

## 基于深度学习的透过散射介质偏振识别

庄秋实, 何泽文, 张春旭, 辛煜\*

南京理工大学电子工程与光电技术学院, 江苏 南京 210094

**摘要** 当偏振光在散射介质中传播时, 由于散射粒子的多重散射作用而造成偏振信息的扰乱和丢失。为了保证偏振信息在散射介质中高效和高保真的传输, 提出一种基于深度学习的透过散射介质偏振识别方法。通过构建卷积神经网络来提取散斑光强信息中入射光波偏振信息的特征, 实现对入射光波偏振态的高分辨率识别, 并使用初始相位不同的偏振光来验证卷积神经网络对偏振态识别的鲁棒性。实验结果表明, 所提方法具有识别速度快和准确率高的优点, 理论上可以通过无限大的数据来训练神经网络, 因此该方法在偏振光学成像和激光通信等领域具有巨大的应用潜力。

**关键词** 散射; 偏振; 散射介质; 深度学习; 神经网络; 高分辨率识别

中图分类号 O438

文献标志码 A

doi: 10.3788/AOS202141.2229001

## Polarization Recognition Through Scattering Media Based on Deep-Learning

Zhuang Qiushi, He Zewen, Zhang Chunxu, Xin Yu\*

School of Electronic and Optical Engineering, Nanjing University of Science &amp; Technology, Nanjing, Jiangsu 210094, China

**Abstract** When polarized light propagates in the scattering medium, the polarization information is disturbed and lost due to multiple scattering of scattering particles. In order to ensure efficient and high-fidelity transmission of polarization information in scattering media, a polarization recognition method through scattering media based on deep learning is proposed. A convolutional neural network is constructed to extract the characteristics of the polarization information of incident light wave from the speckle light intensity information to realize the high resolution recognition of the polarization state of incident light wave, and the robustness of the convolutional neural network for polarization state recognition is verified by using polarized light with different initial phases. Experimental results show that the proposed method has the advantages of fast recognition speed and high accuracy, and the neural network can be trained with infinite data in theory. Therefore, the method has great application potential in polarization optical imaging and laser communication.

**Key words** scattering; polarization; scattering media; deep learning; neural network; precisely recognition

**OCIS codes** 290.5855; 100.4996; 200.4260

## 1 引言

自然界中存在着各种散射介质, 当偏振光透过浑浊水、生物组织和大气等散射介质时, 其会与介质中的散射粒子相互作用。偏振光经过多次散射后, 偏振态将会被严重扰乱<sup>[1-2]</sup>, 从而在目标探测设备

传输的过程中造成偏振信息的有效性降低, 甚至信息失真, 最终导致偏振成像模糊和对比度下降等<sup>[3-5]</sup>。因此, 实现偏振信息的高效且高保真传输对于在浑浊水、雾霾及其他各种散射介质中的偏振光学成像具有重要意义。为了减少散射介质中偏振信息的丢失, Bartolini 团队<sup>[6]</sup>利用交叉线偏振光使探

收稿日期: 2021-03-23; 修回日期: 2021-05-05; 录用日期: 2021-06-02

基金项目: 国家自然科学基金(61107011, 61675098)

通信作者: \*yxin@njust.edu.cn

测深度增加了两个衰减长度;Mullen 等<sup>[7]</sup>利用圆偏振光的保偏优势对激光相位进行调节,有效抑制了水体对偏振光的散射消偏。之后,科研人员发现通过两个正交偏振分量作差(Polarization Difference, PD)的方法可以有效去除由散射导致的退偏光,能够提高总光强的偏振分量,从而实现一定程度的保偏<sup>[8-9]</sup>,但是这种方法会大幅度削弱总光强。以上方法只能在一定程度上降低散射体系扰乱偏振光偏振态的影响,并未在真正意义上实现偏振恢复。近年来,郭忠义团队<sup>[10-14]</sup>提出了一种偏振信息恢复(Polarization Retrieve, PR)算法,该算法基于先验的散射介质穆勒矩阵来恢复入射光的原始偏振信息,在星地通信和浑浊介质中偏振成像方面取得了新的进展,但该算法的处理过程较为繁琐且目前仍处于仿真阶段。

随着科学技术的发展,深度学习技术目前已具备较强的特征提取及分类决策能力,在语音识别、自动驾驶和数据挖掘等领域取得了丰硕成果。深度学习技术通过复杂的人工神经网络和非线性激活函数,拥有强大的特征提取和分类决策能力,可以实现各类非线性数据的拟合<sup>[15]</sup>。深度学习技术在应用过程中跳过了“构建正向数学模型,再求解逆问题”这一传统的思维模式,通过对神经网络的训练可以直接建立目标输入与输出间的联系,从而将问题大大简化<sup>[16]</sup>。目前,深度学习技术在处理光学问题中表现出了巨大的潜力,在散射成像<sup>[17-19]</sup>、相位恢复<sup>[20-21]</sup>、鬼成像<sup>[22]</sup>、

