

DOI: 10.11830/ISSN.1000-5013.202501016



浑浊水体中模拟水生动物的识别

王孝艳^{1,2}, 柴瑜蔓^{1,2}, 蒲继雄^{1,2}

(1. 华侨大学 信息科学与工程学院, 福建 厦门 361021;

2. 华侨大学 福建省光传输与变换重点实验室, 福建 厦门 361021)

摘要: 以浑浊水体作为模型, 研究动态散射场景中的物体识别。以模拟水生动物为例, 搭建并训练神经网络, 利用深度学习技术对水生动物的种类与数量进行识别。将未经训练的散斑图像输入训练好的神经网络, 可以输出水生动物的种类和数目。实验结果表明: 利用深度学习技术可以从浑浊水体中成功识别水生动物的种类与数量, 水生动物的数量识别准确率为 100%, 水生动物的种类识别准确率均大于 99%。

关键词: 水生动物; 图像识别; 动态散射; 浑浊水体; 深度学习; 神经网络

中图分类号: O 436

文献标志码: A

文章编号: 1000-5013(2025)04-0442-06

Recognition of Simulated Aquatic Animal in Turbid Water Environments

WANG Xiaoyan^{1,2}, CHAI Yuman^{1,2}, PU Jixiong^{1,2}

(1. College of Information Science and Engineering, Huaqiao University, Xiamen 361021, China;

2. Fujian Key Laboratory of Light Propagation and Transformation, Huaqiao University, Xiamen 361021, China)

Abstract: Using turbid water as a model, this study investigates object recognition in dynamic scattering environments. Taking simulated aquatic animal as an example, a neural network is constructed and trained to identify the species and quantity of aquatic animals through deep learning techniques. When untrained speckle images are input into a trained neural network, it outputs the categories and number of aquatic animals. The experiment results demonstrate that deep learning techniques can successfully identify both the categories and quantity of aquatic animals in turbid water. The accuracy of quantity recognition reaches 100%, while the accuracy for species recognition exceeds 99% across all tested categories.

Keywords: aquatic animals; image recognition; dynamic scattering; turbid water; deep learning; neural network

在许多生活场景和科学研究中都存在光经过散射介质传输的现象, 例如, 雾霾环境的光学成像、烟雾场景的目标探测、多模光纤的信息传输等。由于光在散射介质的随机散射效应导致出射端的光场呈现散斑状无序分布, 这意味着原有光场信息的重新分布。从散斑场中恢复原始光场信息, 对于生物组织成像、自动驾驶、复杂环境目标识别等领域具有重要的研究意义和应用价值^[1-3]。研究人员提出了一系列方法, 有效实现了透过散射介质的成像^[4-6]。根据光子在散射介质中的传输特点, 可以将光子分为弹道光、蛇形光子和散射光子, 其中, 弹道光基本不与散射介质发生相互作用, 较好地保留了原有的光

收稿日期: 2025-01-09

通信作者: 王孝艳(1986—), 女, 实验师, 主要从事人工智能与光学技术结合的研究。E-mail: xiaoyan_wang_3@foxmail.com。

基金项目: 国家自然科学基金资助项目(62375092)

信息,因此,通过各种技术方法抑制散射光子,获取弹道光子,可以有效改善散射介质带来的负面影响,实现较高质量的成像结果^[7-8]。随着散射程度的增加,探测器采集到的弹道光子数急剧减少,因此,利用弹道光子直接成像的方法应用于强散射场景具有较大的局限性。

