

# 双模式涡旋光束的轨道角动量的精确识别

叶玉儿, 李军依, 曹萌, 夏勇\*

华东师范大学物理与电子科学学院, 精密光谱科学与技术国家重点实验室, 上海 200241

**摘要** 基于轨道角动量(OAM)的自由空间光学通信被认为是很有前景的下一代通信应用,为了实现 OAM 复用通信,需要突破的关键技术之一就是接收端涡旋光束 OAM 的探测。采用卷积神经网络方法,提出并研究了一种双模式涡旋光束的 OAM 精确识别的理论方案。这种 OAM 光束可以提供两个可控的自由度-OAM 量子数和比例参数。研究了训练样本的图片分辨率或样本数目与 OAM 识别准确率的关系。还研究了不同的 OAM 量子数  $l$ 、比例参数  $n$  与 OAM 识别准确率的关系。研究表明,当 OAM 量子数的范围为  $1\sim 10$ ,比例参数为  $0.01\sim 0.99$  时,不同 OAM 模式的识别准确率达到 100%。

**关键词** 成像系统; 涡旋光束; 轨道角动量; 空间光调制器; 机器学习; 卷积神经网络

中图分类号 O439

文献标志码 A

doi: 10.3788/LOP202158.1811021

## Accuracy Recognition of Orbital Angular Momentum of Dual-Mode Vortex Beams

Ye Yuer, Li Junyi, Cao Meng, Xia Yong\*

StateKey Laboratory of Precision Spectroscopy, School of Physics and Electronic Science, East China Normal University, Shanghai 200241, China

**Abstract** Free space optical communication based on orbital angular momentum (OAM) is considered to be a promising next generation communication application. In order to realize OAM multiplexing communication, one of the key technologies is the detection of vortex beam's OAM at the receiving end. Using convolution neural network method, a theoretical scheme for accurate identification of OAM of dual-mode vortex beams is studied. The OAM beam can provide two controllable degrees of freedom, e. g. the topological charge number  $l$  and the proportional coefficient  $n$ . The relationship of the training sample resolution or the number associated with the accuracy of the model is presented. The recognition accuracy is closely related with the quantum number  $l$  of the OAM, and the proportional coefficient  $n$ . This studies show that when  $l$  ranges from 1 to 10, and  $n$  varies from 0.01 to 0.99, the recognition accuracy rate of OAM is 100%.

**Key words** imaging systems; vortex beam; orbital angular momentum; spatial light modulator; machine learning; convolution neural network

**OCIS codes** 110.1758; 050.4865; 050.1970; 070.6120; 100.4996

## 1 引言

角动量是量子力学中一个非常重要的物理量,包含自旋角动量(SAM)和轨道角动量(OAM)。

SAM 和光的偏振态联系在一起,如果光束是左旋或者右旋偏振,则每光子携带  $\pm h/2\pi$  ( $h$  是普朗克常数) SAM; 如果光束是线偏振,则不携带 SAM。1992 年,Allen 等<sup>[1]</sup>首先发现了光学涡旋和 OAM

收稿日期: 2021-02-23; 修回日期: 2021-03-31; 录用日期: 2021-04-22

基金项目: 国家自然科学基金(91836103, 12174115)

通信作者: \*yxia@phy.ecnu.edu.cn

之间的关系,给出了携带 OAM 的涡旋光束具有角向复振幅项  $\exp(il\varphi)$ ,其中,  $l$  为拓扑荷数或者角动量量子数,  $\varphi$  为空间角向的方位坐标。  $l$  可以看成涡旋光束在传播一个波长的过程中,沿光束轴旋转  $2\pi$  相移的数量,可以取任意整数, OAM 光束中每个光子携带 OAM 为  $l\hbar$ ,其中  $\hbar$  是约化普朗克常量<sup>[2-5]</sup>。涡旋光束是一种具有特殊空间光场分布的光束,这种激光束具有独特的物理性质,例如具有桶形的强度分布、螺旋波前、中心相位奇异性和暗中心强度,还可能具有自旋和轨道角动量,并表现出空间传播不变性<sup>[2]</sup>。到目前为止,人们已经发展了多种方法来产生具有中心相位奇点的涡旋光束,例如拉盖尔高斯光束<sup>[6-7]</sup>、高阶贝塞尔高斯光束<sup>[8]</sup>、高阶马提尔光束<sup>[9-10]</sup>等。由于这种光束在光镊<sup>[11]</sup>、量子纠缠<sup>[12]</sup>、显微镜和成像<sup>[13]</sup>、全息加密<sup>[14]</sup>、光通信<sup>[15-19]</sup>等领域的潜在应用,最近引起了人们的极大兴趣。