数字全息成像<sup>[23]</sup>和超分辨率成像<sup>[24-25]</sup>等计算光学成像领域取得了巨大突破。另外,由于深度学习技术具有分类决策的能力,其对具有分数拓扑电荷的 OAM (Orbital Angular Momentum) 模式的高分辨率识别也取得了新的进展<sup>[26]</sup>。深度学习技术在光学领域的成就为解决一些传统算法难以解决的光学问题开辟了新的可能性,并带来了新的思考。

本文提出一种基于深度学习技术的偏振态识别方法,该方法可以快速、精准识别透过强散射介质的光的原始偏振态。首先构建用于识别的神经网络,提取散斑光强信息中所反映的入射光波偏振信息的特征,从而对不同偏振态的入射光进行区分和识别;然后搭建简单的光路,用来采集足够多的样本并对神经网络进行训练;最后通过测试样本来验证神经网络的识别效果。该方法具有识别分辨率高、速度快和精准度高的优点,为偏振光学成像等领域的研究拓展了新的方法和思路。

## 2 基本原理

### 2.1 密集连接网络结构

密集连接网络(DenseNet)<sup>[27]</sup>脱离了加深网络层数和加宽网络结构来提升神经网络性能的定向思维。从特征提取的角度出发,DenseNet 通过旁路设置和特征复用可以大幅度提高特征提取能力,同时减轻了梯度消失和过拟合等问题。DenseNet 的连接机制如图 1 所示,其中 $\oplus$ 为相加操作符号。




图 1 DenseNet 的连接机制

Fig. 1 Connection mechanism of DenseNet

设神经网络输入为  $x_0$ , 共有  $l$  层, 每一层执行一次非线性变换  $H$ , 则第  $l$  层的输出特征  $x_l$  可表示为

$$x_l = H_l\{x_0, x_1, \dots, x_{l-1}\}, \quad (1)$$

式中:  $\{x_0, x_1, \dots, x_{l-1}\}$  为第 0 层到第  $l-1$  层的特征在通道维度上的级联组合, 即每一层特征都在接受来自前面所有层的“集体共识”, 这可以实现信息流动的

最大化, 因此网络可以更薄、更紧凑, 计算效率更高。

由于 DenseNet 需要对不同层的特征图进行拼接叠加, 这就要求不同层的特征图具有相同大小, 但这会造成下采样操作难以进行, 为此网络中设置了多个密集块, 密集块内部采用密集连接, 不同密集块之间利用过渡层来调整特征图的大小, DenseNet 的结构如图 2 所示。




图 2 DenseNet 的结构

Fig. 2 Structure of DenseNet

密集块的结构如图 3 所示,每一个密集块包含  $m$  层瓶颈层,  $k$  为增长率,代表每一个瓶颈层输出特

征图的通道数。当输入通道数为  $n$  的特征图时,其输出特征图的通道数为  $n + m \times k$ 。

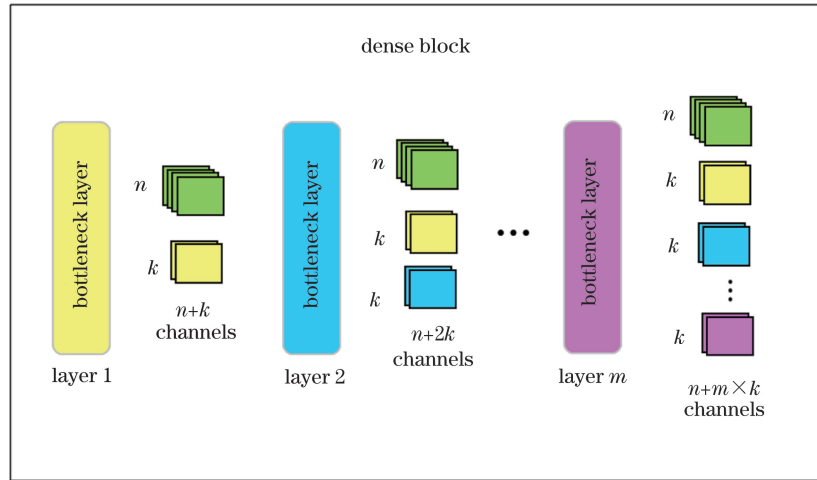


图 3 密集块的结构

Fig. 3 Structure of dense block

瓶颈层的结构如图 4(a)所示,其包含两个批量归一化(BN)层、两个非线性激活函数(ReLU)层、一个  $1 \times 1$  大小的卷积核和一个  $3 \times 3$  大小的卷积核。其中  $1 \times 1$  大小的卷积核用来降低模型参量的复杂度和规模,瓶颈层最终输出的通道数为  $k$ 。在不同密集块

