图像分割的复杂网络理论方法。首先，本论文对材料图像构建复杂网络拓扑结构，使用复杂网络描述材料物相之间关系信息；在此期间，设置两个参数 R 和 T 帮助完成图像的网络拓扑结构构建；接着，通过复杂网络的动态演化获得不同状态的社区结构；最后，提出 RT -模块度来对特征的提取效果进行评价，完成分割任务。该方法将原本模块度计算的 NP-hard 问题转换为两个参数的优化问题，实现了复杂纹理材料图像的分割。
- (2) 面向复杂纹理钙钛矿晶体薄膜图案的传统图像处理方法。该方法将防伪检测过程分为形状检测和纹理检测两个部分，首先，使用形状空间理论中的 CNL 方法提取形状特征信息；其次，使用形状空间理论中的距离度量方法和改进的霍夫圆检测方法完成形状识别；接着，利用形状信息定位薄膜图案数据库；然后，使用 ORB 算法提取纹理特征信息；最后，使用 GMS 算法匹配纹理信息，完成识别验证。该方法通过形状特征加速匹配流程，大大缩短了检测时间，完成了复杂纹理薄膜图案的识别检测。
- (3) 面向复杂纹理钙钛矿晶体薄膜图案的深度学习方法。本方法沿用形状分类思想，将处理过程分为形状检测和纹理识别两部分。首先，通过微调模型完成薄膜图案形状特征信息处理；接着，通过引入协调注意力机制增强模型的纹理分类效果；然后，通过设计损失函数拉大真伪样本差异；最后，利用阈值对样本特征向量各元素中的最大值进行筛选，完成真伪样本判别。该方法摒弃了传统一一对比的方式处理纹理信息，而是使用轻量级神经网络完成识别检测，在低资源占

用的情况下，通过对比特征向量各元素的最大值与阈值的关系，实现仅有真样本情况下的钙钛矿晶体薄膜图案的真伪检测任务。

本论文对以上三个方法进行了实验验证，实验表明这些方法处理具有复杂纹理的材料图像时都具有较好的准确率以及鲁棒性，具有较高的实用价值。这为快速提取材料中的各物相参数提供了数据基础，也为加快材料的制备、新材料的研发及推广应用起到了一定的促进作用。

6.2 工作展望

尽管本论文的方法能够很好的处理具有复杂纹理的材料图像，但是由于不同的材料其纹理复杂且差异巨大，这导致了目前方法仍然有很大的局限性。为了进一步提高本论文方法的有效性，本论文可以在以下几个方面进一步深入研究：

- (1) 优化 RT -模块度参数，提高复杂网络理论方法处理材料图像的速度。复杂网络的特性使得此类算法在面对具有复杂纹理的图片时可获得明显的连通区域，通过社区检测便能实现对图像的分割。但是复杂网络需要动态演化以获取最佳网络拓扑，这个过程消耗了大量的时间和算力。因此可以从公式出发，对复杂网络的最优参数进行范围定位，从而快速高效的完成处理。
- (2) 融合多种不同特征，提高图像的匹配检测准确率。传统的图像处理方式具有较高的准确率但拓展性较差，基于深度学习的图像处理方式自主学习能力很强但需要大量数据进行指导和训练，对数据要求较高。因此寻找一条两者结合的道路，利用传统图像处理提取的特征进行深度学习，将多种特征进行融合并做特征筛选可以极大程度提高最终的匹配检测准确率。
- (3) 平衡深度学习中参数量和精度的关系。在本论文的轻量级模型中，参数量与精度之间存在一定的关联：全连接层神经元数目的增多使得模型的参数量大大增加，并带来了模型精度的提升，但引入 CA 注意力机制却能使模型在参数量基本不变的情况下提高准确率。因此，在未来可以降低模型全连接层神经元的数

