

文章编号: 1005-5630(2024)02-0077-09

DOI: 10.3969/j.issn.1005-5630.202303130056

基于光学衍射神经网络的拉盖尔-高斯光束识别

贺瑜^{1,2}, 陈龙^{1,2}, 胡晓楠^{1,2}, 栾海涛^{1,2}

(1. 上海理工大学光子芯片研究院, 上海 200093;

2. 上海理工大学光电信息与计算机工程学院, 上海 200093)

摘要: 拉盖尔-高斯(Laguerre-Gaussian, LG)光束除了轨道角动量(orbital angular momentum, OAM)维度外, 还拥有径向量子数 p , 因此LG光束可以为光通信和光计算等应用提供更多的物理自由度。但目前常见的干涉、衍射机制的LG光束模式探测方法在受到大气湍流的干扰时, 识别准确率会明显下降, 从而限制了其实际应用。提出了一种基于衍射神经网络(diffractive neural network, DNN)的LG光束识别方式, 实现了 p 在1~3范围内的识别。即使在强湍流强度, 衍射距离为5 m的情况下, 该识别方式的识别准确率依然能达到95%以上。该DNN方法能够为准确识别LG光束模式提供有效途径, 在大容量OAM通信、高维量子信息处理等方面均具有潜在应用价值。

关键词: 拉盖尔-高斯光束; 轨道角动量; 大气湍流; 衍射神经网络

中图分类号: O 438.2 **文献标志码:** A

Laguerre-Gaussian beam recognition based on optical diffractive neural network

HE Yu^{1,2}, CHEN Long^{1,2}, HU Xiaonan^{1,2}, LUAN Haitao^{1,2}

(1. Institute of Photonic Chips, University of Shanghai for Science and Technology, Shanghai 200093, China;

2. School of Optical-Electrical and Computer Engineering, University of Shanghai for Science and Technology, Shanghai 200093, China)

Abstract: Laguerre-Gaussian (LG) beams possess radial quantum number p in addition to orbital angular momentum (OAM) dimension, and thus LG beams can provide more physical degrees of freedom for applications such as optical communication and optical computing. However, the recognition accuracy of the LG beam pattern detection method, which is commonly used by interference and diffraction mechanisms, is significantly reduced when it is disturbed by atmospheric turbulence (AT), which limits its practical application. We propose a diffraction neural network (DNN)-based LG beam recognition method that achieves p in the range of 1-3. Even in the

收稿日期: 2023-03-13

基金项目: 国家重点研发计划(2022YFB2804301)

第一作者: 贺瑜(1997—), 女, 硕士研究生, 研究方向为光与物质的相互作用。E-mail: 2370658009@qq.com

通信作者: 栾海涛(1987—), 男, 研究员, 研究方向为超快激光加工和全息显示。

E-mail: haitaoluan@usst.edu.cn

case of strong turbulence intensity and diffraction distance of 5 m, the recognition accuracy still reaches more than 95%. This DNN method can provide an effective way to accurately identify LG beam patterns, and has potential applications in high-capacity OAM communication and high-dimensional quantum information processing.

Keywords: Laguerre-Gaussian beam; orbital angular momentum; atmospheric turbulence; diffraction neural network

引 言

1992年, Allen等^[1]发现具有特殊螺旋波前 $\exp(i l \phi)$ 的涡旋光束,其中 l 表示拓扑荷(topological charge, TC), ϕ 表示圆柱坐标系中的方位角,其携带的每个光子的轨道角动量(orbital angular momentum, OAM)为 $l\hbar$, \hbar 表示普朗克常数。由于光束截面的相位奇异性,OAM呈现出“暗中空”的强度分布,并且在空间上具有无限的维度正交^[2]。这些空间变化的场分布赋予了OAM许多独特的光学功能,使其可以被广泛应用于光通信^[3]、量子信息处理^[4]、全息^[5-8]等方面。

拉盖尔-高斯(LG)光束是一种特殊的OAM模式,它不仅具有角量子数 l ,还具有径向量子数 p ,这意味着LG光束可以在提高通信容量和调制能力方面提供额外的物理自由度^[9]。但是,对于LG光束中径向量子数 p 的高效精准检测一直是亟待解决的难题。目前,已经出现许多探测LG光束模式的方法,例如,参考光场与物光干涉^[10-12]、各种衍射技术^[13-15]、倾斜双凸透镜^[16]等。必须指出的是,上述方法存在模式检测范围小和衍射效率有限的问题。另外,由于光学系统的不对准以及环境扰动引起的相位失真,更容易导致探测LG光束模式性能的严重下降。如在涉及自由空间光通信的实际混合复杂空间模式中,普遍存在的大气湍流(atmospheric turbulence, AT)就成为了一个棘手的问题^[17]。