之间设置过渡层以实现下采样,过渡层的结构如图 4(b)所示,其由一个  $1 \times 1$  大小的卷积核和一个  $2 \times 2$  的平均池化层组成,其中过渡层的输入通道数为每个密集块的输出通道数  $n + m \times k$ ,过渡层的输出通道数为  $(n + m \times k) / 2$ ,输出特征图的大小缩小  $1/2$ 。

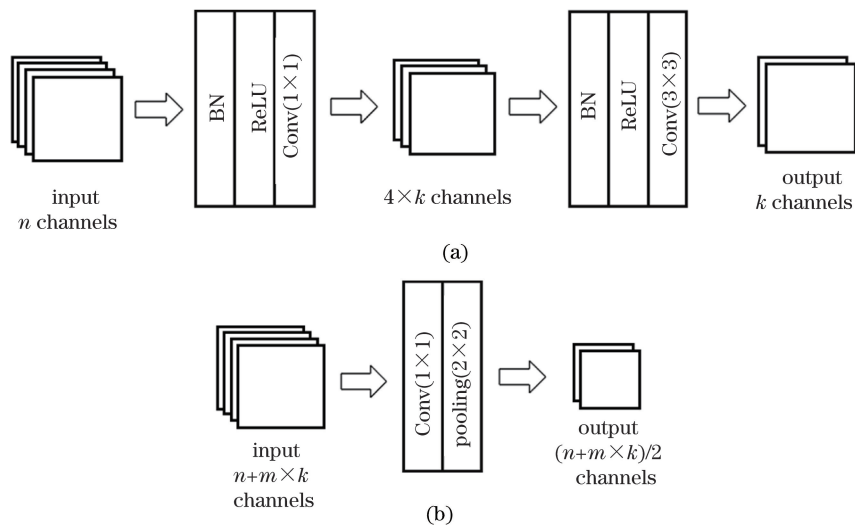


图 4 瓶颈层和过渡层的结构。(a)瓶颈层的结构;(b)过渡层的结构

Fig. 4 Structures of bottleneck layer and transition layer. (a) Structure of bottleneck layer; (b) structure of transition layer

## 2.2 理论基础

当偏振光透过散射介质时,其正向数学模型可以简单描述为

$$\mathbf{y}_{(i,j)} = \mathcal{F}_{(i,j)}(\mathbf{x}), \quad (2)$$

式中:  $\mathbf{x}$  为输入向量,表示入射光的初始偏振态;  $\mathbf{y}_{(i,j)}$  为输出向量,表示偏振光经过散射介质后散射光平面  $(i,j)$  位置点处偏振态扰乱的结果;  $\mathcal{F}_{(i,j)}$  为散射光平面  $(i,j)$  位置点处的正向算子。若要恢复散射光的初始偏振态,则需要进行一个逆向重构,表达式为

$$\mathbf{x} = \mathcal{F}_{(i,j)}^{-1}[\mathbf{y}_{(i,j)}], \quad (3)$$

式中:  $\mathcal{F}_{(i,j)}^{-1}$  为  $\mathcal{F}_{(i,j)}$  的逆,表示散射光平面  $(i,j)$  位置点处的逆算子。使用传统方法求解(3)式较为困难,而神经网络端到端学习的特点可以直接建立输入与输出的内在联系,通过高维度的特征拟合来实现对信息的提取,从而获取散射介质对偏振光作用的逆过程,进而对输入光的偏振态进行准确识别。

## 3 数据采集和模型训练

### 3.1 散射介质

首先将直径为 200 nm 的氧化锌粉末溶解于 15 mL 的聚二甲基硅氧烷灌封胶 A 和 6 mL 的聚二甲基硅氧烷灌封胶 B,从而形成混合溶液;然后将混合溶液置于超声浴中处理 30 min,使溶液彻底混合均匀;接着使用旋涂仪将溶液旋涂至圆形玻璃片上并静置 24 h 使其干燥,其中圆形玻璃片的直径为 1 inch(1 inch=2.54 cm),厚度为 0.8 mm;最终形成的沉积层厚度约为 100  $\mu\text{m}$ ,所得的散射介质样品如图 5 所示。




图 5 散射介质

Fig. 5 Scattering medium

若光在散射介质中传播,当散射粒子的直径远小于入射光的波长时,则光的相干性会随着传播距离的增加呈指数下降。在 2~3 个平均自由程之前,入射光形成的散射为弱散射。入射光经过几个平均

