

光学学报

基于 DenseNet 的散射成像景深拓展研究

林昭苏¹, 王杨云逗^{2,3*}, 王昊¹, 胡川飞¹, 顾敏^{2,3}, 杨晖^{1**}

¹上海理工大学光电信息与计算机工程学院, 上海 200093;

²上海理工大学光子芯片研究院, 上海 200093;

³上海理工大学光电信息与计算机工程学院人工智能纳米光子学中心, 上海 200093

摘要 散射现象广泛存在于自然界中。透过散射介质的大景深成像在计算成像领域具有重要的意义和应用价值。近年来,随着深度学习在计算成像领域的广泛应用,散射成像系统中的景深问题亟待进一步研究和拓展。以 DenseNet 为基础,结合 UNet 框架,建立了一个具有良好迁移性和景深拓展能力的深度卷积神经网络模型——DUNet。通过使用透过不同目数毛玻璃的散斑图像对网络进行训练,使成像景深拓展至距焦面 50 mm 处。初步的小鼠脑片实验结果表明,DUNet 模型将有望应用于深层组织断层扫描。

关键词 光计算; 密集卷积网络; 散射成像; 景深拓展

中图分类号 O439

文献标志码 A

doi: 10.3788/AOS202242.0436001

Expansion of Depth-of-Field of Scattering Imaging Based on DenseNet

Lin Zhaosu¹, Wang Yangyundou^{2,3*}, Wang Hao¹, Hu Chuanfei¹, Gu Min^{2,3}, Yang Hui^{1**}

¹ School of Optical-Electrical and Computer Engineering, University of Shanghai for Science and Technology, Shanghai 200093, China;

² Institute of Photonics Chip, University of Shanghai for Science and Technology, Shanghai 200093, China;

³ Centre for Artificial-Intelligence Nanophotonics, School of Optical-Electrical and Computer Engineering, University of Shanghai for Science and Technology, Shanghai 200093, China

Abstract Scattering is a fundamental phenomenon in nature. The imaging with large depth-of-field through a scattering medium is significant and valuable. In recent years, with the wide application of deep learning in computational imaging, it is urgent to study and further extend the depth-of-field in a scattering imaging system. In the paper, based on DenseNet and combined with the UNet architecture, a deep convolutional neural network model, namely DUNet, with good mobility and depth-of-field expansion ability is proposed. Moreover, the network is trained with speckle images passing through frosted glasses of different mesh, and the depth-of-field can be generalized to 50 mm away from the focal plane. The preliminary results on a rat brain slice demonstrate that the DUNet can be further implemented in the tomographic scanning of deep tissues.

Key words optics in computing; dense convolutional network; scattering imaging; depth-of-field expansion

光束在经过云层、烟雾、生物组织等散射介质时,介质中波长量级的微粒使其发生多重散射,从而导致其波前发生严重畸变,形成无序的出射光场,最终只能在探测平面上接收到散斑图案,难以对目标物体进行观测或成像^[1]。不仅如此,在成像目标远

离系统焦面的应用中,散射现象更是直接限制了成像系统的景深。传统光学成像系统很难解决散射引起的图像失真问题。近年来,随着机器学习的不断发展,深度学习逐渐被用于解决计算成像领域的复杂问题^[2],并在全息成像^[3]、鬼成像^[4]、超分辨成

收稿日期: 2021-11-12; 修回日期: 2021-12-17; 录用日期: 2021-12-23

基金项目: 中国博士后面上基金(2020M671169)

通信作者: *ywang0606@usst.edu.cn; **yanghui313@126.com

像^[5]、散斑图像重建^[6-10]等方面取得重大进展。2018年, Li等^[6]提出 iDiffNet 模型, 实现了强散射下的稀疏图像散斑重建。同年, Li等^[7]在 iDiffNet 的基础上提出了一种“一对多”的深度神经网络模型, 经训练后的网络具有一定的迁移性。2020年, Guo等^[8]提出了 PDSNet 模型, 该模型突破了系统记忆效应范围, 将散射成像系统的成像视场范围扩展至记忆效应范围的 40 倍, 但系统成像景深仍未得到拓展。2020年, Zhu等^[9]使用一种 DINet 模型在无透镜散射成像系统中实现了散斑深度预测与图像重建, 但该方法仅考虑了单一散射介质(220 目毛玻璃)的情况。上述工作虽已使用深度学习解决了部分散射成像问题, 但尚未深入地对不同散射介质的景深拓展进行探索。本文建立了一个基于密集卷积网络 DenseNet 的 DUNet 模型, 该模型封装了 4 种不同目数的毛玻璃作为散射介质, 经过训练后的网络具有一定的迁移性和景深拓展能力, 可实现距离