此外,涡旋光束具有不同 OAM 模式值的相互正交性,而且拓扑荷数可以取任意整数值,每一个拓扑荷数就对应一种 OAM 模式,也就是光束可以具有无限种 OAM 模式,因此将 OAM 模式引入传统光通信领域,发展出了两种新的应用机制—OAM 键控与 OAM 复用<sup>[20-24]</sup>。由于可以克服由大数据,人工智能等新兴技术带来的通信速度和容量的日益增长的需求限制,基于 OAM 的自由空间光学通信被认为是很有前景的下一代通信应用<sup>[16]</sup>。

2004 年, Gibson 等<sup>[25]</sup>首先开展了基于 OAM 的空间自由光通信的研究。在他们的实验中,一张全息图被用来将 OAM 激光束分成 9 个独立的涡旋,然后涡旋在空气中传播了 15 m 到达一个望远镜接收端,在接收端所有的模式都被区分并同时读出。此外,为了实现轨道角动量复用通信,需要突破的关键技术之一就是接收端涡旋光束 OAM 的探测。目前,人们发展了多种方法进行 OAM 光束的探测,这些方法包括全息光栅<sup>[26]</sup>、干涉仪<sup>[27]</sup>、模式转换器和变换<sup>[28]</sup>等。然而,随着整数拓扑荷数的增加,相位异点数目的增加和衍射效应对涡旋光束的光强分布有很大的影响,而且大气湍流对于 OAM 光束在自由空间中超远距离时出现光束波前扭曲,导致涡旋光束 OAM 识别准确率大大下降。近些年人们提出了将机器学习方法用于 OAM 模式探测以提高 OAM 光通信系统性能<sup>[29]</sup>。2014 年, Krenn 等<sup>[20]</sup>首次将机器学习中经典的无监督学习模型之一的自组织特征映射神经网络(SOM)应用到 OAM 光通信领域,对 OAM 模式进行识别。2017 年,

Doster 等<sup>[30]</sup>提出利用卷积神经网络(CNN)和 AlexNet 框架对受大气湍流影响的 OAM 光束强度模式进行分类识别,准确率达到 99% 以上。目前为止,人们已经发展了几种机器学习模型用于光通信中的 OAM 准确识别,这些模型包括人工神经网络、深度神经网络、卷积神经网络、支持向量机、k 近邻、朴素贝叶斯分类器等方案<sup>[31-36]</sup>。

对于单模式的 OAM 光束来说,例如拉盖尔高斯光束,其横向空间的光强度分布为“甜甜圈”形状,不仅不同的 OAM 值大小使“甜甜圈”的光束直径发生变化,而且传播距离也会影响光束直径,所以光束直径的大小无法作为稳定 OAM 识别的特征,从而导致机器学习对单模式 OAM 的识别准确率大大下降。2020 年,本课题组研究了一种新型的单模式 OAM 光束,这种光束的相位分布由  $0 \sim 2\pi$  的相位分布和 0 的平面相位混合组成,因此这种光束就是由高斯光束和传统 OAM 光束混合而成<sup>[37]</sup>。但是这种光束具有非常明显的 OAM 识别特征,此时光束的横向光强度分布从原来的“甜甜圈”强度分布变成“花瓣”形状。然后采用具有 Alexnet 结构的 CNN 模型识别这种单模式涡旋光束的 OAM,识别准确率可以达到 99.8%。由此看出,在 OAM 图像识别中,稳定、可靠和量化的识别特征是最重要的因素,例如光束的横向光强度分布的条纹、点或缝隙的形状和数量。

本文提出了一种采用双模式  $\pm l$  叠加的涡旋光束,在相位板上设计了比例参数  $n$ ,提供了一个新的自由度,不仅具有更明显的花瓣识别特征,而且大大地增加样本数量,为卷积神经网络 ResNet 模型提供充足的样本容量以及提高模型的鲁棒性,涡旋光束 OAM 量子数的识别准确率达到 100%。

## 2 理论模型

### 2.1 双模式 OAM 传输系统的原理图

图 1 为双模式 OAM 光束传输系统。一束高斯激光束入射到空间光调制器(SLM)的屏幕上,通过计算机将编写的相位全息图传输到 SLM 屏幕上,可以将高斯光束整形成相应的涡旋光束。涡旋光束在自由空间中传输一段距离, CCD 相机可以探测到涡旋光束的横向光强度分布,这些图像和通过光场衍射理论进行计算的结果是一致的,由训练好的神经网络模型识别角动量量子数来获得最后的结果。通过在 SLM 上加载不同的相位全息图,计算了大量相应的 OAM 光束强度分布图作为训练集、验证

