

## 基于空间光调制器和深度学习的涡旋光束产生

马文琪<sup>1</sup>, 路慧敏<sup>1\*</sup>, 王建萍<sup>1</sup>, 高云舒<sup>2</sup>, 王增坤<sup>3</sup><sup>1</sup>北京科技大学计算机与通信工程学院, 北京 100083;<sup>2</sup>中央民族大学理学院, 北京 100081;<sup>3</sup>深圳市麓邦技术有限公司, 广东 深圳 518055

**摘要** 基于传统 Gerchberg-Saxton(GS)算法和卷积神经网络(convolutional neural network,CNN),提出了一种利用液晶空间光调制器(LC-SLM)产生涡旋光束的方法。利用该 GS-CNN 方法,产生了具有不同拓扑电荷数的贝塞尔光束,进一步分析了所产生的涡旋光束的均方根误差(root mean squared error, RMSE)和衍射效率(diffraction efficiency),并与传统 GS 算法得到的结果进行了比较。结果表明,采用所提出的 GS-CNN 方法能够产生高质量的涡旋光束,相较于传统的 GS 算法,所产生的涡旋光束的光强与目标光强的差异更小,并且更多输入光场能量被衍射出来。

**关键词** 傅里叶光学; 涡旋光束; 卷积神经网络; 空间光调制器; 迭代傅里叶变换算法

中图分类号 O436

文献标志码 A

doi: 10.3788/AOS202141.1107001

## Vortex Beam Generation Based on Spatial Light Modulator and Deep Learning

Ma Wenqi<sup>1</sup>, Lu Huimin<sup>1\*</sup>, Wang Jianping<sup>1</sup>, Gao Yunshu<sup>2</sup>, Wang Zengkun<sup>3</sup><sup>1</sup> School of Computer & Communication Engineering, University of Science and Technology Beijing, Beijing 100083, China;<sup>2</sup> College of Science, Minzu University of China, Beijing 100081, China;<sup>3</sup> Shenzhen Lubang Technology Co., Ltd., Shenzhen, Guangdong 518055, China

**Abstract** In this work, a method based on the traditional Gerchberg-Saxton (GS) algorithm and convolutional neural network (CNN) is proposed to generate vortex beams using a liquid crystal spatial light modulator (LC-SLM). By adopting this GS-CNN method, the Bessel beams with different topological charges are generated. On this basis, the root mean squared error (RMSE) and diffraction efficiency (DE) of the generated vortex beams are further analyzed and compared with the results obtained by the traditional GS algorithm. The results show that the GS-CNN method proposed in this paper can produce high-quality Bessel vortex beams. Compared with the results from the traditional GS algorithm, the intensity difference between the generated vortex beam and the target light is reduced and there are more input light field energies to be diffracted.

**Key words** Fourier optics; vortex beam; convolutional neural network; spatial light modulator; iterative Fourier transform algorithm

**OCIS codes** 070.6120; 080.4865; 060.2605; 100.5070

## 1 引言

近年来,云计算、大数据、人工智能等技术的迅

速发展对通信容量提出了更高的要求。在自由空间光通信技术领域,研究者们尝试采用时分、频分、波分和空分等复用技术增加通信系统的容量,这一系

收稿日期: 2020-12-11; 修回日期: 2021-01-04; 录用日期: 2021-01-08

基金项目: 国家自然科学基金(61671055)

\* E-mail: hmlu@ustb.edu.cn

列技术在一定程度上缓解了通信容量和需求之间的矛盾,但是都受限于有限的频谱资源<sup>[1]</sup>。涡旋光束具有频率、偏振、时隙和轨道角动量(orbital angular momentum, OAM)等自由度。OAM 的维数在理论上可取无限大的值,能够有效扩充光束的利用空间。OAM 具有螺旋形相位波前,其中拓扑电荷数一般为整数<sup>[2]</sup>。与光波的波长、时隙和幅相特性一样,相互正交的 OAM 均可作为一个独立信道进行通信,因此 OAM 作为一种新的自由度为提高通信容量提供了一种有效的途径<sup>[3-5]</sup>。常见的涡旋光束产生方法有几何模式变换法<sup>[6]</sup>、螺旋相位板法<sup>[7]</sup>、全息光栅法<sup>[8]</sup>和液晶空间光调制器(liquid crystal spatial light modulator, LC-SLM)法<sup>[9]</sup>。LC-SLM 可以在计算机的实时操控下实现光波的波前变换,具有体积小、能耗低、驱动电压低和控制灵活等特点,在光束整形中得到广泛应用<sup>[10]</sup>,也成为制备涡旋光束最常用的方法。