近年来,研究人员提出了一些利用散射光子的新型散射成像技术。散斑相关是基于记忆效应发展的一种散射成像技术,光学的记忆效应指当入射光在一定角度范围内发生倾斜时,被介质散射而形成的散射场是一系列高度相关且具有位移不变性的散斑图样。在记忆效应范围内,Bertolotti 等^[9]通过计算散斑场的自相关,获得了荧光标记物体的非侵入式成像。Katz 等^[10]进一步发展了该技术,提出单帧散斑相关成像技术,在单帧散斑场的基础上,通过空间系综平均实现统计计算,但该技术受限于记忆效应,成像视场较小。光通过散射介质的传输过程可以利用传输矩阵进行描述。通过测量散射介质的传输矩阵,并进行矩阵的反演,Popoff 等^[11]实现了透过散射介质的成像,但这种方法要求散射介质稳定,不适用于动态散射介质。基于波前技术也可以实现散射成像,但该技术需要优化迭代匹配的相位分布,因而相对比较耗时,同样不适用于动态散射场景^[12-14]。

很多实际散射场景是动态变化的,基于传输矩阵和波前整形的散射成像方法需要散斑场在数据采集过程中保持稳定不变,显然不适用于动态散射介质。光束在散射环境中传输,光场将呈现快速变化的特性。因此,要实现动态散射环境中的成像,通常需要在单次采集散斑场的基础上,实现对被散射物体的还原,这对技术提出了更高的挑战。深度学习技术通过搭建神经网络结构并采集数据对网络进行训练,利用训练好的网络,可以在输入散斑场的基础上,还原散射介质前的物体信息^[15]。研究人员提出卷积神经网络、生成对抗网络等深度学习方法实现散射成像,但这些研究大多局限于静态散射场景^[16-18]。基于此,本文以浑浊水体为动态散射场景,对动态散射场景中的物体识别进行研究。

1 实验设计

实验装置示意图,如图 1 所示。图 1 中:L1~L3 为透镜。实验以 HNL210LB 型 He-Ne 激光器(美国 Thorlabs 公司)为光源,激光经过扩束后,入射到 Pluto VIS-006 型空间光调制器(德国 Holoeye 公司)。在空间光调制器上,加载水生动物信息,经过空间光调制器反射后的光束将携带水生动物的信息。反射光束经过水缸传输后,由 PikeF421B 型工业相机(德国 AVT 公司)采集光强。

水缸尺寸(长×宽×高)为 24.0 cm×15.5 cm×15.0 cm。为了模拟浑浊水体,将肠内营养剂(TP-HE)溶解于水中。肠内营养剂成分包含矿物质、蛋白质、脂肪和微量元素等,存在形式较为多样化,蛋白质、脂肪分别以胶体和乳浊液形式存在,矿物质和微量元素主要以溶液形式存在,因此,可较好地模拟浑浊水体这一较为复杂的动态散射场景。

实验中,TP-HE 添加量(v)分别为 10、20、30 mL,水的体积为 3 L。随着 TP-HE 体积浓度的增加,水体变得更加浑浊,散射程度也随之增加。实验测量了光束经过不同体积浓度的浑浊水体的光强衰减,并将其与描述散射程度的光学厚度相联系。由实验数据测得:当 TP-HE 添加量分别为 10、20、30 mL 时,对应的光学厚度分别为 7.14、9.03、9.83。

浑浊水体的原始图像和采集图像,如图 2 所示。由图 2 可知:当 TP-HE 添加量为 10 mL 时,隐约观测到生物结构;当 TP-HE 添加量为 30 mL 时,水体呈现很强的散射效应,难以观测到原始光场信息。

以水生动物为例,对浑浊水体的目标识别进行研究。水生动物包括鱼类、贝壳类及软体动物等 10 种不同类型。将这些水生动物图像加载到空间光调制器上,当光束入射到空间光调制器,反射光束就携带了水生动物的信息,该光束最后穿过浑浊水体。利用这个设计,模拟浑浊水体中的光学成像场景,由于浑浊水体的散射效应,携带生物信息的原始光场将被扰乱,探测器采集到的光强为随机无序分布的散斑场,无法直接获取原始光场信息。