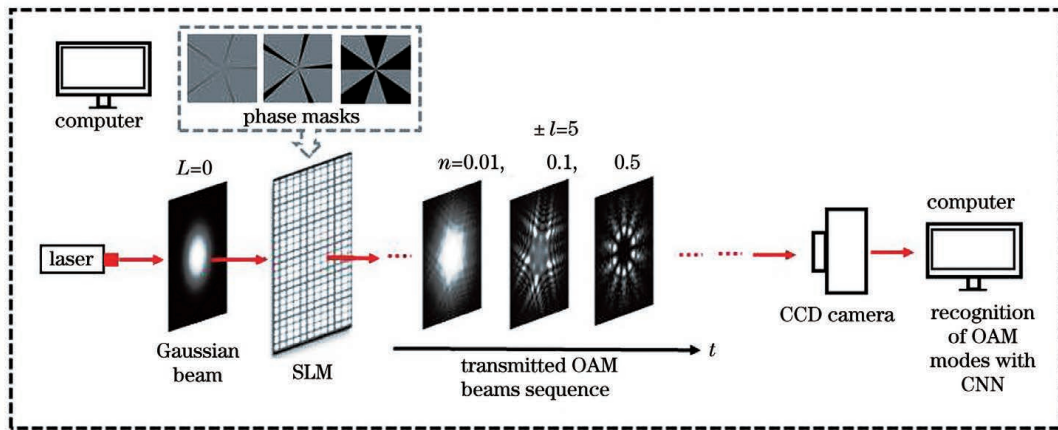


图 1 双模式 OAM 传输系统原理图

Fig. 1 Schematic diagram of dual-mode OAM transmission system

集和测试集 (角动量量子数  $l = 1, 2, \dots, 9, 10$ ; 比例参数  $n = 0.01, 0.02, \dots, 0.99, 1$ ; 传播距离  $z = 21 \text{ cm}, 22 \text{ cm}, \dots, 48 \text{ cm}, 49 \text{ cm}$ )。

### 2.2 双模式涡旋光束的产生

本文采用了一种  $\pm l$  叠加的双 OAM 模式混合光束,其相位分布由 0 和  $\pi$  位相交替组成,  $l$  定义了 OAM 模式的量子数,可以采取任何整数值。这种光束表示同时传输的 OAM 量子数大小相同但是符

号相反的两个 OAM 模式的叠加。OAM 叠加结构的相位径向对称分布,如图 2 (a)~(e)所示。对应的光强度分布显示  $2l$  个光强最大值和最小值排成一圈,如图 2(f)~(j)所示。图 2(a)~(e)展示了产生双模式 OAM 光束其所需要对应加载的全息相位图,为  $0 \sim \pi$  二值化的周期相位板;图 2(f)~(j)展示了叠加后的模式光强分布都是“花瓣”形状,花瓣数量是 OAM 拓扑荷数的两倍。

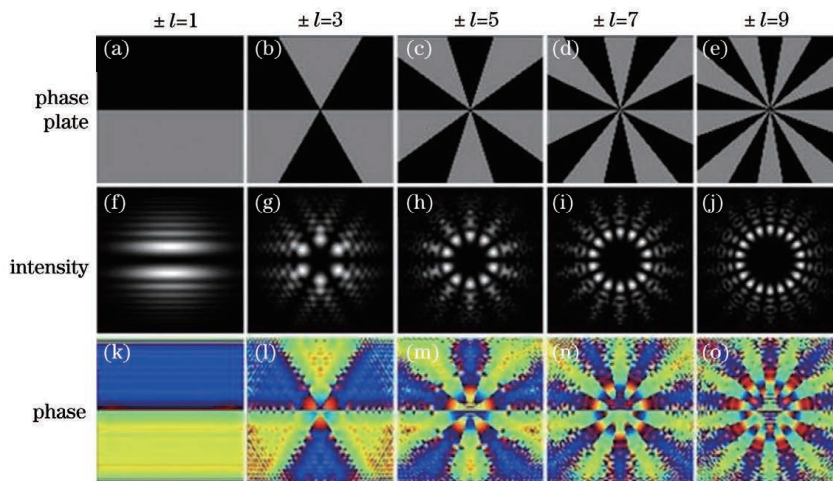


图 2 OAM 取值为 1、3、5、7 和 9 时的相位板、光强分布图以及光束的相位分布图

Fig. 2 Phase plate, light intensity distribution, and phase distribution of the beam when OAM values are 1, 3, 5, 7, and 9, respectively

混合双模式光束的相位函数为

$$\begin{cases} \psi = \pi \varepsilon(t) \\ t = \text{mod}\left(\varphi - \frac{2\pi}{l}\right) - \frac{2\pi n}{l}, \\ \varepsilon(t) = \begin{cases} 1, & t > 0 \\ 0, & t \leq 0 \end{cases} \end{cases} \quad (1)$$

