

# 光学学报

## 基于改进的残差网络的分数涡旋光束模态识别

魏冬梅, 杜乾, 刘芳宁, 王珂, 赵日峰\*

山东师范大学物理与电子科学学院山东省光场调控工程技术研究中心, 山东 济南 250358

**摘要** 利用分数涡旋光束进行信息传输, 可以大大提高通信系统的容量。但在接收端准确测定分数涡旋光束的模态, 尤其在信道中存在湍流的情况下, 存在一定的困难。本文提出了改进的残差网络(I-ResNet)以提高模态检测的正确率。实验结果表明, 本文构建的网络能够准确地识别光束模态, 且具有较好的泛化性。在传输距离为 1500 m、弱湍流( $C_n^2 = 10^{-16} \text{ m}^{-2/3}$ )、模态分辨率  $\Delta l \geq 0.05$  时, 准确率可以达到 100%; 强湍流( $C_n^2 = 10^{-14} \text{ m}^{-2/3}$ )、 $\Delta l = 0.15$  时, 准确率可以达到 96.5%。随着湍流强度或传输距离的增加, 正确识别率下降。这些结果对自由空间光通信系统设计具有一定的指导意义。

**关键词** 分数阶涡旋光束; 模态分辨率; 改进的残差网络; 大气湍流

中图分类号 TN929.12 文献标志码 A

DOI: 10.3788/AOS231361

### 1 引言

涡旋光束具有轨道角动量(OAM)、螺旋相位波前和暗中空光强分布, 自被发现以来引起了广泛关注, 在量子纠缠<sup>[1]</sup>、光学成像<sup>[2]</sup>、非线性光学<sup>[3]</sup>、光通信<sup>[4-8]</sup>等领域具有重要的应用前景。涡旋光束的螺旋相位波前可描述为  $\exp(i l \theta)$ , 其中  $\theta$  为方位角,  $l$  为拓扑荷(TC), 理论上可以取任意有理数<sup>[9-10]</sup>。但是涡旋光束的半径依赖于拓扑荷数  $l$ , 其中心暗斑会随着  $l$  值的增大而增大, 这使得具有较大  $l$  值的涡旋光束在传输、耦合等场合中的应用变得非常困难。在最大  $l$  限制下, 减小相邻拓扑荷数之间的间隔, 可增加模态种类, 有效提升通信容量。例如, OAM 的模态分辨率  $\Delta l$  由 1 变为 0.1, 可用模态扩大了 10 倍, 通信速率可得到极大提升。近年来, OAM 的研究逐渐扩展到分数领域, 分数阶 OAM 光束的产生和模态的精确测量, 对高质量信息传输具有重要意义<sup>[11-19]</sup>。

卷积神经网络(CNN)具有依据数据提取内在特征和划分决策边界的能力, 已经成为一个功能强大的深度学习框架, 提供了一种高效的图像识别方法。近年来, 利用 CNN 识别整数阶 OAM 模态得到了广泛研究并且取得了显著成果<sup>[20-24]</sup>。2019 年, Liu 等<sup>[25]</sup>利用 DenseNet 网络识别  $\Delta l = 0.01$  的未畸变分数涡旋光束, 识别准确率为 98%。2021 年, Na 等<sup>[26]</sup>利用 ATANN 网络对 5 类分数阶 OAM 光束进行识别, 在传输距离为 1000 m、 $C_n^2 = 1 \times 10^{-14} \text{ m}^{-2/3}$ 、 $\Delta l \geq 0.15$  时, 识别准确率可达到 100%; 在传输距离为 1500 m、 $C_n^2 = 1 \times 10^{-15} \text{ m}^{-2/3}$ 、 $\Delta l \geq 0.1$  时, 识别准确率为 99.07%。但是现有算法仍面临在强湍流、长距离条件下分数阶涡旋光束识别准确率有待提高的问题。

本文搭建了改进的残差网络(I-ResNet), 对不同湍流强度、不同传输距离的分数阶涡旋光束进行模态识别。在传输距离为 1000 m、 $C_n^2 = 1 \times 10^{-14} \text{ m}^{-2/3}$ 、 $\Delta l \geq 0.15$  时, 识别准确率可达到 100%; 在传输距离为 1500 m、 $C_n^2 = 1 \times 10^{-15} \text{ m}^{-2/3}$ 、 $\Delta l \geq 0.1$ 、 $\Delta l = 0.05$  时, 识别准确率分别可达到 100% 和 98.7%。结果表明, 该网络能够有效提高识别准确率, 尤其在强湍流、长距离条件下表现更好。

本文搭建了改进的残差网络(I-ResNet), 对不同湍流强度、不同传输距离的分数阶涡旋光束进行模态识别。在传输距离为 1000 m、 $C_n^2 = 1 \times 10^{-14} \text{ m}^{-2/3}$ 、 $\Delta l \geq 0.15$  时, 识别准确率可达到 100%; 在传输距离为 1500 m、 $C_n^2 = 1 \times 10^{-15} \text{ m}^{-2/3}$ 、 $\Delta l \geq 0.1$ 、 $\Delta l = 0.05$  时, 识别准确率分别可达到 100% 和 98.7%。结果表明, 该网络能够有效提高识别准确率, 尤其在强湍流、长距离条件下表现更好。

### 2 分数涡旋光束及其在大气湍流中的传输特性

涡旋光束在源平面上的光场分布<sup>[29]</sup>表示为

$$u_l(r, \theta, 0) = A \exp\left(-\frac{r^2}{w_0^2}\right) \exp(il\theta), \quad (1)$$

式中:  $(r, \theta)$  为平面上的点在柱坐标系下的坐标;  $A$  和  $w_0$  分别为入射高斯光束的复振幅和束腰;  $l$  为拓扑荷数,  $l$  取整数即为整数阶涡旋光,  $l$  取分数即为分数阶涡

收稿日期: 2023-08-04; 修回日期: 2023-09-05; 录用日期: 2023-09-19; 网络首发日期: 2023-10-23

基金项目: 国家自然科学基金(42271093)、山东省本科教学改革研究项目(M2021235)

通信作者: \*yuefengzhao@sdnu.edu.cn

旋光。

涡旋光束在大气中进行传输时, 大气湍流效应对其螺旋相位波前产生扰动, 发生畸变, 引起接收端光强分布的变化。主要表现为光束闪烁、相位在空间和时间上的起伏和漂移。大气湍流效应发生的原因是大气折射率随着空间和时间发生无规则变化。大气折射率