自由程后,最终结果类似于扩散,此时散射变为强散射。当散射粒子的直径远大于输入波长时,入射光经过一个平均自由程后相位便会被完全扰动而变成非相干光,此时直接形成强散射<sup>[28]</sup>。实验样品是通过将直径为 200 nm 的氧化锌粉末以旋涂的方式进行沉积,沉积层的厚度约为 100  $\mu\text{m}$ ,而氧化锌沉积层的平均自由程一般为 3~5  $\mu\text{m}$ ,此时氧化锌粒子的直径虽然小于入射光的波长,但是光的传播距离远大于平均自由程,因此实验中散射介质所形成的散射属于强散射的范畴。

### 3.2 实验装置

搭建的实验光路如图 6 所示,其中  $\lambda$  为波长。激光器发出的绿色激光(波长为 532 nm)首先经过线偏振片 1 后产生线偏振光,然后经过滤波和准直扩束后由分束镜 1 和分束镜 2 分束并照射在空间光调制器上,由空间光调制器调制后经过线偏振片 2 和 1/4 波片并照射在散射介质(ZnO)上,最终由单色科研级 sCMOS 相机来接收散斑图像。实验装置中,空间光调制器是用来对光的相位进行调制,从而产生不同初始相位的光,调制区域是 1024 pixel  $\times$  1024 pixel 大小的中心区域;线偏振片 1 的透光轴方向与线偏振片 2 一致,由线偏振片 2 和 1/4 波片组成偏振控制系统,用来产生多种不同偏振态的光,其中 1/4 波片置于可编程的电动旋转位移台上,当经过空间光调制器调制后的光透过线偏振片 2 和 1/4 波片时,计算机控制电动旋转位移台旋转 1/4 波片,将产生的多种不同偏振态的光照射到散射介质上。




图 6 实验装置

Fig. 6 Experimental device

### 3.3 数据采集

实验过程中,使用琼斯矢量来描述入射光波的偏振态,光束偏振态的改变用线偏振片和 1/4 波片来实现,如图 7 所示。激光发出的光经过线偏振片和 1/4 波片,其中偏振片的透光轴沿  $x$  轴方向,1/4 波片的快轴与  $x$  轴的夹角为  $\theta$ 。




图 7 偏振态控制示意图

Fig. 7 Diagram of polarization state control

光经过线偏振片和 1/4 波片后,出射光的琼斯矢量为

$$E = \begin{bmatrix} \cos^2\theta + i\sin^2\theta & \cos\theta\sin\theta(1-i) \\ \cos\theta\sin\theta(1-i) & \sin^2\theta + i\cos^2\theta \end{bmatrix} \begin{bmatrix} 1 \\ 0 \end{bmatrix} = (\cos^2\theta + i\sin^2\theta) \begin{bmatrix} 1 \\ \frac{\cos\theta\sin\theta(1-i)}{\cos^2\theta + i\sin^2\theta} \end{bmatrix} = (\cos^2\theta + i\sin^2\theta) \begin{bmatrix} 1 \\ b\exp(i\varphi) \end{bmatrix}, \quad (4)$$

式中: $\varphi$  为原点与点  $(\sin 2\theta\cos 2\theta, -\sin 2\theta)$  所在向量与  $x$  轴按逆时针方向所成的角; $b = \frac{|\sin 2\theta|}{\sqrt{1+\cos^2\theta}}$  为  $y$  轴方向分量与  $x$  轴方向分量的振幅比; $\theta$  为波片快轴与线偏振光电矢量振动方向的夹角。当旋转 1/4 波片时, $\theta$  发生变化,则出射光的琼斯矢量也发生变化。实验过程中,通过控制可编程的电动旋转位移台来旋转 1/4 波片,即可产生多种不同的偏振光。

为了提高偏振态识别的鲁棒性并获得足够多的训练数据,利用空间光调制器为每一种偏振光设置不同的初始相位。实验中,每种偏振光的初始相位在  $0 \sim 1.98\pi$  之间等间隔取值,间隔  $\Delta\varphi = 0.02\pi$ ,这样整个数据集中每种偏振光包含 100 种不同的初始相位。

搭建好实验装置后,首先利用可编程的旋转位移台来旋转 1/4 波片,使偏振片的透光轴与 1/4 波片的夹角为  $\theta$ ;接着通过空间光调制器对光的初始相位进行调制以产生 100 种不同初始相位的光,光束经过偏振片和 1/4 波片后照射在 ZnO 散射片上;然后使用 sCOMS 相机对透过散射介质后形成的散斑进行记录;之后继续旋转 1/4 波片来改变  $\theta$  值,并再次利用空间光调制器对光的初始相位进行调制,以此类推,最终完成数据的采集。sCOMS 相机所采集的原始散斑图像大小为  $512 \text{ pixel} \times 512 \text{ pixel}$ ,提取其中心  $128 \text{ pixel} \times 128 \text{ pixel}$  大小的区域作为实验数据集,并从其中随机抽取 10% 作为测试数据集,剩下的 90% 作为训练数据集,测试数据不参与对神经网络的训练。