式中:  $l$  为 OAM 模式的拓扑荷数,  $l$  取整数; 比例参数  $n$  决定了一个周期内 0 相位调制面积所占的比

例,取值范围为  $[0, 1]$ 。图 3(a)~(e)为理论上用于产生混合光束的全息相位图,以  $\pm l = 5$  为例,列举了比例参数  $n$  分别为 0.01, 0.1, 0.5, 0.9 和 0.99 时,给出了对应光强分布图。图 3(a)表示了当比例参数  $n$  接近 0 时, OAM 光束变化成高斯光束具有很微小的相位调制。当比例参数  $n$  接近 1 时,光束就会变成高斯光束。可以看出,这两种情况下,横向空间的光强度分布上反映的 OAM 信息非常少。然

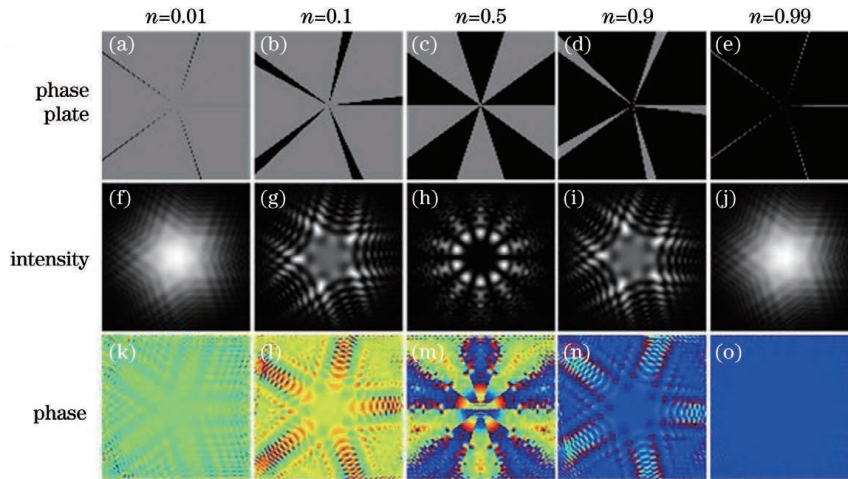


图 3 比例参数  $n$  取 0.01、0.1、0.5、0.9 和 0.99 时的相位板、光强分布图以及光束的相位分布图

Fig. 3 Phase plate, light intensity distribution, and phase distribution of the beam when the proportional coefficient  $n$  is 0.01, 0.1, 0.5, 0.9, and 0.99, respectively

而当  $0 < n < 1$  时, 横向空间的光强度分布上出现非常明显的花瓣或者条纹从而显现出 OAM 的信息, 这些明显的强度分布特征对于采用神经网络模型来

实现 OAM 信息高准确率的识别非常重要。

将相位函数代入到菲涅耳衍射积分方程中, 在探测平面上的电场分布为

$$E(\rho, \theta, z) = \frac{\exp(ikz)}{i\lambda z} \int_0^\infty \int_0^{2\pi} \exp\left(-\frac{r^2}{\omega^2}\right) \exp(i\psi) \exp\left\{\frac{ik}{2z} [r_0^2 - 2\rho r \cos(\varphi - \theta) + \rho^2]\right\} r dr d\varphi, \quad (2)$$

式中:  $k$  是波矢大小;  $z$  是光束空间光调制器到成像屏的距离,  $z$  的取值范围为  $0.10 \sim 0.49$  m;  $\lambda$  是光束的波长。在探测平面上的光强度分布为

$$I = |E(\rho, \theta, z)|^2. \quad (3)$$

### 2.3 神经网络模型

机器学习是让计算机自动学习样本中的数据, 从而得到某种知识和规律。卷积神经网络是机器学习中主要用来处理图像信息的深层前馈神经网络, 具有局部连接、权重共享等特点。本文应用残差网络(ResNet)作为机器学习的网络框架。残差网络通过给非线性的卷积层增加一个恒等函数的方式解决梯度消失的问题, 从而形成更深层的网络。本文采用 ResNet-50 卷积神经网络, 网络结构如表 1 所示。

由(1)~(3)式模拟的光强度分布图按照  $6:2:2$  的比例分成训练集、验证集和测试集, 对应的图片数量分别是 23760、7920 和 7920。训练集用于数据特征的提取、学习。根据学习结果对模型参数进行更新。为了增加模型的鲁棒性, 在样本进行学习之前进行预处理, 将输入的光强分布图进行随机的旋转、翻转、平移、放大、缩小等。同时采用批处理随机梯度下降算法(mini-batchSGD), 将训练集