取决于空气密度, 随着大气中各点空气密度的无规则起伏发生变化。

设光束在大气中传输  $\Delta z$  m, 大气湍流产生随机扰动相位为  $\varphi(x, y)$ 。本文中用角谱法计算分数涡旋光束传输在接收平面上的电场函数<sup>[30]</sup>:

$$U_i(\rho, \theta, \Delta z) = \mathcal{F}^{-1} \left\{ \mathcal{F} \left\{ u_i(r, \theta, 0) \exp[i\varphi(x, y)] \right\} \exp \left[ i\Delta z \sqrt{k^2 - 4\pi^2(f_x^2 + f_y^2)} \right] \right\}, \quad (2)$$

式中:  $(\rho, \theta)$  为接收平面上点的柱坐标;  $\mathcal{F}(\cdot)$  和  $\mathcal{F}^{-1}(\cdot)$  分别为傅里叶变换和傅里叶逆变换;  $k = 2\pi/\lambda$  为波数;  $f_x, f_y$  分别为  $x, y$  方向的频率分量。

数值模拟是研究大气湍流效应的一种基本方法, 相位屏数值模拟光在大气中的传输过程是将光在真空中的传输与湍流介质折射率起伏带来的传播影响看成两个独立过程分别处理, 即在光束传输路径上设置一个符合大气湍流特性的随机相位屏, 光束在真空中传输距离  $\Delta z$  后, 再通过随机相位屏, 这样就等效于在真空传输相位上叠加了湍流引起的随机起伏相位, 如图 1 所示。如果传输距离较远, 可以采取多张相位屏, 即经过  $N$  个大气湍流模拟屏, 传输步数  $N$  为传输距离与两个相位屏间距离的比值, 考虑到本文主要研究对畸变的不同模态的光束进行模态识别, 采用单张相位屏模拟出的光强图像可能会有所不同, 但对于所有不同模态分辨率的光束影响是相似的, 因此对网络识别结

果没有影响。

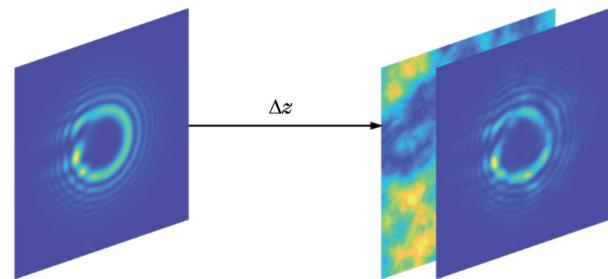


图 1 光束经过相位屏传输示意图

Fig. 1 Schematic diagram of beam transmission through phase screen

本文选择功率谱反演法生成随机相位屏, 采用 Hill-Andrews 模型描述大气折射率的功率谱密度  $\Phi_n(\kappa_x, \kappa_y)$ <sup>[31-32]</sup>:

$$\Phi_n(\kappa_x, \kappa_y) = 0.033 C_n^2 \left[ 1 + 1.802 \sqrt{\frac{\kappa_x^2 + \kappa_y^2}{\kappa_l^2}} - 0.254 \left( \frac{\kappa_x^2 + \kappa_y^2}{\kappa_l^2} \right)^{7/12} \right] \times \exp \left( -\frac{\kappa_x^2 + \kappa_y^2}{\kappa_l^2} \right) \left( \kappa_x^2 + \kappa_y^2 + \frac{1}{L_0^2} \right)^{-11/6}, \quad (3)$$

式中:  $(\kappa_x, \kappa_y)$  是角频率;  $\kappa_l = 3.3/l_0$ ;  $l_0$  和  $L_0$  分别是湍流的内径尺寸和外径尺寸;  $C_n^2$  是大气折射率结构常数, 其大小体现了湍流的强弱。二维相位谱  $\Phi(\kappa_x, \kappa_y)$  和大气折射率功率谱的关系为

$$\Phi(\kappa_x, \kappa_y) = 2\pi k^2 \Delta z \Phi_n(\kappa_x, \kappa_y), \quad (4)$$

其方差可以写为

$$\sigma^2(\kappa_x, \kappa_y) = \left( \frac{2\pi}{N \Delta x} \right)^2 \Phi(\kappa_x, \kappa_y), \quad (5)$$

式中: 相位屏分辨率为  $N \times N$ ;  $\Delta x$  为接收屏栅格距离。通过傅里叶逆变换得到随机相位屏的空间分布函数  $\varphi(x, y)$ <sup>[33]</sup> 为

$$\varphi(x, y) = \mathcal{F}^{-1} [C_{N \times N} \sigma(\kappa_x, \kappa_y)], \quad (6)$$

式中,  $C_{N \times N}$  是一个均值为 0、方差为 1 的复高斯随机矩阵。

设  $l_0 = 2 \text{ mm}$ ,  $L_0 = 50 \text{ m}$ ,  $\Delta z = 1500 \text{ m}$ ,  $\lambda = 594 \text{ nm}$ ,  $w_0 = 0.03 \text{ m}$ 。图 2 模拟仿真了不同湍流强度

的大气湍流相位屏, 其中图 2(a) 对应  $C_n^2 = 10^{-16} \text{ m}^{-2/3}$ , 代表弱湍流; 图 2(b) 对应  $C_n^2 = 10^{-15} \text{ m}^{-2/3}$ , 代表中湍流; 图 2(c) 对应  $C_n^2 = 10^{-14} \text{ m}^{-2/3}$ , 代表强湍流。图 3 展示了分数涡旋光束经 3 种不同湍流强度后的光强分布图。从图中可以看出, 随着湍流强度的增大, 相位失真和光强分布畸变都越严重。

### 3 基于 I-ResNet 的分数涡旋光的模态检测算法

#### 3.1 I-ResNet 网络结构

本文在 ResNet50 网络基础上进行改进, 搭建了 I-ResNet 网络, 其结构如图 4 所示。ResNet50 网络<sup>[34]</sup> 可以分成七个部分: 第一部分 Input, 输入图像; 第二部分 Conv1, 对输入图像卷积; 第三部分 Conv2、第四部分 Conv3、第五部分 Conv4、第六部分 Conv5 为残差块结构部分, 每个残差块由三个卷积层和一个跳跃连接组成, 其中第一个和第三个卷积层的卷积核大小都是  $1 \times 1$ , 第二个卷积层的卷积核大小  $3 \times 3$ ; 第七部分为