### 3.4 参数设置和训练

神经网络的结构如图 8 所示,该神经网络以 DenseNet 框架<sup>[27]</sup>为基础,采用 Python 编程语言和基于 TensorFlow 的深度学习框架进行搭建。神经网络输入大小为  $128 \text{ pixel} \times 128 \text{ pixel}$  的散斑图,第一个卷积层采用  $7 \times 7$  大小的卷积核,步长设置为 2,对输入的散斑图进行特征提取,之后经过 4 个密集块,瓶颈层数量分别设置为 6、12、24 和 16,增长率设置为 32。在每个密集块之间设置一个过渡层,用来压缩密集块所输出的特征图的大小和数量,这里采用的压缩率为 0.5。最后采用一个全局池化层和一个具有多个神经元的全连接层来提取用于分类的信息。




图 8 神经网络的结构

Fig. 8 Structure of neural network

训练过程中使用均方误差作为损失函数,表达式为

$$E_{MS} = \frac{1}{S} \sum_{s=1}^S (y_s - y_s^p)^2, \quad (5)$$

式中: $S$  为样本数量; $y_s$  为真实值; $y_s^p$  为预测值。

训练过程中,使用 Adam (Adaptive Moment Estimation) 优化算法训练 100 个周期,每个周期从准备好的训练数据集中随机抽取 10000 张图片进行一遍训练。初始学习率设置为 0.001,在第 40 个周期降低为之前的 1/10,即变为 0.0001,在第 80 个周期再次缩小为之前的 1/10,即变为 0.00001。神经网络模型使用装有 Intel i7CPU 和 RTX 2070 显卡的计算机进行训练。

## 4 实验及结果分析

### 4.1 实验结果

实验中,在  $\theta$  等间隔变化的间隔值( $\Delta\theta$ )分别为  $1.0^\circ$ 、 $0.5^\circ$  和  $0.2^\circ$  的情况下进行三次实验数据的采集,并分别对神经网络进行训练和测试。当  $\Delta\theta = 1^\circ$

时, $\theta$  的取值范围为  $1^\circ \sim 180^\circ$ ,即产生 180 种不同偏振光,由于每种偏振光包含了 100 种初始相位,因此共采集 18000 张散斑图像,随机抽取其中 10%,即 1800 张散斑图作为测试数据集,剩余 16200 张散斑图作为训练数据集。当  $\Delta\theta = 0.5^\circ$  时, $\theta$  的取值范围为  $1^\circ \sim 180^\circ$ ,即产生 360 种不同偏振光,由于每种偏振光包含了 100 种初始相位,因此共采集 36000 张散斑图像,随机抽取其中 10%,即 3600 张散斑图作为测试数据集,剩余 32400 张散斑图作为训练数据集。当  $\Delta\theta = 0.2^\circ$  时, $\theta$  的取值范围为  $1^\circ \sim 90^\circ$ ,即产生 450 种不同偏振光,由于每种偏振光包含了 100 种初始相位,因此共采集 45000 张散斑图像,随机抽取其中 10%,即 4500 张散斑图作为测试数据集,剩余 40500 张散斑图作为训练数据集。具体参数和结果如表 1 所示。对神经网络进行训练后,随机抽取测试集中的散斑图,用来检验其对不同偏振光的识别效果。从表 1 可以看到,神经网络在三种情况下都得到了极高的识别准确率,并且在识别图片的过程中,平均每张图片所花费的识别时间仅为 7 ms 左右。

表 1 三种情况下采集的数据参数和训练结果

Table 1 Data parameters and training results collected in three cases

$\Delta\theta / (^\circ)$	Range of $\theta / (^\circ)$	Number of pictures	Number of training pictures	Number of test pictures	Test time / s	Accuracy / %
1.0	1-180	18000	16200	1800	13.51	100.0
0.5	1-180	36000	32400	3600	24.45	99.5
0.2	1-90	45000	40500	4500	31.52	99.1

在初始相位相同,即  $\varphi_0 = 0.3\pi$  的情况下,不同偏振光经 ZnO 散射后对应的散斑图如图 9 所示。从图 9 可以看到,光的偏振态和神经网络所预测的结果具有很好的一致性,即使从肉眼来看每张散斑图都相同,但是神经网络能够从  $128 \text{ pixel} \times 128 \text{ pixel}$  大小的散斑图中提取出细微变化的特征并将其放大,从而实现了对不同偏振光的精准识别。