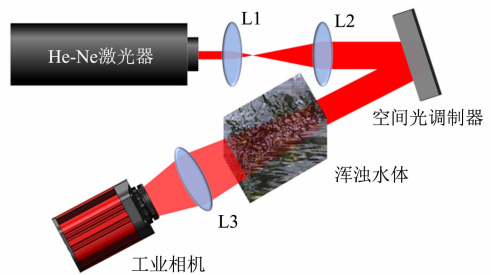


图 1 实验装置示意图

Fig. 1 Schematic diagram of experimental setup

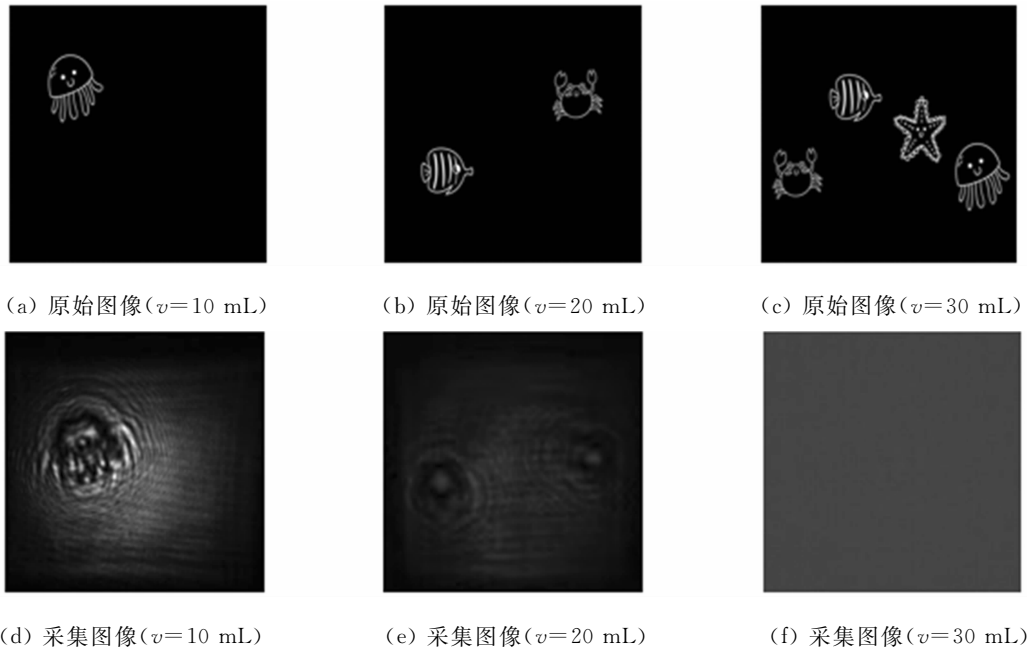


图 2 浑浊水体的原始图像和采集图像

Fig. 2 Original images and collected images of turbid water

2 神经网络结构

为了从失真的散斑图像中识别原始目标信息,设计一种轻量级卷积神经网络结构(图 3)。该网络主要由卷积层、全局最大池化层和全连接层构成,在保证识别精度的基础上,兼顾计算效率与泛化能力。