焦面 50 mm 处的散斑图像重建。

图 1 为获取散斑图样的散射成像系统。经过准直及空间滤波后的连续激光(Thorlabs HNL210L, 波长为 632.8 nm)照射在校准后的相位型空间光调制器(Thorlabs EXULUS-HD2, 像素尺寸为 $8\ \mu\text{m}$, 分辨率为 $1920\ \text{pixel}\times 1200\ \text{pixel}$)上, 并在空间光调制器的中心加载预处理后的 MNIST 数据库^[11]手写数字图像。本文依次使用 4 个不同目数的毛玻璃(Thorlabs, DG10-120-MD, 120 目; DG10-220-MD, 220 目; DG10-600-MD, 600 目; DG10-1500-MD, 1500 目)作为散射成像系统的散射介质, 并将其置于空间光调制器的共轭面处。透镜 L1(焦距 $f=300\ \text{mm}$)与 L2($f=125\ \text{mm}$)构成一个 $4f$ 系统, 以保证 CMOS 相机(Thorlabs DCC645C, 像素尺寸为 $3.6\ \mu\text{m}$, $1280\ \text{pixel}\times 1024\ \text{pixel}$)采集到的有效信息与空间光调制器上加载图像的尺寸相匹配。

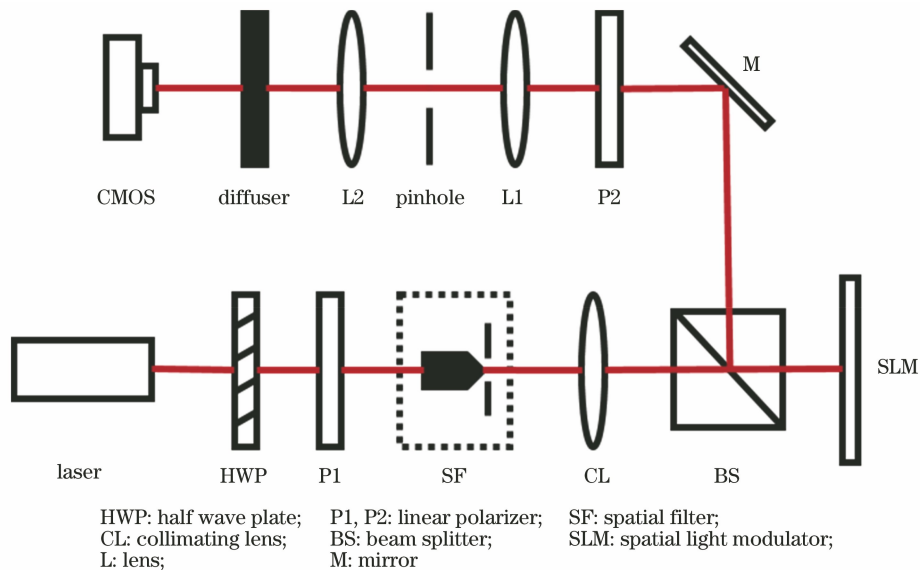


图 1 实验光路

Fig. 1 Experimental light path

对于训练及测试数据集, CMOS 相机依次位于距焦面 0 mm、20 mm 及 40 mm 处, 分别将 120 目、220 目、600 目和 1500 目毛玻璃作为散射介质, 对 600 个手写数字图像进行散斑图样采集, 共获得 7200 组训练及测试数据, 其中 10% 的数据作为测试数据。对于验证数据集, CMOS 相机依次位于距焦面 0 mm、10 mm、20 mm、30 mm、40 mm 及 50 mm 处, 分别对训练及测试中未出现过的 100 个手写数字进行散斑图样采集, 共获得 2400 组验证数据。其中, CMOS 相机的 $800\ \text{pixel}\times 800\ \text{pixel}$ 中心区域数据作为有效数据。