表 1 ResNet 卷积神经网络模型结构

Table 1 Structure of ResNet CNN model

Layer name	Output size	Structure
Conv1	$112 \times 112$	$7 \times 7$ , 64, stride2
Con2_x	$56 \times 56$	$3 \times 3$ , maxpool, stride2 $\begin{bmatrix} 1 \times 1 & 64 \\ 3 \times 3 & 64 \\ 1 \times 1 & 256 \end{bmatrix} \times 3$
Con3_x	$28 \times 28$	$\begin{bmatrix} 1 \times 1 & 128 \\ 3 \times 3 & 128 \\ 1 \times 1 & 512 \end{bmatrix} \times 4$
Con4_x	$14 \times 14$	$\begin{bmatrix} 1 \times 1 & 256 \\ 3 \times 3 & 256 \\ 1 \times 1 & 1024 \end{bmatrix} \times 6$
Con5_x	$7 \times 7$	$\begin{bmatrix} 1 \times 1 & 512 \\ 3 \times 3 & 512 \\ 1 \times 1 & 2048 \end{bmatrix} \times 3$
FC	$1 \times 1$	Average pool, 10dfc, softmax
FLOPs	-	$3.8 \times 10^9$

中一定数量的样本作为一个批次输送到模型中训练, 剩下的样本重复这个过程, 直到遍历全部训练集

样本, 本文设置每次批量大小为 10 张。这样遍历一次样本为一次迭代过程, 总迭代次数是 50。验证集是在训练过程中验证训练准确率的样本, 测试集是用于测试模型识别样本准确率的样本。通过将测试集输入到模型中进行识别, 得到最终的识别结果以及识别准确率。由于测试集是未被用于模型学习训练的样本, 从而保证测试准确率的可靠性。

当训练集样本数为  $N = 23760$ , 模拟的光强度分布图的分辨率为  $400 \text{ pixel} \times 400 \text{ pixel}$  时得到训练的损失函数和准确率变化如图 4 所示。其中短划线和点线分别表示训练集和验证集准确率随迭代次数的变化。其中实线和点划线分别表示训练集和验证集损失函数随迭代次数的变化。当迭代次数达到 16 次时, 模型训练集验证集的准确率以及损失函数都收敛。准确率达到 100%, 损失函数接近于 0。

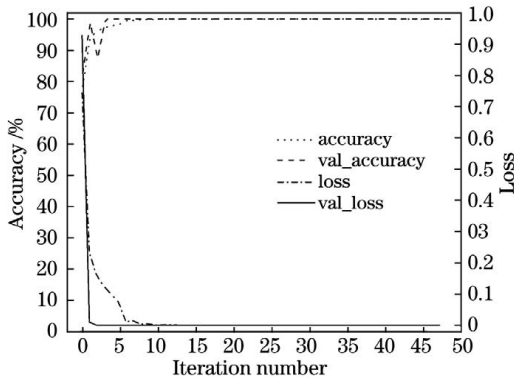


图 4 准确率与损失函数和迭代次数的关系图

Fig. 4 Relationship between accuracy and loss function and number of iterations

### 3 研究结果与分析

机器学习识别涡旋光束的轨道角动量量子数需要大量的训练样本。而不同的样本参数, 比如: 图片样本数目  $N$ 、图片分辨率、轨道角动量量子数的大小  $l$ 、比例参数  $n$  等都会对最终角动量量子数识别的准确率造成影响。本文理论模拟的光强分布图输出是分辨率为  $1000 \text{ pixel} \times 1000 \text{ pixel}$  的 39600 张图片。这些图片中的参数包含: 1) 拓扑荷数为 1~10 的 10 类角动量值; 2) 每一种轨道角动量的不同混合比例; 3) 不同的测量距离。

首先, 研究了光强度分布的图片分辨率对角动量识别准确率的影响。我们先从理论上模拟出光强分布图, 产生的光强分布图的分辨率  $1000 \text{ pixel} \times 1000 \text{ pixel}$ , 在此基础上将图片转换成不同的分辨率的图片。使用的压缩机制是 Antialias 平滑滤波。

对所有输入像素进行高质量的重采样滤波, 以计算输出像素值。当训练样本和测试样本中光强度分布的图片分辨率变化范围从  $2 \text{ pixel} \times 2 \text{ pixel}$  到  $1000 \text{ pixel} \times 1000 \text{ pixel}$  时, 图片分辨率对角动量识别准确率的结果如图 5 所示。随着图片分辨率的不断增大, 模型的角动量识别准确率也不断增加。低分辨率  $2 \text{ pixel} \times 2 \text{ pixel}$  的样本准确率为 37.1%, 但是随着图片分辨率的增加, 在分辨率大于等于  $9 \text{ pixel} \times 9 \text{ pixel}$  时, 准确率趋向 100%。训练模型的时间随着图片分辨率的增加而近似线性增加。由此分析可以看出图片分辨率越高, 角动量识别的准确率越高, 但是采用高分辨率图片的识别模型的训练需要计算机资源也越大。