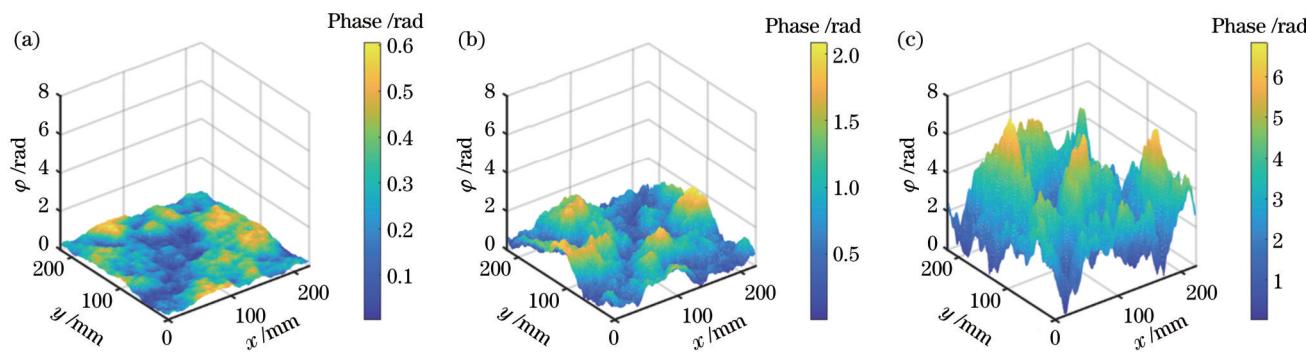


图 2 不同强度下大气湍流相位屏的模拟仿真。(a)  $C_n^2 = 10^{-16} \text{ m}^{-2/3}$ ; (b)  $C_n^2 = 10^{-15} \text{ m}^{-2/3}$ ; (c)  $C_n^2 = 10^{-14} \text{ m}^{-2/3}$

Fig. 2 Simulation of atmospheric turbulence phase screen at different intensities. (a)  $C_n^2 = 10^{-16} \text{ m}^{-2/3}$ ; (b)  $C_n^2 = 10^{-15} \text{ m}^{-2/3}$ ; (c)  $C_n^2 = 10^{-14} \text{ m}^{-2/3}$

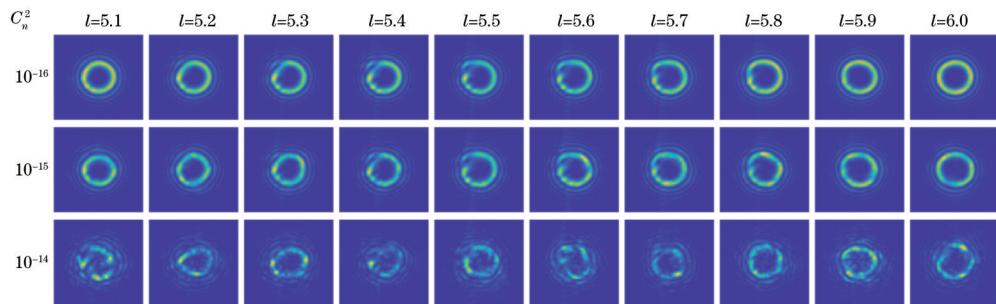


图 3 大气湍流强度对分数涡旋光束光强分布的影响

Fig. 3 Influence of atmospheric turbulence intensity on intensity distribution of fractional vortex beam

全连接(FC)层。网络总共有  $1 + 3 \times (3 + 4 + 6 + 3) = 49$  个卷积层, 加上最后的 FC 层总共 50 层。在训练和测试时, 输入  $224 \times 224$  的原始图像, 首先进行  $7 \times 7$  卷积核和  $3 \times 3$  最大池化处理, 再依次由四个“残差块”、平均池化层, 转化成一个特征向量、输入 FC 层, 最后由 Softmax 函数输出类别。

随着网络层数的加深, 会出现模型退化以及梯度

消失问题, ResNet50 网络使用残差块可以解决这一问题, 但是却有信息丢失、计算量过大以及复杂度过高等新问题<sup>[34]</sup>。为了解决这些问题, 本文搭建了 I-ResNet, 相比于 ResNet50, 改进了网络结构和残差块操作顺序, 将 ImageNet 图像数据集上预训练好的模型迁移到分数涡旋光束模态识别上。

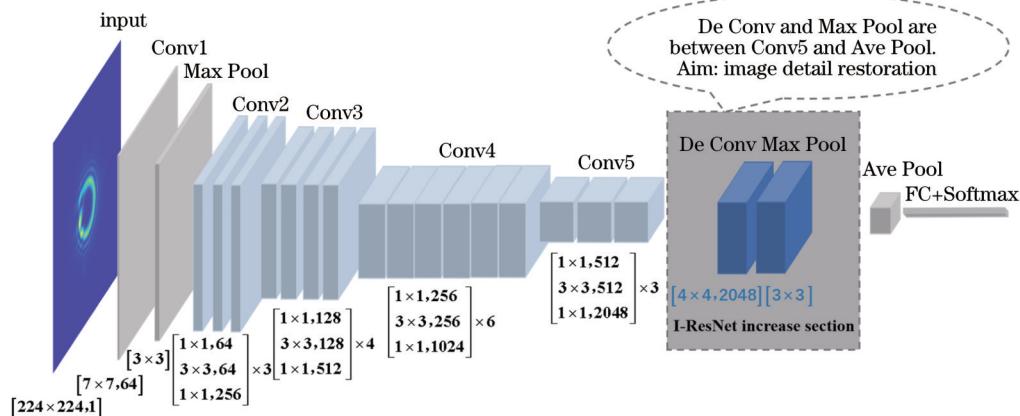


图 4 I-ResNet 网络结构示意图  
Fig. 4 Structure diagram of I-ResNet network

### 1) 改进网络结构

I-ResNet 网络在第六部分(Conv5)和平均池化(Ave Pool)之间加入反卷积(De Conv)和最大池化

(Max Pool), 该部分由一个卷积核大小为  $4 \times 4$ 、步长为 2 的反卷积层和  $3 \times 3$  的最大池化构成, 通过反卷积运算, 可以尽可能地重构原始数据集, 最小化重构误

差。重构误差越小,提取的特征越具有代表性,这样可以有效解决ResNet50网络中的信息丢失问题,提高识别准确率。

### 2)改进残差块操作顺序

ResNet50网络中残差块的结构顺序为“Conv(卷积) $\rightarrow$ BN(数据归一化) $\rightarrow$ ReLU(激活函数)”,然后进入一个“Conv $\rightarrow$ BN $\rightarrow$ ReLU”循环,如图5(a)所示。I-ResNet网络中的残差块结构图如5(b)所示,将BN和ReLU激活函数调整到卷积层之前,先由BN对数据进行归一化,加快网络收敛的速度,同时提高网络的泛化能力,然后将归一化数据输入ReLU进行激活,这样做不仅增加了层间的非线性关系,又增强了网络稀疏性,最后将激活数据输入到卷积层进行卷积提取特征。卷积完成后,不同于ResNet50直接将卷积结果迭代进入下一次循环的残差操作,而是在两次循环之间加入dropout层,使部分神经元以一定的概率暂停工作,避免网络参数过拟合,加快网络训练的收敛速度。