目，引入更轻量的模块挖掘图像数据内的隐藏信息，使得模型能在更低的资源占用下获得更好的识别检测效果。

以上方法仍需要不断的探索和实验才能取得一定的成果，未来任重且道远。

参考文献

- [1] Kalinin S V, Sumpter B G, Archibald R K. Big-deep-smart data in imaging for guiding materials design[J]. *Nature materials*, 2015, 14(10): 973-980.
- [2] Xu Y, Zhang Y, Zhang M, et al. Quantitative analysis of metallographic image using attention-aware deep neural networks[J]. *Sensors*, 2020, 21(1): 43.
- [3] Korniy V, Rusyn B, Lysak Y, et al. Quantitative analysis of metallographic images[C]// 2006 International Conference-Modern Problems of Radio Engineering, Telecommunications, and Computer Science. IEEE, 2006: 251-252.
- [4] Broderick S, Suh C, Nowers J, et al. Informatics for combinatorial materials science[J]. *Jom*, 2008, 60(3): 56-59.
- [5] DeCost B L, Holm E A. A computer vision approach for automated analysis and classification of microstructural image data[J]. *Computational materials science*, 2015, 110: 126-133.
- [6] Alsmadi M K. Content-based image retrieval using color, shape and texture descriptors and features[J]. *Arabian Journal for Science and Engineering*, 2020, 45(4): 3317-3330.
- [7] Zhang H, Peng L, Yu S, et al. Detection of surface defects in ceramic tiles with complex texture[J]. *IEEE Access*, 2021, 9: 92788-92797.
- [8] Wang Y, Han Y, Lin C, et al. Effect of spraying power on the morphology of ysz splat and micro-structure of thermal barrier coating[J]. *Ceramics International*, 2021, 47(13): 18956-18963.
- [9] Han Y, Li R, Zeng Y, et al. Automatic detection of kikuchi bands based on radon transform and ppht[J]. *Journal of Microscopy*, 2022, 285(2): 95-111.
- [10] Han Y, Lai C, Wang B, et al. Segmenting images with complex textures by using hybrid algorithm[J]. *Journal of Electronic Imaging*, 2019, 28(1): 013030.
- [11] Han Y, Lai C, Wang B, et al. Segmentation and analysis method for two-phase ceramic (hfb2-b4c) based on the detection of virtual boundaries[J]. *Image Analysis & Stereology*, 2019, 38(1): 95-105.

- [12] Aksoy B, Salman O K M. A new hybrid filter approach for image processing[J]. Sakarya University Journal of Computer and Information Sciences, 2020, 3(3): 334-342.
- [13] Takahashi T, Kudo Y, Ishiyama R. Mass-produced parts traceability system based on automated scanning of “fingerprint of things” [C]//2017 fifteenth IAPR international conference on machine vision applications (MVA). IEEE, 2017: 202-206.
- [14] Tang Z, Liu X, Liu X, et al. Unclonable anti-counterfeiting labels based on plasmonic-patterned nanostructures[J]. Advanced Engineering Materials: 2101701.
- [15] Barabasi A L, Oltvai Z N. Network biology: understanding the cell’s functional organization[J]. Nature reviews genetics, 2004, 5(2): 101-113.
- [16] Newman M E, Park J. Why social networks are different from other types of networks [J]. Physical review E, 2003, 68(3): 036122.
- [17] Amaral L A N, Ottino J M. Complex networks - augmenting the framework for the study of complex systems[J]. European Physical Journal B – Condensed Matter, 2004, 38(38): 147-162.
- [18] Backes A R, Casanova D, Bruno O M. Texture analysis and classification: A complex network-based approach[J]. Information Sciences, 2013, 219: 168-180.
- [19] Gonçaves W N, Martinez A S, Bruno O M. Complex network classification using partially self-avoiding deterministic walks[J]. Chaos: An Interdisciplinary Journal of Nonlinear Science, 2012, 22(3): 033139.
- [20] Goncalves W N, Machado B B, Bruno O M. A complex network approach for dynamic texture recognition[J]. Neurocomputing, 2015, 153(4): 211-220.
- [21] Pelletier L, O’ Toole E, Schwager A, et al. Centriole assembly in caenorhabditis elegans [J]. Nature, 2006, 444(7119): 619-623.
- [22] Ravasz E, Barabási A L. Hierarchical organization in complex networks[J]. Physical review E, 2003, 67(2): 026112.
- [23] Backes A R, Casanova D, Bruno O M. A complex network-based approach for boundary shape analysis[J]. Pattern Recognition, 2009, 42(1): 54-67.