将相位恢复算法得到的相位全息图加载到纯相位调制型 LC-SLM 上,即可得到预期的涡旋光束。计算相位全息图的相位恢复算法多种多样,目前大多采用迭代傅里叶变换算法(Iterative Fourier transform algorithm, IFTA),该算法在傅里叶变换(FFT)关联的两个空间中迭代计算加载在 LC-SLM 上的相位分布<sup>[11]</sup>。Gerchberg 等<sup>[12]</sup>将 IFTA 应用于相位恢复问题,此时 IFTA 也被称作 GS 算法,但是 GS 算法存在收敛缓慢的问题<sup>[13]</sup>。GS 算法不仅适用于单个拓扑电荷数涡旋光的产生,还适用于 OAM 复用多个拓扑电荷数复合涡旋光的产生,这一特点非常适用于 OAM 键控通信(OAM-SK)系统<sup>[14-15]</sup>的搭建。在含有卷积神经网络(convolutional neural networks, CNN)自适应解调器的 OAM-SK 系统中,往往先选择一组 OAM 状态作为基本状态,然后进行组合并分别映射到数字信号上。因为卷积神经网络分类器易于识别具有鲜明特征的图像,所以 GS 算法的进一步优化有利于 OAM-SK 系统的研究。1980 年,Fienu<sup>[16]</sup>在 GS 算法的基础上提出了输入-输出方法以加快收敛速度,该方法的一个特点是输出始终是满足傅里叶域约束的傅里叶变换函数。为了进一步提高相位恢复算法的性能,研究人员提出了各种改进方法来提升 GS 算法在 LC-SLM 全息图计算中的性能。2002 年, Liu 等<sup>[17]</sup>提出了新的迭代方法,即在傅里叶域中施加修改的约束函数并保持迭代的相位分布不变,提高了输出光束的质量。2010 年,黄利新等<sup>[18]</sup>根据

角谱传播理论,通过引入一种简单的梯度,提出了一种快速、高精度的相位恢复迭代算法即加速角谱迭代法。2016 年, Wang 等<sup>[19]</sup>提出了全息串联方法,该方法对写入空间光调制器两个不同区域的相位分布进行迭代调整,获得了更好的均匀性。2019 年,李昕颖等<sup>[20]</sup>设置了一个用于表征衍射效应的参量,通过迭代的方法确定了该参量的最佳取值,再用改进的 GS 算法对初始相位进行了修正,有效地抑制了散斑和振铃效应。2019 年, Mikhavlov 等<sup>[21]</sup>提出了将机器学习引入到 IFTA 中的新颖方法,实现了所有光点上的高精度功率分布。但是,这些改进算法大多通过引入新的变量来优化结果,这种更广泛的参数选择增加了算法的复杂性,设计人员需要更多经验来掌握收敛特性并选择最适合的算法。

本文提出了一种新的采用 LC-SLM 产生涡旋光束的 GS-CNN 相位恢复算法,该方法利用卷积神经网络训练 GS 算法中输出强度分布与输入强度分布之间的关系,然后通过目标强度分布预测相应的输入强度分布,将预测出来的输入强度分布输入到 GS 算法中,得到 LC-SLM 相位全息图。利用所提出的 GS-CNN 方法,产生了具有单个拓扑电荷数的贝塞尔光束以及两个拓扑电荷数复合的涡旋光束,进一步分析了所产生的涡旋光束的均方根误差(root mean squared error, RMSE)和衍射效率(diffraction efficiency, DE),并与传统 GS 算法得到的结果进行了比较。

