

文章编号: 1002-1582(2026)01-0061-07

基于残差注意力机制的离轴数字全息重建

蒙明伟², 蒋行国^{1*}

(1. 智能感知与控制四川省重点实验室, 四川 宜宾 644005)

(2. 四川轻化工大学 物理与电子工程学院, 四川 宜宾 644005)

摘 要: 离轴数字全息重建具有重要应用价值, 但重建方法仍较为有限, 面临零级衍射干扰, 计算复杂度高以及重建精度受限等问题。针对这些问题, 论文提出一种基于残差注意力机制的离轴数字全息重建方法。首先采用优化后的 U-Net 模型作为网络架构, 并使用模拟生成的离轴菲涅尔全息图进行训练。然后, 通过改进 U-Net 模型中的编码器和解码器结构, 以提升网络特征提取能力, 从而能够实现高质量的离轴数字全息图重建。最终, 为进一步验证该模型的抗噪声性能, 保持网络结构和参数不变, 使用含噪声的数据集进行重建, 并对重建结果进行质量评估。实验结果表明, 相较于最优对比算法, 改进后的网络在数据集上的平均 SSIM 和 PSNR 分别提高了 2.97% 和 15.52%, 而在加噪数据集上平均 SSIM 和 PSNR 则分别提高了 6.48% 和 19.04%。显著提升了离轴数字全息重建的质量和抗噪性能, 为复杂光学成像问题提供了有效的深度学习解决方案。

关 键 词: 数字全息; 离轴全息重建; 深度学习; 残差注意力; 神经网络

中图分类号: O436

文献标识码: A

Off-axis digital holographic reconstruction based on residual attention mechanism

MENG Mingwei², JIANG Xingguo^{1*}

(1. Intelligent Perception and Control Key Laboratory of Sichuan Province, Yibin 644005, China)

(2. College of Physics and Electronic Engineering, Sichuan University of Science And Engineering, Yibin 644005, China)

Abstract: Off-axis digital holographic reconstruction holds significant practical value, yet existing methods remain limited due to challenges such as zero-order diffraction interference, high computational complexity, and restricted reconstruction accuracy. To address these issues, an off-axis digital holographic reconstruction method based on residual attention mechanisms is proposed. The study first employs an optimized U-Net model architecture and utilizes simulated off-axis Fresnel holograms for training. Subsequently, the encoder-decoder structures in the U-Net model are enhanced to improve feature extraction capabilities, enabling high-quality reconstruction of off-axis digital holograms. Finally, to validate the model's noise resistance, reconstruction was performed using noisy datasets while maintaining the original network structure and parameters, with quality assessments conducted on reconstructed results. Experimental results demonstrate that compared to the optimal reference algorithm, the improved network achieves 2.97% higher average SSIM and 15.52% better PSNR performance on standard datasets. Notably, it shows 6.48% and 19.04% improvements in average SSIM and PSNR across noisy datasets. The quality and noise reduction performance of off-axis digital holographic reconstruction are significantly improved, and an effective deep learning solution is provided for complex optical imaging problems.

Keywords: digital holography; off-axis holographic reconstruction; deep learning; residual attention; neural networks

收稿日期: 2025-09-19; 收到修改稿日期: 2025-10-31

基金项目: 四川轻化工大学人才引进项目 (2019RC12)

作者简介: 蒙明伟 (2000—), 男, 硕士研究生, 从事数字全息, 图像处理方面的研究。1917608295@qq.com

蒋行国 1973—), 男, 副教授, 博士, 从事信号处理方面的研究。

* 通讯作者: tonny_jiang@suse.edu.cn

0 引 言

数字全息技术融合了信息光学、全息学、光电子学和数字图像处理。它利用 CCD 记录物光与参考光的干涉图样，并以数字形式存储。然后，通过衍射传播理论计算物光波场的振幅和相位，实现全息图的数字化记录与再现。该技术能够精确获取物体的三维信息，在医学成像^[1]、全息显示^[2]和工业检测^[3]等领域具有重要应用价值。然而，传统数字全息重建方法存在计算效率低、对噪声敏感，以及同轴全息的孪生像和离轴全息的零级干扰等问题，限制了实际应用，因此需要新方法来提高性能。

