

分类号: TP391

密 级: 公开

学校代码: 10363

学 号: 2210330172



安徽工程大学

Anhui Polytechnic University

硕士学位论文

题 目

基于深度学习的计算全息

技术研究

论 文 作 者

李夏雨

校 内 导 师

韩超（教授）

校 外 导 师

郝旭耀（工程师）

专业学位类别

电子信息

研究方向（领域）

先进传感与检测技术

论文提交日期: 2024 年 5 月 31 日

分类号：TP391

单位代码：10363

密 级：公开

学 号：2210330172

题 目 基于深度学习的计算全息技术研究

题 目 Research on Computer-generated
Holographic Based on Deep Learning

论 文 作 者： 李夏雨

校 内 导 师： 韩超（教授）

校 外 导 师： 郝旭耀（工程师）

专业学位类别： 电子信息

研究方向（领域）： 先进传感与检测技术

论文答辩日期： 2024 年 5 月 23 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：李夏雨

日期：2024 年 5 月 25 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或部分内容编入有关数据库进行检索，可以采用影印、缩印或扫描等复制手段保存和汇编本学位论文。

保密 ☐，在 年解密后适用本版权书。

本学位论文属于

不保密 ☒。

学位论文作者签名：李夏雨

日期：2024 年 5 月 25 日

指导教师签名：韩超

日期：2024 年 5 月 25 日

基于深度学习的计算全息技术研究

摘要

光学全息显示技术利用光的干涉原理,实现了对物体光波振幅和相位的同步记录,由于光波的相位包含了物体的深度信息,因此重建记录的物光波时,物体的深度信息也被重建。计算机硬件和软件技术不断发展与进步中,计算全息显示技术应运而生。计算全息可通过模拟光波的干涉、衍射过程得到计算全息图,计算全息相比于光学全息包含更精确的深度信息,同时实验装备简单,全息图储存更加方便,其中纯相位计算全息图因其高效的衍射效率,成为目前主流显示方法之一。近年来,深度学习算法在技术的不断推进中逐步展现出其成熟的特质,随着图形处理器计算能力的提高,几乎所有的深度学习框架都支持图像处理工具包,这使得深度学习在去噪、超分辨率成像、图像识别等图像处理领域取得了良好的效果,深度学习也为解决计算全息领域的问题提供新的思路与启发。本文对基于深度学习的计算全息技术研究和实验进行展开,主要工作内容如下:

(1) 首先,阐释了光学全息显示技术与计算全息显示技术的基本原理,详细介绍了基于菲涅耳衍射的计算全息基本原理及三种衍射方法。其次,介绍了深度学习基本原理及典型的网络模型。最后,介绍了基于深度学习的计算全息显示技术原理。

(2) 针对传统迭代算法需在成像质量和计算速度之间进行权衡的问题,本文将自定义注意力残差块与卷积神经网络结合,构建注意力残差网络,通过训练网络,注意力模块提高网络对特征的提取能力,同时残差块防止网络的过拟合,在快速生成全息图的同时提升重建像质量。软件仿真和光学实验验证了所提算法的可行性。

(3) 针对迭代方法得到纯相位全息图伴随的散斑噪声问题,本文提出将注意力残差块嵌入小波网络每一层卷积块之后,构建注意力小波残差网络。小波变换代替池化减小纯相位全息图的尺寸,注意力模块精准捕捉纯相位全息图噪声,残差块提高网络特征信息的融合能力。逆小波变换代替上采样得到去噪后的全息

图。仿真实验表明，改进后的网络能有效去除斑点噪声，同时获得高质量的全息图。

关键词：计算全息；深度学习；全息显示；相位优化；散斑去噪

RESEARCH ON COMPUTER-GENERATED HOLOGRAPHIC BASED ON DEEP LEARNING

ABSTRACT

Optical holographic display technology uses the principle of interference of light to realize the synchronous recording of the amplitude and phase of the object's light wave, and since the phase of the light wave contains the depth information of the object, the depth information of the object is also reconstructed when reconstructing the recorded object's light wave. In the continuous development and progress of computer hardware and software technology, computational holographic display technology came into being. Computational holography can be obtained by simulating the interference and diffraction process of light waves, computational holography contains more accurate depth information than optical holography, while the experimental equipment is simple, the hologram is more convenient to store, which is due to the high diffraction efficiency of the pure phase computational hologram, which has become one of the mainstream display methods. In recent years, the development of deep learning algorithms has gradually matured, with the improvement of the computing power of the graphics processor, almost all deep learning frameworks support image processing toolkit, which makes deep learning in the field of image processing such as denoising, super-resolution imaging, image recognition and other image processing has achieved good results, and deep learning is also for solving the problem of computational holography to provide a new way of thinking. In this paper, we launch the research and experimentation on deep learning based computational holography, and the main work is as follows:

- (1) The basic principles of optical holographic display and

computational holographic display are introduced, and the basic principles of computational holography based on Fresnel diffraction and based on the theory of angular spectrum diffraction are explained in detail. The basic principle of deep learning and typical network model are introduced, and the principle of computational holographic display technology based on deep learning is elaborated.

(2) For the traditional iterative algorithm, which needs to trade-off between imaging quality and computational speed, this paper combines the customized attention residual block with the convolutional neural network to construct the attention residual network. By training the network, the attention module improves the feature extraction ability of the network, and at the same time, the residual block prevents the network from overfitting, so as to improve the quality of the holograms while generating the holograms quickly. Software simulation and optical experiments show the feasibility of the proposed algorithm.

(3) Aiming at the speckle noise problem accompanying the pure phase hologram obtained by the iterative method, this paper proposes to construct the attention wavelet residual network by embedding the attention residual block into the wavelet network after each layer of convolution block. Wavelet transform instead of pooling reduces the size of the pure phase hologram, the attention block accurately captures the pure phase hologram noise, and the residual block improves the fusion ability of the network feature information. The inverse wavelet transform replaces upsampling to get the denoised hologram. Simulation experiments show that the improved network can effectively remove speckle noise while obtaining high-quality holograms.

KEY WORDS: computational holography, deep learning, holographic

display, phase optimization, speckle denoising

目录

摘要	I
ABSTRACT.....	III
第 1 章 绪论.....	1
1.1 课题研究背景及意义.....	1
1.2 国内外研究现状.....	2
1.2.1 计算全息发展概况	2
1.2.2 深度学习发展概况	4
1.2.3 基于深度学习的计算全息概况.....	6
1.3 本文主要研究内容和结构安排.....	9
第 2 章 计算全息和深度学习基本原理.....	11
2.1 全息显示基本原理.....	11
2.1.1 光学全息显示的基本原理.....	11
2.1.2 计算全息显示的基本原理.....	13
2.2 计算全息的衍射模型.....	14
2.2.1 菲涅耳衍射模型基本原理.....	14
2.2.2 菲涅耳衍射常用计算方法.....	15
2.3 深度学习基本原理.....	18
2.3.1 深度学习背景介绍	18
2.3.2 典型网络模型介绍	19
2.4 基于深度学习的计算全息技术.....	23
2.5 本章小结	25
第 3 章 基于卷积神经网络的纯相位全息图生成.....	26
3.1 基于卷积神经网络的纯相位全息图生成原理.....	26
3.1.1 纯相位全息图生成流程.....	26
3.1.2 角谱传播模型原理	26
3.2 网络结构	27
3.2.1 神经网络的结构	27
3.2.2 注意力残差模块	28
3.2.3 损失函数	30
3.2.4 数据集	31
3.3 数值仿真与分析.....	31
3.3.1 重建图像质量的评价标准.....	31
3.3.2 重建结果与分析	32
3.4 光学实验结果分析.....	34
3.4.1 实验光路图	34
3.4.2 光学重建结果	35
3.5 本章小结	37
第 4 章 基于注意小波残差网络的纯相位全息图去噪算法.....	38
4.1 散斑噪声和去噪原理.....	38

4.1.1 全息图中散斑噪声模型.....	38
4.1.1 离散小波去噪原理	39
4.2 网络结构介绍.....	40
4.2.1 基本网络结构	40
4.2.2 数据集制作	42
4.2.4 损失函数	42
4.3 仿真实验结果分析.....	43
4.3.1 测试图去噪实验	43
4.3.2 不同噪声全息图降噪实验对比.....	44
4.4 光学实验结果分析.....	47
4.5 本章小结	47
第 5 章 总结与展望.....	48
5.1 本文总结	48
5.2 下一步工作展望.....	48
参考文献.....	50
攻读硕士期间发表的文章.....	56
致 谢	57

第 1 章 绪论

1.1 课题研究背景及意义

在人类从真实世界获取的信息中，视觉信息占据了至关重要的地位，其比重高达约八成^[1]，大脑要耗费近一半的算力去处理获取的视觉信息。在真实世界中，三维物体不断训练着人类大脑的视觉感知和理解力，使人类大脑和眼睛不断适应三维立体场景，然而目前主流的显示技术多基于二维平面，面临着深度信息匮乏以及逼真度不足等问题。探索新型显示技术，更加还原真实世界，是目前显示领域重要目标之一。

随着科学技术的飞速发展，全息显示技术再次成为国内外研究领域关注的焦点。显示技术的起源可以追溯到 1948 年，英国科学家 Dennis Gabor 于 1948 年首次提出了全息术的概念^[2]。全息术能全方位的捕捉并记录物体光波的波前信息，基于全息图再现的重建像，可以再现出物体的全部信息供人眼感知。传统光学显示技术使用光学系统实现波前记录和重建，但光学实验光路搭设繁琐复杂，并且要求较高的精密度，同时获得的全息图不易保存，这些因素限制了光学全息在显示领域的发展。因实验设备繁琐、全息图难以保存等问题发展受到限制。随着图像处理单元计算能力的提高以及显示器件的不断更新，1966 年德国科学家 Lohmann 首次提出计算全息显示技术^[3]，并制成第一张计算全息图，从此全息显示技术再次得到新的发展，成为显示领域的主流方法之一。

计算全息技术基于衍射光学理论，首先构建一个精确的数学模型，以描述波前记录物理衍射传播过程的。随后，通过解析该模型所对应的逆问题，得以获取用于重建目标的计算全息图。因此计算全息不仅能得到真实图像全息图还能得到虚拟物体的全息图。在计算机飞速发展支持下的计算全息在多个显示场景中广泛应用，包括二维显示^[4]、真三维显示^[5]和体显示^[6-8]。其中，计算全息三维显示因能提供精确的深度信息，从根本上避免了由汇聚调焦冲突引起的视觉疲劳问题，重建像也具有强烈的真实感而被称为“光学等价物”，同时，可刷新动态空间光调制器的研制使得全息图实现动态重建，因此计算全息三维显示近年来应用广泛，

如车载抬头显示、娱乐设施显示、医学检测等。目前大多计算全息算法通过迭代的方法生成高质量的纯相位全息图，通过迭代的方式，将生成问题转化为求解最优化问题^[9-11]。迭代得到的全息图再现象质量高，收敛效果好，但迭代算法受限于收敛速度及散斑噪声的问题^[12]，同时动态空间光调制器难以实现振幅和相位同时调制，这在一定程度上制约了计算全息显示技术在商业领域的广泛应用。科学发展，科技进步，人工智能热潮的来临为计算全息的发展再添新的活力，深度学习为计算全息算法和光学成像提供更多可能性。