DUNet 网络结构框架如图 2 所示, 借鉴了 UNet 中的跳层连接方式, DUNet 模型以密集卷积网络 DenseNet^[12]为基础。其中, 密集块由密集连接层组成, 密集连接层又包含批归一化(BN)、线性整流函数(ReLU)及卷积(Conv.)操作。网络的编码部分共有 4 个密集块, 解码部分共有 3 个密集块。密集连接层的通道增长率均为 16, 其稠密连接的特性保证了网络对特征的重复利用。网络中的多个密集块在增强特征传输的同时, 减少了由于网络加深导致的梯度消失现象。在密集块中加入概率为 0.5 的神经元随机失活, 以防止网络在训练过程中产生

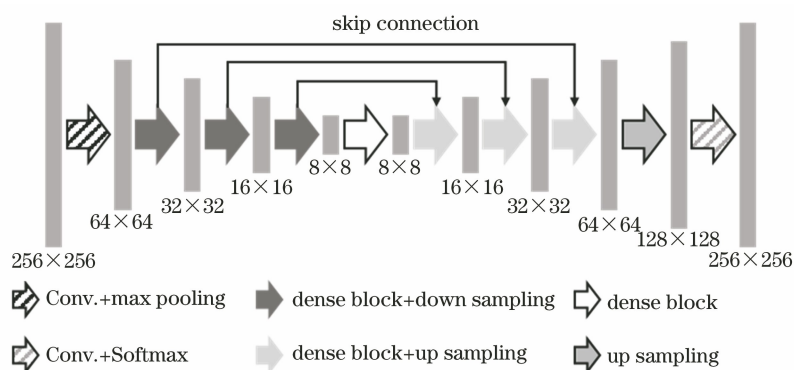


图 2 DUNet 网络结构框架图

Fig. 2 Architecture of DUNet network structure

过拟合。输出层为适用于多分类任务的非线性激活函数 Softmax。

DUNet 模型的标签为 256×256 的二值图像。网络输入层使用双线性插值法将散斑图像降采样至 256×256 , 从而减少网络参数, 降低训练成本。网络的优化参数为均方根 (RMS), 使用交叉熵 (CE) 函数作为训练损失函数, 使用负皮尔逊相关系数 (NPCC) 作为测试损失函数。网络共进行了 100 次训练, 初始学习率为 10^{-5} 。

将验证集数据输入训练好的 DUNet 模型中, 对其景深拓展能力进行验证。表 1 展示了不同探测位置处, 手写数字各项重建指标的平均量化结果。其中, 每一个探测位置均使用了 4 种不同目数的毛玻璃。皮尔逊相关系数 (PCC) 及结构相似性 (SSIM) 均高于 0.77, Jaccard 相似系数 (JI) 均高于 0.65。该结果表明网络具有良好的泛化性和鲁棒

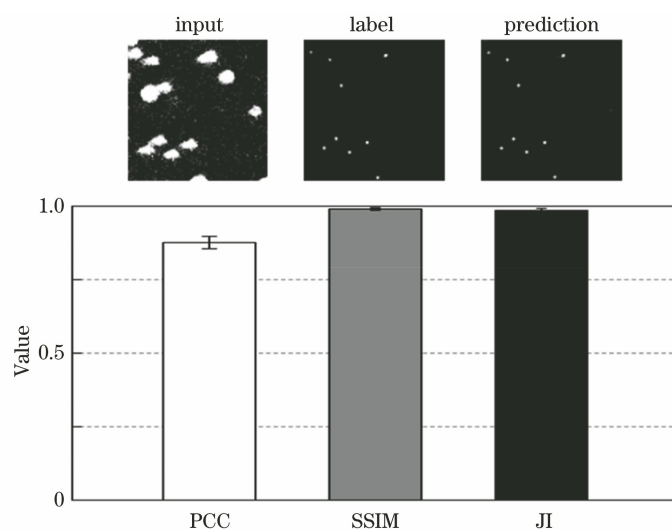
性, 且由 50 mm 处散斑重建量化分析结果可推断: DUNet 可实现对散射成像系统景深的进一步拓展。