图 5 图片分辨率对角动量识别准确率的影响  
Fig. 5 Influence of image resolution on OAM recognition accuracy

其次, 机器学习的过程就是从大量的数据中提取特征, 更新模型中的参数, 所以样本数量是一个重要影响因素。图 6 是在图片分辨率为  $400 \text{ pixel} \times 400 \text{ pixel}$  时, 样本数从  $0.01N \sim N$  范围内, 角动量识别准确率随样本数量变化的关系图。其中插图为样本数  $0.01N$  变化到  $0.1N$  时, 识别准确率的变化

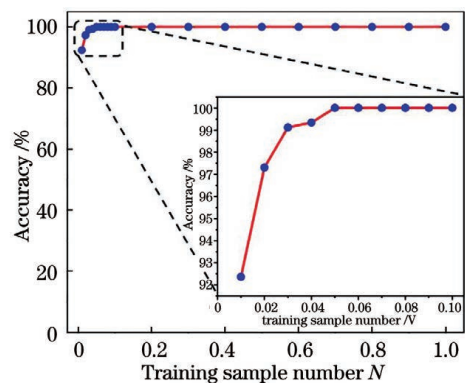


图 6 训练样本数对角动量识别准确率的影响  
Fig. 6 Influence of training sample number on OAM recognition accuracy

情况。总的变化趋势是随着训练样本数量的增加,模型的识别准确率也逐渐增加,并接近 100%。当训练样本数为 0.01N 时,模型的识别准确率仍有 92.3%。当训练样本数等于 0.05N 时,模型的识别准确率接近 100%,同时还发现迭代次数为 22 时,识别准确率收敛到 100%。随着训练样本数量继续增加,识别准确率一直保持在 100%,并且收敛所需的迭代次数逐渐降低。当训练样本为 N 时,收敛所需的迭代次数最小为 4 次,即在迭代次数为 4 时,识别准确率就可以收敛到 100%。迭代次数的缩减可以大大节约训练时间。由此可知,ResNet 模型可以更快地对涡旋光束的角动量量子数进行准确分类。

再次,研究了  $l=1\sim 10$  范围内的轨道角动量量子数的识别准确率。设置训练集样本数量为 N,光强度分布图的分辨率为 400 pixel×400 pixel 进行模型训练。将测试集中的图片导入训练后的模型中进行角动量量子数的识别,获得的混淆矩阵如图 7 所示。横坐标表示输入角动量量子数,纵坐标表示机器学习识别的角动量量子数。当机器学习识别到的轨道角动量值和光强度分布图的真实轨道角动量值相等时,这个数值就会落在对角线上对应的位置上。若除对角线外的矩阵元中有大于 0 的数值存在,则说明轨道角动量对这些图片的识别存在偏差。从图 7 中可以看到数值都落在对角线上,说明该模型对于每一个不同的角动量量子数都可以准确识别。值得注意的是,由于测试集的样本是从总样本中随机抽取出来的,所以不同轨道角动量的测试集样本数也不相同。

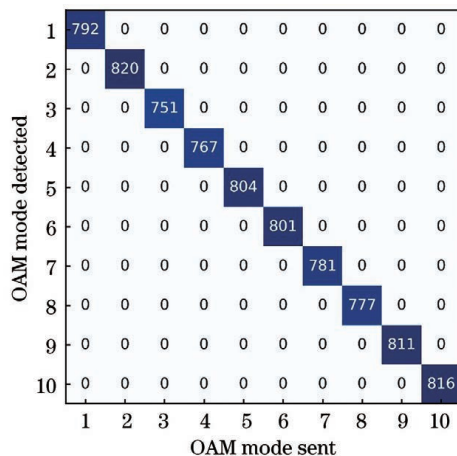


图 7 混淆矩阵

Fig. 7 Confusion matrix

最后,研究了比例参数  $n$  对角动量量子数的识

别准确率的影响。比例参数  $n$  的取值为  $[0, 1]$ ,取值间隔  $\Delta n=0.01$ 。总的图片样本数为 40400 张,测试集为 8080 张,光强度分布图的分辨率为 400 pixel×400 pixel。比例参数对轨道角动量量子数的识别准确率的结果如图 8 所示。图 8 中横坐标表示比例系数  $n$  的取值,纵坐标表示测试集的识别准确率。从图 8 可以看出,当  $n$  取值为 0.01~0.99 时准确率都为 100%。 $n$  取值在 0.01 和 0.99 范围内时双模式的光强分布图有花瓣图案出现,花瓣图案包含有明显的轨道角动量特征。当  $n$  取值为 0 或者 1 时,花瓣图案特征并不是非常的明显,但是 ResNet 模型对角动量的识别准确率也可以达到 96.3%和 97.5%,这说明了 CNN 对于细微变化的花瓣图案也能够高准确率的识别。