神经网络(neural network, NN)由于其强大的数据处理能力,已经被广泛应用于计算机视觉^[18]、语言处理^[19]和光学信息处理^[20-21]等领域。2019年以来,相关研究团队通过卷积神经网络(convolutional neural network, CNN)实现了对

30阶OAM模式的LG光束的高精度识别。在AT的影响下,这些LG光束传播50m,系统对其仍然保持着高于89%的识别准确率^[22]。2021年,本研究团队使用衍射神经网络(diffractive neural network, DNN)实现了对768阶LG光束的模式识别,且准确率高达95%^[23]。最近,基于衍射实现三维空间神经元链接的光学DNN得到广大研究者的青睐^[24]。DNN可以以光速、近乎无能耗地实现深度学习,已被广泛应用于全光学图像分析、特征检测和对象分类中。其中,互补金属氧化物(complementary metal oxide semiconductor, CMOS)集成D2NN芯片被证明可以用于处理相位信息,获取Zernike系数^[25]。因此,复振幅波前调控能力为LG光束模式的探测提供了新的思路。

采用DNN的架构,通过观测输出光强的空间位置,实现了对LG光束模式的识别。概念图如图1所示。设计了一个3层的DNN模型,当输入间隔 $\Delta l = 1$, $\Delta p = 1$ 的LG光束模式时,发现网络能够对其进行很好地识别,计算准确率高达99%。进一步模拟、分析实际光路中存在的环境因素、系统误差以及各方面影响因素对该模型的影响,优化DNN模型,提升其鲁棒性。具体操作为,在光束的传播路径中插入随机相位来模拟AT,并且在不同的AT强度下传输5m。结果显示,在AT强度 $C_n^2 = 3 \times 10^{-13} \text{ m}^{-2/3}$ 情况下,识别准确率超过95%,说明DNN模型具有较强的抗干扰能力。

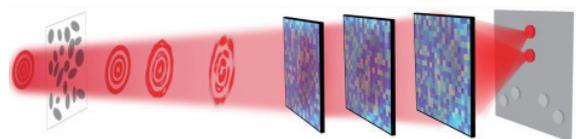


图 1 LG 光束的 DNN 识别概念图

Fig. 1 DNN identification concept diagram of LG beam

1 基于 LG 光束识别的 DNN 网络

1.1 拉盖尔-高斯光束

LG 光束是亥姆霍兹方程在缓变振幅近似下的一个特解, 可以表示为

$$LG_{pl}(r, \phi, z) = \frac{C_{pl}}{w_0} \left(\frac{\sqrt{2}r}{w(z)} \right)^l L_p^{|l|} \left(\frac{2r^2}{w(z)^2} \right) \exp\left(-\frac{r^2}{w(z)}\right) \exp(il\phi) \exp(i\phi) \quad (1)$$

式中: C_{pl} 为常数; w_0 为基模束腰半径; l 为角量子数; p 为径向量子数, 可取任意非负整数; r 为光斑半径; ϕ 为圆柱坐标系中的方位角; ϕ 为古伊相位。 $w(z)$ 和 ϕ 分别为

$$w(z) = w_0 \sqrt{1 + \left(\frac{z}{f}\right)^2} \quad (2)$$

$$\phi = (l + 2p + 1) \arctan \frac{z}{f} - k \left(z + \frac{r^2}{2R} \right) \quad (3)$$

式中: $R = z + \frac{f^2}{z}$; k 为波数; f 为共焦参数, 也称为瑞丽长度, $f = \frac{\pi w_0^2}{\lambda}$

$L_p^{|l|}(\theta)$ 为缩合拉盖尔多项式

$$L_p^{|l|}(\theta) = \sum_{m=0}^p \frac{(p+|l|)! (-\theta)^m}{(|l+m)! m! (p-m)!} \quad (4)$$

采用 Python 编写程序, 将式(1)的模型展示出来, 给出了拓扑荷数 l 为 1~3, 径向指数 p 为 1~2 的 LG 光束模拟光强和相位分布, 结果如图 2 所示。

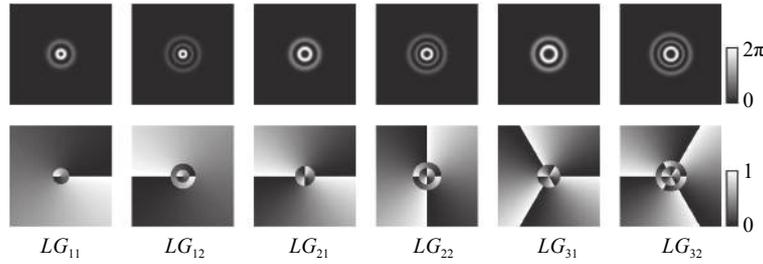


图 2 LG 光束模拟图

Fig. 2 LG beam simulation diagram

1.2 大气湍流模型及其影响

当光束在大气中传播时, 它将在空间和时间上受到大气压强、温度的影响, 从而导致信道产生起伏。并且存在于大气中的气体分子和杂质会对光束的传输产生散射和吸收等作用, 从而导致光束发生质心漂移、波前扰动和强度变化。这些因素会对自由空间光通信系统会造成不利的影。因此, 为了确保光通信系统的效率, 需要深入研究大气湍流的物理原理, 并了解不同的湍流程度对光束的影响。