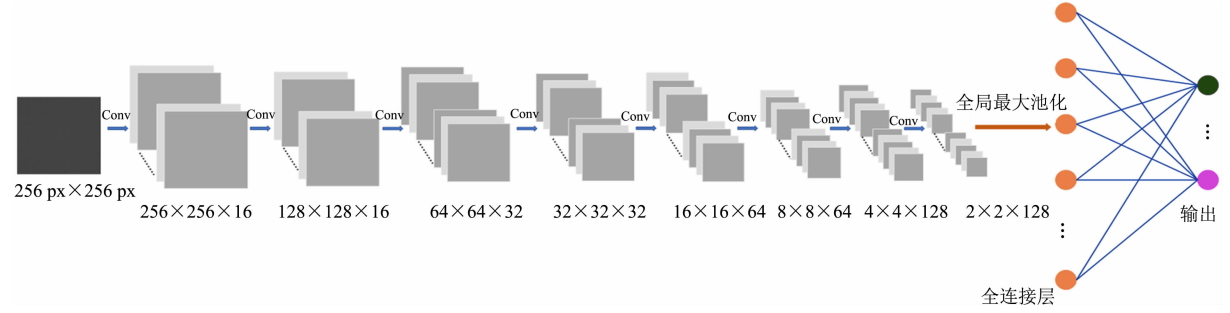


图 3 轻量级卷积神经网络结构

Fig. 3 Lightweight convolutional neural network architecture

为了将输入图像(256 px×256 px)转化为高维特征向量,首先,构建图像降维与特征提取模块。在初始阶段,使用 16 个大小为 4×4、步长为 1 的卷积核对图像进行卷积操作,提取图像中的边缘、纹理等低层次局部特征。然后,网络通过 7 次连续的卷积操作(每次卷积核大小为 4×4,步长为 2),在逐步压缩特征图空间尺寸的同时,提取更高层次的语义特征,如图像内部形状结构和空间分布模式。该过程使特征表达更加紧凑,同时提升了计算效率。

为了增强模型的训练稳定性与收敛速度,在每个卷积层后均引入批量归一化层,动量设置为 0.95。同时,在部分卷积层后引入 Dropout 机制,防止过拟合,提升模型的稳健性。激活函数采用 Leaky-ReLU,相较于传统的 ReLU 函数,其在负值区域保留微小梯度,有助于缓解神经元死亡问题,提升模型的非线性建模能力。经过上述卷积模块处理后,网络输出一个维度为 2×2×128 的高维特征张量,表示从散斑图像中提取出的深层抽象特征。神经网络通过浅层卷积提取低级图像特征(如边缘、纹理),中间层逐步捕捉图像的局部结构与空间关系,高层卷积核则能够通过感受野的扩大学习到全局语义信息,从而实现对水生动物种类与数量的准确判别。

在训练阶段,图像类别信息首先通过独热编码转换为与类别数等长的二进制向量,作为监督学习的目标标签。通过寻找二进制编码中最大值所在位置,即可获得其对应类别。高维特征张量提取完成

后,网络将该张量输入全局最大池化层,该操作在每一个通道内选取最大的响应值,从而在显著压缩空间维度的同时,保留通道中最具代表性的特征信息。池化后的特征向量进一步输入至全连接层,并通过 Softmax 激活函数输出一个长度为类别数的概率向量。

Softmax 函数将输出映射为概率空间,其中,每个元素表示图像属于对应类别的概率值,所有类别的概率总和为 1。在推理阶段,网络将选取概率向量中最大元素对应的索引位置转换为实际类别,实现图像识别任务的输出。

训练的优化器为 Adam,初始学习率为 1×10^{-3} ,并根据训练过程中的验证集性能动态调整学习率,降低损失,实现更高质量的输出。为了定量评价网络从散斑中还原初始光场信息的能力,定义识别准确率(η)为

$$\eta = \frac{N_{\text{cor}}}{N_{\text{tot}}} \times 100\%。$$
(1)

式(1)中: N_{tot} 为预测的总数量; N_{cor} 为准确预测的数量。

3 实验结果与讨论

将不同添加量的 TP-HE 溶解于水中,模拟不同散射程度的浑浊水体。通过设计的实验装置,利用相机采集模拟水生动物经过浑浊水体的散斑图像。输入采集的图像,训练神经网络。将未训练过的散斑图像输入训练网络中,利用网络识别水生动物的种类和数量。

首先,在空间光调制器上随机加载 10 种不同类型的水生动物,每次只加载 1 种水生动物,这些水生动物随机出现在空间光调制器的任意位置,以此模拟浑浊水体中存在一种水生动物的场景。每种水生动物可以出现在 400 个不同位置,相机共采集了 4 000 张散斑图像,将 3 200 张散斑图像作为训练集,将 400 张散斑图像作为测试集,将 400 张散斑图像作为验证集。