具有不同初始相位的同一偏振光( $\theta = 20^\circ$ )经 ZnO 散射后对应的散斑图如图 10 所示。从图 10 可以看到,对于同一偏振态、不同初始相位的光,经过 ZnO 散射后形成的散斑各不相同,但神经网络仍然能够很好地完成对入射光波偏振态的识别,这表明在完成训练后,神经网络已经具备了提取散斑图中某种偏振光一般特征的能力。

为了提高神经网络识别的分辨率,实验过程中尝试减小  $\Delta\theta$  的值。从表 1 可以看到,在减小  $\Delta\theta$  值以后,神经网络识别的准确率略有下降,但是下降幅度很小;当  $\Delta\theta = 0.2^\circ$  时,识别的准确率仍然能够达




图 9 相同初始相位、不同偏振光经 ZnO 散射后形成的散斑图。(a)  $\theta = 20.2^\circ$ ; (b)  $\theta = 20.4^\circ$ ; (c)  $\theta = 20.6^\circ$ ; (d)  $\theta = 20.8^\circ$

Fig. 9 Speckle pattern formed after scattering by ZnO with the same initial phase and different polarized light. (a)  $\theta = 20.2^\circ$ ; (b)  $\theta = 20.4^\circ$ ; (c)  $\theta = 20.6^\circ$ ; (d)  $\theta = 20.8^\circ$

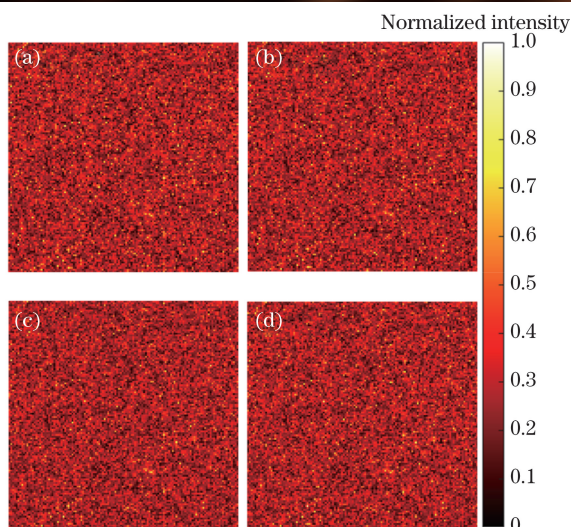


图 10 不同初始相位、同一偏振态光经 ZnO 散射后形成的散斑图。(a)  $\varphi_0 = 0.3\pi$ ; (b)  $\varphi_0 = 0.6\pi$ ; (c)  $\varphi_0 = 0.9\pi$ ; (d)  $\varphi_0 = 1.2\pi$

Fig. 10 Speckle pattern of light scattered by ZnO with different initial phase and the same polarization state. (a)  $\varphi_0 = 0.3\pi$ ; (b)  $\varphi_0 = 0.6\pi$ ; (c)  $\varphi_0 = 0.9\pi$ ; (d)  $\varphi_0 = 1.2\pi$

到 99.1%，这表明构建的神经网络可以通过提供数量更大、种类更多的训练数据集来进一步提高识别能力，从而达到一个极限分辨率的大小，并且识别的准确率不会受到太大的影响。

#### 4.2 学习率分析

学习率是指在梯度下降算法中如何使用损失函数的梯度来调整网络的超参数，其决定了训练过程中目标参数能否收敛到最小值以及收敛到最小值的速度。如果学习率太小，那么收敛速度过于缓慢，并且很容易被困在局部最小值点或鞍点；如果学习率过大，那么会导致梯度在某一区域振荡而无法收敛




图 12 训练过程中测试数据的识别精度曲线。(a)  $\Delta\theta = 1.0^\circ$ ; (b)  $\Delta\theta = 0.5^\circ$ ; (c)  $\Delta\theta = 0.2^\circ$

Fig. 12 Recognition accuracy curve of test data during training. (a)  $\Delta\theta = 1.0^\circ$ ; (b)  $\Delta\theta = 0.5^\circ$ ; (c)  $\Delta\theta = 0.2^\circ$

当  $\Delta\theta = 0.5^\circ$  时，固定学习率后测试数据的识别精度曲线如图 13 所示。从图 13(a) 可以看到，当学

到最小值。学习率对模型训练的影响如图 11 所示。从图 11 可以看到，当学习率为某一较大的固定值时，前期收敛速度很快，但是会在最优值附近的较大范围内摆动，而无法收敛到最优点；当学习率为某一较小的固定值时，收敛速度很慢，并且陷入了局部最小点。因此，在神经网络的训练过程中，为了保证能在较短的时间内达到全局最优解，需要根据训练周期数来调整学习率的大小。