## 2 基本原理

### 2.1 GS-CNN 方法

GS-CNN 方法的基本原理是预测正确的 GS 算法的输入强度分布  $\hat{A}_m(x, y)$  (神经网络预测出来的输入强度分布)以生成目标强度分布  $A_{des}(x, y)$ , 其中  $(x, y)$  为强度分布中的位置坐标。该方法首先利用卷积神经网络训练预测函数  $f_{CNN}[A_{des}(x, y)] = \hat{A}_m(x, y)$  [ $f_{CNN}(\cdot)$  为预测函数], 然后将预测的输入强度分布输入到 GS 算法中, 得到修正的相位全息图  $p_{phase}(x, y)$ , 其流程如图 1 所示, 其中 MSE 为均方误差。GS-CNN 方法分为四个阶段。第一阶段为数据收集阶段。将预先定义的输入强度分布  $A_m(x, y)$  (生成训练集时收集的大量输入强度分布)输入到 GS 算法中, 得到相位全息图, 然后将相位全息图与输入强度分布结合并进行傅里叶变换, 最终获得输出强度分布  $A_{out}(x, y)$ 。记录 2000 对输入强度

分布和输出强度分布,并将它们构成的数据集分成训练数据集和测试数据集。第二阶段为训练卷积神经网络。利用训练数据集训练卷积神经网络以确定预测函数。在这个阶段中,训练数据集中的输出强度分布  $A_{out}^{train}(x,y)$  被当作是目标强度分布,已知的训练数据集中的输入强度分布  $A_{in}^{train}(x,y)$  被当作是生成理想输出所需的输入强度分布。第三阶段为利用测试数据集评估预测函数的预测能力。在这个阶段中,利

用测试数据集中的输出强度分布  $A_{out}^{test}(x,y)$  预测对应的输入强度分布,即  $\tilde{A}_{in}(x,y) = f_{CNN}[A_{out}^{test}(x,y)]$ ,然后通过计算  $\tilde{A}_{in}(x,y)$  和真实输入强度分布  $A_{in}^{test}(x,y)$  之间的均方误差来衡量预测误差。第四阶段为相位全息图的产生。当卷积神经网络训练结束后,将目标强度分布输入到预测函数中,得到相应的预测输入强度分布,然后将此输入强度分布输入到 GS 算法中,得到相位全息图。

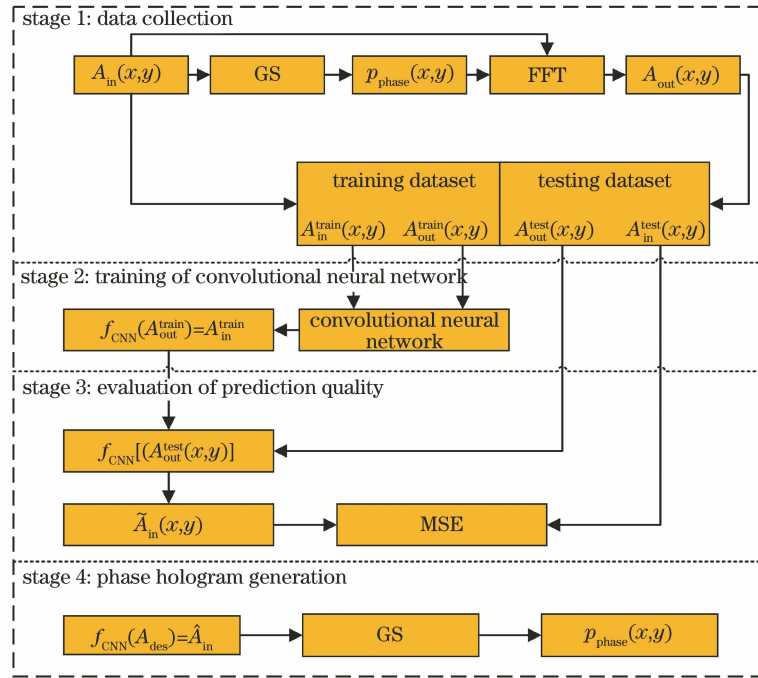


图 1 GS-CNN 方法的流程图

Fig. 1 Flow chart of GS-CNN method

为了衡量输出涡旋光束的质量,采用均方根误差表示输出强度分布和目标强度分布之间的误差,采用衍射效率表示输入光束的能量利用率, RMSE 越低表示误差越小, DE 越高表示效率越高。它们可以描述为

$$R_{RMSE} = \sqrt{\frac{\sum_{i=1}^N [A_{des}(i) - \hat{A}_{out}(i)]^2}{\sum_{i=1}^N [A_{des}(i)]^2}}, \quad (1)$$

$$D_{DE} = \frac{\sum_{i=1}^N \hat{A}_{out}(i)}{\sum_{i=1}^N A_{in}(i)}, \quad (2)$$