水生动物的种类识别结果,如图 4 所示。图 4 中: L 为损失。由图 4 可知:训练集和验证集的准确率不断上升,大约经过 20 代的训练后,网络即可准确识别出单个水生动物的类型;当 TP-HE 添加量变大时,水体的散射程度更高,这意味着原始光场信息被破坏得更严重,探测器采集的有效信息量更少,验证集的识别准确率一开始出现一定的震荡,最终的识别准确率略微下降。

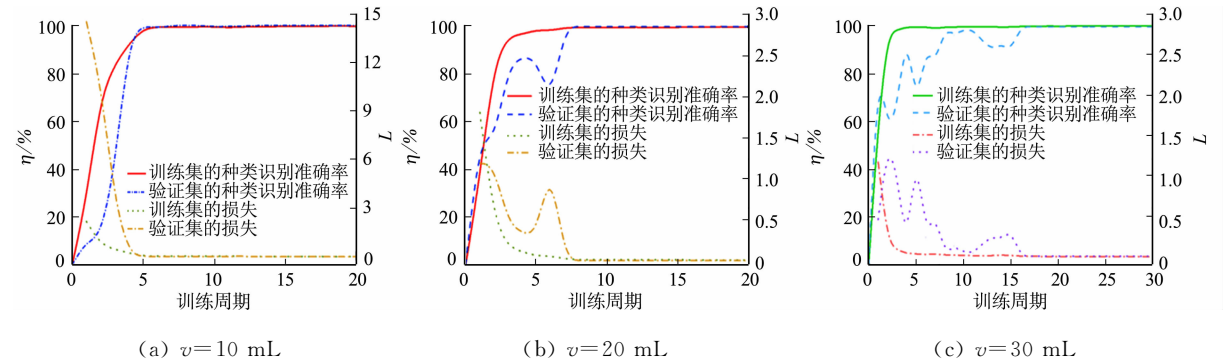


图 4 水生动物的种类识别结果

Fig. 4 Categories recognition results of aquatic animal

使用测试集的 400 张图像进行测试,当 TP-HE 添加量分别为 10、20 mL 时,种类识别准确率为 100%;当 TP-HE 添加量为 30 mL 时,种类识别准确率达 99.8%。

为了测试网络对更为复杂成像场景的识别能力,空间光调制器上加载了不同数量的水生动物。光束经过浑浊水体后,相机共采集 8 395 张散斑图像,将 6 761 张散斑图像作为训练集,将 839 张散斑图像作为测试集,将 840 张散斑图像作为验证集输入神经网络进行训练。其中,水生动物的类型有 10 种,包含有 2、3、4、5 只水生动物 4 种不同的情况。该实验中 TP-HE 添加量为 30 mL,更大的添加量带来更强的散射效应,进一步加大图像识别的难度。

当图像中包含更多复杂信息时,对神经网络的识别能力要求更高,为了使网络能够更有效地识别图像信息,采用大小为 4×4 、步长为 2 的卷积核代替最大池化层。同时,在卷积层后添加了批量归一化层

用于解决过拟合,并采用 Dropout 机制优化网络的泛化能力。此外,采用多输出方式,提升训练速度并减少网络的参数。

多种水生动物的识别结果,如图 5 所示。由图 5 可知:随着训练次数的不断增加,训练集和验证集的识别准确率均不断上升;大约经过 20 代的训练后,网络即可准确识别出多种水生动物的数量与种类。