- [24] Backes A R, Bruno O M. Shape classification using complex network and multi-scale fractal dimension[J]. Pattern Recognition Letters, 2010, 31(1): 44-51.
- [25] Scabini L F, Condori R H, Gonçalves W N, et al. Multilayer complex network descriptors for color–texture characterization[J]. Information Sciences, 2019, 491: 30-47.
- [26] Imani Z, Soltanizadeh H. Histogram of the node strength and histogram of the edge weight: two new features for rgb-d person re-identification[J]. Science China Information Sciences, 2018, 61(9): 1-14.
- [27] Abin A A, Mahdisoltani F, Beigy H. Wisecode: wise image segmentation based on community detection[J]. The Imaging Science Journal, 2014, 62(6): 327-336.
- [28] Newman M E, Girvan M. Finding and evaluating community structure in networks[J]. Physical review E, 2004, 69(2): 026113.
- [29] Newman M E. Modularity and community structure in networks[J]. Proceedings of the national academy of sciences, 2006, 103(23): 8577-8582.
- [30] Li W. Modularity segmentation[C]//International Conference on Neural Information Processing. Springer, 2013: 100-107.
- [31] Li S, Wu D O. Modularity-based image segmentation[J]. IEEE Transactions on Circuits and Systems for Video Technology, 2015, 25(4): 570-581.
- [32] Linares O A, Botelho G M, Rodrigues F A, et al. Segmentation of large images based on super-pixels and community detection in graphs[J]. IET Image Processing, 2017, 11(12): 1219-1228.
- [33] Nguyen T K, Coustaty M, Guillaume J L. A new image segmentation approach based on the louvain algorithm[C]//2018 International Conference on Content-Based Multimedia Indexing (CBMI). IEEE, 2018: 1-6.
- [34] Nguyen T K, Coustaty M, Guillaume J L. A combination of histogram of oriented gradients and color features to cooperate with louvain method based image segmentation. [C]//VISIGRAPP (4: VISAPP). 2019: 280-291.

- [35] Gammoudi I, Mahjoub M A. Brain tumor segmentation using community detection algorithm[C]//2021 International Conference on Cyberworlds (CW). IEEE, 2021: 57-63.
- [36] Gonzalez R C. Digital image processing[M]. Pearson education india, 2009.
- [37] Sharma N, Mishra M, Shrivastava M. Colour image segmentation techniques and issues: an approach[J]. International Journal of Scientific & Technology Research, 2012, 1(4): 9-12.
- [38] Ning J, Zhang L, Zhang D, et al. Interactive image segmentation by maximal similarity based region merging[J]. Pattern Recognition, 2010, 43(2): 445-456.
- [39] Roerdink J B, Meijster A. The watershed transform: Definitions, algorithms and parallelization strategies[J]. Fundamenta informaticae, 2000, 41(1, 2): 187-228.
- [40] Shi J, Malik J. Normalized cuts and image segmentation[J]. IEEE Transactions on pattern analysis and machine intelligence, 2000, 22(8): 888-905.
- [41] Felzenszwalb P F, Huttenlocher D P. Efficient graph-based image segmentation[J]. International journal of computer vision, 2004, 59(2): 167-181.
- [42] Chatterjee O, Das K, Dutta S, et al. Phase extraction and boundary removal in dual phase steel micrographs[C]//2010 Annual IEEE India Conference (INDICON). IEEE, 2010: 1-5.
- [43] 裘俊彦, 潘安霞. 基于形态学的球墨铸铁金相组织分割算法研究[J]. 铸造, 2014, 63(9): 906-909.
- [44] Ananyev M, Medvedev D, Gavriyuk A, et al. Cu and gd co-doped baceo3 proton conductors: experimental vs sem image algorithmic-segmentation results[J]. Electrochimica Acta, 2014, 125: 371-379.
- [45] Lopez P, Lira J, Hein I. Discrimination of ceramic types using digital image processing by means of morphological filters[J]. Archaeometry, 2015, 57(1): 146-162.
- [46] Sun Q D, Gao S F, Huang J W, et al. Metallographical image segmentation and compression[C]//Applied Mechanics and Materials: volume 152. Trans Tech Publ, 2012: 276-280.