### 3)引入迁移学习

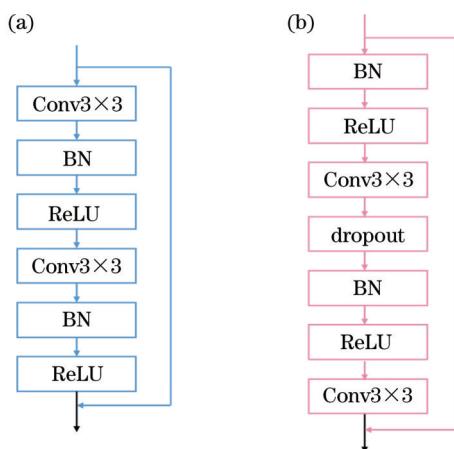


图5 残差结构。(a) ResNet50残差块结构;(b) I-ResNet残差块结构

Fig. 5 Residual structure. (a) ResNet50 residual block; (b) I-ResNet residual block

I-ResNet网络特征提取能力强大,但网络参数量也大,当样本数据量相对较小时,直接进行训练,往往不能达到最佳分类效果,通常使用迁移学习来解决这一问题。迁移学习<sup>[35]</sup>是将已学习到的关于问题A的权重和特征应用于不同但相关的问题B上来,从而更好地解决问题B。本文使用在ImageNet图像数据集上训练的ResNet50预训练模型。在迁移过程中,基于预训练分类模型整体架构,将I-ResNet网络增加的De Conv和Max Pool参数作随机初始化,并添加一个10分类的FC层替换原有FC层。相较于训练一个全新的网络,迁移学习有利于网络快速收敛,从而提升网络的分类效果。

## 3.2 实验结果及其分析

### 1)数据集构造

本文用数值计算模拟分数涡旋光束, $C_n^2$ 分别取 $10^{-16} \text{ m}^{-2/3}$ 、 $10^{-15} \text{ m}^{-2/3}$ 、 $10^{-14} \text{ m}^{-2/3}$ 。模态分辨率 $\Delta l$ 集合为{0.05, 0.10, 0.15, 0.20, 0.25},对应每类模态分辨率,取10种不同模态,共有 $5 \times 10 = 50$ 种模态的分数涡旋光束。

表1列出了5类模态分辨率 $\Delta l$ 及各自相应的模态范围,表2给出了 $\Delta l = 0.1$ 时,各模态光束(5.1, 5.2, 5.3, 5.4, 5.5, 5.6, 5.7, 5.8, 5.9, 6.0)通过不同湍流强度、不同传输距离的数据集。以 $l=5.1$ 为例,光束在 $C_n^2 = 1 \times 10^{-16} \text{ m}^{-2/3}$ 、传输距离为500 m时,由于湍流的随机性,生成300幅不同的随机光强图,同样传输1000、1500 m也各有300幅不同的随机光强图,这样 $l=5.1$ 分别经过三种湍流强度、三种传输距离,有 $300 \times 3 \times 3 = 2700$ 幅随机光强图,因此 $\Delta l = 0.1$ ,对应10种模态(5.1, 5.2, 5.3, 5.4, 5.5, 5.6, 5.7, 5.8, 5.9, 6.0)分别有2700幅随机光强图,共有 $2700 \times 10 = 27000$ 幅分数阶随机光强图。类似地,构造了 $\Delta l$ 为0.05、0.15、0.20、0.25对应的数据集。表3列出了传输距离为1000 m、 $C_n^2$ 分别取 $10^{-16} \text{ m}^{-2/3}$ 、 $10^{-15} \text{ m}^{-2/3}$ 、 $10^{-14} \text{ m}^{-2/3}$ 、 $\Delta l = 0.1$ 的模态整数部分取值分别为1、2、5及各自相应的模态范围。

表1 5类模态分辨率及相应的模态范围

Table 1 Five mode resolutions and corresponding mode ranges

$\Delta l$ (Mode resolution)	0.05	0.10	0.15	0.20	0.25
Mode range	5.10~5.55	5.10~6.00	5.10~6.45	5.10~6.90	5.10~7.35

### 2)模态检测结果

模态的正确识别率( $R$ )=预测正确的样本数量( $l_n$ )与测试样本总数量( $l_N$ )的比值。

$$R = \frac{l_n}{l_N} \times 100\%. \quad (7)$$

图6给出了5类不同模态分辨率的分数涡旋光束分别在不同湍流强度下传输不同距离时的模态检测结果,图中方块直线代表 $C_n^2 = 1 \times 10^{-16} \text{ m}^{-2/3}$ ,三角虚线

代表 $C_n^2 = 1 \times 10^{-15} \text{ m}^{-2/3}$ ,点虚线代表 $C_n^2 = 1 \times 10^{-14} \text{ m}^{-2/3}$ 。其中图6(a)、6(b)、6(c)分别表示传输距离为500、1000、1500 m。从图6(a)可以看出,在传输距离为500 m时, $\Delta l \geq 0.1$ 时三种湍流强度下均可以100%正确识别。随着 $\Delta l$ 的减小、 $C_n^2$ 的增强,分数涡旋光束识别开始出现错误,当 $C_n^2 = 1 \times 10^{-14} \text{ m}^{-2/3}$ 、 $\Delta l = 0.05$ 时,准确率为93.3%;从图6(b)可以看出,在传输距离为1000 m时, $C_n^2 = 1 \times 10^{-14} \text{ m}^{-2/3}$ 、 $\Delta l \geq$

表 2  $\Delta l=0.1$  的光束数据集  
Table 2 Beam dataset of  $\Delta l=0.1$

$\Delta l=0.1$	$C_n^2/m^{-2/3}$	$\Delta z/m$	Sample number	Total number
5.1		500	300	3000
5.2	$1 \times 10^{-16}$	1000	300	3000
5.3		1500	300	3000
5.4		500	300	3000
5.5	$1 \times 10^{-15}$	1000	300	3000
5.6		1500	300	3000
5.7		500	300	3000
5.8	$1 \times 10^{-14}$	1000	300	3000
5.9		1500	300	3000
6.0				

表 3 模态整数部分取值及相应的模态范围  
Table 3 Integer parts of  $l$  and corresponding mode ranges

$l_{\text{integer}}$ (Integer part of $l$ )	1	2	5
Mode range	1. 10–2.00	2. 10–3.00	5. 10–6.00