在数字全息成像领域，传统方法大多将压缩感知^[4]和小波变换^[5]应用于全息重建的研究。近年来，随着深度学习技术的快速发展，深度学习在图像分割^[6]、超分辨率成像^[7]和目标检测^[8]等领域取得了重大突破。得益于卷积神经网络 (CNN)^[9]、生成对抗网络 (GAN)^[10]和循环神经网络 (RNN)^[11]等网络架构在图像处理方面的显著优势，越来越多的学者将深度学习和数字全息进行融合，取得了显著进展。2020 年，Wang 等^[12]基于 Y-Net 网络提出了一种新的卷积网络 Y4-Net，该网络专为双波长数字全息光路设计，能够从单张全息图中高效重建出双波长的复振幅信息。2021 年，He 等^[13]提出了一种基于 U-Net 的同轴数字全息图单帧再现方法，可利用单幅同轴全息图消除零级像和孪生像。同年，Pu 等^[14]对 U-Net 网络进行改进，使其能够同时重建不同尺度的全息图。2022 年，Cheng 等^[15]将深度学习应用于二维连续太赫兹同轴数字全息中的振幅重建，效果良好。2023 年，Liu 等^[16]提出了一种基于深度学习的彩色全息图重建方法，改进了 U-Net 网络模型，实现了高精度、保真度的彩色全息图重建。近两年来，数字全息领域的研究呈现出与深度学习网络架构模型互相融合的趋势，以应对复杂场景下的重建挑战。2025 年，Yan 等^[17]在 U-Net 架构中引入 Transformer 增强的多光谱通道注意力机制，同步实现相位解包裹与像差补偿。同年，Hu 等^[18]提出了基于图神经网络的全息重建模型，通过挖掘振幅和相位物理关联，实现小样本条件下的高精度光场复原。上述深度学习在数字全息领域的研究主要集中于同轴全息，而针对离轴数字全息的重建方法仍需要进一步研究。此外，离轴全息在重建过程中依然面临计算复杂度高、重建精度受限等挑战，亟需更高效、精准的重建方法来提高整体性能。

因此，为提升重建质量并优化计算效率，论文提出了一种基于残差注意力机制的离轴全息重建方法。该方法旨在通过深度学习技术实现高精度的图像重建，具体工作包括：采用模拟生成的离轴菲涅尔全息图构建训练数据集，并对比分析所提方法与传统方法及其他流行网络的重建效果。

1 数字全息图重建原理

如图 1 所示，相干光照射物体产生物光，物光与参考光在 CCD 记录面上干涉，形成数字全息图，物平面与记录面间距为 d 。设到达全息记录面的物光波的复振幅为 $O(x, y)$ ，参考光的复振幅为 $R(x, y)$ ，且

$$O(x, y) = a_o(x, y) \exp(i\varphi_o(x, y)) \quad (1)$$

$$R(x, y) = a_r(x, y) \exp(i\varphi_r(x, y)) \quad (2)$$

式中， $a_o(x, y)$ ， $a_r(x, y)$ ， $\varphi_o(x, y)$ 和 $\varphi_r(x, y)$ 分别表示物光和参考光在记录面上的振幅和相位，则物光和参考光发生干涉后强度分布为

$$I(x, y) = |O(x, y)^2 + R(x, y)^2| \quad (3)$$

将上式展开后得

$$I(x, y) = |O(x, y)^2| + |R(x, y)^2| + O(x, y)R^*(x, y) + O^*(x, y)R(x, y) \quad (4)$$

式中， $|O(x, y)^2|$ 与 $|R(x, y)^2|$ 分别对应物光波与参考光波自身的强度信息； $O(x, y)R^*(x, y)$ 代表由共轭参考光所调制的物光波； $O^*(x, y)R(x, y)$ 则表示为参考光调制的共轭物光波。




图 1 离轴全息成像原理图

参考光和物光单独到达全息图的强度分别为上式的第一、二项。第三项包含了它们的振幅和相位信息。

数字全息再现时则利用再现光波照射数字全息图，通过消除零级干扰和相位解包裹等处理，重构物体波前。数字全息再现原理如图 2 所示。




图2 波前再现原理图

2 基于RAU-Net的离轴数字全息图重建网络

U-Net网络广泛应用于图像处理等领域,如图3所示。该网络采用编码-解码架构,并结合跳跃连接,以有效融合不同尺度的特征信息。在编码阶段,利用传统的双层卷积块进行特征提取,并通过最大池化层逐步降低空间分辨率,以获取更具全局语义信息的特征。在解码阶段,采用转置卷积进行上采样,逐步恢复图像的空间细节。最终,通过 1×1 卷积生成单通道的重建图像。