- [47] Sun Q D, Qiu Y P, Yan W Y, et al. Steel microscopic image preprocessing and its grain features extraction[C]//Advanced Materials Research: volume 740. Trans Tech Publ, 2013: 591-596.
- [48] 陈岳林, 汪杰君. 金相组织定量识别分析研究[J]. 特种铸造及有色合金, 2005, 25(3): 135-137.
- [49] Tang G, Chen L, Wang Z, et al. Faithful fabrication of biocompatible multicompartamental memomicrospheres for digitally color-tunable barcoding[J]. Small, 2020, 16(24): 1907586.
- [50] Kim M S, Lee G J, Leem J W, et al. Revisiting silk: a lens-free optical physical unclonable function[J]. Nature Communications, 2022, 13(1): 1-12.
- [51] Liu J, Chen J. An improved iterative watershed according to ridge detection for segmentation of metallographic image[J]. Metallographic Image, 2012, 1(1): 8-13.
- [52] Chen Y, Chen J. A watershed segmentation algorithm based on ridge detection and rapid region merging[C]//2014 IEEE International Conference on Signal Processing, Communications and Computing (ICSPCC). IEEE, 2014: 420-424.
- [53] Lowe D G. Object recognition from local scale-invariant features[C]//Proceedings of the seventh IEEE international conference on computer vision: volume 2. IEEE, 1999: 1150-1157.
- [54] Lowe D G. Distinctive image features from scale-invariant keypoints[J]. International journal of computer vision, 2004, 60(2): 91-110.
- [55] Bay H, Tuytelaars T, Gool L V. Surf: Speeded up robust features[C]//European conference on computer vision. Springer, 2006: 404-417.
- [56] Rublee E, Rabaud V, Konolige K, et al. Orb: An efficient alternative to sift or surf[C]//2011 International conference on computer vision. Ieee, 2011: 2564-2571.
- [57] Han F, Liu Y, Li F, et al. Self-assembly of coordination polymers on plasmonic surfaces for computer vision decodable, unclonable and colorful security labels[J]. Journal of Materials Chemistry C, 2019, 7(42): 13040-13046.

- [58] Duda R O, Hart P E, et al. Pattern classification and scene analysis: volume 3[M]. Wiley New York, 1973.
- [59] Prewitt J M, et al. Object enhancement and extraction[J]. Picture processing and Psychopictorics, 1970, 10(1): 15-19.
- [60] Marr D, Hildreth E. Theory of edge detection[J]. Proceedings of the Royal Society of London. Series B. Biological Sciences, 1980, 207(1167): 187-217.
- [61] Canny J. A computational approach to edge detection[J]. IEEE Transactions on pattern analysis and machine intelligence, 1986(6): 679-698.
- [62] Kass M, Witkin A, Terzopoulos D. Snakes: Active contour models[J]. International journal of computer vision, 1988, 1(4): 321-331.
- [63] Wang Q, Li X, Chang T, et al. Nondestructive imaging of hidden defects in aircraft sandwich composites using terahertz time-domain spectroscopy[J]. Infrared Physics & Technology, 2019, 97: 326-340.
- [64] Pham D L, Prince J L. An adaptive fuzzy c-means algorithm for image segmentation in the presence of intensity inhomogeneities[J]. Pattern recognition letters, 1999, 20(1): 57-68.
- [65] Chen L, Han Y, Cui B, et al. Two-dimensional fuzzy clustering algorithm (2dfcm) for metallographic image segmentation based on spatial information[C]//2015 2nd International Conference on Information Science and Control Engineering. IEEE, 2015: 519-521.
- [66] Velichko A, Holzapfel C, Mücklich F. 3d characterization of graphite morphologies in cast iron[J/OL]. Advanced Engineering Materials, 2007, 9(1-2): 39-45. <https://onlinelibrary.wiley.com/doi/abs/10.1002/adem.200600175>. DOI: <https://doi.org/10.1002/adem.200600175>.
- [67] Gola J, Britz D, Staudt T, et al. Advanced microstructure classification by data mining methods[J]. Computational Materials Science, 2018, 148: 324-335.
- [68] 陈念贻, 陆文聪, 刘旭, 等. 支持向量机算法在冶金和材料科学中的应用[J]. 中国稀土学报, 2004(z1): 255-258.