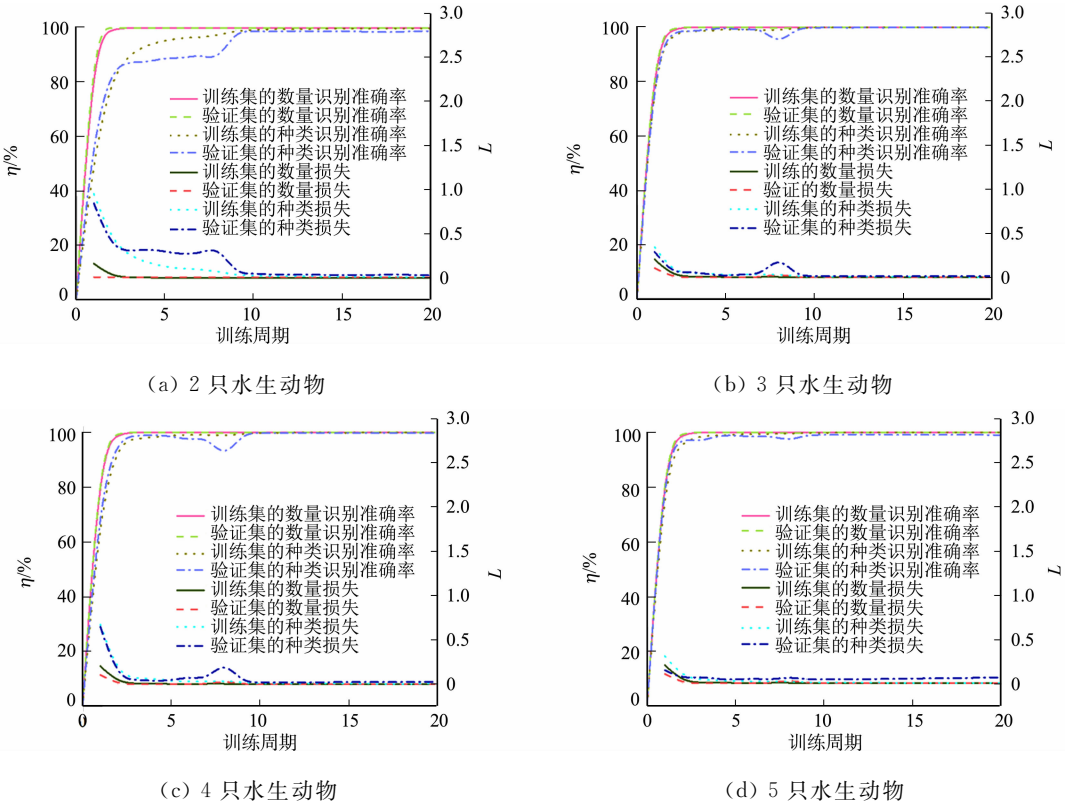


图 5 多种水生动物的识别结果

Fig. 5 Identification results of various aquatic animals

使用测试集的 839 张图像进行测试,神经网络对水生动物的数量识别准确率为 100%;当散斑图像中包含 2 只水生动物时,神经网络的数量识别准确率为 99.6%;当散斑图像中包含 3 只水生动物时,神经网络的数量识别准确率为 99.8%;当散斑图像中包含 4 只水生动物时,神经网络的数量识别准确率为 99.8%;当散斑图像中包含 5 只水生动物时,神经网络的数量识别准确率为 99.7%。

4 结束语

以浑浊水体为例,对动态散射场景中的目标识别进行研究。将 TP-HE 溶解于水中,形成浑浊水体,并通过控制 TP-HE 添加量,改变水体的浑浊程度。将 10 种不同类型的水生动物加载在空间光调制器上,光束经空间光调制器反射后入射到浑浊水体中,由于浑浊水体的散射,导致出射光场变为光强无序的散斑状分布,利用相机采集对应的光强分布。为了从散斑场中恢复出原始入射光场信息,设计了一个轻量级卷积神经网络,利用采集的部分数据训练神经网络。将未经训练的散斑场输入训练好的网络,可以输出水生动物的种类和数目。

参考文献:

[1] 左超,陈钱. 计算光学成像:何来,何处,何去,何从? [J]. 红外与激光工程,2022,51(2):158-341. DOI:10. 3788/IR-LA20220110.

[2] 卞耀明,司徒国海. 透过散射介质光学成像技术的研究进展[J]. 中国激光,2024,51(11):256-283. DOI:10. 3788/CJL240678.