近年来，深度学习在众多领域飞速发展^[13-15]，其强大的数据处理能力、特征提取、非线性预测能力及泛化推广能力吸引计算全息算法与之相结合，同时卷积神经网络的提出，以及图像处理单元的商业化普及，使得基于深度学习的计算全息技术迅速发展^[16-18]。目前基于深度学习的计算全息技术根据网络训练中的约束差异，可划分为数据驱动深度学习和模型驱动深度学习两大类^[19]。数据驱动深度学习生成效果受限于数据集质量、规模和通用性，相对而言，模型驱动深度学习因其在模型构建和优化方面的优势，已成为当前深度学习计算全息技术发展的主要方向。模型驱动深度学习用菲涅耳衍射模型精确描述光场传播物理过程从而得到预测全息图重建结果，网络参数更新依据预测全息图重建结果和网络输入原图间的损失函数，使网络自主求解全息图的编码方式，不需要预制大量数据集，同时在更短的时间得到更优质全息图。基于深度学习的计算全息技术一定程度上解决了计算全息迭代算法存在的耗时、全息图含噪问题，未来将成为全息领域的有利工具。

本研究基于深度学习展开对计算全息技术的研究，将深度学习与计算全息算法相结合，模型驱动深度学习提高全息图的生成速度及质量，数据驱动深度学习对全息图进行去噪处理，提高已有全息图的重建质量。

1.2 国内外研究现状

1.2.1 计算全息发展概况

英国科学家 Dennis Gabor 在 1948 年提出全息术，利用光的干涉原理，参考

光波和物光波进行相互干涉,把物光波携带的相位和振幅信息以干涉条纹的形式精确记录在感光材料中,随后用特定激光照射选用的感光材料,再现出被记录物光波信息。传统的光学全息历经汞灯、激光、白光三个阶段,光学全息过程复杂,生成全息图结果不可控因素较多,因此发展较为缓慢。随着计算机的更新发展,1965年,Kozma和Kelly首次提出计算全息的概念^[20],同年,德国光学学者Lohmann等人结合计算机理论中的抽样定理提出迂回相位编码,生成第一张计算全息图,标志着计算全息技术真正意义上的起点。1967年,Paris采用快速傅里叶变换代替传统衍射计算方法,有效提高了计算全息图的生成速度^[21]。1969年,Lesem等人提出了相位型编码技术,该技术将物体表面的散射现象通过随机相位进行模拟,均匀分散了物体的低频信息^[22]。1971年,Ichioka等人提出将三维物体切分成平行于全息面的多个平面,并使用傅里叶变换计算全息面物光波阵面,这也是著名的“乒乓算法”^[23],随着可刷新动态空间光调制器的发展,动态三维全息显示发展迅速,1992年,美国麻省理工学院研究小组生成了第一张真彩色的实时三维全息图。

由于动态空间光调制器不能同时调制振幅和相位,因此目前纯相位全息显示是目前主流方法之一,纯相位全息图衍射效率高、无孪生像。振幅信息包含物体表面特性如颜色等,缺失振幅信息会导致全息图包含信息不完整,重建像质量较低,因此为改善计算机生成纯相位全息图生成质量,需要借助相位优化算法^[24]。1972, Gerchberg和Saxton根据全息平面和重建图像平面的振幅分布,通过反复迭代实现相位恢复,求得全息面光场信息,这就是著名的GS算法^[25]。此后大量的研究都基于GS算法进行改进,Alexander Kuzmenko等人提出加权GS算法,该方法在迭代计算中,将限制条件替换为振幅乘以一个分数形式的权重系数系统,该系统在迭代过程中变化并控制输入对象的振幅,收敛速率高于GS算法但存在无法收敛的情况^[26]。国内四川大学的伍旻等人提出一种自适应加权GS算法,通过构造指数形式的反馈系数,确保收敛的稳定性,同时提出一种近似二次相位来抑制光学重建中的伪影,提高重建像的质量^[27]。

1984年,R.Hauck等人提出的误差扩散算法是另一种类型的迭代算法,该算法的迭代对象不是全息面和物面,而是在全息平面的各个像素之间进行迭代,同

时误差扩散算法只需要复振幅全息图就能计算出纯相位全息图^[28]。在此基础上,东南大学的常琛亮等人提出用双系数误差扩散抑制散斑噪声^[29],安徽工程大学的周婷婷将分层角谱和误差扩散相结合用来生成三维物体的全息图^[30],清华大学的刘珂瑄等人^[31]提出图案自适应误差扩散算法,在误差函数的计算中,依据图像幅值分布情况和传播距离,设置了自适应调制因子,通过调制因子,算法能够为每个对象图案和每个传播距离获取优化的幅度值,光学实验证明该算法能有效提高再现质量。

除了迭代算法,一些非迭代算法也被广泛研究。非迭代算法无需优化过程,能直接得到全息图,因此计算速度较快,但重建质量通常不如迭代算法。1978年,Hsueh 等人^[32]提出一种创新的双相位编码方法,该方法基于欧拉公式,能成功将归一化复振幅编码为两个纯相位分量,再通过将两幅相位型全息图相干叠加,还原全息平面的复振幅场,基于此研究 Mendoza-Yero 等人^[33]进一步提出单像素编码法,该方法利用互补的二元光栅对分解后的双相位分量进行像素级精细采样,再将采样后的两个纯相位分量进行相加,从而得到纯相位全息图。Tsang 等人^[34]提出一种快速非迭代产生纯相位全息图的方法,即相位掩膜法。该方法在源图像上添加具有周期性相位图案的相位掩膜,并将其转换为全息图,由于相同的相位图案被添加到源图像中均匀分布的局部区域,因从相位全息图的重建图像将呈现出精细的像素化而非噪点外观。

除了迭代算法和非迭代算法,近年一些别的算法也被应用在纯相位全息图的生成及相位恢复中^[35-37]。随着机器学习的发展,深度学习在各领域大放光彩,深度学习与计算全息的结合也逐渐成为国内外研究重点。

1.2.2 深度学习发展概况

心理学家麦卡洛克和数学逻辑学家皮兹于 1943 年在论文中提出了一个基于神经网络的数学模型,称为 MP 模型,打开了神经网络的新时代^[38]。1957 年,心理学家罗森布莱特提出了感知机学习,这是一种类似于人类学习过程的学习方法,并于次年正式提出了“感知器”,是由两层神经元组成的神经网络^[39]。感知器可以对输入的数据集进行二分类,并在数据集中自动更新权值,开辟了人工神

经网络向硬件方向的发展。1969 年,“AI 之父”马文明斯基证明感知器本质上是线性模型^[40],只能处理线性分类问题,由于当下这个问题无法解决,同时感知器也没有被推广到多层神经网络中,导致人工神经网络的发展停滞了近二十年。

被誉为“深度学习之父”的杰弗里·辛顿于 1980 年提出通过采用多个隐藏层的深度结构,代替传统感知器的单层结构^[41],1986 年,杰弗里·辛顿又提出一种反向传播算法,即 BP (Backpropagation) 算法。BP 算法适用于多层感知器,误差不仅能正向传播,同时增加了反向传播过程,并在反向传播时进行权重的更新,直到输出的误差在允许范围内^[42]。BP 算法成功解决了非线性分类问题,使人们再一次关注人工神经网络。1989 年,辛顿的学生 LeCun 首次提出 LeNet^[43],并成功将其应用于手写数字字符识别任务中,为此后卷积神经网络的发展奠定坚实的基础。

此后几年不断有新的模型被提出,直到杰弗里·辛顿和他的学生鲁斯兰·萨拉赫丁诺夫于 2006 年正式提出深度学习概念^[44],并提出首先通过无监督的学习逐层训练模型,再利用有监督的反向传播算法进行调整,该方法能有效解决梯度消失问题。同年辛顿等人开始基于 LeNet 研究卷积神经网络^[45],这一年也被称为深度学习元年,该算法一经提出,学术界便反响巨大,深度学习也再次成为研究风向。2011 年提出的 ReLU 激活函数也能有效抑制梯度消失问题^[46]。

基于之前学者的研究,自 2012 年,深度学习迎来研究成果爆发期。2012 年,Alex Krizhevsky 等人^[47]提出了 AlexNet,该网络在 LeNet 基础上设计了更深层的网络,同时每个卷积层后添加 ReLU 激活函数,解决了梯度消失问题,提升了收敛速度。AlexNet 在 ImageNet 大赛上夺冠,其性能达到了碾压第二名的效果,也是第一个在 ImageNet 大规模图像数据集分类任务上取得成功的深度学习模型。经过世界大赛的卓越表现,深度学习再次成为各界关注的焦点。2013 年,欧洲委员会启动超级计算机项目,该项目基于模仿人脑进行运算。同年,百度成立了深度学习研究院。2014 年出现两个有影响力的卷积神经网络模型,VGGNet^[48]和 Inception Net^[49],同年,Ian Goodfellow 等人^[50]提出生成对抗网络(Generative Adversarial Networks, GAN),将生成模型和判别模型紧密联系。2016 年,谷歌公司基于深度学习开发的 AlphaGo 击败国际顶尖围棋选手,2017 年,OpenAI 开发

了 ChatGPT，这是第一个能够生成连贯文本的深度学习模型，深度学习在不同领域的显著成果，表明了深度学习技术的无限可能。深度学习发展历程如图 1-1 所示。




图 1-1 深度学习发展历程

深度学习通过多层隐藏的神经网络对大规模的数据进行训练，得到大量的特征信息，从而对样本进行分类和与预测。因其强大的学习能力、特征提取能力和自适应能力，被广泛应用在计算机视觉、语言处理、自动驾驶等领域，与不同学科交叉融合，突破瓶颈，因此基于深度学习的计算全息也迎来新的发展。

1.2.3 基于深度学习的计算全息概况

2018 年，日本大阪大学的 Horisaki 等人^[51]首次用深度学习实现相位全息图的生成。神经网络的设计是基于 U 型网络改进的残差神经网络，网络结构如图 1-2 所示。Horisaki 等人用振幅分布均一的随机相位充当相位全息图数据集，对光传播的逆过程进行学习，使网络习得自动生成全息图，同时用菲涅耳衍射得到用来验证的纯相位全息图。结果表明 Horisaki 等人提出的深度学习算法能成功生成全息图，并且由神经网络所生成的全息图能进行重建，但是受限于数据集的选择，训练出的网络对真实图像的泛化性较差。




图 1-2 U 型残差神经网络工作原理

2020 年，韩国首尔国立大学的 Lee 等人^[52]在 Horisaki 等人的基础上对数据集进行了优化，新的数据集不是通过简单地训练随机相位及其传播的全息图像生成，而是由多个输入强度剖面及其传播的全息图组成，并且通过调整随机点的组合基本形状或密度基本形状来丰富训练数据集。通过该方法制得的数据集使网络能够生成各种类型图像的多深度全息图，而无需学习特定对象，数据集生成过程如图 1-3 所示。同时提出多深度全息图生成网络，网络输入为不同深度的多个图像，产生可以在其原始深度重建输入图像的复杂全息图，数值实验和光学重建证明了所提出网络在快速生成全息图的同时提高了生成质量。