- [69] Kai H E, Pang P F, Zhang W W, et al. Automatic classification method for low-dimensional nanomaterials based on sem image[J]. *Nanotechnology and Precision Engineering*, 2012, 10(1): 24-29.
- [70] Marconcini M, Camps-Valls G, Bruzzone L. A composite semisupervised svm for classification of hyperspectral images[J]. *IEEE Geoscience and Remote Sensing Letters*, 2009, 6(2): 234-238.
- [71] Zhao H, Comer M. A hybrid markov random field/marked point process model for analysis of materials images[J]. *IEEE Transactions on Computational Imaging*, 2016, 2(4): 395-407.
- [72] Heung B, Bulmer C E, Schmidt M G. Predictive soil parent material mapping at a regional-scale: a random forest approach[J]. *Geoderma*, 2014, 214: 141-154.
- [73] Wang Q, Ma S, Yue D. Identification of damage in composite structures using gaussian mixture model-processed lamb waves[J]. *Smart Materials and Structures*, 2018, 27(4): 045007.
- [74] De Albuquerque V H C, Cortez P C, de Alexandria A R, et al. A new solution for automatic microstructures analysis from images based on a backpropagation artificial neural network[J]. *Nondestructive Testing and Evaluation*, 2008, 23(4): 273-283.
- [75] Dengiz O, Smith A E, Nettleship I. Grain boundary detection in microstructure images using computational intelligence[J]. *Computers in industry*, 2005, 56(8-9): 854-866.
- [76] DeCost B L, Lei B, Francis T, et al. High throughput quantitative metallography for complex microstructures using deep learning: A case study in ultrahigh carbon steel[J]. *Microscopy and Microanalysis*, 2019, 25(1): 21-29.
- [77] Azimi S M, Britz D, Engstler M, et al. Advanced steel microstructural classification by deep learning methods[J]. *Scientific reports*, 2018, 8(1): 1-14.
- [78] Yang Z, Li X, Brinson L C, et al. Microstructural materials design via deep adversarial learning methodology[J/OL]. *Journal of Mechanical Design*, 2018, 140(11). <https://doi.org/10.1115%2F1.4041371>. DOI: 10.1115/1.4041371.

- [79] Giben X, Patel V M, Chellappa R. Material classification and semantic segmentation of railway track images with deep convolutional neural networks[C]//2015 IEEE International Conference on Image Processing (ICIP). IEEE, 2015: 621-625.
- [80] Gibert X, Patel V M, Chellappa R. Deep multitask learning for railway track inspection [J]. IEEE transactions on intelligent transportation systems, 2016, 18(1): 153-164.
- [81] Mulewicz B, Korpala G, Kusiak J, et al. Autonomous interpretation of the microstructure of steels and special alloys[C]//Materials Science Forum: volume 949. Trans Tech Publ, 2019: 24-31.
- [82] Zheng X, Zhu Y, Liu Y, et al. Inkjet-printed quantum dot fluorescent security labels with triple-level optical encryption[J]. ACS Applied Materials & Interfaces, 2021, 13(13): 15701-15708.
- [83] Han Y, Yang S, Chen Q. Recognition and segmentation of complex texture images based on superpixel algorithm and deep learning[J/OL]. Computational Materials Science, 2022, 209: 111398. <https://www.sciencedirect.com/science/article/pii/S0927025622001690>. DOI: <https://doi.org/10.1016/j.commatsci.2022.111398>.
- [84] Erdos P, Renyi A. On random graphs[J]. Publications Mathematicae, 1959, 6: 290-297.
- [85] Erds P, Rényi A. On the strength of connectedness of a random graph[J]. Acta Mathematica Academiae Scientiarum Hungarica, 1964, 12(1): 261-267.
- [86] Watts D J, Strogatz S H. Collective dynamics of small-world networks[J]. Nature, 1998, 393(6684): 440-442.
- [87] Barabási A L, Albert R. Emergence of scaling in random networks[J]. Science, 1999, 286 (5439): 509-512.
- [88] Boccaletti S, Latora V, Moreno Y, et al. Complex networks: Structure and dynamics[J]. Physics reports, 2006, 424(4-5): 175-308.
- [89] Lesne A. Complex networks: from graph theory to biology[J]. Letters in Mathematical Physics, 2006, 78(3): 235-262.