图 11 学习率对模型训练的影响模拟图

Fig. 11 Simulation diagram of effect of learning rate on model training

训练过程中，神经网络识别测试样本中散斑图的准确率如图 12 所示。从图 12 可以看到，当 0~40 周期的学习率设置为 0.001 时，从第 10 个训练周期开始，识别的准确率迅速上升，最高值很快达到了 70% 以上，但是变化幅度较大；在第 40 个训练周期将学习率降低为之前的 1/10，即变为 0.0001 后，识别的准确率再次迅速上升，超过了 90%，并且整体波动幅度减小；在第 80 个周期将学习率再次降低为之前的 1/10，即变为 0.00001 后，识别的准确率达到 99% 以上，并且在最后 10 个周期基本稳定在一个固定值，这得益于在训练过程中对学习率的调整。

习率设置为较大固定值(0.01)时，第 10 个训练周期后的识别准确率迅速上升到最高值并很快达到

70%，这得益于较大的学习率可以使准确率迅速接近最优值，但之后准确率上升缓慢且波动幅度极大，最高值只能达到 90%，这是因为学习率太大会导致损失函数在达到收敛状态的过程中，只能在最优值

附近的一个较大区域内摆动。从图 13(b) 可以看到，当学习率设置为较小固定值(0.00001)时，准确率的上升速度缓慢，陷入局部最优值，准确率最高只能达到 95%，并且波动幅度较大。




图 13 学习率固定的情况下测试数据的识别精度曲线。(a)学习率为 0.001;(b)学习率为 0.00001  
Fig. 13 Recognition accuracy curve of test data after fixed learning rate. (a) Learning rate is 0.001;  
(b) learning rate is 0.00001

## 5 讨 论

构建的神经网络实现了对散斑光强信息中偏振信息的提取和识别，所提方法有两点值得讨论。首先，实验中神经网络识别的偏振光主要是由琼斯矢量描述的线偏振、圆偏振和椭圆偏振这三种最常见的偏振光，并不包含径向偏振和角向偏振等特殊的偏振光。事实上，径向偏振光和角向偏振光可以利用空间光调制器、1/2 波片和 1/4 波片三个器件的组合来产生<sup>[29]</sup>，后续实验中可以尝试加入径向偏振光和角向偏振光的训练数据集，通过深化神经网络的结构来提供数量更大、种类更多的训练数据集，从而进一步提高神经网络的识别能力。

其次，所提方法作为基于深度学习的方法，端到端的特性决定了该方法并不能描述偏振光在散射体系中具体的传输特性和偏振态的演变过程，但是证明了偏振光经过强散射介质后形成的散斑光强信息能够反映原偏振光的偏振信息，并且不需要复杂的光路设计，也不需要宽带波前整形等繁琐过程，仅需提供输入、输出信息，这为光波透过散射介质后偏振特性的研究开辟了新的可能性。

## 6 结 论

本文基于深度学习方法实现了对透过强散射介质后偏振光偏振态的高分辨率识别。通过实验证明，当偏振光透过强散射介质后形成的散斑光

强信息中具有能够反映入射光波偏振信息的特征。构建的神经网络架构以 DenseNet 框架为基础，能够提取散斑图中细微变化的特征，从而精确区分透过散射介质后偏振光的偏振态。另外，构建的神经网络可以识别具有不同初始相位的偏振光的偏振态信息，证明其已经具备了提取某一偏振态一般特征的能力。所提方法无需复杂的光路设计，具有识别速度快和准确率高的优点，为偏振光在散射介质中传输的研究拓展了新的方法和思路，在生物医学成像和大气通信等领域具有很大的应用潜力。

## 参 考 文 献

- [1] Bicout D, Brosseau C, Martinez A S, et al. Depolarization of multiply scattered waves by spherical diffusers: influence of the size parameter [J]. *Physical Review E*, 1994, 49(2): 1767-1770.
- [2] Xu M, Alfano R R. Randomwalk of polarized light in turbid media [J]. *Physical Review Letters*, 2005, 95(21): 213901.
- [3] Brusciaglioni P, Zaccanti G, Wei Q N. Transmission of a pulsed polarized light beam through thick turbid media: numerical results [J]. *Applied Optics*, 1993, 32(30): 6142-6150.
- [4] Liu F, Han P L, Wei Y, et al. Deeply seeing through highly turbid water by active polarization imaging [J]. *Optics Letters*, 2018, 43(20): 4903-4906.
- [5] Liu F, Sun S J, Han P L, et al. Development of underwater polarization imaging technology [J].