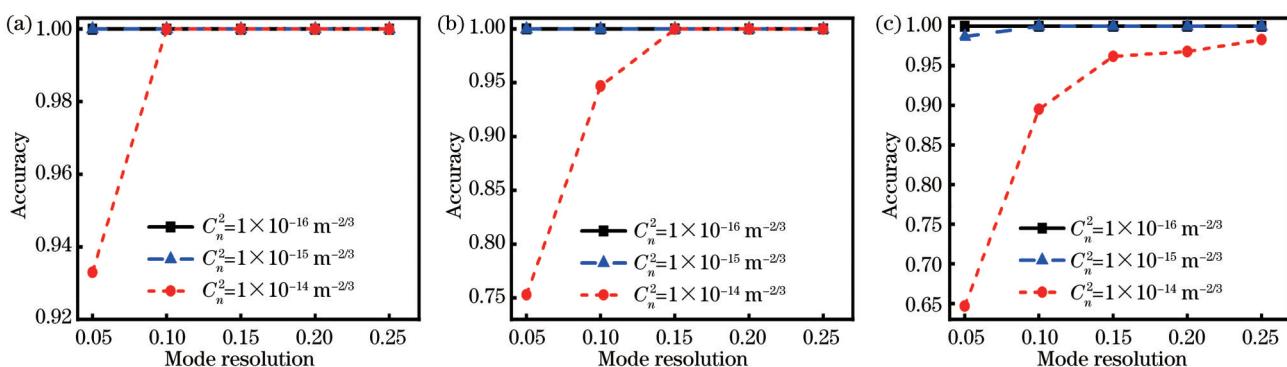


图 6 模态分辨率对模态检测的影响。(a)  $\Delta z=500$  m; (b)  $\Delta z=1000$  m; (c)  $\Delta z=1500$  m  
Fig. 6 Influence of mode resolution on mode detection. (a)  $\Delta z=500$  m; (b)  $\Delta z=1000$  m; (c)  $\Delta z=1500$  m

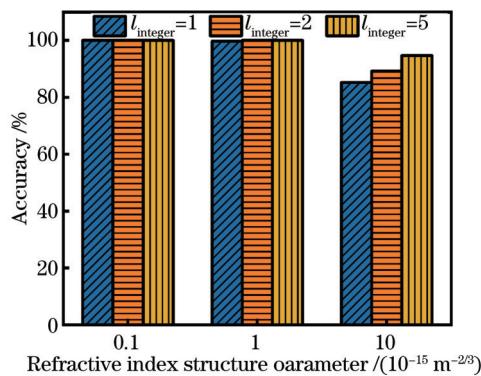


图 7 模态整数部分对模态检测的影响  
Fig. 7 Influence of mode integer part on mode detection

### 3) 迭代次数对模态检测的影响

以传输距离为 1500 m、 $\Delta l=0.15$  的分数涡旋光束为例说明迭代次数对模态检测的影响。 $C_n^2$  分别取  $10^{-16} m^{-2/3}$ 、 $10^{-15} m^{-2/3}$ 、 $10^{-14} m^{-2/3}$ ，epoch 为 50，batch

0.15 时，准确率为 100%，模态分辨率较小的分数涡旋光束受湍流强度影响大， $\Delta l=0.1$  和  $\Delta l=0.05$  的准确率分别为 94.7% 和 75.3%；从图 6(c)可以看出，在传输距离为 1500 m、 $C_n^2=1 \times 10^{-16} m^{-2/3}$  时，网络的识别准确率仍能达到 100%，当湍流强度增加时，图像会遭受更严重的失真，会造成模态分辨率越低，准确率降低越明显。在  $\Delta l=0.05$ 、 $C_n^2=1 \times 10^{-14} m^{-2/3}$  时，准确率为 64.7%。

取传输距离为 1000 m、 $C_n^2$  分别取  $10^{-16} m^{-2/3}$ 、 $10^{-15} m^{-2/3}$ 、 $10^{-14} m^{-2/3}$ 、 $\Delta l=0.1$  的模态整数部分取值分别为 1、2、5 的  $\Delta l=0.1$  的分数涡旋光束进行模态检测。图 7 为模态整数部分对模态检测的影响。结果表明， $C_n^2=10^{-16} m^{-2/3}$  时，模态整数部分取值分别为 1、2、5 的分数涡旋光束的正确识别率都达到了 100%； $C_n^2=10^{-15} m^{-2/3}$  时，只有模态整数部分取值为 1 的分数涡旋光束的正确识别率未达到 100%； $C_n^2=10^{-14} m^{-2/3}$  时，模态整数部分取值为 1 的分数涡旋光束的正确识别率下降到 85.2%，表明模态整数部分取值越小，受强湍流的影响越大，正确识别率下降越明显。

size 为 20。图 8(a)和 8(b)分别给出了准确率和损失率随迭代次数的变化趋势。图 8(a)表明，当  $C_n^2=10^{-14} m^{-2/3}$  时，验证集波动大，达到收敛的迭代次数增加，迭代近 50 次才能稳定。图 8(b)图表明，当  $C_n^2=10^{-16} m^{-2/3}$  时，损失函数在初始时存在波动，这是由于网络参数并未训练完备，未找到最优解，在迭代近 15 次左右损失函数达到收敛，表明输入图像的特征得到了有效的学习和分类。然而当  $C_n^2$  分别取  $10^{-15} m^{-2/3}$ 、 $10^{-14} m^{-2/3}$  时，需要迭代 30 次、40 次左右时，损失值基本趋于稳定并达到最小值。综上所述，随着湍流强度增大，光束受干扰的程度增加，学习时间变长，达到稳定的迭代次数也变大。

### 4) 混淆矩阵

取传输距离为 1500 m、 $C_n^2$  分别取  $10^{-16} m^{-2/3}$ 、 $10^{-15} m^{-2/3}$ 、 $10^{-14} m^{-2/3}$ 、 $\Delta l=0.2$  和  $\Delta l=0.1$  的测试集的分数涡旋光束进行分类识别。图 9 所

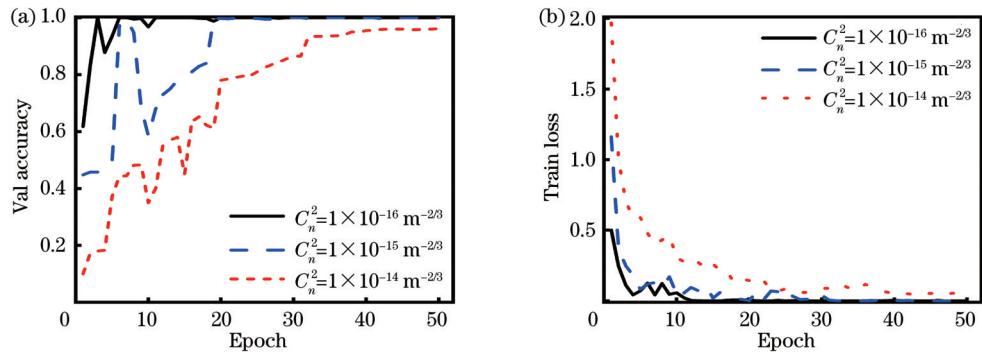


图 8 准确率与损失率随迭代次数的变化。(a) 准确率随迭代次数的变化;(b) 损失率随迭代次数的变化

Fig. 8 Accuracy rate and loss rate varying with number of iterations. (a) Accuracy rate varying with number of iterations; (b) loss rate varying with number of iterations