- [90] 贾进章, 刘剑, 宋寿森. 基于邻接矩阵图的连通性判定准则[J]. 辽宁工程技术大学学报 (自然科学版), 2003, 22(2): 158-160.
- [91] Mao G, Zhang N. Analysis of average shortest-path length of scale-free network[J]. Journal of Applied Mathematics, 2013, 2013.
- [92] Dijkstra E W, et al. A note on two problems in connexion with graphs[J]. Numerische mathematik, 1959, 1(1): 269-271.
- [93] MacQueen J, et al. Some methods for classification and analysis of multivariate observations[C]//Proceedings of the fifth Berkeley symposium on mathematical statistics and probability: volume 1. Oakland, CA, USA, 1967: 281-297.
- [94] Kendall D G. Shape manifolds, procrustean metrics, and complex projective spaces[J]. Bulletin of the London mathematical society, 1984, 16(2): 81-121.
- [95] Stoyan D, Kendall W S, Chiu S N, et al. Stochastic geometry and its applications[M]. John Wiley & Sons, 1995.
- [96] Small C G. The statistical theory of shape[M]. Springer Science & Business Media, 1996.
- [97] Han Y, Wang B, Idesawa M, et al. Recognition of multiple configurations of objects with limited data[J]. Pattern Recognition, 2010, 43(4): 1467-1475.
- [98] Han Y, Koike H, Idesawa M. Recognizing objects with multiple configurations[J]. Pattern Analysis and Applications, 2014, 17(1): 195-209.
- [99] Rosten E, Drummond T. Machine learning for high-speed corner detection[C]//European conference on computer vision. Springer, 2006: 430-443.
- [100] Harris C, Stephens M, et al. A combined corner and edge detector[C]//Alvey vision conference: volume 15. Citeseer, 1988: 10-5244.
- [101] Calonder M, Lepetit V, Strecha C, et al. Brief: Binary robust independent elementary features[C]//European conference on computer vision. Springer, 2010: 778-792.
- [102] Hamming R W. Error detecting and error correcting codes[J]. The Bell system technical journal, 1950, 29(2): 147-160.

- [103] Bian J, Lin W Y, Matsushita Y, et al. Gms: Grid-based motion statistics for fast, ultra-robust feature correspondence[C]//Proceedings of the IEEE conference on computer vision and pattern recognition. 2017: 4181-4190.
- [104] Krizhevsky A, Sutskever I, Hinton G E. Imagenet classification with deep convolutional neural networks[J]. Advances in neural information processing systems, 2012, 25: 1097-1105.
- [105] Simonyan K, Zisserman A. Very deep convolutional networks for large-scale image recognition[M/OL]. arXiv, 2014. <https://arxiv.org/abs/1409.1556>. DOI: 10.48550/ARXIV.1409.1556.
- [106] He K, Zhang X, Ren S, et al. Deep residual learning for image recognition[C]//Proceedings of the IEEE conference on computer vision and pattern recognition. 2016: 770-778.
- [107] Badrinarayanan V, Kendall A, Cipolla R. Segnet: A deep convolutional encoder-decoder architecture for image segmentation[J]. IEEE Transactions on Pattern Analysis & Machine Intelligence, 2017: 1-1.
- [108] Howard A G, Zhu M, Chen B, et al. Mobilenets: Efficient convolutional neural networks for mobile vision applications[M/OL]. arXiv, 2017. <https://arxiv.org/abs/1704.04861>. DOI: 10.48550/ARXIV.1704.04861.
- [109] Sandler M, Howard A, Zhu M, et al. Mobilenetv2: Inverted residuals and linear bottlenecks[C]//Proceedings of the IEEE conference on computer vision and pattern recognition. 2018: 4510-4520.
- [110] Howard A, Sandler M, Chu G, et al. Searching for mobilenetv3[C]//Proceedings of the IEEE/CVF International Conference on Computer Vision. 2019: 1314-1324.
- [111] Fukushima K, Miyake S. Neocognitron: A self-organizing neural network model for a mechanism of visual pattern recognition[M]//Competition and cooperation in neural nets. Springer, 1982: 267-285.
- [112] Cadieu C F, Hong H, Yamins D L, et al. Deep neural networks rival the representation of primate it cortex for core visual object recognition[J]. PLoS computational biology, 2014, 10(12): e1003963.