图 1-3 基于数值传播的训练集生成方法

同年，斯坦福大学的 Peng 等人^[53]，提出了模型驱动深度学习网络框架，所谓模型驱动深度学习是指区别于使用单纯拟合图像数据集和相位全息图数据集的数据驱动深度学习，模型驱动深度学习将光场传播过程用数学模型代替嵌入网络充当约束，网络直接通过输入的图像数据集预测相位全息图，并进行数值重建，网络参数根据输入图像数据集和数值重建结果之间的损失函数进行更新，神经网络自主学习相位全息图编码方式。Peng 等人分别用两个神经网络对图像相位生成和相位编码进行分工，无法做到端到端的学习，清华大学的吴佳琛等人^[54]提出了一种端到端的深度学习神经网络，物理衍射传播被嵌入神经网络的解码部分，网络可以在无监督的情况下自主学习纯相位全息图的潜在编码方式，该全息编码器能够在 0.15s 内生成高保真 4K 分辨率全息图。同时，针对应用前景广泛的三维全息显示研究，北卡罗来纳大学的 Eybposh 等人^[55]提出一种 DeepCGH 算法，该算法通过无监督学习训练网络，能得到三维物体的表面复振幅信息，安徽工程大学的孙骁^[56]在此基础上提出一种改进算法，将深度学习和分层角谱相结合，改进网络如图 1-4 所示。首先，通过训练好的 LeNet 网络预测出三维物体完整的复振幅信息；然后，依据深度信息对复振幅信息进行平行切片后通过角谱传播生成子全息图；最后，将子全息图层层叠加得到完整全息图，并进行数值重建。网络根据输入振幅和重建振幅之间的损失函数进行参数更新。试验结果表明所提方法的可行性，并通过光学实验证明重建质量有效提高。




图 1-4 LeNet 网络模型

在全息图去噪方面，深度学习使用之初不是专门用于全息图去噪，但是全息图本质是条纹干涉图，因此用于针对去除干涉条纹图的散斑去噪网络也被广泛使用于全息图散斑去噪。2019 年，HAO 等人^[57]提出了一种基于卷积神经网络(CNN)的电子散斑干涉边缘模式批量去噪方法。之后全息领域学者提出针对全息图去噪的神经网络。2020 年，Yan 等人^[58]提出了一种两帧的神经网络去噪方法，分别计算出散斑噪声全息图的正弦和余弦干涉图，将正，余弦图一同输入网络分别去噪。同年，Yin 等人^[59]提出利用神经网络对内容相同但噪声不同的全息图重建图进行学习，达到降噪目的。2022 年，西安交通大学的周孟航^[60]提出一种基于多尺度空间注意力的卷积神经网络去噪方法，该方法通过添加不同尺度的空间注意力机制对相位信息进行去噪，邮箱降低空间分布不一致的散斑噪声。2023 年，刘珂瑄等人^[61]又提出一种模型驱动神经网络，用于高保真度和高速度的相位全息图生成。

目前，深度学习和计算全息的结合已成为全息显示领域主要研究方向之一，国内外许多研究人员不断的提出新的网络结构和算法，验证了深度学习在全息领域的巨大潜力，本文将针对基于深度学习的计算全息算法进行研究。

1.3 本文主要研究内容和结构安排

本文对基于深度学习的计算全息技术展开研究，首先介绍了全息显示技术基本原理及分类，并使用软件进行仿真实验；接着对深度学习原理及经典网络结构展开介绍，详细介绍了基于深度学习的计算全息图生成过程，并进行软件仿真实验；最后介绍了本论文针对全息图生成及散斑降噪提出的算法模型。

论文具体内容如下：

第 1 章，绪论。介绍了本课题的研究背景及意义，包括计算全息、深度学习的发展过程，全息显示技术的广泛应用，重点介绍了基于深度学习的计算全息显示技术发展概况。最后对所研究的内容进行了概括性的总结，并对各章节的核心内容进行了简要的概述。

第 2 章，全息技术基本理论介绍。介绍了光学全息显示技术的波前记录、波前再现过程，分析了计算全息显示技术的基本原理，主要介绍了计算全息三种衍

射方法，并对三种衍射方法进行公式推导和仿真实验。

第 3 章，基于深度学习的纯相位全息图生成算法研究，将角谱算法和深度学习相结合。本章包括网络结构介绍，数据集制备以及仿真结果对比。

第 4 章，在小波卷积神经网络框架基础上，将 CBAM 嵌入残差块，构成 CBAM-残差模块，采用双重注意力模块对全息图散斑噪声通道和空间特征进行辨别，对散斑噪声进行特征细化，同时避免梯度爆炸问题。通过散斑干涉测量生成高精度数据集对网络进行训练，提高了模型的泛化能力。全息图散斑噪声数据集的去噪实验验证了该网络具有良好的去噪性能，与其他去噪算法的对比实验表明所提网络的可行性和有效性，具有一定的实用价值。

第 5 章，总结与展望。对本文工作进行总结，同时对下一步的工作进行展望，以期推动相关领域的发展。

第2章 计算全息和深度学习基本原理

计算全息显示技术是光学全息技术在计算机上进行数字化的结果，能完整记录物光波信息，并进行重建。计算全息包含波前计算、波前编码和波前重建。本章首先介绍了光学全息技术和计算全息技术的基本原理，着重介绍了计算全息的衍射模型以及对三种衍射模型进行仿真，其次介绍了深度学习的基本原理及三种经典网络结构，最后对基于深度学习的计算全息进行阐释，通过流程图说明算法基本原理，同时进行仿真实验。

2.1 全息显示基本原理

2.1.1 光学全息显示的基本原理

传统的光学全息显示利用物光波和参考光波相干涉原理产生相干条纹，相干条纹被记录在光敏材料（如全息干板）上，这个过程称为波前记录，如图 2-1 所示。再利用光的衍射原理，用特定光源照射光敏材料，就可以在对应的深度再现出物体的振幅和相位信息，这个过程称为波前再现，如图 2-2 所示。




图 2-1 波前记录过程

设物光的复振幅为：

$$O(x, y) = O_0(x, y) \exp[j\phi_0(x, y)] \quad (2-1)$$

参考光的复振幅为：

$$R(x, y) = O_0(x, y) \exp[j\varphi_R(x, y)] \quad (2-2)$$

物光和参考光相干叠加后得到全息干板上的光场如式 (2-3) 所示。

$$H(x, y) = O(x, y) + R(x, y) \quad (2-3)$$

此时的光强可以表示为：

$$\begin{aligned} I(x, y) &= H(x, y) \times H^*(x, y) \\ &= [O(x, y) + R(x, y)] \times [O^*(x, y) + R^*(x, y)] \\ &= |O(x, y)|^2 + |R(x, y)|^2 + R^* \times O + R \times O^* \\ &= O_0^2(x, y) + R_0^2(x, y) + 2O_0(x, y)R_0(x, y)\cos[\varphi_O(x, y) - \varphi_R(x, y)] \end{aligned} \quad (2-4)$$

式中, O 表示物光波, R 表示参考光波, O_0 表示物光传播到感光材料(全息干板)上的振幅分布, φ_O 表示物光传播到感光材料(全息干板)上的相位分布, R_0 表示参考光在感光材料(全息干板)上的振幅分布, φ_R 表示参考光在感光材料(全息干板)上的相位分布。




图 2-2 波前再现过程

式(2-4)中, 第一项表示物光的强度分布, 第二项表示参考光的强度分布, 第三项表示物光和参考光干涉结果, 其中包含物光波相位和振幅信息。

设波前再现使用照明光为 L , 如式 (2-5) 所示。

$$L(x, y) = L_0(x, y) \exp[j\varphi_L(x, y)] \quad (2-5)$$

当用照射光 L 照射全息图后, 全息干板上的复振幅 $H'(x, y)$ 如式 (2-6) 所

示。

$$H'(x, y) = L(x, y) \cdot T_p(x, y) \quad (2-6)$$

式中, L_0 为照射光的幅值分布, φ_L 表示照射光的相位分布。

2.1.2 计算全息显示的基本原理

计算全息显示技术不仅可以记录和再现真实物体, 通过编码也可以再现虚拟物体。使用计算机生成全息图, 首先需要采集物体的物光信息进行, 由于计算机只能处理离散数据的特性, 因此需要将连续采集的物光信息根据奈奎斯特抽样定理进行离散化, 抽样间隔需满足奈奎斯特间隔, 如式 (2-7) 所示。

$$\Delta x \leq \frac{1}{2B_x}, \Delta y \leq \frac{1}{2B_y} \quad (2-7)$$

式中, Δx , Δy 分别表示采样间隔, $2B_x$, $2B_y$ 分别表示带宽。

当满足以上采样间隔原理时, 不会因为抽样点过多导致计算加大、过少导致信息缺失, 并且原始函数能从离散数据中还原。

离散后目标函数需要通过数值计算的方式模拟物光波波前传播及衍射过程, 得到全息图。例如傅里叶全息图, 将目标函数通过傅里叶变换, 完成光波从物平面传播到感光材料上得到傅里叶全息图。

全息图上包含的复振幅信息, 需要使用计算机编码为与显示器件相匹配的计算全息图, 即计算全息图的透过率函数。傅里叶迂回相位编码是计算全息常用编码方式, 为计算全息特有, 如式 (2-8) 所示。

$$\Psi(x, y) = F \left\{ H(x, y) \Psi_r(x, y) \right\}_{K_x = \frac{K_0 x}{f}, K_y = \frac{K_0 y}{f}} \quad (2-8)$$

$$\Psi_r(x, y) = \exp(-jk_0 \sin \theta x) \quad (2-9)$$

式中, $\Psi(x, y)$ 表示重构图像复振幅, $H(x, y)$ 表示复振幅, $\Psi_r(x, y)$ 表示重构光的复振幅, θ 表示重构光的倾斜角。

计算全息的再现过程不同于光学全息直接用照射光照射全息干板, 计算全息图被加载到空间光调制器等波前调制器件上, 再通过特定激光照射重建物光波前。计算全息显示技术流程如图 2-3 所示。




图 2-3 计算全息原理图

2.2 计算全息的衍射模型

根据标量衍射理论，光波的菲涅耳衍射可以通过多种衍射公式进行计算，常见的衍射计算方法有傅里叶变换算法^[62]、卷积算法^[63]和角谱衍射算法^[64]。

2.2.1 菲涅耳衍射模型基本原理

在傍轴近似情况下，菲涅耳衍射积分近似表达如式（2-10）所示。

$$U(x, y) = \frac{1}{j\lambda d} \exp(jkd) \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} u(x_0, y_0) \exp\left\{j \frac{k}{2d} [(x - x_0)^2 + (y - y_0)^2]\right\} dx_0 dy_0 \quad (2-10)$$

$$k = 2\pi / \lambda \quad (2-11)$$

式中， λ 表示照射光波长， k 表示波数， d 表示衍射距离， $u(x_0, y_0)$ 表示衍射面光场复振幅分布。

设 f_x 表示 x 方向空间频率， f_y 表示 y 方向空间频率，则：

$$f_x = \frac{x}{\lambda d}; f_y = \frac{y}{\lambda d} \quad (2-12)$$

则菲涅耳衍射积分公式可变形为式（2-13）：

$$U(x, y) = \frac{1}{j\lambda d} \exp(j \frac{2\pi}{\lambda} d) \exp[j \frac{\pi}{\lambda d} (x^2 + y^2)] \times \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} u(x_0, y_0) \exp[j \frac{\pi}{\lambda d} (x_0^2 + y_0^2)] \exp[-j2\pi(x_0 f_x + y_0 f_y)] dx_0 dy_0 \quad (2-13)$$

同时，为了满足菲涅耳近似的条件，需要对衍射孔径、衍射距离做一定要求，

衍射距离 d 要满足式 (2-14) :

$$d^3 = \frac{P}{4\lambda} [(x - x_0)^2 + (y - y_0)^2]_{\max}^2 \quad (2-14)$$

菲涅耳衍射过程如图 2-4 所示。




图 2-4 菲涅耳衍射过程

2.2.2 菲涅耳衍射常用计算方法

(1) 傅里叶变换算法

由菲涅耳衍射公式可知，其过程是一个傅里叶变换，计算公式如式 (2-15) 所示。

$$U(x, y) = \frac{1}{jd\lambda} \exp(jkd) \exp\left[\frac{jk}{2d}(x^2 + y^2)\right] \times \mathcal{F} \left\{ U_0(x_0, y_0) \exp\left[\frac{jk}{2d}(x_0^2 + y_0^2)\right] \right\} \quad (2-15)$$