Davis^[26] 根据大气折射率结构常数 C_n^2 数值的大小, 将大气湍流划分成 3 种: 强湍流, $C_n^2 > 2.5 \times 10^{-13} \text{ m}^{-2/3}$; 中湍流, $6.4 \times 10^{-17} \text{ m}^{-2/3} < C_n^2 < 2.5 \times 10^{-13} \text{ m}^{-2/3}$; 弱湍流, $C_n^2 < 6.4 \times 10^{-17} \text{ m}^{-2/3}$ 。

为了模拟更加真实的大气湍流影响, 采用了 Ochs 等^[27] 提出的大气湍流功率谱密度函数模型

$$\phi_n(k) = 0.033 C_n^2 \exp\left(\frac{k_x^2 + k_y^2}{k_l^2}\right) \left(k_x^2 + k_y^2 + \frac{1}{L_0}\right)^{\frac{11}{6}} \times \left(1 + 1.802 \sqrt{\frac{k_x^2 + k_y^2}{k_l^2}} - 0.254 \frac{k_x^2 + k_y^2}{k_l^2}\right) \quad (5)$$

式中: $k_l = \frac{3.3}{l_0}$; l_0, L_0 分别表示湍流的内、外尺度; k_x, k_y 分别表示不同位置处 (x, y) 的波数分量。

将 LG 光束在大气湍流中传输的过程模拟成 LG 光束经过一个厚度忽略不计的大气湍流相位屏, 进行相位调制。相位调制是将一个随机矩阵 C 与大气相位功率谱密度函数模型相乘后, 再进行傅里叶逆变换得到的, 以实现随机和滤波处理的效果, 其表达式为

$$\phi_n(x, y) = \mathcal{F}^{-1} \left\{ C \times \frac{2\pi}{N\Delta x} \sqrt{\varphi(k_x, k_y)} \right\} \quad (6)$$