式中:  $A_{des}(i)$  为目标强度分布中的点  $i$  的值;  $\hat{A}_{out}(i)$  为预测输出的输出强度分布中的点  $i$  的值;  $A_{in}(i)$  为输入强度分布中的点  $i$  的值;  $N$  为强度分布中的点的数量。

## 2.2 卷积神经网络

卷积神经网络的输入数据通常是图像或二维数据矩阵,所以本文选择卷积神经网络对传统 GS 算

法进行优化。典型的卷积神经网络一般由输入层、卷积层、池化层、全连接层和输出层构成<sup>[22]</sup>。在卷积层中,一个二维输入矩阵与一个二维卷积核经过卷积运算得到一个二维输出矩阵。池化层则对上一层进行子采样,目的是缓解卷积层对位置的过度敏感性。全连接层能够把每一个结点与上一层的所有结点相连,以综合前面提取到的特征。在本文中,由于输入数据和输出数据均为二维矩阵,因此卷积神经网络中没有设置全连接层。其次输入矩阵形状和输出矩阵形状一样,因此需要保证二维矩阵经过卷积层之后形状不变。卷积层的输出形状由输入形状和卷积核窗口形状共同决定,为了使二维矩阵经过卷积层之后形状不变,通过设置卷积层超参数填充的取值来改变输出形状。最后在卷积层之后添加归一化层,进行数据的归一化处理,从而数据在经过激活函数之前,网络性能保持稳定。

在机器学习中,通常需要评估若干候选模型的

表现以选择模型,可供选择的候选模型可以是有着不同超参数的同类模型。一般在训练数据集和测试数据集以外,预留一部分数据来进行模型选择,这部分数据被称作验证数据集<sup>[23]</sup>。基于上述分析,在本文所搭建的卷积神经网络中,卷积层个数是一个关键的超参数。因此,对卷积层个数分别为 3、4、5 和 6 的卷积神经网络进行训练,结果如图 2(a)所示。

当卷积层个数为 3、4、5 和 6 时, MSE 分别为 0.715、0.708、0.602 和 0.598。当卷积层个数为 5 时, MSE 有缓慢下降的趋势,但是随着卷积层个数的增加,计算量也会增加。基于精度和计算量的综合考虑,本文选择卷积层个数为 5 的卷积神经网络,如图 2(b)所示,其中 C1、C2、C3、C4 和 C5 均代表卷积层。

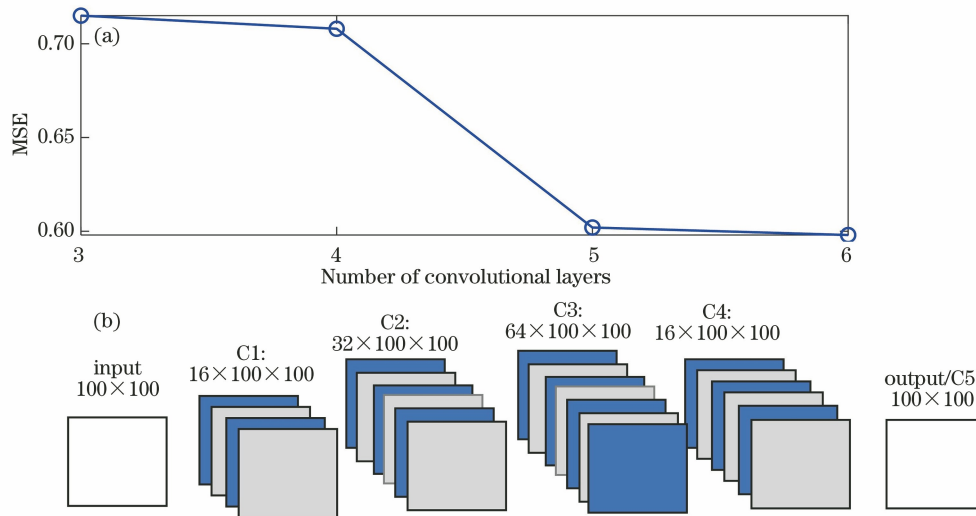


图 2 卷积神经网络模型的选择。(a) MSE 随卷积层个数的变化曲线;(b)卷积神经网络的结构图

Fig. 2 Model selection of CNN. (a) MSE versus number of convolutional layers;