式中， $\mathcal{F}$ 表示傅里叶变换。通过单次傅里叶变换完成的衍射过程称为快速傅里叶变换。

进行快速傅里叶变化时，抽样点数、衍射距离、衍射面的大小和光波波长是明确的，只需要计算观察面的尺寸大小。

设衍射面共有 N 个抽样点，在 x 方向上的宽度为 L_{x0} ，则根据抽点定理，可得抽样点最高空间频率为：

$$u_{\max} = \frac{N_x}{2L_{x_0}} \quad (2-16)$$

衍射光的空间频率方向为：

$$u_{\max} = \frac{1}{X} = \frac{\cos \alpha_{\max}}{\lambda} \quad (2-17)$$




图 2-5 衍射屏最大尺寸示意图

由图 2-5 和式 (2-17) 可得：

$$u_{\max} = \frac{\sin(p/2 - \alpha)}{\lambda} = \frac{L_{x_{\max}}/2}{\lambda \sqrt{(L_{x_{\max}}/2)^2 + d^2}} \quad (2-18)$$

由抽样点式和式 (2-18) 可得观察面最大尺寸为：

$$L_{x_{\max}} = \frac{2\lambda N_x d}{\sqrt{4L_{x_0}^2 - \lambda^2 N_x^2}} \quad (2-19)$$

因为是傍轴计算，所以可得：

$$L_{x_{\max}} = \frac{N_x \lambda d}{L_{x_0}} \quad (2-20)$$

上式可以看出，使用快速傅里叶变化进行计算，衍射观察面的尺寸和波长、抽样点和衍射距离都有关系。当衍射 d 较小时，衍射观察面信号对应的也会较小，所以该种计算方法适用于衍射距离 d 较大的情况，图 2-6 为傅里叶算法仿真结果。




图 2-6 傅里叶算法仿真图

(2) 卷积算法

根据卷积定理，空域中的卷积运算可以通过傅里叶变换转化为空域中的乘积计算。因此，可以利用卷积计算来简化菲涅耳衍射积分的计算过程。步骤如下：首先，进行傅里叶变换，从空域转换到频域进行计算，计算公式如式（2-21）所示。

$$U(\xi, \eta) = \mathcal{F}\{U_0(x_0, y_0)\} \times \mathcal{F}\left\{\exp\left[\frac{jk}{2d}(x^2 + y^2)\right]\right\} \quad (2-21)$$

式中， ξ, η 是频域 u 坐标， $\mathcal{F}$ 表示傅里叶变换。

其次，将计算结果进行逆傅里叶变换转换回空域，完成衍射计算，计算公式如式（2-22）所示。

$$U(x, y) = \frac{\exp(jkd)}{j\lambda d} \times \mathcal{F}^{-1}\{U(\xi, \eta)\} \quad (2-22)$$

式中， $\mathcal{F}^{-1}$ 表示逆傅里叶变换过程。

在卷积计算中，相同频率的频谱才能相乘，所以最高频率也要相等，因此抽样数也相等，对应的衍射面和观察面的尺寸也应相同，图 2-7 为卷积算法仿真结果。




图 2-7 卷积算法仿真图

(3) 角谱算法

由式（2-10）可得脉冲响应为 (x_0, y_0) 处的脉冲响应为：

$$h(x - x_0, y - y_0) = \frac{1}{j\lambda d} \exp(jkd) \quad (2-23)$$

由上式可以看出脉冲响应是不变的，因此可以通过傅里叶变换直接计算得到菲涅耳衍射的传递函数如式（2-24）所示。

$$H(\xi, \eta) = \exp \left\{ jkd \left[1 - \frac{\lambda^2}{2} (\xi^2 + \eta^2) \right] \right\} \quad (2-24)$$

所以，菲涅耳衍射积分可简化为式（2-25）。

$$U(x, y) = \mathcal{F}^{-1} \left\{ \mathcal{F} \{ U_0(x_0, y_0) \} \exp \left\{ jkd \left[1 - \frac{\lambda^2}{2} (\xi^2 + \eta^2) \right] \right\} \right\} \quad (2-25)$$

上述由一次傅里叶变换和一次傅里叶逆变换完成衍射过程的算法，称为角谱算法，角谱算法的衍射面和观察面大小也相同，图 2-8 为角谱算法仿真结果。




图 2-8 角谱算法仿真结果

2.3 深度学习基本原理

2.3.1 深度学习背景介绍

传统的机器学习算法是结合手工特征和机器学习模型，深度学习算法从数据中自动学习特征，去除手工学习环节，提高机器学习模型的能力。深度学习本质是一个复杂的非线性变换结构算法，模拟人脑神经网络的工作方式，构建深层次的神经网络对数据进行表征学习。

神经网络是深度学习的核心，犹如人类的神经网络，由大量神经元组成，每个神经元通过连接权重和激活函数处理输入信息，神经网络由输入层、隐藏层和输出层组成，“深度”就体现在隐藏层，隐藏层可以有多个。

数据通过输入层输入神经网络，在前向传播过程中，按照权重和偏置进行加权求和，并经过激活函数进行非线性变换，最后从输出层输出结果并且得到损失函数，损失函数用来衡量输出值与预期值的差值。

损失函数对网络输出求偏导作为初始误差信号，通过链式法则，将初始误差信号反向传播到每个神经元的输入端，在求出每个神经元的输入对其输出的偏导数，将这个偏导数与初始误差信号相乘，得到每个神经元的误差信号，最终求出每个权重和偏置的梯度，更新网络参数，过程如图 2-9 所示。




图 2-9 损失函数更新参数过程示意图

为了最小化损失函数，快速更新神经网络的权重和偏置，一些优化算法被提出。常见的优化算法包括随机梯度下降法、Adagrad 法、动量梯度下降法等。

2.3.2 典型网络模型介绍

深度学应用在各个领域中，应用情况不同，神经网络的形态也各不相同。在光学成像和计算领域，应用较为广泛的神经网络由卷积神经网络（convolutional neural network, CNN）^[65]、残差网络（residual network, ResNet）^[66]、和生成式对抗网络（generative adversarial network, GAN）^[67]，下面将分别介绍这三种神经网络。

（1）卷积神经网络

卷积神经网络拥有出色的表征学习能力,可根据网络层次对输入数据进行平移不变分类。该网络可进行监督学习和非监督学习,主要用于于图像和视觉数据的处理。CNN 核心特点是卷积操作,卷积神经网络结构如图 2-10 所示,主要组成部分包括输入层、卷积层、激活函数、池化层和全连接层。




图 2-10 卷积神经网络结构

数据经过输入层进行预处理,包括归一化、去均值和白化过程。随后将处理过的数据输入卷积层,卷积层由若干卷积核组成,卷积核相当于一个窗口滤波器。针对网络训练,可以采用自定义大小的卷积核作为滑动窗口,对数据进行卷积操作,目的是提取输入数据的不同特征,不同的卷积层特征提取的部位不同,因此多层网络能提取更复杂的特征。卷积过程如图 2-11 所示。




图 2-11 卷积过程(a)~(d)

在卷积层之后数据要经过一个重要的部分,也就是激活函数。激活函数实质上是一个非线性函数,如果输出数据不经过激活函数,只有线性变换,那么网络

只能输出多元线性方程，无法拟合复杂的函数。常见的激活函数有 sigmoid 激活函数、ReLU 激活函数和 tanh 激活函数。

池化层用来处理卷积后维度变大的数据，相当于在空间范围内做维度约减，通常有两种处理方式：平均池化和最大池化，区别如图 2-12 所示。




图 2-12 不同池化方式。(a)平均池化；(b)最大池化

池化层在神经网络中扮演着重要角色，它不仅能够减少神经元的数量，还能增强网络对局部变化的稳定性。同时，通过扩大感受野的范围，池化层有助于网络更好地捕捉输入数据中的关键特征。

最后通过全连接层对提取到的特征进行非线性组合，把所有局部特征变成全局特征，按照分类数量输出数据。

卷积神经网络基于卷积操作具有参数共享的特点，减少了大量的计算，在针对图像、识别等任务时有显著优点，同时卷积神经网络具有的平移不变性和鲁棒性提高了网络的泛化能力和抗干扰能力。

(2) 残差网络

残差网络的出现是为了解决隐藏层过多造成的梯度消失或梯度爆炸问题。例如卷积神经网络处理大量的图像等信息，需要使用非常多的卷积层、池化层，难免会出现退化问题，残差网络采取跳跃连接的方法避免梯度爆炸等问题。




图 2-13 残差块和正常块对比

残差网络的主要作用是残差块，残差块通过跳跃连接，将网络冗余层训练为恒等映射，也就是冗余层的输入输出信息一致。如图 2-13 所示，a 是正常块。b 是残差块。残差块在输入和激活函数之前添加了跳跃连接。正常块激活函数的输入为

$$H(x) = F(x) \quad (2-26)$$

残差块激活函数的输入为：

$$H(x) = F(x) + x \quad (2-27)$$

在训练过程中，当输出已经是最优解时，存在一些未使用的卷积层是可以直接抛弃的，但在常规神经网络中，训练不会取舍网络层数，随着网络深度的加深，训练错误会先减少再增多。在残差网络中，通过加入一个恒等映射 x ，使网络的学习目标由 $H(x)=x$ 转换为 $F(x)=H(x)-x$ ，当达到最优解时，只需将 $F(x)=0$ ，这时的输出就是 $H(x)=x$ ，网络对 $F(x)=0$ 的拟合更加容易。因此当网络训练到冗余层时，残差网络通过学习残差 $F(x)=0$ 决定该层恒等映射上一层的输入，使得冗余层不影响网络深度加深带来的问题。

同时残差块作为轻量型模块可以嵌入其他神经网络，跳跃连接制造残差，恒等映射加深网络，残差网络只需要学习输入输出有差别的一部分，简化了学习难度。

(3) 生成对抗网络

生成对抗网络是一种无监督深度学习模型，通过生成模块和判别模块在网络中相互博弈学习，不断优化输出。生成对抗网络模型如图 2-14 所示，主要由生成器（G）和判别器（D）构成。




图 2-14 生成对抗网络模型

生成器用来生成假数据，目的是尽可能骗过判别器。判别器用来判断是真实数据还是生成器生成的假数据。

第一阶段，固定判别器，训练生成器。使用性能较好的判别器，去判断生成器生成的假数据。随着被判别器不断识破，生成器也不断提高生成质量。

第二阶段，固定生成器，训练判别器。生成器性能在第一阶段不断增强，判别器难以区分真假数据，所以第二阶段训练判别器，通过持续训练使其最终能够精确识别出假数据。

第三阶段，重复第一阶段、第二阶段。重复训练得到一个质量较高的生成器和判别能力较强的判别器。

生成对抗网络是生成器和判别器的博弈过程，博弈结果是生成器能生成足以以假乱真的图片，判别器能判断图片的真假。目前生成对抗网络应用于数据生成、图像生成、图像转换等方面。

2.4 基于深度学习的计算全息技术

深度学习强大的预测能力，解决了计算全息的限制问题，为计算全息技术的

发展进步提供新的路径。在全息图压缩、相位恢复及散斑去噪等方面都有巨大贡献。小节主要介绍基于深度学习的计算全息图生成与重建，通过流程示意图解析计算全息图生成过程，过程如图 2-15 所示。




图 2-15 基于深度学习生成计算全息图流程

数据集的质量影响网络训练结果，从而决定全息图的生成质量。数据驱动深度学习需要先用传统方法生成全息图，后进行数据增强扩大数据集数量。模型驱动深度学习直接使用真实图像作为数据集。