- [113] Rumelhart D E, Hinton G E, Williams R J. Learning representations by back-propagating errors[J]. *nature*, 1986, 323(6088): 533-536.
- [114] LeCun Y, Bengio Y, Hinton G. Deep learning[J]. *nature*, 2015, 521(7553): 436-444.
- [115] Guo Y, Liu Y, Oerlemans A, et al. Deep learning for visual understanding: A review[J]. *Neurocomputing*, 2016, 187: 27-48.
- [116] Kalan S M M, Soltanolkotabi M, Avestimehr A S. Fitting relus via sgd and quantized sgd [C]//2019 IEEE International Symposium on Information Theory (ISIT). IEEE, 2019: 2469-2473.
- [117] Hu J, Shen L, Sun G. Squeeze-and-excitation networks[C]//Proceedings of the IEEE conference on computer vision and pattern recognition. 2018: 7132-7141.
- [118] Carro-Temboury M R, Arppe R, Vosch T, et al. An optical authentication system based on imaging of excitation-selected lanthanide luminescence[J]. *Science advances*, 2018, 4 (1): e1701384.
- [119] Cheng Y. Mean shift, mode seeking, and clustering[J]. *IEEE transactions on pattern analysis and machine intelligence*, 1995, 17(8): 790-799.
- [120] Xu R, Wunsch D. Survey of clustering algorithms[J]. *IEEE Transactions on neural networks*, 2005, 16(3): 645-678.
- [121] Sander J, Ester M, Kriegel H P, et al. Density-based clustering in spatial databases: The algorithm gdbscan and its applications[J]. *Data mining and knowledge discovery*, 1998, 2(2): 169-194.
- [122] Machado B B, Scabini L F, Margarido Orue J P, et al. A complex network approach for nanoparticle agglomeration analysis in nanoscale images[J]. *Journal of Nanoparticle Research*, 2017, 19(2): 1-11.
- [123] Brandes U, Delling D, Gaertler M, et al. On modularity clustering[J]. *IEEE transactions on knowledge and data engineering*, 2007, 20(2): 172-188.
- [124] Song J, Huang C, Lv M, et al. Effects of tic content and melt phase on microstructure and mechanical properties of ternary tib₂-based ceramic cutting tool materials[J]. *Materials Science and Engineering: A*, 2014, 605: 137-143.

- [125] Vallauri D, Adrián I A, Chrysanthou A. Tic-tib2 composites: A review of phase relationships, processing and properties[J]. *Journal of the European Ceramic Society*, 2008, 28(8): 1697-1713.
- [126] DeCost B L, Hecht M D, Francis T, et al. Uhcsdb: ultrahigh carbon steel micrograph database[J]. *Integrating Materials and Manufacturing Innovation*, 2017, 6(2): 197-205.
- [127] Cai W, Chen S, Zhang D. Fast and robust fuzzy c-means clustering algorithms incorporating local information for image segmentation[J]. *Pattern recognition*, 2007, 40(3): 825-838.
- [128] Long J, Shelhamer E, Darrell T. Fully convolutional networks for semantic segmentation [C]//*Proceedings of the IEEE conference on computer vision and pattern recognition*. 2015: 3431-3440.
- [129] Zhou Z, Rahman Siddiquee M M, Tajbakhsh N, et al. Unet++: A nested u-net architecture for medical image segmentation[M]//*Deep learning in medical image analysis and multimodal learning for clinical decision support*. Springer, 2018: 3-11.
- [130] Alom M Z, Hasan M, Yakopcic C, et al. Recurrent residual convolutional neural network based on u-net (r2u-net) for medical image segmentation[M/OL]. *arXiv*, 2018. <https://arxiv.org/abs/1802.06955>. DOI: 10.48550/ARXIV.1802.06955.
- [131] Breve F. Interactive image segmentation using label propagation through complex networks[J]. *Expert Systems With Applications*, 2019, 123: 18-33.
- [132] Fu Y, Zhu H, Chen J, et al. Metal halide perovskite nanostructures for optoelectronic applications and the study of physical properties[J]. *Nature Reviews Materials*, 2019, 4(3): 169-188.
- [133] Liu Y, Zheng Y, Zhu Y, et al. Unclonable perovskite fluorescent dots with fingerprint pattern for multilevel anticounterfeiting[J]. *ACS Applied Materials & Interfaces*, 2020, 12(35): 39649-39656.
- [134] Bay H, Ess A, Tuytelaars T, et al. Speeded-up robust features (surf)[J]. *Computer vision and image understanding*, 2008, 110(3): 346-359.