式中： N 是设置的总采样点数； Δx 是它的采样间隔； $\varphi(k_x, k_y)$ 是相位功率谱密度函数。

如图 3 所示，不同 AT 参数对 LG 光束影响不同，在实际传播中不可以忽略不计。

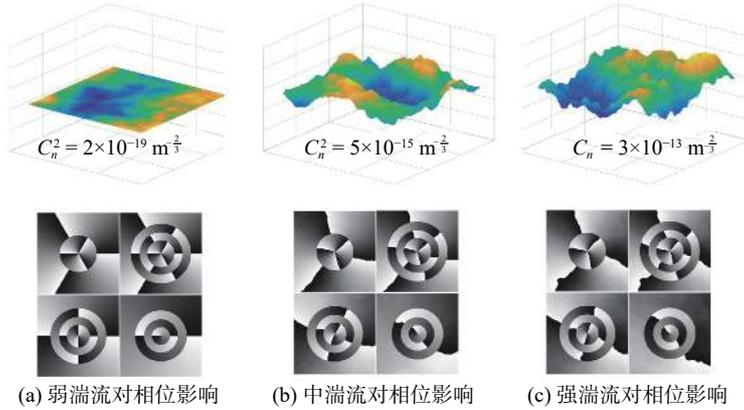


图 3 不同强度下的 AT 对相位的影响

Fig. 3 Phase effects under different ATs

1.3 用于 LG 光束识别的 DNN 网络

根据文献 [24]，本文给出如图 4(a)所示的 DNN 网络模型制备流程图。DNN 模型主要分

为 3 部分：分别为输入层、输出层和隐藏层。其中输入层和输出层对应相应的输入光场和输出光场，隐藏层则是变量优化层，可以是振幅型、相

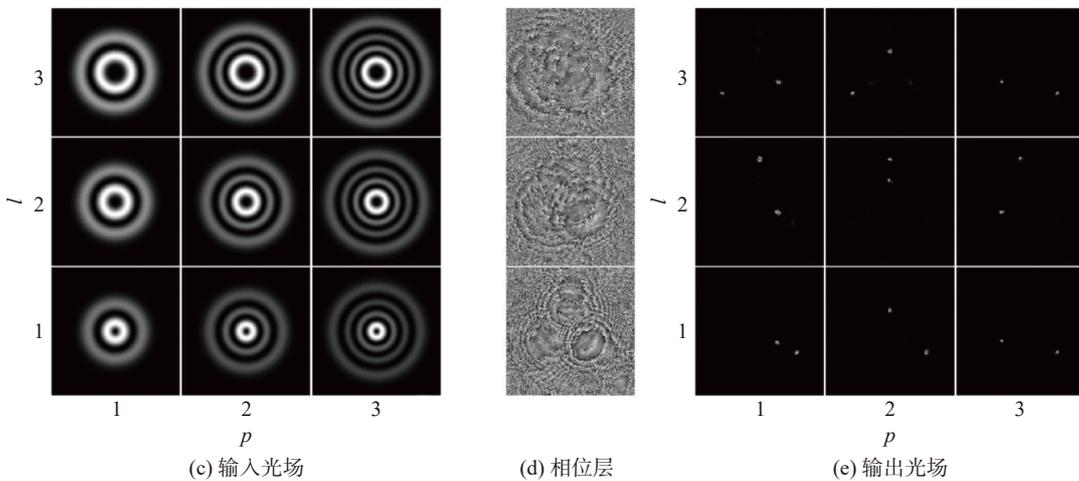
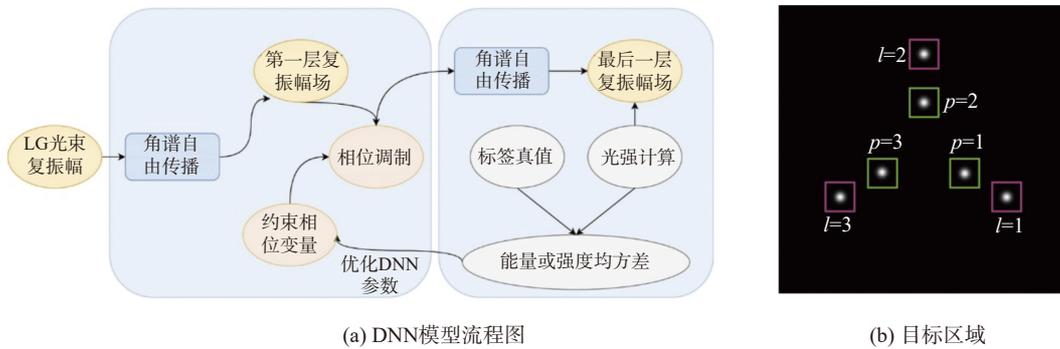


图 4 不同 LG 模式的 DNN 识别图

Fig. 4 DNN identification diagram of different LG modes

位型或者复振幅型。每层神经元之间通过角谱理论衍射传播连接。具体衍射表达式为

$$U(x, y, z) = \mathcal{F}^{-1} \{ A_0(f_x, f_y, 0) H(f_x, f_y) \} \quad (7)$$

$$\text{式中: } H(f_x, f_y) = \begin{cases} e^{jkz \sqrt{1 - (\lambda f_x)^2 - (\lambda f_y)^2}, \sqrt{f_x^2 + f_y^2} < \frac{1}{\lambda}} \\ 0, \text{ other} \end{cases},$$

是自由空间的传递函数; A_0 是输入平面, 即 LG 光束的频谱, 由输入平面的光场 $U_0(x, y, 0)$ 作傅里叶变换获得。

接着, 对通过 DNN 训练后网络识别 LG 光束的整体过程做详细描述。首先, 选取分辨率为 256×256 , 单个像素大小 $12.5 \mu\text{m}$, 光波波长 633 nm 作为网络的基本参数。其次, 利用 LG 模型生成 l 为 $1 \sim 3$ 和 p 为 $1 \sim 3$ 的 9 阶不同模式作为网络的输入光场。网络的输出光场如图 4(b) 所示, 规定目标区域外环代表 l 的识别, 内环代表 p 的识别。通过搭建 3 层相位变量层作为网络对光场的调制层, 并且每层之间的传播距离为 150 mm 。接着, 使用均方误差 MSE 作为损失函数来衡量 DNN 输出层光强 s_K^{M+1} 与标签真值 g_K^{M+1} 之间的差异, 其表达式为

$$E(\varphi_i^q) = \frac{1}{K} \sum_K (s_K^{M+1} - g_K^{M+1})^2 \quad (8)$$

式中, K 表示输出平面的测量点数。

本文设置目标函数为 $\min_a E(\varphi_i^q)$ 来优化 DNN 设计。应用误差反向传播和下降梯度法来训练 DNN, 损失函数对 DNN 网络的误差梯度表达式为

$$\frac{\partial E(\varphi_i^q)}{\partial \varphi_i^q} = \frac{4}{k} \sum_k (s_k^{M+1} - g_k^{M+1}) \cdot \text{Real} \left\{ (m_k^{M+1})^* \frac{\partial m_k^{M+1}}{\partial \varphi_i^q} \right\} \quad (9)$$