针对研究目的不同，神经网络的选择也不相同，本文选用 U-Net 进行纯相位全息图的生成，选取小波神经网络对纯相位全息图进行去噪。

基于深度学习的计算全息图生成相较于传统生成方法在成像质量、生成速度上均有提升，图 2-16 是进行仿真比较的结果。




图 2-16 深度学习生成全息图与传统方法生成全息图对比。(a)原图；(b)传统方法生成全息图；(c)传统方法全息图重建；(d)深度学习生成全息图；(e)深度学习全息图重建。

2.5 本章小结

本章主要介绍了光学全息和计算全息基本理论,全息显示技术再现的关键在于衍射模型的选择,衍射过程模拟光的传播过程,本章着重介绍了基于菲涅耳衍射的三种计算模型,分析了三种算法的计算公式并对三种衍射算法进行仿真。在深度学习方面,首先介绍了深度学习和人工神经网络的基本理论,介绍了卷积神经网络、残差网络和对抗生成网络模型,最后介绍了基于深度学习的计算全息技术流程,并进行仿真实验。

第3章 基于卷积神经网络的纯相位全息图生成

虽然通过迭代算法能生成重建效果较好的纯相位全息图,但生成速度有极大的优化可能性,本章将深度学习与角谱传播相结合,在神经网络预测出复振幅信息后,采用角谱传播衍射模型生成纯相位全息图,通过仿真实验和光学实验可以看出,该算法在快速生成全息图的同时提高全息图的生成质量。

3.1 基于卷积神经网络的纯相位全息图生成原理

3.1.1 纯相位全息图生成流程

本章基于深度学习生成全息图是将深度学习和角谱传播结合。采用物体振幅信息和复振幅信息组成的数据集训练卷积神经网络结构,使卷积神经网络能预测出物体的复振幅信息,再将复振幅通过角谱传播的方式生成全息图,再重建出原始图像。利用构建的损失函数对比重建物体振幅与目标物体振幅的差异,当误差在一定范围内时输出全息图与重建图像,具体流程如图 3-1 所示。




图 3-1 基于卷积神经网络生成纯相位全息图流程图

3.1.2 角谱传播模型原理

在第二章简述了角谱传播模型是由一次傅里叶变换和一次傅里叶逆变换完成衍射过程的算法。经过注意力卷积神经网络推断出的复振幅信息基于角谱衍射理论计算出物体平面传播到全息平面的光场复振幅分布,角谱传播严格遵守标量

衍射理论，计算公式如（3-1）所示。

$$U(x, y) = \mathcal{F}^{-1} \{ \mathcal{F}[u(x, y)] \cdot H(f_x, f_y) \} \quad (3-1)$$

式中， $\mathcal{F}$ 表示傅里叶变换， $\mathcal{F}^{-1}$ 表示傅里叶逆变换， $u(x, y)$ 表示物平面光场分布，

$U(x, y)$ 表示全息面光场分布， $H(x, y)$ 表示传递函数，传递函数如（3-2）所示。

$$H(f_x, f_y) = \begin{cases} \exp\left(i \frac{2\pi}{\lambda} z \sqrt{1 - \lambda^2 f_x^2 - \lambda^2 f_y^2}\right), & \lambda^2 f_x^2 + \lambda^2 f_y^2 < 1 \\ 0, & else \end{cases} \quad (3-2)$$

式中， λ 表示物光与参考光波长， f_x, f_y 分别表示 x 轴和 y 轴方向的空间频率， z 表示传播距离。

数值计算菲涅耳衍射场时，需要对式（3-1）进行离散采样，采样矩阵计算公式如（3-3）所示。

$$U_0^c(m, n) = U_0(m\delta_x, n\delta_y) \quad (3-3)$$

式中， δ_x, δ_y 表示采样间隔， (m, n) 表示采样坐标。

$$\begin{aligned} m &= -\left\lfloor \frac{M}{2} \right\rfloor, -\left\lfloor \frac{M}{2} \right\rfloor + 1, \dots, \left\lceil \frac{M}{2} \right\rceil - 1, \\ n &= -\left\lfloor \frac{N}{2} \right\rfloor, -\left\lfloor \frac{N}{2} \right\rfloor + 1, \dots, \left\lceil \frac{N}{2} \right\rceil - 1, \end{aligned} \quad (3-4)$$

式中， $M=L_x/\delta_x$ ， $N=L_y/\delta_y$ ，分别表示沿 x, y 的采样点数， $\lceil \cdot \rceil$ 表示向上取整， $\lfloor \cdot \rfloor$ 表示向下取整操作。

3.2 网络结构

3.2.1 神经网络的结构

本章使用经典 U-Net 作为基础神经网络，U-Net 能用较少的训练图片，产生更准确的分割，并且因其结构特性，能结合底层特征和高层特征的信息。将衍射模型写入网络，使网络不仅能自主生成全息图，同时完成图像再现，并且引入了自定义注意力残差块，改进后的神经网络如图 3-2 所示。




图 3-2 卷积神经网络结构示意图

网络整体也是 U 型，前半部分是特征提取网络，由四层结构相同的下采样块组成，每层由两个 3×3 卷积块、一个注意力残差块和步长为 2 最大池化层组成。后半部分是上采样过程，上采样每层由转置卷积、两个 3×3 卷积块和通过跳跃连接与来自特征提取部分的相应特征图的串联操作。下采样特征提取，上采样特征重构。

3.2.2 注意力残差模块

注意力机制（Convolution Block Attention Module, CBAM）是一种轻量型模块，可用于前馈卷积神经网络，结合了通道（channel）和空间（spatial）注意力模块。对于输入的全息图，注意力机制模块会沿着空间和通道两个维度推断注意力图，再将推断出的注意力图相乘，进行自适应特征优化，如图 3-3 所示。输入特征全息图 V ，在通道注意力机制中进行全局最大池化和均值池化，将池化后的向量送入全连接层，产生每个通道的权重 M_C 。将通道权重应用到输入的特征全息图的每个通道上，对其进行加权组合，输出通道特征全息图 V' 。将 V' 输入空间注意力机制，经过两个卷积层，一个用于捕获水平方向的信息，另一个用于捕获垂直方向的信息，两个卷积层的输出进行逐元素相乘，以获得不同位置的交互信息。交互信息经过 Sigmoid 激活函数得到位置权重 M_S ，将位置权重应用到 V' ，以对其进行加权组合，输出空间特征全息图 V'' ，CBAM 模块的输出是通道注意力模块和空间注意力模块的输出的乘积。具体过程如图 3-4 所示。CBAM 计

算公式如 (3-5) (3-6) (3-7) (3-8) 所示。

$$V' = M_c(F) \cdot F \quad (3-5)$$

$$V'' = M_s(V') \cdot V' \quad (3-6)$$

$$M_c(F) = \sigma(MLP(AvgPool(F)) + MLP(MaxPool(F))) \quad (3-7)$$

$$M_s = \sigma(f^{7 \times 7}([AvgPool(F); MaxPool(F)])) \quad (3-8)$$

式中, $\cdot$ 表示逐元素相乘, σ 表示 Sigmoid 激活函数, $f^{7 \times 7}$ 表示 7×7 大小的卷积核。




图 3-3 CBAM 注意力机制概述




图 3-4 注意力子模块示意图

本文改进网络通过加入 CBAM 模块改变资源分配, 使网络在针对全息图进行降噪时更加关注散斑噪声, 压缩不重要特征, 从而提高网络的降噪能力。同时 CBAM 是一种轻量型模块, 可以直接嵌入网络。

加入 CBAM 模块后, 为防止网络层数增加导致计算速度减慢, 梯度爆炸问

题，将 CBAM 模块嵌入残差块，抑制网络退化的同时加强浅层与深层特征的信息融合后的 CBAM-残差块如图 3-5 所示。




图 3-5 CBAM-残差块基本单元

3.2.3 损失函数

注意力卷积神经网络的损失函数使用均方误差（MSE），表示预测数据和原始数据对应误差的平方和均值，均方误差计算公式如（3-9）所示。

$$loss = \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{n} \quad (3-9)$$

式中， y_i 为目标强度图像： $y_i = |A|^2$ ， $\hat{y}_i$ 为重建强度图像： $\hat{y}_i = |\hat{A}|^2$ ， n 为训练数量。

可以看出，当 $y_i = \hat{y}_i$ 时，损失函数达到最优值，预测结果于真实复振幅完全相同，但理想结果不可能实现，所以当损失函数收敛到最小值时，网络训练到最优解。在网络训练过程中使用 Adam 优化器^[68]，在超参数的设置部分，初始学习率为 0.0001，最高学习率为 $3e^{-4}$ ，最低学习率为 e^{-3} ，每次训练随机选取批量为 1000 张图片。

3.2.4 数据集

本章数据集由物体的振幅信息及其复振幅信息组成，利用 Python 语言随机生成图像的振幅信息和复振幅信息，将数据集编码，生成文件，训练网络时可直接调用，生成训练数据集 30000，验证数据 10000，同时使用 Set12 灰度图数据集作为性能测试图，做对比实验。

3.3 数值仿真与分析

本文仿真实验所用语言为 Python，在 Pytorch 框架中实现，采用 64 位 Windows10 操作系统，内存 16.0G，显卡 NVIDIA2060Ti。

3.3.1 重建图像质量的评价标准

为使用直观数据说明降噪任务完成情况，本文引入常用的两种质量评估指标即峰值信噪比（Peak Signal-to-Noise Ratio, PSNR）和结构相似度（Structural Similarity, SSIM）。

峰值信噪比数学表达式为：

$$PSNR = 10 \cdot \log_{10} \left(\frac{MAX_I^2}{MSE} \right) \quad (3-10)$$

式中，MAXI 表示图像最大可能像素值，MSE 表示均方误差，其计算公式如（3-11）所示。

$$MSE = \frac{1}{mn} \sum_{i=0}^{m-1} \sum_{j=0}^{n-1} [X(i, j) - Y(i, j)]^2 \quad (3-11)$$

式中，X、Y 分表表示两幅 $m \times n$ 的图像。

结构相似度数学表达式为：

$$SSIM(x, y) = \frac{(2\mu_x\mu_y + C_1)(2\sigma_{xy} + C_2)}{(\mu_x^2 + \mu_y^2 + C_1)(\sigma_x^2 + \sigma_y^2 + C_2)} \quad (3-12)$$

其中， x, y 分别表示两幅图像， μ_x, μ_y 分别表示 x, y 的亮度、对比度和结构的平均值， σ_x, σ_y 分别表示 x, y 的标准差， σ_{xy} 表示 x, y 的协方差， C_1, C_2 为常数，保证分母为 0 时的稳定性。

3.3.2 重建结果与分析

选取干涉条纹图进行仿真实验，将条纹图输入训练好的网络，得到输出的全息图和重建图，并与传统迭代 GS 算法进行对比。对比结果如图 3-6 所示，可以看出提出算法在重建质量上有明显提升，重建图噪声较少，且边缘过渡较为光滑。




图 3-6 测试图算法对比。(a)测试图原图；(b)本章所提算法全息重建图；(c)传统 GS 算法全息重建图

对二维图像进行仿真实验，选取图像研究领域经典图像(摄影师)输入网络，将得到的结果与传统 GS 算法进行分析对比，对比结果如图 3-7 所示，可以看出本章算法得到的全息图能清晰显示出摄影师轮廓，重建图散斑噪声少，表 3-1 为本章算法和传统 GS 算法重建对比实验的 PSNR 和 SSIM 结果，量化实验差异。同时对比了本章算法和传统 GS 算法的计算时间结果如表 3-2 所示，本次实验使用图像尺寸均为 256×256 ，为保证实验计算结果的准确性，使用 Set12 数据集进行验证实验，取 12 张照片平均运行时间后对比发现实验结果与表 3-2 相吻合，本章算法虽然在计算时间上略长于传统 GS 算法，但传统 GS 算法迭代次数有限，无法自主求解最优解，且成像质量较差。