示为测试集准确率, 图 10 所示为测试集混淆矩阵, 混淆矩阵的横坐标表示输入光束的真实模态, 纵坐标代表通过网络预测模态, 对角线元素表示模态识别正确。测试结果表明, 在  $C_n^2 = 10^{-16} \text{ m}^{-2/3}$  时, 测试准确率都达到了 100%。而在  $C_n^2 = 10^{-14} \text{ m}^{-2/3}$ 、 $\Delta l = 0.2$  时, 测试准确率为 96.83%;  $\Delta l = 0.1$  时, 测试准确率下降到 89.5%。例如拓扑荷数为 5.8 的光束, 容易被误认为 5.7、5.9, 这三种光强图都有微小的径向缺口, 因此容易被错误识别。

##### 5) 网络模型对模态检测的影响

取传输距离为 1500 m、 $C_n^2$  分别取  $10^{-16} \text{ m}^{-2/3}$ 、

$10^{-15} \text{ m}^{-2/3}$ 、 $10^{-14} \text{ m}^{-2/3}$ 、 $\Delta l = 0.1$  的分数涡旋光束, 分别

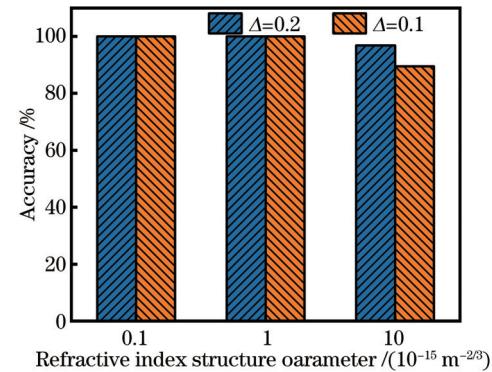


图 9 测试集准确率

Fig. 9 Testing set accuracy

		$C_n^2=1 \times 10^{-16} \text{ m}^{-2/3}$									$C_n^2=1 \times 10^{-15} \text{ m}^{-2/3}$									$C_n^2=1 \times 10^{-14} \text{ m}^{-2/3}$																	
		True OAM mode	5.1	5.2	5.3	5.4	5.5	5.6	5.7	5.8	5.9	6.0	5.1	5.2	5.3	5.4	5.5	5.6	5.7	5.8	5.9	6.0	5.1	5.2	5.3	5.4	5.5	5.6	5.7	5.8	5.9	6.0					
$\Delta l = 0.2$	Predicted OAM mode	5.1	60	0	0	0	0	0	0	0	0	60	0	0	0	0	0	0	0	0	0	0	57	2	0	0	0	0	0	0	0	0					
	5.2	5.3	0	60	0	0	0	0	0	0	0	0	60	0	0	0	0	0	0	0	0	0	3	56	0	0	0	0	0	0	0	0					
	5.3	5.4	0	0	60	0	0	0	0	0	0	0	0	60	0	0	0	0	0	0	0	0	0	2	60	0	0	0	0	0	0	0	0				
	5.4	5.5	0	0	0	60	0	0	0	0	0	0	0	0	60	0	0	0	0	0	0	0	0	0	0	0	60	0	0	0	0						
	5.5	5.6	0	0	0	0	60	0	0	0	0	0	0	0	0	60	0	0	0	0	0	0	0	0	0	0	0	60	0	0	0	0					
	5.6	5.7	0	0	0	0	0	60	0	0	0	0	0	0	0	0	60	0	0	0	0	0	0	0	0	0	0	0	60	0	0	0	0				
	5.7	5.8	0	0	0	0	0	0	60	0	0	0	0	0	0	0	0	60	0	0	0	0	0	0	0	0	0	0	0	60	0	0	0	0			
	5.8	5.9	0	0	0	0	0	0	0	60	0	0	0	0	0	0	0	0	60	0	0	0	0	0	0	0	0	0	0	0	60	0	0	0	0		
	5.9	6.0	0	0	0	0	0	0	0	0	60	0	0	0	0	0	0	0	0	60	0	0	0	0	0	0	0	0	0	0	0	60	0	0	0	0	
$\Delta l = 0.1$	Predicted OAM mode	5.1	60	0	0	0	0	0	0	0	0	0	60	0	0	0	0	0	0	0	0	0	50	7	0	0	0	0	0	0	0	0					
	5.2	5.3	0	60	0	0	0	0	0	0	0	0	60	0	0	0	0	0	0	0	0	0	10	49	2	0	0	0	0	0	0	0					
	5.3	5.4	0	0	60	0	0	0	0	0	0	0	0	60	1	0	0	0	0	0	0	0	0	4	55	2	0	0	0	0	0	0	0				
	5.4	5.5	0	0	0	60	0	0	0	0	0	0	0	0	60	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0				
	5.5	5.6	0	0	0	0	60	0	0	0	0	0	0	0	0	60	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0			
	5.6	5.7	0	0	0	0	0	60	0	0	0	0	0	0	0	0	60	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0		
	5.7	5.8	0	0	0	0	0	0	60	0	0	0	0	0	0	0	0	60	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	
	5.8	5.9	0	0	0	0	0	0	0	60	0	0	0	0	0	0	0	0	60	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
	5.9	6.0	0	0	0	0	0	0	0	0	60	0	0	0	0	0	0	0	0	60	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0

图 10 测试集混淆矩阵

Fig. 10 Testing set confusion matrix

采用ResNet50和I-ResNet网络进行模态识别,结果如表4所示。当 $C_n^2 = 10^{-16} \text{ m}^{-2/3}$ 时,两种网络正确识别率都达到了100%;在 $C_n^2 = 10^{-15} \text{ m}^{-2/3}$ 时,I-ResNet网络相对于ResNet50网络正确识别率提高0.2个百分点;在 $C_n^2 = 10^{-14} \text{ m}^{-2/3}$ 时,正确识别率提高了6.1个百分点。表明I-ResNet网络相较于ResNet50网络识别准确率有所提高,尤其在抗强湍流强度下表现能力较强。

表4 ResNet50和I-ResNet网络模态识别结果比较

Table 4 Comparison of mode recognition results of ResNet50 and I-ResNet networks

$C_n^2$	$1 \times 10^{-16} \text{ m}^{-2/3}$	$1 \times 10^{-15} \text{ m}^{-2/3}$	$1 \times 10^{-14} \text{ m}^{-2/3}$
ResNet50	100%	99.8%	83.4%
I-ResNet	100%	100%	89.5%