式中: $m_k^{M+1} = \sum_{k_1} n_{k_1}^M$, k 为前一层衍射网络神经元的相位因子; $\frac{\partial m_k^{M+1}}{\partial \varphi_i^q}$ 表示输出层复数光场对前面网络层的神经元相位值的梯度; Real 表示对复数光场取实部运算。网络在设置学习率为 0.01 的条件下, 经过 2 000 次的迭代优化后, 相应相位变量层参数已被更新完毕, 同时损失函

数得到收敛, 最终得到预期光场。如图 4 所示, 当网络输入 LG (l 为 $1 \sim 3$, p 为 $1 \sim 3$) 经过图 4(d) 中的 3 层相位后得到如图 4(e) 所示的光强分布。

1.4 用于 AT 影响下 LG 光束识别的 DNN 网络

由于大气湍流在实际中的影响无法忽略, 因此本文选取 3 种不同强度的 C_n^2 (弱湍流 $C_n^2 = 2 \times 10^{-19} \text{ m}^{-2/3}$, 中湍流 $C_n^2 = 5 \times 10^{-15} \text{ m}^{-2/3}$, 强湍流 $C_n^2 = 3 \times 10^{-13} \text{ m}^{-2/3}$) 来进行衍射 LG 光束 DNN 识别的模拟, 见图 5(a), (d) 和 (g)。

由于 LG 光束在衍射过程中光的波前会扩散, 也就是说, 原来平行的光线会变成在不同方向上发散的光线, 从而导致在屏幕上形成一个光斑, 并且这个光斑会随着距离的增加而变大。过大的光斑对计算机的训练会造成巨大的挑战, 因此, 为了能对 AT 影响下的衍射 LG 光束进行 DNN 识别, 需要对 LG 光束做预处理操作。

步骤一, 选取像素个数 1280×1280 , 像素大小 $12.5 \mu\text{m}$, 光波波长 633 nm 作为 LG 光束预处理的基本参数。

步骤二, 在选取的参数下, 依据 LG 模型生成所需的 9 阶 LG 光束 (l 为 $1 \sim 3$ 和 p 为 $1 \sim 3$) 的光场分布。

步骤三, 在每种不同强度参数下, 随机生成 40 个大气湍流相位屏, 作为每一阶 LG 光束在自由空间传播 5 m 中的 AT 影响。如此操作, 生成的 1 080 张 LG 光束图像作预处理后的输入光场。

步骤四, 不同 LG 光束通过角谱理论自由传输 5 m 后得到对应的输出光场。

步骤五, 由于所得输出光场尺寸较大, 为了满足之后的 DNN 搭建的输入要求, 将衍射后光场经过 $4f$ 缩束系统后, 得到最终的光强和相位分布, 并截取以中心为准的 256×256 像素的区域作为 DNN 搭建的输入光场, 见图 5(a), (d) 和 (g)。