(b) structural diagram of CNN

### 3 分析与讨论

贝塞尔光束在传播的过程中,光场强度分布不变,且遇到障碍物后可以恢复原有光场分布,其在自由空间传播时具有一定的抗干扰能力,对光通信具有重要意义。因此基于提出的 GS-CNN 方法,本文采用高斯光束入射到 LC-SLM 中,产生了拓扑电荷数  $l$  分别为 1、3 的贝塞尔光束以及  $l$  为 1、4 复用的贝塞尔光束,仿真结果如图 3 所示。其中,图 3(a)~(c)给出了不同拓扑电荷数的涡旋光束的目标光强分布,图 3(d)~(f)给出了 GS-CNN 方法得到的输出光强分布,图 3(g)~(i)给出了生成的涡旋光束的相位全息图,可以看出,相位呈不规则分布。其中,取样点个数为  $100 \times 100$ ,高斯光束波长为 632.8 nm,束腰半径为 3 mm。由图 3(a)~(f)可以看出,随着拓扑电荷数的增大,涡旋光束的直径变大,而 LC-SLM 上的相位调控也变得更加复杂。因此,在采用 OAM 进行调制时,除了需要考虑系统性能,也要充分考虑 LC-SLM 调控的复杂程度。对比目标光强分布和输出光强分布,可以看出,二者直观

上没有差异,具有较高的相似度。

为了分析 GS-CNN 方法生成的贝塞尔光束的质量,针对输出光强和目标光强之间的具体差异进行了定量的计算,图 4 给出了相应的 RMSE 结果。可以看出,随着迭代次数的增大,所生成的涡旋光束的输出光强与目标光强之间的 RMSE 都以较快的速度收敛,最终 RMSE 分别为 0.0549 ( $l=1$ )、0.0584 ( $l=3$ )和 0.0510 ( $l=1$  and 4),数值较为接近。因此,采用 GS-CNN 方法能够产生较高质量的具有不同拓扑电荷数的涡旋光束。此外,图 4 也给出了 GS-CNN 方法和传统 GS 算法的对比。从图 4(a)可以看出,当涡旋光束的拓扑电荷数为 1 时,与传统 GS 算法相比较,GS-CNN 方法迭代终止时的 RMSE 下降了 0.0579。而当拓扑电荷数为 3 或 1 与 4 复用时,GS-CNN 方法和传统 GS 算法的结果差异变大,采用 GS-CNN 方法后,其 RMSE 值相较传统 GS 算法分别降低了 0.0609 和 0.0503,如图 4(b)、(c)所示。这是由于卷积神经网络预测输入强度分布会减小输出强度分布与目标强度分布之间的误差。




图 3 GS-CNN 方法的仿真实验结果。(a)~(c) 贝塞尔光束的目标光强分布;(d)~(f) 生成的涡旋光束的输出强度分布;(g)~(i) 生成的涡旋光束的 LC-SLM 相位全息图

Fig. 3 Simulation experimental results by GS-CNN method. (a)–(c) Target intensity distributions of Bessel beams; (d)–(f) output light intensity distributions of generated vortex beams; (g)–(i) LC-SLM phase holograms of generated vortex beams




图 4 不同方法产生的贝塞尔光束的输出光强与目标光强的 RMSE。(a)  $l=1$ ; (b)  $l=3$ ; (c)  $l=1$  and 4

Fig. 4 RMSE of output light intensity and target light intensity of Bessel beam generated by each method.

(a)  $l=1$ ; (b)  $l=3$ ; (c)  $l=1$  and 4

图 5 进一步给出了采用 GS-CNN 方法产生不同拓扑电荷数贝塞尔光束时,输入光束能量与输出光束能量之间的 DE,并与传统 GS 算法得到的结果进行了比较。从图 5(a)可以看出,在涡旋光束的拓