表 3-1 对比实验 PSNR(dB)/SSIM 值

参数	本章算法重建图	传统 GS 算法重建图
PSNR(dB)	29.32	25.46
SSIM	0.8671	0.5193

表 3-2 对比实验计算时间(ms)

	本章算法重建图	传统 GS 算法重建图
计算时间/ms	5.2	3.6




图 3-7 摄影师对比仿真图。(a)摄影师原图；(b)本章算法重建图；(c)本章算法全息图；(d)传统 GS 算法重建图；(e)传统 GS 算法全息图

为进一步说明本章算法在重建质量上的提升，选取猩猩(baboon)作为仿真对象，与二维误差扩散算法和傅里叶算法进行重建后对比，图 3-8 为对比结果，可以看出本章算法在重建质量上有明显提升，重建像细节更清晰，散斑噪声较少。得到的重建像对比度高，更符合人眼视觉观看要求，但三者生成重建像的时间量级相差不大。以 PSNR 为评价指标，本章算法比误差扩散提升约 0.2dB。




图 3-8 不同算法猩猩(baboon)重建像对比。(a)本章算法 baboon 重建像；(b)误差扩散算法 baboon 重建像；(c)傅里叶算法 baboon 重建像

3.4 光学实验结果分析

3.4.1 实验光路图

为了进一步探索本文算法在光学实验中的重建质量，本文构建了如图 3-9 所示的光学系统。波长 532 nm 的激光束作为光源，光源发射相干光束通过衰减片、空间滤波器、偏振片和分束器后照射在载有纯相位全息图的空间光调制器上。实验中使用的空间光调制器为纯相位型空间光调制器，其像素间距为 $6.4\ \mu\text{m}$ ，采样点数为 1920×1080 像素。空间光调制器对像素进行调制，经过 $4f$ 系统滤波后，被型号为 Cannon 500D 相机采集，如图 3-10 为搭建的光路实物图。




图3-9 光学实验系统结构示意图




图 3-10 实验光路图搭建

3.4.2 光学重建结果

光学重建结果如图 3-11 所示，本章算法的光学重建过程中表现出色，重建结果的对比度高、散斑噪声较弱且亮度分布均匀，与数值仿真中取得的结果相吻合，从而验证了本章算法在实际应用中的有效性。




图 3-11 光学重建结果。(a)本章算法光学重建；(b)误差扩散算法光学重建；(c)傅里叶算法光学重建

对彩色全息图使用本章算法进行重建后进行光学实验，实验结果如图 3-12 所示，尽管彩色全息图没有完整重现全部色彩通道，但物体轮廓清晰可见，深度信息也能表达，为后续研究彩色全息和三维全息创造了可能性。




图 3-12 彩色图光学重建。(a)橘子原图；(b)梨子原图；(c)橘子光学重建图；(d)梨子光学重建图

3.5 本章小结

本章在卷积神经网络（U-Net）基础上提出残差卷积网络，详细阐述了网络搭建，数据集构造以及损失函数选择。针对传统算法计算时间长，重建像质量不高等问题，将深度学习和角谱传播相结合，利用训练好的神经网络预测输入图像的复振幅信息，在经过角谱衍射传播生成全息图和重建像。在仿真实验中，本章所提出的算法在成像质量上比误差扩散算法、傅里叶算法和传统 GS 算法有明显提升，PSNR 值和 SSIM 值均高于传统算法。在光学实验中，控制其他变量统一，光学成像的质量也优于传统算法。

第 4 章 基于注意小波残差网络的纯相位全息图去噪算法

在计算全息中，编码过程中的近似采样产生量化误差，量化误差导致重构图像的相干性不受控制而产生散斑噪声。目前降低散斑噪声的方法主要有光学的方法和数字图像处理的方法。光学的降噪方法可以通过多幅全息图叠加平均法，或通过降低光源的相干性实现，但是光学方法需要严格的实验条件，装置复杂。数字图像处理方法包括空间域滤波法和变换域滤波法。数字图像处理在全息图散斑降噪中无需复杂的实验条件，且操作简单。但由于散斑噪声分布不均匀，会造成纹理信息的损失和过渡平滑的边缘。本章基于基础小波网络提出CBAM-小波残差网络，在小波神经网络基础上引入Convolution Block Attention Module (CBAM) 注意力机制和残差块，将CBAM注意力机制和残差块整合，利用残差块改进小波卷积神经网络效率的同时，CBAM注意力机制将特征映射作为输入保证全息图特征提取中包含的信息不会减少。使用仿真散斑数据集训练网络，使得网络更具泛用性。

4.1 散斑噪声和去噪原理

4.1.1 全息图中散斑噪声模型

产生散斑噪声是因为相干性强的激光在物体表面散射，形成了一系列的子波，由于散射子波的相位随机分布，导致在物体周围空间就形成了无数随机分布的散斑。1976 年，Arsenault 证明了含噪全息图 I 、原始全息图 R 与散斑噪声 N 之间的关系式，如式 (4-1) 所示。

$$I(x, y) = R(x, y)N(x, y) = r_i \exp(f_i) n_k \exp(f_k) \quad (4-1)$$

式中， (x, y) 表示图像的坐标位置， x 为横坐标， y 为纵坐标。 $R(x, y)$ 表示未受污染的原始图像在坐标 (x, y) 处的数值。 $N(x, y)$ 表示与原始图像分布相互独立的散斑噪声复振幅。 r_i 与 ϕ_i 分别表示物光场的振幅与相位， n_k 与 ϕ_k 分别为散斑噪声的振幅和相位。最后 $I(x, y)$ 表示原始图像 R 受到散斑噪声 N 污染后的图像。散斑噪声分布复杂，所以传统的光学去噪和数字图像去噪方法很难有效的抑制散斑噪声。

4.1.1 离散小波去噪原理

二维离散小波去噪的方法在数字图像处理中应用广泛，且去噪效果较好，其原理是将原始图像通过二维离散小波变换分解为近似系数和细节系数。近似系数捕捉图像的低频部分，而细节系数捕捉高频细节和噪声，对细节系数进行阈值处理，去除噪声。将处理后的近似系数和阈值处理后的细节系数合成，进行逆二维离散小波变换，得到去噪后的图像

选择离散小波基函数 $\psi(x,y)$ 对一个大小为 $M \times N$ 的图像 $I(x,y)$ 进行分解得到水平分量、垂直分量、对角分量、低频分量，分量的公式分别如 (4-2) (4-3) (4-4) (4-5) 所示。

水平分量：

$$a[i, j] = \sum_{x=0}^{M-1} \sum_{y=0}^{N-1} I[x, y] \cdot \psi[i-2x, j-y] \quad (4-2)$$

垂直分量：

$$b[i, j] = \sum_{x=0}^{M-1} \sum_{y=0}^{N-1} I[x, y] \cdot \psi[i-x, j-2y] \quad (4-3)$$

对角分量：

$$c[i, j] = \sum_{x=0}^{M-1} \sum_{y=0}^{N-1} I[x, y] \cdot \psi[i-2x, j-2y] \quad (4-4)$$

低频分量：

$$d[i, j] = \sum_{x=0}^{M-1} \sum_{y=0}^{N-1} I[x, y] \cdot \phi[i-x, j-y] \quad (4-5)$$

式中， $\phi[i,j]$ 为 $\psi(x,y)$ 的补充函数，通常是一个高通滤波器。

低频分量包含近似成分，垂直分量、对角分量和水平分量包含细节成分，为方便书写，将细节系数定义为 $w(i,j)$ 。对细节成分的系数进行阈值处理，计算公式如 (4-6) 所示。

$$w[i, j] = \begin{cases} w[i, j], & \text{if } |w[i, j]| \geq \lambda \\ 0, & \text{if } |w[i, j]| < \lambda \end{cases} \quad (4-6)$$

阈值处理的目的是将较小的细节系数设为零，以去除噪声的影响。这是因为噪声通常体现在高频部分，而真实信号更多地表现在低频部分和部分高频部分。对近似分量 $a[i, j]$ 进一步分解,同时对分解的细节分量进行阈值处理，直到达到所需的分解层数。将处理后的近似分量和阈值处理后的细节分量合成，进行逆二维离散小波变换，得到去噪后的图像，逆变换计算公式如（4-7）所示。

$$I[i, j] = \sum_{x=0}^{M-1} \sum_{y=0}^{N-1} I[x, y] \cdot \psi[i-2x, j-y] + \sum_{x=0}^{M-1} \sum_{y=0}^{N-1} I[x, y] \cdot \psi[i-x, j-2y] \\ + \sum_{x=0}^{M-1} \sum_{y=0}^{N-1} I[x, y] \cdot \psi[i-2x, j-2y] + \sum_{x=0}^{M-1} \sum_{y=0}^{N-1} I[x, y] \cdot \phi[i-x, j-y] \quad (4-7)$$

4.2 网络结构介绍

4.2.1 基本网络结构

本文提出的全息图去噪网络包括骨干网络、收缩子网和扩展子网三部分。骨干网络由 U-Net 组成。将小波变换写入网络每一层，收缩子网由离散小波变换（Discrete Wavelet Transform, DWT）和卷积神经网络模块（Convolutional Neural Network Module, CNN）组成，为三级收缩子网，每一级由 DWT、CNN 块和 CBAM-残差块三个模块构成。扩展子网由逆小波变换（Inverse Wavelet Transform, IWT）和卷积神经网络模块组成。本文提出的全息图去噪网络架构如图 4-1 所示。




图 4-1 注意力小波残差网络模型

首先将带有噪声的纯相位全息图输入网络，对全息图进行小波分解。全息图经离散小波变换 DWT 后被分解成四个子图像，分解过程如图 4-2 所示，离散小波变换的四个滤波器（一个低通滤波器 F_{LL} 、三个高通滤波器 F_{LH} 、 F_{HL} 、 F_{HH} ）在变换期间具有卷积步长为 2 的固定参数。本文的小波变换采用 haar 小波基，其四个滤波器定义如公式（4-8）所示。

$$F_{LL} = \begin{bmatrix} 1 & 1 \\ 1 & 1 \end{bmatrix}, F_{LH} = \begin{bmatrix} -1 & -1 \\ 1 & 1 \end{bmatrix}, F_{HL} = \begin{bmatrix} -1 & 1 \\ -1 & 1 \end{bmatrix}, F_{HH} = \begin{bmatrix} 1 & -1 \\ -1 & 1 \end{bmatrix} \quad (4-8)$$

很显然 F_{LL} 、 F_{LH} 、 F_{HL} 、 F_{HH} 彼此正交，并形成 4×4 可逆矩阵，全息图被分解为四个子全息图 I_{LL} 、 I_{LH} 、 I_{HL} 、 I_{HH} ，计算公式如（4-9）所示。

$$\begin{cases} I_{LL} = (F_{LL} * I) \downarrow 2 \\ I_{LH} = (F_{LH} * I) \downarrow 2 \\ I_{HL} = (F_{HL} * I) \downarrow 2 \\ I_{HH} = (F_{HH} * I) \downarrow 2 \end{cases} \quad (4-9)$$

式中， $*$ 表示卷积过程； $\downarrow$ 表示尺度因子为 2 的标准下采样过程。根据 Harr 小波变换理论，将全息图分解，分解后的 I_{LL} 、 I_{LH} 、 I_{HL} 、 I_{HH} 对应式（4-2）（4-3）（4-4）（4-5）中的分量。