将预处理后的每类 360 张光场分布作为 DNN 模型输入光场, 具体每类选取 288 张图片作为训练集, 剩下的 72 张作为测试集。经过

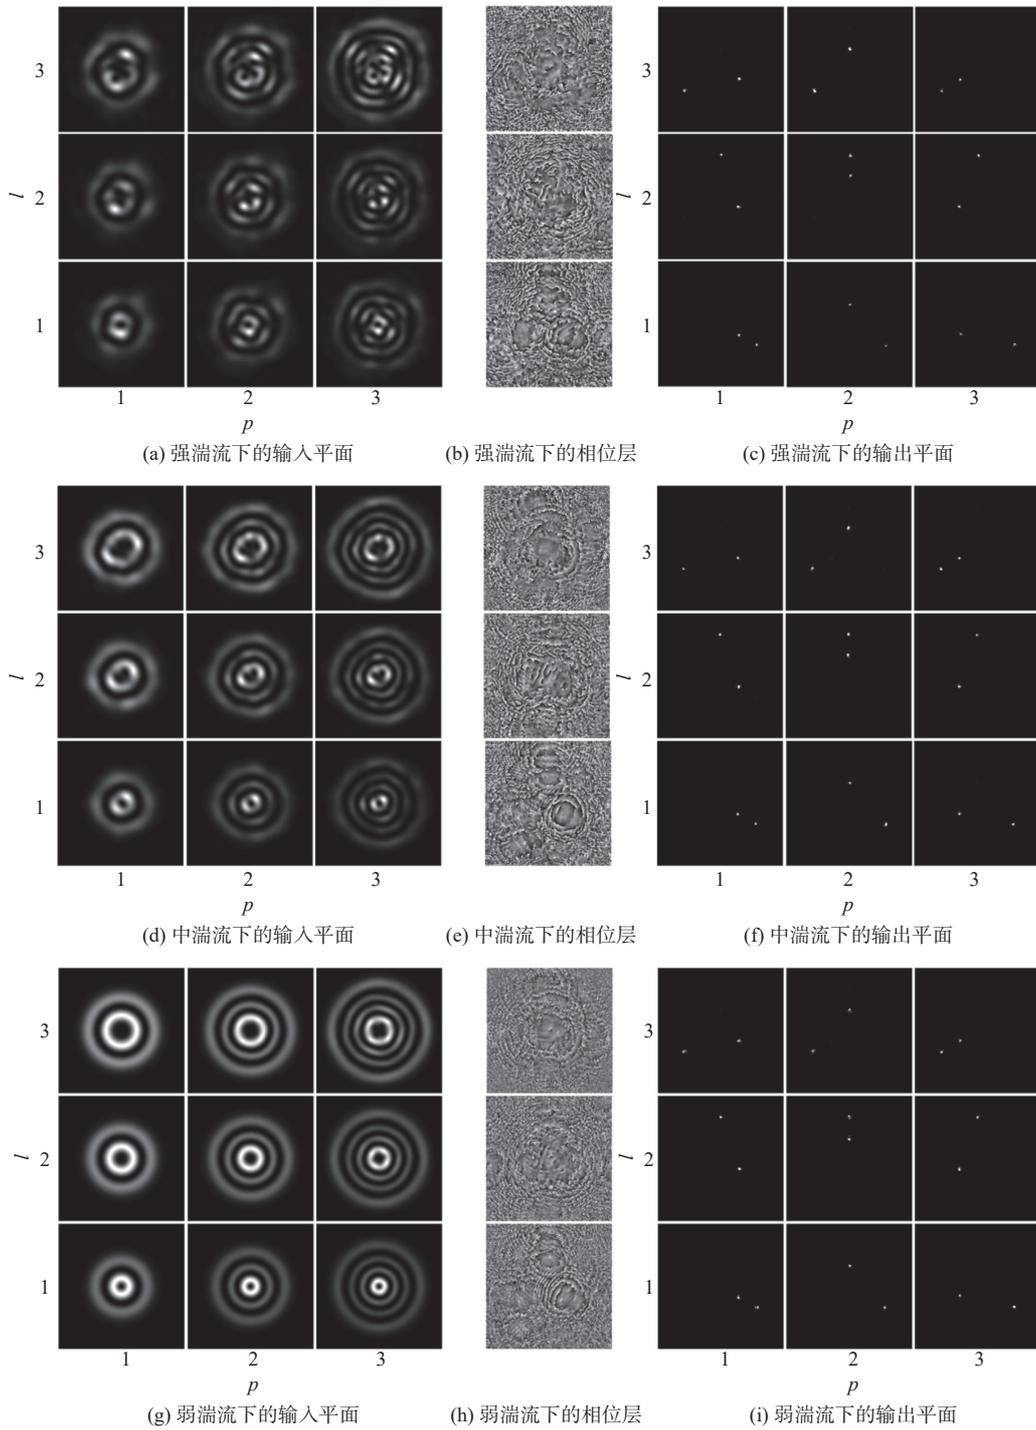


图 5 不同大气湍流强度下的 LG 模式识别

Fig. 5 LG pattern recognition under different ATs

2000 次反复迭代，最终得到预期光场，如图 5(c)，(f)和(i)所示。

分析了每类 AT 影响下的识别准确率，如图 6 所示，训练过程随着迭代次数的增加，模式识别测试机的准确度稳步上升。可以看到在 250

次左右，3 种湍流下的识别准确率分别达到了 100%，100% 和 95%。由于强湍流影响下的 LG 模式光场(振幅及相位)发生较大畸变，DNN 对其的识别准确率相比其他强度的影响存在明显下降。

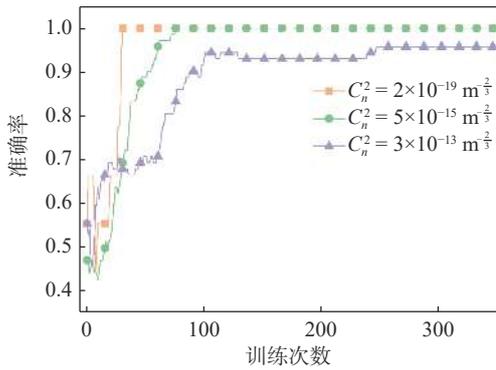


图 6 不同 ATs 强度下训练识别准确率曲线

Fig. 6 Training recognition accuracy curve under different ATs

2 讨论

2.1 相位层个数影响

当网络参数固定后, 为了验证 DNN 深度信息, 即层数对结果预测能力的影响, 分别使用 1 层、2 层、3 层和 4 层的 4 种深度信息对网络进行训练。经过 2 000 次的训练后, 最终得到不同层数下的识别准确率(如表 1 所示)。从 1 层增加到 3 层时候, 识别准确率从 88.9% 升到 97.2%, 可见在所选取参数下, 衍射器件层数增加对神经网络信息处理能力是有正向影响的。但当层数增加到 4 层的时, 准确率不再升高, 这说明深度信息已经饱和, 再多的层数也不会使网络性能进一步提高, 甚至还会使得网络性能下降。因此认为, 网络在完成某项任务的时候所需要的神经元个数是存在最优值的, 少了不能实现好的