[3] 刘飞,吴晓琴,段景博,等. 浅谈计算成像在光电探测中的应用(特邀)[J]. 光子学报,2021,50(10):1011001. DOI: 10. 3788/gzxb20215010. 1011001.

- [4] 陈子阳,陈丽,范伟如,等.基于相关全息原理的散射成像技术及其进展[J].激光与光电子学进展,2021,58(2):9-22. DOI:10.3788/LOP202158.0200001.
- [5] 程雪岷,罗烈玉,张泽森,等.计算光学框架下的抗散射成像技术研究(特邀)[J].红外与激光工程,2025,54(1):36-45. DOI:10.3788/IRLA20240298.
- [6] KANG S,KWON Y,LEE H,*et al.* Tracing multiple scattering trajectories for deep optical imaging in scattering media[J]. Nature Communication,2023,14(1):6871. DOI:10.1038/s41467-023-42525-7.
- [7] BAEK W J,PARK J,CIAO L. Depth-resolved imaging through scattering media using time-gated light field tomography[J]. Optics Letters,2024,49(22):6581-6584. DOI:10.1364/OL.541549.
- [8] WANG Q Z,LIANG X,WANG L,*et al.* Fourier spatial filter acts as a temporal gate for light propagating through a turbid medium[J]. Optics Letters,1995,20(13):1498-1500. DOI:10.1364/OL.20.001498.
- [9] BERTOLOTTI J,VAN PUTTEN E G,BLUM C,*et al.* Non-invasive imaging through opaque scattering layers[J]. Nature,2012,491(4721):232-234. DOI:10.1038/nature11578.
- [10] KATZ O,HEIDMANN P,FINK M,*et al.* Non-invasive single-shot imaging through scattering layers and around corners *via* speckle correlations[J]. Nature Photonics,2014,8:784-790. DOI:10.1038/nphoton.2014.189.
- [11] POPOFF S M,LEROSEY G,CARMINATI R,*et al.* Measuring the transmission matrix in optics: An approach to the study and control of light propagation in disordered media[J]. Physics Review Letters,2010,104:100601. DOI:10.1103/PhysRevLett.104.100601.
- [12] VELLEKOOP I M,MOSK A P. Focusing coherent light through opaque strongly scattering media[J]. Optics Letters,2007,32(16):2309-2311. DOI:10.1364/OL.32.002309.
- [13] WOO C M,ZHAO Qi,ZHONG Tianting,*et al.* Optimal efficiency of focusing diffused light through scattering media with iterative wavefront shaping[J]. APL Photonics,2022,7:046109. DOI:10.1063/5.0085943.
- [14] ZHAO Wenjing,DU Ziheng,ZHAI Aiping,*et al.* Wavefront imaging of a biological sample using DMD-based single-pixel phase-shifting interferometric techniques: An experimental comparison[J]. Optics & Laser Technology,2024,172:110483. DOI:10.1016/j.optlastec.2023.110483.
- [15] TANG Pusong,ZHENG Kanpei,YUAN Weiming,*et al.* Learning to transmit images through optical speckle of a multimode fiber with high fidelity[J]. Applied Physics Letters,2022,121(8):081107. DOI:10.1063/5.0099159.
- [16] LI S,DENG M,LEE J,*et al.* Imaging through glass diffusers using densely connected convolutional networks[J]. Optica,2018,5:803-813. DOI:10.1364/OPTICA.5.000803.
- [17] YANG Kui,HAN Pingli,GONG Rui,*et al.* High-quality 3D shape recovery from scattering scenario *via* deep polarization neural networks[J]. Optics and Laser in Engineering,2023,173:107934. DOI:10.1016/j.optlaseng.2023.107934.
- [18] CHEN Musheng,JI Xin,LIN Shunda,*et al.* Image reconstruction of scattered vortex light field based on deep learning[J]. Optics and Laser Technology,2023,163:109347. DOI:10.1016/j.optlastec.2023.109347.

(责任编辑:钱筠 英文审校:陈婧)