表 1 量化分析结果

Table 1 Quantitative analysis results

Distance /mm	PCC	SSIM	JI
0	0.795	0.801	0.670
10	0.783	0.805	0.699
20	0.756	0.778	0.659
30	0.822	0.813	0.699
40	0.760	0.789	0.686
50	0.791	0.811	0.715

通过对 DUNet 进行进一步优化训练, 实现了透过 $200 \mu\text{m}$ 厚小鼠脑片的荧光小球的图像重建。图 3 为荧光小球在焦平面处的重建结果和量化分析结果, 其中 PCC 为 0.876, SSIM 及 JI 指标均高于 0.98。实验结果充分表明, DUNet 可实现透过一定

图 3 透过 $200 \mu\text{m}$ 小鼠脑片的荧光小球图像重建结果及量化分析Fig. 3 Reconstruction and quantitative analysis of fluorescence bead image using $200 \mu\text{m}$ thick rat brain slice as scattering medium

厚度的生物组织的散斑重建。

本文提出了基于密集卷积网络 DenseNet 的 DUNet 模型,该模型对于不同的探测位置具有良好的泛化性,对于不同的散斑图像重建场景具有优秀的迁移性和普适性。

参 考 文 献

- [1] Zhu L, Shao X P. Research progress on scattering imaging technology[J]. Acta Optica Sinica, 2020, 40(1): 0111005.
朱磊, 邵晓鹏. 散射成像技术的研究进展[J]. 光学学报, 2020, 40(1): 0111005.
- [2] Zuo C, Feng S J, Zhang X Y, et al. Deep learning based computational imaging: status, challenges, and future[J]. Acta Optica Sinica, 2020, 40(1): 0111003.
左超, 冯世杰, 张翔宇, 等. 深度学习下的计算成像: 现状、挑战与未来[J]. 光学学报, 2020, 40(1): 0111003.
- [3] Rivenson Y, Zhang Y, Günaydın H, et al. Phase recovery and holographic image reconstruction using deep learning in neural networks [J]. Light: Science & Applications, 2018, 7: 17141.
- [4] Lü M, Wang W, Wang H, et al. Deep-learning-based ghost imaging[J]. Scientific Reports, 2017, 7(1): 17865.
- [5] Wang H D, Rivenson Y, Jin Y Y, et al. Deep learning enables cross-modality super-resolution in fluorescence microscopy[J]. Nature Methods, 2019, 16(1): 103-110.
- [6] Li S, Deng M, Lee J, et al. Imaging through glass diffusers using densely connected convolutional networks[J]. Optica, 2018, 5(7): 803-813.
- [7] Li Y Z, Xue Y J, Tian L. Deep speckle correlation: a deep learning approach toward scalable imaging through scattering media[J]. Optica, 2018, 5(10): 1181-1190.
- [8] Guo E, Zhu S, Sun Y, et al. Learning-based method to reconstruct complex targets through scattering medium beyond the memory effect [J]. Optics Express, 2020, 28(2): 2433-2446.
- [9] Zhu S, Guo E L, Cui Q Y, et al. Locating and imaging through scattering medium in a large depth [J]. Sensors, 2020, 21(1): 90.
- [10] Wang Y, Lin Z S, Wang H, et al. High-generalization deep sparse pattern reconstruction: feature extraction of speckles using self-attention armed convolutional neural networks [J]. Optics Express, 2021, 29(22): 35702-35711.
- [11] Yann L C, Corinna C, Christopher J B. MNIST handwritten digit database[EB/OL]. [2021-11-12]. <http://yann.lecun.com/exdb/mnist>.
- [12] Huang G, Liu Z, van der Maaten L, et al. Densely connected convolutional networks [C] // 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), July 21-26, 2017, Honolulu, HI, USA. New York: IEEE Press, 2017: 2261-2269.