## 4 结 论

本文构建了I-ResNet网络,在ResNet50网络的基础上,在网络最后一个残差块和平均池化之间增加反卷积层和最大池化,并改进残差块结构顺序,成功将ImageNet图像数据集上的预训练模型迁移应用到分数涡旋光束模态识别任务中。实验结果证明,I-ResNet网络的识别准确率提高,尤其是在强湍流条件下,识别准确率提高更为显著。在 $C_n^2 = 10^{-14} \text{ m}^{-2/3}$ 、传输距离为500 m、 $\Delta l \geq 0.1$ 和 $\Delta l = 0.05$ 时,准确率分别达到了100%和93.3%。随传输距离的增加,模态分辨率较小的分数涡旋光束识别准确率下降得越快,在传输距离为1500 m、 $\Delta l = 0.05$ 时,准确率仅有64.7%。因此,这些结果对自由空间光通信编码设计方案具有重要指导意义。

与现有算法相比,本文搭建的I-ResNet网络识别准确率得到提高,但是当分数涡旋光束在强湍流、长距离、模态分辨率小的条件下,识别准确率仍较低,今后可以进一步改进网络结构,以提高识别准确率。

## 参 考 文 献

- [1] Erhard M, Fickler R, Krenn M, et al. Twisted photons: new quantum perspectives in high dimensions[J]. Light: Science & Applications, 2018, 7(3): 17146.
- [2] Tamburini F, Anzolin G, Umbriaco G, et al. Overcoming the Rayleigh criterion limit with optical vortices[J]. Physical Review Letters, 2006, 97(16): 163903.
- [3] Zhou Z Y, Ding D S, Jiang Y K, et al. Orbital angular momentum light frequency conversion and interference with quasi-phase matching crystals[J]. Optics Express, 2014, 22(17): 20298-20310.
- [4] Willner A E, Zhao Z, Liu C, et al. Perspectives on advances in high-capacity, free-space communications using multiplexing of orbital-angular-momentum beams[J]. APL Photonics, 2021, 6(3): 030901.
- [5] Wang J, Liu J, Li S H, et al. Orbital angular momentum and beyond in free-space optical communications[J]. Nanophotonics, 2022, 11(4): 645-680.
- [6] 刘娟, 杜乾, 刘芳宁, 等. 基于深度相位估计网络的涡旋光束相位校正[J]. 光学学报, 2023, 43(6): 0601013.
- [7] 叶玉儿, 李军依, 曹萌, 等. 双模式涡旋光束的轨道角动量的精确识别[J]. 激光与光电子学进展, 2021, 58(18): 1811021.
- [8] Ye Y E, Li J Y, Cao M, et al. Accuracy recognition of orbital angular momentum of dual-mode vortex beams[J]. Laser & Optoelectronics Progress, 2021, 58(18): 1811021.
- [9] 李岩松, 陈君, 傅钢坤, 等. 障碍物遮挡下漂移涡旋光束拓扑荷数的测量[J]. 光学学报, 2023, 43(2): 0226002.
- [10] Li Y S, Chen J, Fu G K, et al. Measurement of topological charge of obstructed wandering vortex beams[J]. Acta Optica Sinica, 2023, 43(2): 0226002.
- [11] 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.
- [12] Bai Y H, Lü H R, Fu X, et al. Vortex beam: generation and detection of orbital angular momentum[J]. Chinese Optics Letters, 2022, 20(1): 012601.
- [13] Li P Y, Wang B, Song X B, et al. Non-destructive identification of twisted light[J]. Optics Letters, 2016, 41(7): 1574-1577.
- [14] Zhu J, Zhang P, Fu D Z, et al. Probing the fractional topological charge of a vortex light beam by using dynamic angular double slits[J]. Photonics Research, 2016, 4(5): 187-190.
- [15] Berkhouit G C G, Lavery M P J, Courtial J, et al. Efficient sorting of orbital angular momentum states of light[J]. Physical Review Letters, 2010, 105(15): 153601.
- [16] Berger B, Kahlert M, Schmidt D, et al. Spectroscopy of fractional orbital angular momentum states[J]. Optics Express, 2018, 26(24): 32248-32258.
- [17] Alperin S N, Niederriter R D, Gopinath J T, et al. Quantitative measurement of the orbital angular momentum of light with a single, stationary lens[J]. Optics Letters, 2016, 41(21): 5019-5022.
- [18] Deng D, Lin M C, Li Y, et al. Precision measurement of fractional orbital angular momentum[J]. Physical Review Applied, 2019, 12(1): 014048.
- [19] Zhang H, Zeng J, Lu X Y, et al. Review on fractional vortex beam[J]. Nanophotonics, 2022, 11(2): 241-273.
- [20] Na Y B, Ko D K. Deep-learning-based high-resolution recognition of fractional-spatial-mode-encoded data for free-space optical communications[J]. Scientific Reports, 2021, 11: 2678.
- [21] 杜浩波, 陈君, 傅钢坤, 等. 基于卷积神经网络和多孔干涉仪的分数完美涡旋光束轨道角动量的识别[J]. 光学学报, 2023, 43(4): 0426001.
- [22] Du H B, Chen J, Fu G K, et al. Recognition of orbital angular momentum of fractional perfect optical vortex beam based on convolutional neural network and multiaperture interferometer [J]. Acta Optica Sinica, 2023, 43(4): 0426001.
- [23] Zhou H P, Pan Z Z, Dedo M I, et al. High-efficiency and high-precision identification of transmitting orbital angular momentum modes in atmospheric turbulence based on an improved convolutional neural network[J]. Journal of Optics, 2021, 23(6): 065701.
- [24] 刘雪莲, 陈旭东, 林志立, 等. 深度学习辅助测量强散射涡旋光束拓扑荷数[J]. 光学学报, 2022, 42(14): 1426001.
- [25] Liu X L, Chen X D, Lin Z L, et al. Deep learning aided measurement of topological charge number of strongly scattered vortex beams[J]. Acta Optica Sinica, 2022, 42(14): 1426001.
- [26] Li Z X, Li X, Jia H J, et al. High-efficiency anti-interference OAM-FSO communication system based on Phase compression and improved CNN[J]. Optics Communications, 2023, 537: 129120.
- [27] Hao Y, Zhao L, Huang T, et al. High-accuracy recognition of orbital angular momentum modes propagated in atmospheric