图 4-2 二维离散小波变换分解过程

然后，子全息图经过由三层全卷积网络（Fully Convolutional Network, FCN）组成的 CNN 块，该模块用来减少特征映射通道，以实现紧凑表示，每层全卷积网络是由 3×3 的卷积层、批量归一化层和校正线性单元依次连接组成。再经过 CBAM-残差块，自适应地学习和关注子全息图中的通道特征和位置特征。最后，由 IWT 对子全息图进行上采样，重构去噪后的全息图。

4.2.2 数据集制作

传统全息图是由干涉生成的条纹图，计算全息技术使用数值计算实现相干条纹获取，其中纯相位全息图因能量利用率高，共轭像易去除而广泛应用。目前用于深度学习的网络降噪图像数据集不适合本改进网络的训练，所以需要自己制作数据集。本文数据集由 Matlab 软件生成，首先使用泽尔尼克（Zernike）条纹多项式系数生成 1000 张无噪声相位图，尺寸为 256×256 像素。进而对生成的相位图进行随机散斑仿真，减去初始散斑场后得到无噪声散斑干涉条纹图，相移得到包裹相位图。为了使数据集更加的丰富，同时对包裹相位图添加不同等级的高斯噪声，形成包含共 5000 张散斑噪声包裹相位图。其中 4500 张用作训练，500 张用于测试。如图 4-3 所示是部分噪声图及无噪声图。




图 4-3 数据集部分示例

4.2.4 损失函数

采 L2 范数作为损失函数，其计算公式如（4-10）所示。

$$L(\Theta) = \frac{1}{2N} \sum_{i=1}^N \|F(y_i, \Theta) - x_i\|_F^2 \quad (4-10)$$

其中， Θ 表示网络参数， $F(y, \Theta)$ 表示网络输出， $\{y_i, x_i\}_1^N$ 表示训练集， y_i 表示第 i 个网络输入图像， x_i 表示第 i 个对应的标签。

采用 ADAM 优化器优化网络，使 $L(\Theta)$ 最小化。其参数如表 4-1 所示，其他参数使用默认值。初始学习率为 0.001，每次批量输入 24 对数据，每运行 40 次实现一次整个训练集的训练。实验所用语言为 Python，在 Pytorch 框架中实现，采用 64 位 Windows10 操作系统，内存 16.0G，显卡 NVIDIA2060Ti。

表 4-1 ADAM 优化器具体参数

参数名称	数值
批量大小	24
第一次估计的指数衰减率	0.9
第二次估计的指数衰减率	0.999
学习速率	0.01
防止除零	10

4.3 仿真实验结果分析

4.3.1 测试图去噪实验

模型训练完成后，选取一组噪声分布较均匀的噪声图，将改进网络与目前使用广泛的降噪方法可训练非线性反应扩散算法（Trainable Nonlinear Response Diffusion, TNRD）^[69]、三维块匹配算法（3D Block Matching, BM3D）^[70]、多级小波神经网络（Multi-level Wavelet Convolutional NeuralNetwork, MWCNN）^[71]进行对比，去噪结果如图 4-4 所示。可以看出，训练后的网络降噪效果远好于其他三种去噪算法。BM3D 算法和 TNRD 算法虽能有效去除噪声，但损失细节，同时需要多张全息图得到一张去噪全息图，MWCNN 算法没有最大限度的提取有效信息。改进网络在原本的噪声被有效去除的基础上，最大限度的提取有效信息，去噪结果显著。由于小波变换的特点，在分布不均匀的噪声区域能重点去噪，各个区域都能取得较好的去噪效果。同时由于下采样和上采样中 DWT 和 IWT 的可逆性，能保证细节不损失。

本章同样使用 PSNR 和 SSIM 作为质量评价指标，根据 PSNR 和 SSIM 的计算公式可知，二者值越大，图像质量越好。将测试图用改进方法和对比方法分别

去噪后，再分别计算三张测试图的 PSNR 值和 SSIM 值，结果如表 4-2 所示，可看出改进方法去噪后的全息图 PSNR 值和 SSIM 值均大于对比方法去噪后的全息图评价指标。




图 4-4 不同算法测试图去噪结果对比

表 4-2 不同算法降噪结果 PSNR(dB)/SSIM 值

测试图	BM3D	TNRD	MWCNN	CBAM-MWRN
	(PSNR/SSIM)	(PSNR/SSIM)	(PSNR/SSIM)	(PSNR/SSIM)
1	29.85/0.8512	30.02/0.8523	30.25/0.8554	31.81/0.8710
2	28.47/0.8002	28.89/0.8103	29.23/0.8263	29.45/0.8401
3	29.91/0.8812	29.25/0.8755	29.85/0.8790	31.95/0.9012

4.3.2 不同噪声全息图降噪实验对比

CBAM-小波残差网络对干涉条纹图的降噪效果显著，为测试网络对纯相位全息图的降噪能力，选取图像研究领域经典 Lena 图作为测试图，将 Lena 全息图输入网络，同时用 BM3D 算法，TNRD 算法，MWCNN 算法对全息图进行降噪，并将降噪后的全息图重建，结果如图 4-5 所示。




图 4-5 对比试验结果。(a)未去噪全息图；(b)BM3D 算法去噪全息图；(c)TNRD 算法去噪全息图；(d)MWCNN 网络去噪全息图；(e)CBAM-小波残差网络去噪全息图；(f)~(j)对应全息图重建图

为验证本文改进算法对不同纯相位全息图生成算法的去噪效果，将误差扩散算法、双相位算法、Gerchberg-Saxton 算法三种经典算法生成的全息图经改进网络去噪后重建图与未去噪重建图进行对比，对比结果如图 4-6 所示。



图 4-6 仿真结果。(a)误差扩散算法重建图；(b)双相位算法重建图；(c)Gerchberg-Saxton 算法重建图；(d)误差扩散算法去噪后重建图；(e)双相位算法去噪后重建图；(f)Gerchberg-Saxton 算法去噪后重建图

可以看出, 误差扩散算法及双相位算法全息图经网络去噪后成像质量有明显提升, 由表 4-3 可知, Gerchberg-Saxton 算法去噪后重建图 PSNR 提升为 0.2 分贝左右。

表 4-3 不同算法去噪前后 PSNR(dB)/SSIM 值

	误差扩散算法	双相位算法	Gerchberg-Saxton 算法
去噪前重建	22.36/0.7913	24.87/0.8223	31.75/0.8812
去噪后重建	25.12/0.8122	26.35/0.8459	31.77/0.8867

为进一步说明改进网络对全息图去噪时进行细节优化, 如图 10 选取经典全息图片进行去噪仿真。(a)~(d)为未去噪全息图重建图, (e)~(h)为改进网络去噪后全息图重建图, 可以看出改进网络在各个区域都能很好恢复出相位信息。




图 4-7 未去噪全息图重建图(a)~(d)与去噪全息图重建图对比(e)~(h)

4.4 光学实验结果分析

图 4-8 为重建像光学重建结果对比如下图所示。可以清晰地看到去噪后的光学重建像质量有明显提升，散斑噪声较少，亮度均匀。




图 4-8 未去噪全息图重建图光学重建(a)~(d)与去噪全息图重建图光学重建(e)~(h)对比

4.5 本章小结

本章算法在小波卷积神经网络框架基础上，将 CBAM 嵌入残差块，构成 CBAM-残差模块，采用双重注意力模块对全息图散斑噪声通道和空间特征进行辨别，对散斑噪声进行特征细化，同时避免梯度爆炸问题。通过散斑干涉测量生成高精度数据集对网络进行训练，提高了模型的泛化能力。全息图散斑噪声数据集的去噪实验验证了该网络具有良好的去噪性能，与其他去噪算法的对比实验表明所提网络的可行性和有效性，具有一定的实用价值。

第5章 总结与展望

5.1 本文总结

本研究将深度学习理论与计算全息技术二者相结合,将神经网络用于全息图的快速生成以及全息图去噪,本文的主要研究内容与成果如下:

(1) 通过阅读并调研大量文献,从多个维度阐述了研究背景与意义。同时,深入分析了国内外研究现状,以此为基础,确立了本文研究工作的总体思路。

(2) 首先,对计算全息和深度学习的基本原理进行介绍,对计算全息基于菲涅耳衍射的三种算法进行仿真,以及基于深度学习的计算全息生成方法的流程进行阐述,尤其是对基于深度学习生成计算全息图的算法研究进行了简要的概述和数值仿真实验。

(3) 针对纯相位全息图生成,本文基于卷积神经网络提出残差卷积网络,将深度学习和角谱衍射相结合,通过振幅信息预测出相位信息,再经过衍射得到纯相位全息图。仿真实验和光学实验证明提出算法再成像质量上有提升。

(4) 为进一步提升图像质量,抑制纯相位全息图散斑噪声,本文提出注意力小波残差网络。网络对图像进行小波分解,同时深层网络对散斑特征进行提取,逆小波变换对全息图进行重建,得到高质量纯相位全息图。仿真实验和光学实验结果验证了提出算法的可行性。

5.2 下一步工作展望

本论文基于深度学习对计算全息技术算法展开了相关探索,取得了一些初步成果。计算全息与深度学习结合的研究前景非常广泛,本文的研究深度与广度还有待提高,还有进一步的研究工作需要完成,主要包括以下两点:

(1) 本文使用已有神经网络进行改进,原神经网络并不是为计算全息图生成和散斑去噪设计,因此神经网络不具备泛化能力,下一步工作将优化神经网络的结构,提高全息图生成速度和质量。

(2) 本文使用的数据集由二维灰度图像组成,对于彩色图像、三维物体没

有进行研究。下一步计划进行彩色图像和三维物体的计算和重建。

参考文献

- [1] Párraga C A, Troscianko T, Tolhurst D J. Spatiochromatic properties of natural images and human vision[J]. *Current Biology*, 2002, 12(6): 483-487.
- [2] Gabor D. A new microscopic principle[J]. *Nature*, 1948, 161(4098): 777-778.
- [3] Lohmann A W, Paris D P. Binary Fraunhofer holograms, generated by computer[J]. *Applied Optics*, 1967, 6(10): 1739-1748.
- [4] Li J, Teng Q, Zhang N, et al. Deep learning method of stochastic reconstruction of three-dimensional digital cores from a two-dimensional image[J]. *Physical Review E*, 2023, 107(5): 055309.
- [5] Liu S, Li Y, Su Y. Recent Progress in True 3D Display Technologies Based on Liquid Crystal Devices[J]. *Crystals*, 2023, 13(12): 1639.
- [6] H. A D, Priyanuj B, S. V A D, et al. Light sheets for continuous-depth holography and three-dimensional volumetric displays[J]. *Nature Photonics*, 2023, 17(5): 427-434.
- [7] Bai Y C, Deng H, Yang C N, et al. Sub-pixel marking and depth-based correction methods for the elimination of voxel drifting in integral imaging display[J]. *Optics Express*, 2024, 32(7): 12243-12256.
- [8] Dorrah A H, Bordoloi P, de Angelis V S, et al. Light sheets for continuous-depth holography and three-dimensional volumetric displays[J]. *Nature Photonics*, 2023, 17(5): 427-434.
- [9] 王化宾, 何渝, 赵立新. 基于改进 Gerchberg-Saxton 算法的全息双面光刻方法[J]. *激光与光电子学进展*, 2023, 60(16): 69- 75.
- [10] Zhou P, Zhou J, Lv Y. Metasurface CGH optimization for CTIS based on interior point method[J]. *Laser Physics Letters*, 2024, 21(5): 055207.
- [11] 高乾程, 何泽浩, 刘珂瑄等. 面向纯相位型全息显示的自适应混合约束迭代算法[J]. *物理学报*, 2023, 72(02): 79-87.
- [12] Zhou P C, Li Y, Liu S X, etc. Dynamic compensatory Gerchberg–Saxton algorithm for multiple-plane reconstruction in holographic displays[J]. *Optics Express*, 2019, 27(6): 8958-8967.
- [13] Cumbajin E, Rodrigues N, Costa P, et al. A Real-Time Automated Defect Detection System for