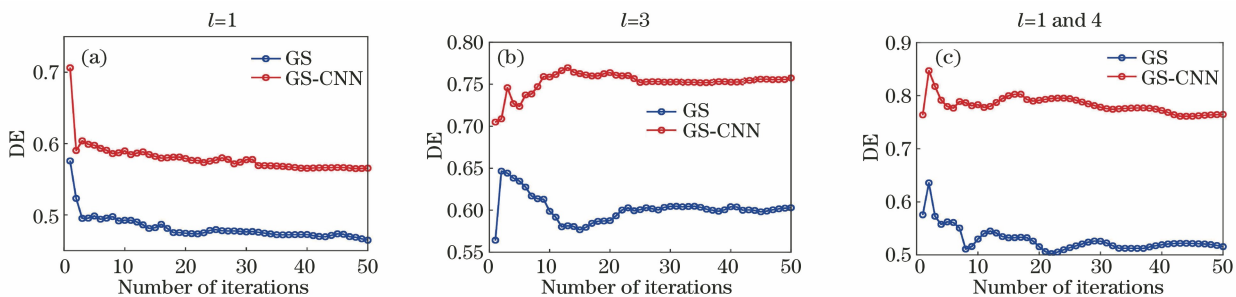


图 5 贝塞尔涡旋光束的输入光束能量与输出光束能量之间的 DE。(a)  $l=1$ ; (b)  $l=3$ ; (c)  $l=1$  and 4

Fig. 5 DE between input beam energy and output beam energy of Bessel vortex beam. (a)  $l=1$ ; (b)  $l=3$ ; (c)  $l=1$  and 4

拓扑电荷数为 1 的条件下,使用传统 GS 算法和 GS-CNN 方法产生涡旋光束时,迭代终止时的 DE 分别为 0.4762 和 0.5656,后者 DE 提高了 0.0954。当涡旋光束的拓扑电荷数为 3 时,相比于 GS 算法得到的结果,GS-CNN 方法的 DE 提高了 0.1559,如图 5(b)所示。当涡旋光束的拓扑电荷数为 1 与 4 复合时,相比于 GS 算法得到的结果,GS-CNN 方法的 DE 提高了 0.2565,如图 5(c)所示。结果表明,产生不同拓扑电荷数的涡旋光束时,相比于 GS 算法,GS-CNN 方法的 DE 均会得到提升。而在基于 OAM 的光通信系统中,发射端产生涡旋光束的 DE 低,成本高,所以使用 GS-CNN 方法制备涡旋光束更适用于光通信系统。

## 4 结 论

在不引入任何新变量的前提下,基于传统 GS 算法和卷积神经网络,提出了一种采用 LC-SLM 产生涡旋光束的方法,并应用该方法成功地产生了高质量的贝塞尔光束。针对产生的不同拓扑电荷数的涡旋光束的质量,采用均方根误差和衍射效率进行了定量的衡量。结果表明,相比于 GS 算法得到的结果,所提方法得到的单个拓扑电荷数涡旋光和多个拓扑电荷数复合涡旋光的质量都有明显提升,其中 RMSE 相比于原始 GS 算法降低了 5%~6%。

### 参 考 文 献

- [1] Guo Z Y, Gong C F, Liu H J, et al. Research advances of orbital angular momentum based optical communication technology [J]. Opto-Electronic Engineering, 2020, 47(3): 190593.  
郭忠义, 龚超凡, 刘洪郡, 等. OAM 光通信技术研究进展[J]. 光电工程, 2020, 47(3): 190593.
- [2] Liao H Y. Simulation and experimental study on generation and detection of orbital angular beams [D]. Beijing: Beijing University of Posts and Telecom, 2019.  
廖焕宇. 轨道角动量光束产生与探测的仿真以及实验研究[D]. 北京: 北京邮电大学, 2019.
- [3] Shao W. Research on key technologies in free-space optical communications based on orbital angular momentum multiplexing [D]. Shanghai: Shanghai University, 2019.  
邵蔚. 基于轨道角动量复用的空间光通信关键技术研究[D]. 上海: 上海大学, 2019.
- [4] Liu M W, Li Y C. Propagation of OFDM-OAM optical signal in atmospheric turbulence [J]. Acta Optica Sinica, 2019, 39(7): 0706002.