- turbulences based on deep learning[J]. IEEE Access, 2020, 8: 159542-159551.
- [24] Liu J M, Wang P P, Zhang X K, et al. Deep learning based atmospheric turbulence compensation for orbital angular momentum beam distortion and communication[J]. Optics Express, 2019, 27(12): 16671-16688.
- [25] 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.
- [26] Na Y B, Ko D K. Adaptive demodulation by deep-learning-based identification of fractional orbital angular momentum modes with structural distortion due to atmospheric turbulence [J]. Scientific Reports, 2021, 11: 23505.
- [27] Cao M, Yin Y L, Zhou J W, et al. Machine learning based accurate recognition of fractional optical vortex modes in atmospheric environment[J]. Applied Physics Letters, 2021, 119(14): 141103.
- [28] Zhou J W, Yin Y L, Tang J H, et al. Recognition of high-resolution optical vortex modes with deep residual learning[J]. Physical Review A, 2022, 106(1): 013519.
- [29] Berry M V. Optical vortices evolving from helicoidal integer and fractional phase steps[J]. Journal of Optics A: Pure and Applied Optics, 2004, 6(2): 259-268.
- [30] Lochab P, Senthilkumaran P, Khare K. Propagation of converging polarization singular beams through atmospheric turbulence[J]. Applied Optics, 2019, 58(23): 6335-6345.
- [31] Hill R J. Models of the scalar spectrum for turbulent advection [J]. Journal of Fluid Mechanics, 1978, 88(3): 541-562.
- [32] Andrews L C, Phillips R L. Laser Beam Propagation through Random Media[M]. Bellingham: SPIE Press, 2005.
- [33] 骆传凯, 卢芳, 苗志芳, 等. 径向阵列涡旋光束在大气中的传输与扩展[J]. 光学学报, 2019, 39(6): 0601004.
- [34] Luo C K, Lu F, Miao Z F, et al. Propagation and spreading of radial vortex beam array in atmosphere[J]. Acta Optica Sinica, 2019, 39(6): 0601004.
- [35] He K M, Zhang X Y, Ren S Q, et al. Deep residual learning for image recognition[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), June 27-30, 2016, Las Vegas, NV, USA. New York: IEEE Press, 2016: 770-778.
- 郑远攀, 李广阳, 李晔. 深度学习在图像识别中的应用研究综述[J]. 计算机工程与应用, 2019, 55(12): 20-36.
- Zheng Y P, Li G Y, Li Y. Survey of application of deep learning in image recognition[J]. Computer Engineering and Applications, 2019, 55(12): 20-36.

## Fractional Vortex Beam Modes Recognition Based on I-ResNet Network

Wei Dongmei, Du Qian, Liu Fangning, Wang Ke, Zhao Yuefeng<sup>\*</sup>

*Shandong Provincial Engineering and Technical Center of Light Manipulations, School of Physics and Electronics, Shandong Normal University, Jinan 250358, Shandong, China*

### Abstract

**Objective** Vortex beams with orbital angular momentum, helical phase wave front, and dark void intensity distribution have caught extensive attention since their discovery, and boast important application prospects in quantum entanglement, optical imaging, nonlinear optics, optical communication, and other fields. Meanwhile, their helical phase wave front can be described as  $\exp(il\theta)$ , where  $\theta$  is the azimuth and  $l$  is the topological charge, with any rational number taken theoretically. However, the beam radius depends on the topological charge and its central dark spot will increase with the rising  $l$  value, which makes the applications of the vortex beams with large  $l$  value in transmission and coupling difficult. Under the maximum  $l$  limit, reducing the interval between adjacent topological loads can increase the mode types and improve the communication capacity. For example, the mode resolution  $\Delta l$  of orbital angular momentum (OAM) is changed from 1 to 0.1, the available modes are expanded by ten times, and the communication rate can be greatly improved. In recent years, the OAM research has gradually extended to the fractional field. The generation of fractional OAM beams and the accurate mode measurement are of significance for high-quality information transmission. Therefore, we construct an improved residual network to identify the modes of fractional vortex beams with different turbulence intensities and transmission distances. To this end, the convolutional neural network is adopted to improve the mode detection accuracy and communication reliability.

**Methods** We construct a new convolutional neural network I-ResNet to identify the modes of fractional vortex beams transmitted by different distances under different turbulence intensities. I-ResNet network based on the ResNet50 network adds a deconvolution layer and maximum pooling between the last residual block and Ave Pool, deepens the number of network layers to 51 layers, and improves the operation sequence of the residual block to BN normalization, ReLU activation function, Conv, dropout layer, and until the next BN. The pre-trained model migration on the ImageNet image dataset is applied to the mode recognition task of fractional vortex beams. Compared with the existing references, our study numerically simulates the fractional vortex beam datasets of five types of mode resolutions and corresponding ten OAM modes under three turbulence intensities and three transmission distances. The number of light intensity images is greatly increased to provide sufficient sample number for I-ResNet to improve the network robustness. By learning and training a large number of samples, the built network structure can accurately identify the beam modes. Additionally, two

sets of fractional vortex beams with different mode resolutions are set up to test the network, which proves that the network has strong generalization ability. Then, by comparing the training results of different network models, it is further verified that the built network can improve the recognition accuracy.

**Results and Discussions** The simulation results show that the constructed network can identify the beam modes accurately with sound generalization. At a transmission distance of 500 m and  $\Delta l \geq 0.1$ , the three turbulence intensities can be identified 100% correctly [Fig. 6(a)]. When the transmission distance is 1000 m, the recognition accuracy can reach 100% with  $C_n^2 = 10^{-14} \text{m}^{-2/3}$  and  $\Delta l \geq 0.15$ , the fractional vortex beams with small mode resolution are greatly affected by the turbulence intensity, and the accuracy of  $\Delta l = 0.1$  is 94.7% [Fig. 6(b)]. Under the transmission distance of 1500 m, with the increasing turbulence intensity, the beam interference degree grows, which causes longer learning time, and increasing iteration number in which the accuracy and loss rate reach stability (Fig. 8). The I-ResNet network has better performance against strong turbulence than ResNet50, and the correct recognition rate is improved by 6.1 percentage points (Table 4). Under the same transmission distance, the smaller value of the mode integer part results in greater influence exerted by strong turbulence and a more obvious decline in recognition accuracy (Fig. 7). The network is proven to have strong generalization ability by the test set confusion matrix (Fig. 10).

**Conclusions** We construct I-ResNet, improve the network structure and operation order of residual blocks based on the ResNet50 network and apply the pre-trained model on the ImageNet image dataset to the mode recognition task of fractional vortex beams. The simulation results show that the recognition accuracy of I-ResNet is improved, especially under strong turbulence, and the recognition accuracy is more significant. Under the transmission distance of 1500 m, the accuracy can reach 100% with  $C_n^2 = 10^{-16} \text{m}^{-2/3}$  and  $\Delta l \geq 0.05$ . The recognition accuracy can reach 96.5% with  $C_n^2 = 10^{-14} \text{m}^{-2/3}$  and  $\Delta l = 0.15$ . With the increasing turbulence intensity or transmission distance, the recognition accuracy decreases. Therefore, the results have a certain guiding significance for designing free-space optical communication systems.

**Key words** fractional vortex beam; mode resolution; improved residual network; atmospheric turbulence