图3 U-Net结构

尽管U-Net通过跳跃连接在一定程度上缓解了特征丢失问题,但受卷积与池化操作的影响,仍会导致高频信息丢失,从而影响精细结构的恢复。此外,由于全息图易受到散斑噪声、光学系统误差等因素的干扰,U-Net在强噪声环境下易引入伪影或导致细节模糊,从而影响重建质量。同时,由于采用较深的网络结构,U-Net在训练过程中可能面临梯度消失或梯度爆炸问题,影响模型的稳定性和收敛速度,从而限制其在离轴数字全息重建任务中的应用。针对以上问题,论文提出了RAU-Net,它通过残差模块、通道空间注意力模块和高效上采样模块的协同工作,实现高质量重建。总体框架如图4所示,通过编码器-解码器结构隐式学习衍射逆变换,实现从离轴全息图到复振幅光场的端到端物理映射。首先,在编码阶段采用残差块来代替双层卷积块,并在后面添加CBAM(通道空间注意力模块),以此来提取图像的多层次特征信息,并通过最大池化逐步降低空间分辨率,提高对全局关键信息的提取能力。然

后,在解码阶段通过双线性插值上采样和卷积操作来代替转置卷积恢复图像空间信息,并结合跳跃连接充分利用低级与高级特征,提高细节复原能力。最后,通过 1×1 卷积生成重建图像,同时保证全局结构和局部细节的一致性,实现高质量的图像重建。




图4 RAU-Net结构

2.1 残差模块

为有效缓解深层网络训练中的梯度消失和过拟合等问题,并增强特征表示能力,在改进的网络结构中引入残差块,如图5所示。残差块由两个 3×3 卷积层、批量归一化层和Relu激活函数组成,同时采用跳跃连接以实现恒等映射,使得梯度能够更顺畅地向前传播,提高模型的收敛速度和稳定性。针对离轴全息重建中高频信息易丢失、训练不稳定的难点,残差模块凭借恒等映射稳定了梯度流,并实现了对关键衍射特征的多层次复用。




图5 残差模块

2.2 CBAM注意力模块

为提升网络特征表达能力并增强对关键区域的关注,引入轻量级通道空间注意力模块。该模块依次通过通道与空间注意力机制,以串联加权

方式对输入特征进行自适应优化。具体流程如图6所示：输入特征先经通道注意力加权生成中间特征F1，再通过空间注意力处理得到F2。最终，将增强后的特征与原始输入相加，以缓解信息丢失与梯度消失问题。CBAM在有效聚焦关键信息、提升重建质量的同时，保持了即插即用的轻量级优势。




图6 通道空间注意力模块

现有相关研究^[19,20]，将注意力模块应用于计算全息图生成，即从图像到全息图。而本文将CBAM注意力模块首次系统地应用于离轴数字全息重建，实现全息图到图像这一逆问题求解过程。在此次重建任务中，CBAM注意力模块专门用于在特征空间实现自适应的频带选择与区域优选，以针对性抑制离轴全息中特有的零级干扰和共轭像噪声。

通道注意力模块通过全局池化与共享MLP，自适应生成通道权重，增强关键衍射特征并抑制噪声，从而提升重建图像的质量与鲁棒性，如图7所示。通道注意力机制模块的引入，解决了不同特征通道中衍射信息重要性各异的问题。该模块通过分析全息图的全局上下文，自动增强承载关键衍射特征的通道，同时抑制包含冗余背景或噪声的通道。这种对特征通道的自适应加权机制，使网络能够择重关注，从而更精准地提取与重建目标相关的信息，显著提升了重建图像的结构保真度与噪声鲁棒性。




图7 通道注意力模块

空间注意力模块通过并行使用全局平均池化和全局最大池化，分别捕捉特征图的空间重要性特征，并将两种特征在通道维度拼接后，经过 7×7 卷积层进行空间关系建模，最终通过Sigmoid函数生成空间注意力权重图。如图8所示。在离轴数字全息重建任务中，空间注意力模块通过自主学习特征图的空间重要性分布，使网络能够精确锁定全息图中承载物体波前信息的关键干涉条纹区域，并自适应增强这些区域的响应强度，从而在复杂成像环境下显著提升重建图像的信噪比和细节还原能力，确保物体轮廓与纹理特征的高保真重建。