- Ceramic Pieces Manufacturing Process Based on Computer Vision with Deep Learning[J].
Sensors, 2023, 24(1): 232.
- [14] Zheng Y, Shen C, Wang Z, et al. Unsupervised deep neural network for fast computer-generated holography with continuous depth control[J]. Optics and Lasers in Engineering, 2024, 180: 108310.
- [15] Taye M M. Understanding of machine learning with deep learning: architectures, workflow, applications and future directions[J]. Computers, 2023, 12(5): 91.
- [16] Wang J, Shang, Zhao X, et al. A convolutional neural network-based rate control algorithm for VVC intra coding[J]. Displays, 2024, 82102652-.
- [17] Feng K, Li J, Li M, et al. Visible and NIR microscopic hyperspectrum reconstruction from RGB images with deep convolutional neural networks. [J]. Optics Express, 2024, 32(3): 4400-4412.
- [18] Achatz J, Lukovic M, Hilt S, et al. Convolutional neural networks for quality and species sorting of roundwood with image and numerical data[J]. Expert Systems with Applications, 2024, 246123117.
- [19] 刘珂瑄, 吴佳琛, 何泽浩, 等. 基于深度学习的计算全息显示进展[J]. 液晶与显示, 2023, 38(06): 819- 828+ 690.
- [20] Kozma A, Kelly D L. Spatial filtering for detection of signals submerged in noise[J]. Applied Optics, 1965, 4(4): 387-392.
- [21] Paris D P. Image processing by computer-generated binary filters[C]//Computerized Imaging Techniques. SPIE, 1967, 10: 73-78.
- [22] Lesem L B, Hirsch P M, Jordan J A. The kinoform: a new wavefront reconstruction device[J]. IBM Journal of Research and Development, 1969, 13(2): 150-155.
- [23] Ichioka Y, Izumi M, Suzuki T. Scanning halftone plotter and computer-generated continuous-tone hologram[J]. Applied Optics, 1971, 10(2): 403-411.
- [24] 赵燕. 三维场景的计算全息显示技术[D]. 清华大学, 2016.
- [25] Gerchberg R W, Saxton W O. A practical algorithm for the determination of phase from image and diffraction plane pictures[J]. SPIE Ailestone Series MS, 1994, 93: 306-306.

- [26] Kuzmenko A, Iezhov P, Kim J T. Weighting iterative Fourier transform algorithm for kinoform implemented with phase-only SLM[C]//Digital Holography and Three-Dimensional Imaging. Optica Publishing Group, 2011: DTuC37.
- [27] Wu Y, Wang J, Chen C, et al. Adaptive weighted Gerchberg-Saxton algorithm for generation of phase-only hologram with artifacts suppression[J]. Optics Express, 2021, 29(2): 1412-1427.
- [28] Hauck R, Bryngdahl O. Computer-generated holograms with pulse-density modulation[J]. JOSAA, 1984, 1(1): 5-10.
- [29] Chang C, Xia J, Lei W. Speckle suppression in phase-only holographic display by optimizing phase distribution[C]//Digital Holography and Three-Dimensional Imaging. Optica Publishing Group, 2015: DW3A. 5.
- [30] 周婷婷, 韩超. 三维纯相位全息显示中的散斑噪声抑制[J]. 中国激光, 2018, 45(12): 232-237.
- [31] Liu K, He Z, Cao L. Pattern-adaptive error diffusion algorithm for improved phase-only hologram generation[J]. Chinese Optics Letters, 2021, 19(5): 050501.
- [32] Hsueh C K, Sawchuk A A. Computer-generated double-phase holograms[J]. Applied Optics, 1978, 17(24): 3874-3883.
- [33] Mendoza-Yero O, Mínguez-Vega G, Lancis J. Encoding complex fields by using a phase-only optical element[J]. Optics Letters, 2014, 39(7): 1740-1743.
- [34] Tsang P W M, Chow Y T, Poon T C. Generation of edge-preserved noise-added phase-only hologram[J]. Chinese Optics Letters, 2016, 14(10): 100901.
- [35] Seldowitz M A, Allebach J P, Sweeney D W. Synthesis of digital holograms by direct binary search[J]. Applied Optics, 1987, 26(14): 2788-2798.
- [36] Yoshikawa N, Yatagai T. Phase optimization of a kinoform by simulated annealing[J]. Applied Optics, 1994, 33(5): 863-868.
- [37] Zhou G, Chen Y, Wang Z, et al. Genetic local search algorithm for optimization design of diffractive optical elements[J]. Applied Optics, 1999, 38(20): 4281-4290.
- [38] McCulloch W S, Pitts W. A logical calculus of the ideas immanent in nervous activity[J]. The Bulletin of Mathematical Biophysics, 1943, 5: 115-133.

- [39] Rosenblatt F. The perceptron: a probabilistic model for information storage and organization in the brain[J]. Psychological Review, 1958, 65(6): 386.
- [40] Marvin M, Seymour A P. Perceptrons[J]. Cambridge, MA: MIT Press, 1969, 6: 318-362.
- [41] Ackley D H, Hinton G E, Sejnowski T J. A learning algorithm for Boltzmann machines[J]. Cognitive Science, 1985, 9(1): 147-169.
- [42] Hinton G E, Salakhutdinov R R. Reducing the dimensionality of data with neural networks[J]. Science, 2006, 313(5786): 504-507.
- [43] LeCun Y, Boser B, Denker J S, et al. Backpropagation applied to handwritten zip code recognition[J]. Neural Computation, 1989, 1(4): 541-551.
- [44] Hinton G E, Salakhutdinov R R. Reducing the dimensionality of data with neural networks[J]. Science, 2006, 313(5786): 504-507.
- [45] Hinton G E, Osindero S, Teh Y W. A fast learning algorithm for deep belief nets[J]. Neural Computation, 2006, 18(7): 1527-1554.
- [46] Nair V, Hinton G E. Rectified linear units improve restricted boltzmann machines[C]//Proceedings of the 27th International Conference on Machine Learning (ICML-10). 2010: 807-814.
- [47] Krizhevsky A, Sutskever I, Hinton G E. Imagenet classification with deep convolutional neural networks[J]. Advances in Neural Information Processing Systems, 2012, 25.
- [48] Simonyan K, Zisserman A. Very deep convolutional networks for large-scale image recognition[J]. arXiv preprint arXiv:1409.1556, 2014.
- [49] Szegedy C, Liu W, Jia Y, et al. Going deeper with convolutions[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. 2015: 1-9.
- [50] Goodfellow I, Pouget-Abadie J, Mirza M, et al. Generative adversarial nets[J]. Advances in Neural Information Processing Systems, 2014, 27.
- [51] Horisaki R, Takagi R, Tanida J. Deep-learning-generated holography[J]. Applied Optics, 2018, 57(14): 3859-3863.
- [52] Lee J, Jeong J, Cho J, et al. Deep neural network for multi-depth hologram generation and its training strategy[J]. Optics Express, 2020, 28(18): 27137-27154.

- [53] Peng Y, Choi S, Padmanaban N, et al. Neural holography with camera-in-the-loop training[J]. ACM Transactions on Graphics (TOG), 2020, 39(6): 1-14.
- [54] Wu J, Liu K, Sui X, et al. High-speed computer-generated holography using an autoencoder-based deep neural network[J]. Optics Letters, 2021, 46(12): 2908-2911.
- [55] Eybposh M H, Caira N W, Atisa M, et al. DeepCGH: 3D computer-generated holography using deep learning[J]. Optics Express, 2020, 28(18): 26636-26650.
- [56] 孙骁, 韩超. 基于深度学习和分层角谱的三维纯相位全息显示[J]. 激光与光电子学进展, 2022, 59(04): 53-61.
- [57] Hao F, Tang C, Xu M, et al. Batch denoising of ESPI fringe patterns based on convolutional neural network[J]. Applied Optics, 2019, 58(13): 3338-3346.
- [58] Yan K, Chang L, Andrianakis M, et al. Deep learning-based wrapped phase denoising method for application in digital holographic speckle pattern interferometry[J]. Applied Sciences, 2020, 10(11): 4044.
- [59] Yin D, Gu Z, Zhang Y, et al. Speckle noise reduction in coherent imaging based on deep learning without clean data[J]. Optics and Lasers in Engineering, 2020, 133: 106151.
- [60] 周孟航, 赵自新, 杨兴宇等. 基于多尺度空间注意力的高精度数字全息散斑去噪方法[J]. 强度与环境, 2022, 49(05): 170-177.
- [61] Liu K ,Wu J ,He Z , et al.54.2: High - fidelity model - driven deep learning network for phase - only computer - generated holography[J].SID Symposium Digest of Technical Papers,2023,54(S1):402-404.
- [62] 崔文乐, 韩利琪, 霍晓敏等. 菲涅耳衍射积分的单次傅里叶变换算法[J]. 大学物理, 2019, 38(02): 9-16.
- [63] 罗天娇, 张亚萍. 计算全息不同重建算法的研究和比较[J]. 云南师范大学学报(自然科学版), 2016, 36(01): 25-29.
- [64] 韩佳成, 郭文雅, 赵亚楠等. 菲涅耳衍射积分的角谱算法[J]. 河北大学学报(自然科学版), 2023, 43(03): 237-247.
- [65] Liu Z, Mao H, Wu C Y, et al. A convnet for the 2020s[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. 2022: 11976-11986.

- [66] 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.
- [67] Radford A, Metz L, Chintala S. Unsupervised representation learning with deep convolutional generative adversarial networks[J]. arXiv preprint arXiv:1511.06434, 2015.
- [68] Kingma D P, Ba J. Adam: A method for stochastic optimization[J]. arXiv preprint arXiv:1412.6980, 2014.
- [69] Chen Y, Yu W, Pock T. On learning optimized reaction diffusion processes for effective image restoration[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. 2015: 5261-5269.
- [70] Kemao Q, Wang H, Gao W, et al. Phase extraction from arbitrary phase-shifted fringe patterns with noise suppression[J]. Optics and Lasers in Engineering, 2010, 48(6): 684-689.
- [71] Zhang K, Zuo W, Chen Y, et al. Beyond a gaussian denoiser: Residual learning of deep cnn for image denoising[J]. IEEE Transactions on Image Processing, 2017, 26(7): 3142-3155.

攻读硕士期间发表的文章

- [1] Li X Y, Han C, Zhang C. Phase-only hologram denoising based on attention wavelet residual neural network[J]. Optics Communications, 2024, 557: 130353.

致 谢

本论文研究是在我的导师韩超教授的指导下完成的,感谢韩超老师学术上的教诲和生活上的关心。

感谢我的父母多年来对我的养育,因为站在了你们的肩膀上才看到了更广阔的世界。感谢所有家人对我的爱护,对我求学路上的支持。

感谢我的好朋友们,陪我走过人生中一些艰难时刻,听我无休止的抱怨,给予我宽慰,没有你们我也不能行路至此。

感谢实验室的小伙伴们,师兄师姐、师弟师妹、同门对我的帮助,不会忘记我们一起在实验室留下的欢声笑语。