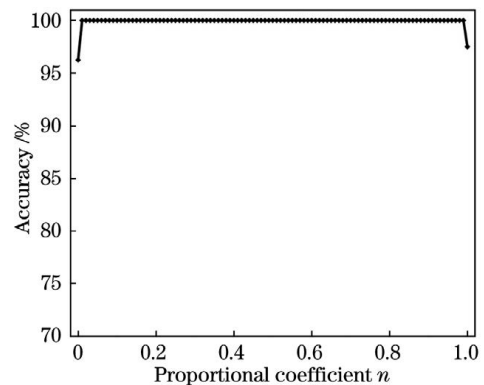


图 8 比例参数  $n$  对角动量识别准确率的影响

Fig. 8 Influence of proportional coefficient  $n$  on OAM recognition accuracy

## 4 结 论

本文研究了一种双模式 OAM 涡旋光束,其相位分布混合了  $\pi$  和 0 的相位分布,并且引入了一个比例参数  $n$ ,用来描述一个周期内  $\pi$  相位比例的大小。根据菲涅耳衍射积分方程计算了双模式 OAM 光束在自由空间的传播特性。这种光束在横向光强分布上出现的花瓣或者条纹的图案,是一个对于 CNN 来说可以识别 OAM 信息的明显特征。引入比例参数可以有效增加样本数量,不仅为轨道角动量光通信提供一个新的自由度,而且提高模型的鲁棒性,使得模型的适应性更强。本文选择的 ResNet 卷积神经网络模型不仅具有较深的网络结构,而且可以更好地提取数据特征。研究了轨道角动量值、比例参数、光强分布图分辨率以及样本数量对识别准确率的影响。当 OAM 量子数的范围为 1~10,角动量比例参数为 0.01~0.99 时,不同 OAM 模式

的识别准确率接近 100%。这些结果为下一代基于 CNN 的 OAM 光通信提供了潜在的应用前景。

### 参 考 文 献

- [1] Allen L, Beijersbergen M W, Spreeuw R J C, et al. Orbital angular momentum of light and the transformation of Laguerre-Gaussian laser modes[J]. *Physical Review A*, 1992, 45(11): 8185-8189.
- [2] Yin J P, Gao W J, Zhu Y F. Generation of dark hollow beams and their applications[J]. *Progress in Optics*, 2003, 45: 119-204.
- [3] Padgett M J. Orbital angular momentum 25 years on [J]. *Optics Express*, 2017, 25(10): 11265-11274.
- [4] Shen Y J, Wang X J, Xie Z W, et al. Optical vortices 30 years on: OAM manipulation from topological charge to multiple singularities[J]. *Light: Science & Applications*, 2019, 8: 90.
- [5] Zhu L, Wang J. A review of multiple optical vortices generation: methods and applications [J]. *Frontiers of Optoelectronics*, 2019, 12(1): 52-68.
- [6] 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.
- [7] O'Neil A T, MacVicar I, Allen L, et al. Intrinsic and extrinsic nature of the orbital angular momentum of a light beam [J]. *Physical Review Letters*, 2002, 88(5): 053601.
- [8] Paterson C, Smith R. Higher-order Bessel waves produced by axicon-type computer-generated holograms [J]. *Optics Communications*, 1996, 124(1/2): 121-130.
- [9] Chávez-Cerda S, Padgett M J, Allison I, et al. Holographic generation and orbital angular momentum of high-order Mathieu beams [J]. *Journal of Optics B: Quantum and Semiclassical Optics*, 2002, 4(2): S52-S57.
- [10] Li H R, Yin J P. Generation of a vectorial Mathieu-like hollow beam with a periodically rotated polarization property [J]. *Optics Letters*, 2011, 36(10): 1755-1757.
- [11] Padgett M, Bowman R. Tweezers with a twist [J]. *Nature Photonics*, 2011, 5(6): 343-348.
- [12] Erhard M, Fickler R, Krenn M, et al. Twisted photons: new quantum perspectives in high dimensions [J]. *Light: Science & Applications*, 2018, 7(3): 17146.
- [13] Tamburini F, Anzolin G, Umbriaco G, et al. Overcoming the Rayleigh criterion limit with optical vortices [J]. *Physical Review Letters*, 2006, 97(16): 163903.
- [14] Fang X Y, Ren H R, Gu M. Orbital angular momentum holography for high-security encryption [J]. *Nature Photonics*, 2020, 14(2): 102-108.
- [15] 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.
- [16] 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.
- [17] Wang J. Twisted optical communications using orbital angular momentum [J]. *Science China Physics, Mechanics & Astronomy*, 2018, 62(3): 1-21.
- [18] Yin X L, Cui X Z, Chang H, et al. Research progress of orbital angular momentum modes detecting technology based on machine learning [J]. *Opto-Electronic Engineering*, 2020, 47(3): 190584. 尹霄丽, 崔小舟, 常欢, 等. 基于机器学习的轨道角动量光束模式探测技术研究进展 [J]. *光电工程*, 2020, 47(3): 190584.
- [19] 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.
- [20] Krenn M, Fickler R, Fink M, et al. Communication with spatially modulated light through turbulent air across Vienna [J]. *New Journal of Physics*, 2014, 16(11): 113028.
- [21] Krenn M, Handsteiner J, Fink M, et al. Twisted light transmission over 143 km [J]. *Proceedings of the National Academy of Sciences of the United States of America*, 2016, 113(48): 13648-13653.
- [22] Willner A J, Ren Y X, Xie G D, et al. Experimental demonstration of 20 Gbit/s data encoding and 2 ns channel hopping using orbital angular momentum modes [J]. *Optics Letters*, 2015, 40(24): 5810-5813.
- [23] Wang J, Yang J Y, Fazal I M, et al. Terabit free-space data transmission employing orbital angular momentum multiplexing [J]. *Nature Photonics*, 2012, 6(7): 488-496.
- [24] Huang H, Xie G D, Yan Y, et al. 100 Tbit/s free-space data link enabled by three-dimensional multiplexing of orbital angular momentum, polarization, and wavelength [J]. *Optics Letters*, 2014, 39(2): 197-200.
- [25] Gibson G, Courtial J, Padgett M J, et al. Free-space