图8 空间注意力模块

2.3 上采样模块

上采样模块旨在实现特征图的空间分辨率提升与精细化特征提取，如图9所示。上采样模块在解码器中承担着重建图像空间分辨率与几何结构恢复的关键任务。该模块采用双线性插值实现特征图的尺度扩展，有效避免了转置卷积可能带来的棋盘格伪影问题，保证了重建图像的视觉平滑度。随后通过卷积层进行特征变换与语义信息融合，结合批量归一化确保训练稳定性，使网络能够从压缩的特征表示中逐步恢复物体的精细结构和边缘细节。




图9 上采样模块

3 实验与结果

3.1 实验数据集

实验使用Matlab自带的digitTrainArrayData数据集作为网络输入的标签，并将这些数据集通过菲涅尔衍射积分的S-FFT计算模拟生成菲涅尔离轴数字全息图。假设照明光源的波长为437nm，物体到全息记录面的距离 $d=1000\text{mm}$ ，CCD像素宽度为0.00465mm，参考光选为平行光，计算物光波到达CCD平面的物光波复振幅和参考光复振幅进行相干叠加，计算干涉场强度，再将干涉强度进行归一化，形成数字全息图。实验将对digitTrain4DArrayData数据集中的5000张图像进行处理，将其依次转换为数字全息图。在训练之前，选择其中3500张作为训练集，1000张作为验证集，500张作为测试集。在此过程中，将手写数字图像和生成的数字全息图的尺寸统一调整为 256×256 像素。之后保持所有条件不变，在生成数字全息图中加入随机相位噪声。生成菲涅尔离轴数字全息图和重建过程如图10所示。




图10 传统数字全息图生成重建过程

3.2 网络训练

训练的损失函数采用的是一种混合损失函数，旨在同时优化结构相似性（SSIM）和均方误差（MSE）损失，从而提升深度学习模型在图像重建任务中的性能。SSIM 损失通过比较图像块的亮度、对比度和结构，能有效恢复物体轮廓细节与干涉条纹对比度。MSE 损失作为像素级损失，保证了重建图像的整体保真度和亮度准确性，但其对全息图中的关键结构化信息不敏感，容易导致重建结构中的细节模糊。与 SSIM 损失结合使用，可以避免 MSE 损失的不足，即兼顾图像结构保留和像素级精度，从而提升模型在图像重建任务中的适应性和重建图像的整体质量。其计算公式为

Mixed Loss = $a \cdot \text{SSIMLoss} +$
 $(1 - a) \cdot \text{MSELoss}$

(5)

式中， α 的取值范围为 0 到 1，通过可调参数 α 来平衡 SSIM 损失和 MSE 损失的贡献，以适应不同的训练任务。SSIM 和 MSE 的定义将在以下公式里给出。经过多次实验，发现将参数 α 设置为 0.7 效果最优，优化器选择了 Adam 算法，以对模型参数进行有效的权重优化。学习率设置为 0.0001，以平衡收敛速度和稳定性。为了防止过拟合，采用了早停机制，设置早停轮次为 20 轮。当验证集上的损失函数在连续 20 轮内未能改善时，训练将自动停止，从而确保保存最佳的训练模型。

本实验在 Python 3.9.13 环境下，采用 PyTorch 框架构建模型，并在 NVIDIA GeForce RTX 3060 Ti 上完成训练。

3.3 结果与分析

在训练完成后，使用预先生成的 500 张测试集对网络进行评估。为验证传统角谱法重建、原始 U-Net 网络、Holo U-Net 以及 RAU-Net 网络在数字全息重建中的性能差异，依次应用这四种方法进行测试。在使用 U-Net 网络和 Holo U-Net 进行训练时，仅更改网络模型，其余参数保持不变。而对于角谱法，则从 500 张测试集中选取部分图像进行重建。角谱法是一种基于衍射传播理论的经典全息重建方法，其核心思想是通过傅里叶变换计算衍射传播过程，从而恢复物光波前。然而，该方法对噪声较为敏感，且在重建过程中易出现低频丢失或高频干扰，导致重建图像的细节信息不足。结果如图 11 所示。四种重建图像的 SSIM 值和 PSNR 值如表 1 和表 2 所示。