- Laser & Optoelectronics Progress, 2021, 58(6): 0600001.  
刘飞, 孙少杰, 韩平丽, 等. 水下偏振成像技术研究及进展[J]. 激光与光电子学进展, 2021, 58(6): 0600001.
- [6] Bartolini L, de Dominicis L, Fornetti G, et al. Improvement in underwater phase measurement of an amplitude-modulated laser beam by polarimetric techniques[J]. Optics Letters, 2007, 32(11): 1402-1404.
- [7] Mullen L, Cochenour B, Rabinovich W, et al. Backscatter suppression for underwater modulating retroreflector links using polarization discrimination[J]. Applied Optics, 2009, 48(2): 328-337.
- [8] Walker J G, Chang P C Y, Hopcraft K I. Visibility depth improvement in active polarization imaging in scattering media[J]. Applied Optics, 2000, 39(27): 4933-4941.
- [9] Miller D A, Dereniak E L. Selective polarization imager for contrast enhancements in remote scattering media[J]. Applied Optics, 2012, 51(18): 4092-4102.
- [10] Tao Q Q. Research of the active imaging system based on the polarization retrieve[D]. Hefei: Hefei University of Technology, 2017: 36-40.  
陶强强. 基于偏振恢复的主动成像系统研究[D]. 合肥: 合肥工业大学, 2017: 36-40.
- [11] Xu Q, Guo Z Y, Tao Q Q, et al. Multi-spectral characteristics of polarization retrieve in various atmospheric conditions[J]. Optics Communications, 2015, 339: 167-170.
- [12] Xu Q, Guo Z Y, Tao Q Q, et al. A novel method of retrieving the polarization qubits after being transmitted in turbid media[J]. Journal of Optics, 2015, 17(3): 035606.
- [13] Tao Q Q, Guo Z Y, Xu Q, et al. Retrieving the polarization information for satellite-to-ground light communication[J]. Journal of Optics, 2015, 17(8): 085701.
- [14] Tao Q Q, Sun Y X, Shen F, et al. Active imaging with the AIDS of polarization retrieve in turbid media system[J]. Optics Communications, 2016, 359: 405-410.
- [15] Barbastathis G, Ozcan A, Situ G H. On the use of deep learning for computational imaging[J]. Optica, 2019, 6(8): 921-943.
- [16] 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.
- [17] Li S, Deng M, Lee J, et al. Imaging through glass diffusers using densely connected convolutional networks[J]. Optica, 2018, 5(7): 803-813.
- [18] Lyu M, Wang H, Li G W, et al. Learning-based lensless imaging through optically thick scattering media[J]. Advanced Photonics, 2019, 1(3): 036002.
- [19] Meng L, Hu H F, Hu J Z, et al. Image reconstruction of multimode fiber scattering media based on deep learning[J]. Chinese Journal of Lasers, 2020, 47(12): 1206005.  
孟球, 胡海峰, 胡金洲, 等. 基于深度学习的多模光纤散射介质成像重建[J]. 中国激光, 2020, 47(12): 1206005.
- [20] Rivenson Y, Zhang Y, Günaydin H, et al. Phase recovery and holographic image reconstruction using deep learning in neural networks[J]. Light, Science & Applications, 2018, 7: 17141.
- [21] Sinha A, Lee J, Li S, et al. Lensless computational imaging through deep learning[J]. Optica, 2017, 4(9): 1117-1125.
- [22] Lyu M, Wang W, Wang H, et al. Deep-learning-based ghost imaging[J]. Scientific Reports, 2017, 7(1): 17865.
- [23] Ren Z B, Xu Z M, Lam E Y. Learning-based nonparametric autofocusing for digital holography[J]. Optica, 2018, 5(4): 337-344.
- [24] Zhao F, Zhu L X, Fang C Y, et al. Deep-learning super-resolution light-sheet add-on microscopy (Deep-SLAM) for easy isotropic volumetric imaging of large biological specimens[J]. Biomedical Optics Express, 2020, 11(12): 7273-7285.
- [25] Xiao K, Tian L J, Wang Z Y. Fast super-resolution fluorescence microscopy imaging with low signal-to-noise ratio based on deep learning[J]. Chinese Journal of Lasers, 2020, 47(10): 1007002.  
肖康, 田立君, 王中阳. 基于深度学习的低信噪比下的快速超分辨荧光显微成像[J]. 中国激光, 2020, 47(10): 1007002.
- [26] Liu Z W, Yan S, Liu H G, et al. Super high-resolution recognition of optical vortex modes assisted by a deep-learning method[J]. Physical Review Letters, 2019, 123(18): 183902.
- [27] 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.
- [28] Sheng P, van Tiggelen B. Introduction to wave scattering, localization and mesoscopic phenomena. second edition[J]. Waves in Random and Complex

Media, 2007, 17(2): 235-237.

- [29] Zhai Z S, Hu Y T, Lü Q H, et al. Research on controlling the polarization state of laser beam with a spatial light modulator[J]. Laser & Optoelectronics

Progress, 2016, 53(3): 032601.

- 翟中生, 胡勇涛, 吕青花, 等. 基于空间光调制器的光束偏振态控制方法研究[J]. 激光与光电子学进展, 2016, 53(3): 032601.