- information transfer using light beams carrying orbital angular momentum [J]. *Optics Express*, 2004, 12(22): 5448-5456.
- [26] Zhang N, Yuan X C, Burge R E. Extending the detection range of optical vortices by Damman vortex gratings [J]. *Optics Letters*, 2010, 35(20): 3495-3497.
- [27] Zhou H L, Shi L, Zhang X L, et al. Dynamic interferometry measurement of orbital angular momentum of light [J]. *Optics Letters*, 2014, 39(20): 6058-6061.
- [28] Wen Y H, Chremmos I, Chen Y J, et al. Spiral transformation for high-resolution and efficient sorting of optical vortex modes [J]. *Physical Review Letters*, 2018, 120(19): 193904.
- [29] LeCun Y, Bengio Y, Hinton G. Deep learning [J]. *Nature*, 2015, 521(7553): 436-444.
- [30] Doster T, Watnik A T. Machine learning approach to OAM beam demultiplexing via convolutional neural networks [J]. *Applied Optics*, 2017, 56(12): 3386-3396.
- [31] Liu Z W, Yan S, Liu H G, et al. Superhigh-resolution recognition of optical vortex modes assisted by a deep-learning method [J]. *Physical Review Letters*, 2019, 123(18): 183902.
- [32] Zhao Q S, Hao S Q, Wang Y, et al. Orbital angular momentum detection based on diffractive deep neural network [J]. *Optics Communications*, 2019, 443: 245-249.
- [33] Li J, Zhang M, Wang D S. Adaptive demodulator using machine learning for orbital angular momentum shift keying [J]. *IEEE Photonics Technology Letters*, 2017, 29(17): 1455-1458.
- [34] Zhao Q S, Hao S Q, Wang Y, et al. Mode detection of misaligned orbital angular momentum beams based on convolutional neural network [J]. *Applied Optics*, 2018, 57(35): 10152-10158.
- [35] Tian Q H, Li Z, Hu K, et al. Turbo-coded 16-ary OAM shift keying FSO communication system combining the CNN-based adaptive demodulator [J]. *Optics Express*, 2018, 26(21): 27849-27864.
- [36] Li J, Zhang M, Wang D S, et al. Joint atmospheric turbulence detection and adaptive demodulation technique using the CNN for the OAM-FSO communication [J]. *Optics Express*, 2018, 26(8): 10494-10508.
- [37] Mao Z X, Yu H Y, Xia M, et al. Broad bandwidth and highly efficient recognition of optical vortex modes achieved by the neural-network approach [J]. *Physical Review Applied*, 2020, 13(3): 034063.