- [135] Lin Y, Zhang H, Feng J, et al. Unclonable micro-texture with clonable micro-shape towards rapid, convenient, and low-cost fluorescent anti-counterfeiting labels[J]. *Small*, 2021, 17(30): 2100244.
- [136] Illingworth J, Kittler J. A survey of the hough transform[J]. *Computer vision, graphics, and image processing*, 1988, 44(1): 87-116.
- [137] Gu Y, He C, Zhang Y, et al. Gap-enhanced raman tags for physically unclonable anti-counterfeiting labels[J]. *Nature communications*, 2020, 11(1): 1-13.
- [138] Liu Y, Han F, Li F, et al. Inkjet-printed unclonable quantum dot fluorescent anti-counterfeiting labels with artificial intelligence authentication[J]. *Nature communications*, 2019, 10(1): 1-9.
- [139] Jing L, Xie Q, Li H, et al. Multigenerational crumpling of 2d materials for anticounterfeiting patterns with deep learning authentication[J]. *Matter*, 2020, 3(6): 2160-2180.
- [140] Hou Q, Zhou D, Feng J. Coordinate attention for efficient mobile network design[C]// *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*. 2021: 13713-13722.
- [141] Ma N, Zhang X, Zheng H T, et al. Shufflenet v2: Practical guidelines for efficient cnn architecture design[C]// *Proceedings of the European conference on computer vision (ECCV)*. 2018: 116-131.
- [142] Tan M, Le Q. Efficientnet: Rethinking model scaling for convolutional neural networks [C]// *International conference on machine learning*. PMLR, 2019: 6105-6114.
- [143] Chattopadhyay A, Sarkar A, Howlader P, et al. Grad-cam++: Generalized gradient-based visual explanations for deep convolutional networks[C]// *2018 IEEE winter conference on applications of computer vision (WACV)*. IEEE, 2018: 839-847.
- [144] Wen Y, Zhang K, Li Z, et al. A discriminative feature learning approach for deep face recognition[C]// *European conference on computer vision*. Springer, 2016: 499-515.

作者在攻读硕士学位期间公开发表的论文

攻读硕士期间论文发表情况：

1. “Unclonable Micro-Texture with Clonable Micro-Shape towards Rapid, Convenient, and Low-Cost Fluorescent Anti-Counterfeiting Labels”, in *Small*, June 2021 (联合一作, 已发表, SCI 一区)
2. “基于轻量级网络的防伪标签检测算法”, 上海大学学报 (自然科学版), 2022.4. (第一作者, 已录用, 中文核心)

攻读硕士期间专利获取情况：

1. “专利名称：不可复制防伪标签的薄膜图案数据库建立及分类识别方法”，发明人：韩越兴张宏坤巫金波王冰钱权。专利号专利号：ZL202011559042.0，授权日：2021 年 12 月 03 日，授权公告号：CN 112598008 B。(导师一作，本人二作，已授权)

攻读硕士期间软著获取情况：

1. “软件名称：不可复制防伪标签的薄膜图案数据库建立及分类识别软件 V1.0”，创作人：韩越兴，张宏坤，登记号：2019SR0944666，申请人：上海大学，开发完成日期：2019 年 7 月 31 日，登记日期：2019 年 9 月 11 日。

致谢

光阴荏苒，日月如梭。转眼间已经二十有六，人生的求学之路也已经告一段落，每每想到此事不禁心生空寂。回想求学岁月，对曾经帮助过我的老师同学不禁心生感激。

首先，要感谢我的导师韩越兴老师。本论文是在导师韩越兴老师的悉心指导下完成的。对我而言，韩老师是一个亦师亦友存在，韩老师对于学术严谨认真，具有敏锐的学术洞察力，对工作兢兢业业，一丝不苟，对于我们具有较高的要求，这也使得我养成了科学的思维和严谨的工作态度。在生活上韩老师乐观积极，谦和大气平易近人，十分关心我们的日常生活，对待学生真诚友善，是我学习的榜样。

其次，感谢父母的关心和呵护，给我一个温馨的港湾，让我可以在劳累的时候有一处停靠休息的地方；在我难过的时候可以抚慰我的心灵；在失落的时候能给我前进的动力。

另外，还要感谢陈侨川老师对我研究方面的指导，为我的科研之路指出问题，使我不断完善；感谢王冰老师对于我论文的指导，王老师对待科研认真的态度以及对待问题一针见血的洞察力令我十分敬重；感谢巫金波老师的数据支持，为我的实验以及材料知识方面提供的指导和帮助。

还要，感谢我的同门，博士学姐以及师兄师弟师妹们，感谢我的舍友，感谢所有帮助过我的老师、同学、朋友们，是你们与我风雨同舟，是你们的支持以及乐观积极的态度感染了我，给了我不断学习提高的动力，成就了现在的自己。

最后，向百忙中抽出时间的盲审专家和各位答辩老师致以最衷心的感谢，谢谢你们。