通过对四种算法重建图像的比较，可以明显看出，传统角谱法重建的数字全息图在细节上与原始图像存在较大差异，且重建图像在色彩表现

上显得较为暗淡，整体重建质量较低。相比之下，使用 U-Net 网络重建的图像在视觉效果上与原图相近，但在细节清晰度方面略显不足，且周围存在一些白色斑点，这可能是由于学习过程中受到噪声干扰所致。而 Holo U-Net 网络重建的结果虽然在视觉效果上更好，但图像下方始终存在条状白色伪影。值得注意的是，RAU-Net 网络在数字全息图重建中表现出显著的优势，无论是从视觉效果还是细节信息的表达上均有明显提升。同时，重建图像周围的白点明显减少，表明 RAU-Net 网络在抗噪声能力方面得到了显著增强。




图 11 四种算法重建效果图

表 1 重建图像的结构相似性指数

	角谱法	U-Net	Holo U-Net	RAU-Net
图片 1	0.1021	0.9205	0.9421	0.9683
图片 2	0.0726	0.9547	0.9601	0.9839
图片 3	0.0834	0.9399	0.9357	0.9669
图片 4	0.0862	0.9134	0.9344	0.9652
平均值	0.0861	0.9321	0.9431	0.9711

表 2 重建图像的峰值信噪比

	角谱法	U-Net	Holo U-Net	RAU-Net
图片 1	13.6908	26.4034	23.2081	31.2864
图片 2	21.2016	31.4839	23.9485	37.8736
图片 3	16.6131	27.7067	22.9442	29.4067
图片 4	16.7782	25.6795	22.8936	29.9792
平均值	17.0709	27.8183	23.2487	32.1365

为了更深入地验证 RAU-Net 网络与流行网络在抗干扰能力上的差异，在原有数据集的基础上加入随机相位噪声，并保持其他实验参数不变，仅更换网络模型。图 12 展示了原始 U-Net、Holo U-Net 和 RAU-Net 的重建效果。加噪后重建图像的 SSIM 值和 PSNR 值如表 3 和表 4 所示。




图 12 加噪后重建效果比较

表 3 加噪后重建图像的结构相似性指数

	U-Net	Holo U-Net	RAU-Net
图片 1	0.8945	0.8951	0.9449
图片 2	0.8304	0.8571	0.9031
图片 3	0.8479	0.8616	0.9368
平均值	0.8576	0.8713	0.9278

表 4 加噪后重建图像的峰值信噪比

	U-Net	Holo U-Net	RAU-Net
图片 1	23.3843	24.4151	28.4597
图片 2	21.8034	22.1691	24.7111
图片 3	20.0992	19.6501	25.6776
平均值	21.7623	22.0781	26.2828

通过对比两种网络在噪声条件下对全息图的重建结果，可以看出，原始 U-Net 网络重建的图像在左上角出现了明显的白色噪声，且整体重建效果在细节特征和清晰度方面均较差，通过 Holo U-Net 重建的图像白色噪点略微减少。相比之下，RAU-Net 网络重建的图像中白色噪声显著减少，图像质量得到显著提升。这表明 RAU-Net 网络在数字全息图重建中具有较强的噪声抑制能力，能够获得更为清晰的重建图像。

3.4 质量评估

为了对三种方法重建数字全息图的质量进行评估，采用了结构相似性指数 (SSIM) 和峰值信噪比 (PSNR) 对重建图像质量进行评估。

SSIM 的计算公式为

$$\text{SSIM}(I_1, I_2) = \frac{(2\mu_1\mu_2 + c_1)(2\sigma_{(1,2)} + c_2)}{(\mu_1^2 + \mu_2^2 + c_1)(\sigma_1^2 + \sigma_2^2 + c_2)} \quad (6)$$

式中 μ_1 是 I_1 的平均值； μ_2 是 I_2 的平均值； σ_1^2 是 I_1 的方差， σ_2^2 是 I_2 的方差， $\sigma_{(1,2)}$ 是 I_1 和 I_2 的交叉协方差。稳定常数 c_1, c_2 可以选择 $c_1 = (K_1 L)^2$ ， $c_2 = (K_2 L)^2$ ，其