表 1 不同层数对应的识别准确率

Tab. 1 Recognition accuracy of different layers

层数	1层	2层	3层	4层
准确率/%	88.9	94.4	97.2	97.2

约束结果, 多了在神经网络训练过程中会引入了冗余不可控自由度, 可能造成神经网络性能下降。

2.2 相位层对准误差

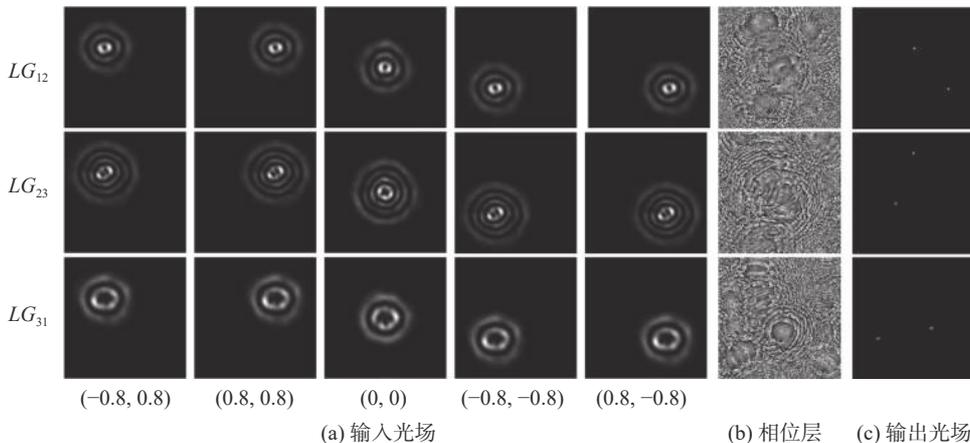
由于光路的不准直等因素很有可能导致系统无法取得理想的效果, 为了探究对准误差对 DNN 模型识别 LG 光束的影响, 将光束偏移 12.5~62.5 μm , 以此来模拟实际光路中对不准的情况。结果如表 2 所示, 识别准确率由最初的 100% 骤减至 38.4%。

表 2 偏移对 DNN 的影响

Tab. 2 Impact of offset on DNNs

偏移量/ μm	12.5	25.0	37.5	50.0	62.5
准确率/%	100	100	73.2	47.8	38.4

为了避免偏移对网络的影响, 将光束的偏移引入 DNN 中一同训练。在光束预处理步骤五中, 选取偏离中心 90 个像素点(1.125 mm)的 4 个方向, 如图 7(a)所示, 将其作为训练集代入训练。经过 2 000 次的反复迭代, 得到了新的相位信息, 见图 7(b), 对应的输出光场如图 7(c)所示。模拟结果表明, LG_{12} 、 LG_{23} 和 LG_{31} 经过迭代后的相位层后, 最终输出光场的识别准确率提升至 92%。由此可见, DNN 具有良好的适配性。



(a) 输入光场

(b) 相位层 (c) 输出光场

图 7 引入偏移训练的 DNN 模型

Fig. 7 DNN model with the grating

3 结 论

提出了一种 DNN 辅助的 LG 光束模式识别。用 LG 光束模式强度图来训练 DNN，成功地识别了 l 为 1~3 和 p 为 1~3 的 LG 光束模式，训练后的 DNN 模型在不同 AT 环境下均具有良好的识别能力。为了探究神经网络深度信息对 DNN 的影响，测试了 1~4 层衍射层 DNN 对 LG 模式识别的准确率，发现在所选取参数下，3 层能达到最佳识别准确率。因为 DNN 在 LG 模式探测时具有鲁棒性，在构建 DNN 时将光束的偏移考虑到训练参数中，以此来对抗外界因素所带来的影响。未来，本研究可能在光通信、量子通信等领域显示出巨大潜力，同时也为人工智能光学芯片的研究做好铺垫。

参考文献:

- [1] ALLEN, L, BEIJERSBERGEN, M W, SPREEUW, R, et al. , Orbital angular momentum of light and the transformation of Laguerre-Gaussian laser modes[J]. *Physical review A*, 1992, 45(11): 8185.
- [2] FORBES A, DE OLIVEIRA M, DENNIS M R. Structured light[J]. *Nature Photonics*, 2021, 15(4): 253 – 262.
- [3] YAN Y, XIE G D, LAVERY M P J, et al. High-capacity millimetre-wave communications with orbital angular momentum multiplexing[J]. *Nature Communications*, 2014, 5: 4876.
- [4] LEACH J, JACK B, ROMERO J, et al. Quantum correlations in optical angle-orbital angular momentum variables[J]. *Science*, 2010, 329(5992): 662 – 665.
- [5] REN H R, BRIERE G, FANG X Y, et al. Metasurface orbital angular momentum holography[J]. *Nature Communications*, 2019, 10(1): 2986.
- [6] FANG X Y, WANG H J, YANG H C, et al. Multichannel nonlinear holography in a two-dimensional nonlinear photonic crystal[J]. *Physical Review A*, 2020, 102(4): 043506.
- [7] REN H R, FANG X Y, JANG J, et al. Complex-amplitude metasurface-based orbital angular momentum holography in momentum space[J]. *Nature Nanotechnology*, 2020, 15(11): 948 – 955.
- [8] FANG X Y, YANG H C, YAO W Z, et al. High-dimensional orbital angular momentum multiplexing nonlinear holography[J]. *Advanced Photonics*, 2021, 3(1): 015001.
- [9] HE Y L, LI Y, CAI Y, et al. A full-duplex 100-GHz radio-over-fiber communication system based on frequency quadrupling[J]. *Optik*, 2018, 175: 148 – 153.
- [10] HARRIS M, HILL C A, TAPSTER P R, et al. Laser modes with helical wave fronts[J]. *Physical Review A*, 1994, 49(4): 3119 – 3122.
- [11] BASISTIY I V, SOSKIN M S, VASNETSOV M V. Optical wavefront dislocations and their properties[J]. *Optics Communications*, 1995, 119(5/6): 604 – 612.
- [12] OSTROVSKY E, COHEN K, TSESSES S, et al. Nanoscale control over optical singularities[J]. *Optica*, 2018, 5(3): 283 – 288.
- [13] NARAG J P C, HERMOSA N. Probing higher orbital angular momentum of Laguerre-Gaussian beams via diffraction through a translated single slit[J]. *Physical Review Applied*, 2019, 11(5): 054025.
- [14] FERREIRA Q S, JESUS-SILVA A J, FONSECA E J S, et al. Fraunhofer diffraction of light with orbital angular momentum by a slit[J]. *Optics Letters*, 2011, 36(16): 3106 – 3108.
- [15] AMBUJ A, VYAS R, SINGH S. Diffraction of orbital angular momentum carrying optical beams by a circular aperture[J]. *Optics Letters*, 2014, 39(19): 5475 – 5478.
- [16] LIU P, CAO Y Q, LU Z H, et al. Probing arbitrary Laguerre-Gaussian beams and pairs through a tilted biconvex lens[J]. *Journal of Optics*, 2021, 23(2): 025002.
- [17] WILLNER A E, HUANG H, YAN Y, et al. Optical communications using orbital angular momentum beams[J]. *Advances in Optics and Photonics*, 2015, 7(1): 66 – 106.
- [18] GOODFELLOW I J, BULATOV Y, IBARZ J, et al. Multi-digit number recognition from street view imagery using deep convolutional neural networks[J]. arXiv preprint arXiv: 1312.6082, 2013.
- [19] GU J X, WANG Z H, KUEN J, et al. Recent advances in convolutional neural networks[J]. *Pattern Recognition*, 2018, 77: 354 – 377.
- [20] LOHANI S, KNUTSON E M, O'DONNELL M, et al. On the use of deep neural networks in optical communications[J]. *Applied Optics*, 2018, 57(15): 4180 – 4190.
- [21] ZAHAVY T, DIKOPOLTSEV A, MOSS D, et al.

- Deep learning reconstruction of ultrashort pulses[J]. *Optica*, 2018, 5(5): 666 – 673.
- [22] WANG P P, LIU J M, SHENG L J, et al. Convolutional neural network-assisted optical orbital angular momentum recognition and communication[J]. *IEEE Access*, 2019, 7: 162025 – 162035.
- [23] LUAN H T, LIN D J, LI K Y, et al. 768-ary Laguerre-Gaussian-mode shift keying free-space optical communication based on convolutional neural networks[J]. *Optics Express*, 2021, 29(13): 19807 – 19818.
- [24] LIN X, RIVENSON Y, YARDIMCI N T, et al. All-optical machine learning using diffractive deep neural networks[J]. *Science*, 2018, 361(6406): 1004 – 1008.
- [25] GOI E, SCHOENHARDT S, GU M. Direct retrieval of Zernike-based pupil functions using integrated diffractive deep neural networks[J]. *Nature Communications*, 2022, 13(1): 7531.
- [26] DAVIS J I. Consideration of atmospheric turbulence in laser systems design[J]. *Appl Optics*, 1966, 5(1): 139 – 147.
- [27] OCHS G R, HILL R J. Optical-scintillation method of measuring turbulence inner scale[J]. *Applied optics*, 1985, 24(15): 2430 – 2432.

(编辑: 李晓莉)