- 刘旻雯, 李迎春. OFDM-OAM 光信号在大气湍流中的传输[J]. 光学学报, 2019, 39(7): 0706002.
- [5] Zhang K N, Liu Y X, Pu J X, et al. Scintillation index of vortex beams propagating in oceanic turbulence[J]. Chinese Journal of Lasers, 2019, 46(7): 0705001.  
张凯宁, 刘永欣, 蒲继雄, 等. 涡旋光束在海洋湍流中传输的闪烁因子[J]. 中国激光, 2019, 46(7): 0705001.
- [6] Tamm C, Weiss C O. Bistability and optical switching of spatial patterns in a laser[J]. Journal of the Optical Society of America B, 1990, 7(6): 1034-1038.
- [7] Beijersbergen M W, Coerwinkel R P C, Kristensen M, et al. Helical-wavefront laser beams produced with a spiral phase plate [J]. Optics Communications, 1994, 112(5/6): 321-327.
- [8] Heckenberg N R, McDuff R, Smith C P, et al. Generation of optical phase singularities by computer-generated holograms [J]. Optics Letters, 1992, 17(3): 221-223.
- [9] Curtis J E, Koss B A, Grier D G, et al. Dynamic holographic optical tweezers [J]. Optics Communications, 2002, 207(1/2/3/4/5/6): 169-175.
- [10] Kong D J, Sun X Y, Dong Z L, et al. Progress in femtosecond laser processing technology based on space beam shaping [J]. Laser & Optoelectronics Progress, 2020, 57(11): 111416.  
孔德键, 孙小燕, 董卓林, 等. 飞秒激光空间光束整形加工技术研究进展[J]. 激光与光电子学进展, 2020, 57(11): 111416.
- [11] Bryngdahl O. Geometrical transformations in optics [J]. Journal of the Optical Society of America A, 1974, 64(8): 1092-1099.
- [12] Gerchberg R W, Saxton W O. Practical algorithm for the determination of phase from image and diffraction plane pictures[J]. Optik, 1972, 35(2): 237-250.
- [13] Zhang X Y. Research on compound optimization algorithm of liquid crystal on silicon phase hologram [D]. Beijing: Central University for Nationalities, 2019.  
张晓谕. 硅基液晶相位全息图的复合优化算法研究[D]. 北京: 中央民族大学, 2019.
- [14] Fu S Y, Zhai Y W, Yin C, et al. Mixed orbital angular momentum amplitude shift keying through a single hologram[J]. OSA Continuum, 2018, 1(2): 295-308.
- [15] Li X K, Li Y, Zeng X N, et al. Perfect optical vortex array for optical communication based on orbital angular momentum shift keying [J]. Journal of

- Optics, 2018, 20(12): 125604.
- [16] Fienup J R. Iterative method applied to image reconstruction and to computer-generated holograms [J]. Proceedings of SPIE, 1979, 207: 2-13.
- [17] Liu J S, Taghizadeh M R. Iterative algorithm for the design of diffractive phase elements for laser beam shaping [J]. Optics Letters, 2002, 27(16): 1463-1465.
- [18] Huang L X, Yao X, Cai D M, et al. A high accuracy and fast iterative algorithm for phase retrieval [J]. Chinese Journal of Lasers, 2010, 37(5): 1218-1221. 黄利新, 姚新, 蔡冬梅, 等. 一种快速高精度的相位恢复迭代法 [J]. 中国激光, 2010, 37(5): 1218-1221.
- [19] Wang D, Jin B Q, Wang Y, et al. Adaptive flattop beam shaping with a spatial light modulator controlled by the holographic tandem method [J]. IEEE Photonics Journal, 2016, 8(1): 6500107.
- [20] Li X Y, Qian X F, Meng N N, et al. Optimization algorithm of diffractive optical elements for beam shaping [J]. Acta Optica Sinica, 2019, 39(11): 1105003.
- 李昕颖, 钱晓凡, 孟妮妮, 等. 光束整形衍射光学元件的优化算法 [J]. 光学学报, 2019, 39(11): 1105003.
- [21] Mikhaylov D, Zhou B F, Kiedrowski T, et al. High accuracy beam splitting using spatial light modulator combined with machine learning algorithms [J]. Optics and Lasers in Engineering, 2019, 121: 227-235.
- [22] Wan S N. Research and implementation of face recognition based on convolution neural network [D]. Chengdu: University of Electronic Science and Technology of China, 2016. 万士宁. 基于卷积神经网络的人脸识别研究与实现 [D]. 成都: 电子科技大学, 2016.
- [23] Chen X, Zhu R, Wang Z Y, et al. Handwritten digits recognition based on fused convolutional neural network model [J]. Computer Engineering, 2017, 43(11): 187-192. 陈玄, 朱荣, 王中元, 等. 基于融合卷积神经网络模型的手写数字识别 [J]. 计算机工程, 2017, 43(11): 187-192.