中 L 为图像的动态范围。 K_1, K_2 都远远小于 1。SSIM 旨在更好地模拟人眼对图像质量的感知。两个图像之间的 SSIM 索引范围在 0 到 1 之间，SSIM 的值越接近 1，表明重建图像的质量越高。表 1 展示了测试集中四张图像经过传统角谱法、U-Net、Holo U-Net 和 RAU-Net 重建后的数字全息图的 SSIM 值。从表 1 可以看出，RAU-Net 网络的 SSIM 值明显高于传统角谱法重建、U-Net 网络和 Holo U-Net 网络的重建结果。这一数据表明，RAU-Net 网络在图像的亮度、对比度和结构信息上与原始图像的差异较小，表明其重建质量得到了明显提升。

PSNR 则是基于均方误差 (MSE) 定义，来衡量重建图像与原始图像之间的差异。其计算公式为

$$\text{PSNR} = 10 \cdot \log_{10} \left(\frac{\text{MAX}_I^2}{\text{MSE}} \right) = 20 \cdot \log_{10} \left(\frac{\text{MAX}_I}{\sqrt{\text{MSE}}} \right) \quad (7)$$

式中，MAX 为图像的最大像素值，MSE 可定义为

$$\text{MSE} = \frac{1}{mn} \sum_{i=0}^{m-1} \sum_{j=0}^{n-1} [I(i, j) - K(i, j)]^2 \quad (8)$$

式中， mn 为图像大小； $I(i, j)$ 为原始图像； $K(i, j)$ ，为重建图像；PSNR 的单位为 dB，值越大，说明重建图像的质量越好。表 2 给出了测试集中的四张图片经过传统角谱法，U-Net 和 Holo U-Net 以及 RAU-Net 之后重建的数字全息图的 PSNR 值。

从表 2 的 PSNR 值可以看出，RAU-Net 网络重建出来的图像的 PSNR 明显更高，说明重建出来的图像与原始图像在像素级别上的差异更小，表明其重建质量得到了明显提升。

从表 3 可以看出，RAU-Net 网络在加噪数字全息图的重建中，所得到的结构相似性指数 (SSIM) 值均高于原始 U-Net 网络和 Holo U-Net 的重建结果。这表明 RAU-Net 网络能够更有效地保持图像的结构和细节特征，进一步验证了其在噪声环境下优越的重建性能。

从表 4 的结果可以看出，在加噪数字全息图的重建中，RAU-Net 网络所得到的峰值信噪比 (PSNR) 值均高于其他两种网络。这表明 RAU-Net 网络在重建过程中能够更有效地抑制噪声干扰，保留更多图像细节，显著提升了重建图像的质量。

4 结 论

论文通过改进 U-Net 网络，结合残差块和通道空间注意力模块，提出了一种基于残差注意力机

制的离轴数字全息重建方法。该方法能显著提升特征提取和细节恢复能力,实现高质量重建。最终实验结果表明,提出的方法在结构相似性指数和峰值信噪比上均优于所对比算法,显著提升了重建精度。抗干扰测试也验证了改进网络的鲁棒性,即使在噪声环境下仍能保持较高重建质量。该方法为解决实际全息成像中的噪声干扰问题提供了新的技术手段,并展现了深度学习技术在复杂光学问题中的巨大潜力。

参考文献:

- [1] Zhong W. Application of artificial intelligence digital holography technology based on medical sensors in the development of medical image fusion[J]. *Measurement: Sensors*, 2024, 33:101146.
- [2] 张虎鸣, 颜盼盼, 仲崇力, 等. 基于HOE的全息显示双目视差构建方法[J]. *液晶与显示*, 2024, 39(07):892—900.
Zhang Huming, Yan Panpan, Zhong Chongli, et al. A construction method of binocular parallax for holographic display based on HOE[J]. *Liquid Crystals And Displays*, 2024, 39(07):892—900.
- [3] Fosodeder P, Hubmer S, Ploier A, et al. Phase-contrast THz-CT for non-destructive testin[J]. *Optics Express*, 2021, 29(10):15711—15723.
- [4] 张华, 曹良才, 金国藩, 等. 基于压缩感知算法的无透镜数字全息成像研究[J]. *激光与光电子学进展*, 2020, 57(08):9—19.
Zhang Hua, Cao Liangcai, Jin Guopan, et al. Research on lensless digital holographic imaging based on compressed sensing algorithm[J]. *Laser & Optoelectronics Progress*, 2020, 57(08):9—19.
- [5] 付泰, 陈艾帅, 胡磊, 等. 基于小波变换的全息图压缩编码比较研究[J]. *应用光学*, 2024, 45(01):99—106.
Fu Tai, Chen Aishuai, Hu Lei, et al. A comparative study on hologram compression coding based on wavelet transform[J]. *Journal of Applied Optics*, 2024, 45(01):99—106.
- [6] Khalifa A F, Badr E. Deep learning for image segmentation: a focus on medical imaging[J]. *Comput. Mater. Contin*, 2023, 5(1):1995—2024.
- [7] Qiao C, Li D, Liu Y, et al. Rationalized deep learning super-resolution microscopy for sustained live imaging of rapid subcellular processes[J]. *Nature Biotechnology*, 2023, 41(3):367—377.
- [8] Liu J, Pan C, Yan W Q. Litter detection from digital images using deep learning[J]. *SN Computer Science*, 2022, 4(2):134.
- [9] Zhao X, Wang L, Zhang Y, et al. A review of convolutional neural networks in computer vision[J]. *Artificial Intelligence Review*, 2024, 57(4):99.
- [10] De Souza V L T, Marques B A D, Batagelo H C, et al. A review on generative adversarial networks for image generation[J]. *Computers & Graphics*, 2023, 114:13—25.
- [11] Sherstinsky A. Fundamentals of recurrent neural network (RNN) and long short-term memory (LSTM) network[J]. *Physica D: Nonlinear Phenomena*, 2020, 404:132306.
- [12] Wang K, Qian K, Di J, et al. Y4-Net: a deep learning solution to one-shot dual-wavelength digital holographic reconstruction[J]. *Optics Letters*, 2020, 45(15):4220—4223.
- [13] 何晨, 房鸿, 张宁超. 基于深度学习的单帧同轴数字全息重建方法[J]. *光子学报*, 2021, 50(12):275—284.
He Chen, Fang Hong, Zhang Ningchao. Single-frame coaxial digital holographic reconstruction method based on deep learning[J]. *Acta Photonica Sinica*, 2021, 50(12):275—284.
- [14] 浦健, 桂进斌, 张凯. 基于深度学习的多尺度数字全息图重建[J]. *激光与光电子学进展*, 2022, 59(02):86—93.
Pu Jian, Gui Jinbin, Zhang Kai. Multi-scale digital hologram reconstruction based on deep learning[J]. *Laser & Optoelectronics Progress*, 2022, 59(02):86—93.
- [15] 成珂阳, 李琦. 深度学习用于连续太赫兹同轴数字全息重建[J]. *中国激光*, 2023, 50(19):246—256.
Cheng Keyang, Li Qi. Deep learning is used for continuous terahertz coaxial digital holographic reconstruction[J]. *Chinese Journal Of Lasers*, 2023, 50(19):246—256.
- [16] 刘俊彤, 桂进斌, 陈艾帅, 等. 基于深度学习的彩色全息图重建[J]. *激光与光电子学进展*, 2024, 61(08):86—92.
Liu Juntong, Gui Jinbin, Chen Aishuai, et al. Deep learning-based color hologram reconstruction[J]. *Laser & Optoelectronics Progress*, 2024, 61(08):86—92.
- [17] 严利平, 苗小喆, 黄柳. MScU-Net全息相位解包裹与像差同步求解[J]. *光学精密工程*, 2025, 33(15):2441—2454.
Yan Liping, Miao xiaozhe, Huang Liu. MScU-Net holographic phase unwrapping and aberration synchronous solving[J]. *Optics and Precision Engineering*, 2025, 33(15):2441—2454.
- [18] 胡先飞, 桂进斌, 董昭, 等. 基于图神经网络的数字全息图重建[J]. *光学学报*, 2025, 45(07):66—74.
Hu Xianfei, Gui Jinbin, Dong Zhao, et al. Digital hologram reconstruction based on graph neural networks[J]. *Acta Optica Sinica*, 2025, 45(07):66—74.
- [19] 赵长春. 基于注意力机制的计算全息图生成算法研究[D]. 重庆理工大学, 2024.
Zhao Changchun. Research on computational hologram generation algorithm based on attention mechanism[D]. *Chongqing University Of Technology*, 2024.
- [20] 孙康生, 韩超, 秦海峰, 等. 基于注意力卷积神经网络的高质量全息图快速生成算法[J]. *物理学报* 2025, 74(08):169—178.
Sun Kangsheng, Han Chao, Qin Haifeng, et al. A fast generation algorithm for high-quality holograms based on attention convolutional neural networks[J]. *Acta Physica Sinica*, 2025, 74(08):169—178.