# 分数阶涡旋光衍射过程的机器学习识别\*

郭焱 吕恒 丁春玲 袁晨智 金锐博

(武汉工程大学,光学信息与模式识别湖北省重点实验室,武汉 430205)(2024年10月18日收到;2024年11月8日收到修改稿)

分数阶涡旋光束具有分数轨道角动量 (fractional orbital angular momentum, FOAM) 模式, 理论上可以 无限增加传输容量,因此在光通信领域具有巨大的应用前景.然而,分数阶涡旋光束在自由空间传播时,螺旋 相位的不连续性使其在实际应用中容易受到衍射的影响,进而影响 FOAM 阶次识别的准确度,严重制约基 于 FOAM 的实际应用.如何实现有衍射条件下的分数阶涡旋光的机器学习识别,目前仍是一个亟需解决且 少见诸报道的问题.本文提出一种基于残差网络 (residual network, ResNet)的深度学习 (deep learning, DL) 方法,用于精确识别分数阶涡旋光衍射过程的传播距离和拓扑荷值.实验结果表明,该方法可以在湍流条件 下识别传播距离为 100 cm,间隔为 5 cm,模式间隔为 0.1 的 FOAM 模式,准确率为 99.69%.该技术有助于推 动 FOAM 模式在测距、光通信、微粒子操作等领域的实际应用.

关键词:分数阶涡旋光束,机器学习,大气湍流,残差网络 PACS: 42.50.Tx, 42.25.Fx, 07.05.Mh CSTR: 32037.14.aps.74.20241458

DOI: 10.7498/aps.74.20241458

## 1 引 言

光学涡旋是一种具有螺旋型波前结构和确 定光子轨道角动量 (orbital angular momentum, OAM) 的特殊光场<sup>[1-5]</sup>. 20 世纪 70 年代科学家就 提出了光学涡旋的概念,并对涡旋光场的环形光强 分布特征和光轴处存在的相位奇异性进行了大量 研究<sup>[6,7]</sup>. 然而直到 1992 年, Allen 等<sup>[8]</sup> 才从理论上 阐明了携带轨道角动量涡旋光场的物理图像,即具 有螺旋相位波前且涡旋中心光强为零的光束. 涡旋 光束携带 exp(iℓθ) 的相位因子,其中每个光子都 携带ℓħ轨道角动量,θ为空间方位角,ℓ为拓扑荷 数 (topological charges, TC),因此涡旋光束也被 称为轨道角动量光束<sup>[9]</sup>. 与自旋角动量不同,轨道 角动量可以取任意数,因此利用光子的轨道角动量

可以构建高维希尔伯特空间.这种特性使得它可以 成为高维经典信息和量子信息的理想载体[10]. 当 轨道角动量取分数时,光束成为分数阶涡旋光束, 具有分数轨道角动量 (fractional orbital angular momentum, FOAM). FOAM 具有独特的物理性 质,如任意的径向缺口、丰富的相位结构和更高的 调制维度[11]. 这些物理性质使得分数阶涡旋光具 有更多的调控参数,从而可以承载更多的信息,具 有更强的编码能力和参数控制能力,因此,分数阶 涡旋光已被广泛应用于光学微粒操作[12]、光信息 传输<sup>[13,14]</sup>、光学成像<sup>[15]</sup>等领域.在分数阶涡旋光束 的应用中,对其OAM 阶次进行识别是一项核心的 任务. 传统的识别方法包括 Mach-Zehnder 干涉 法[16,17]、模式互转换法[18,19] 和机器学习法[20-24] 等. 其中,机器学习法具有独特的优势,可以在学习过 程中将各种外部因素考虑在内,并自动进行模式识

\* 国家自然科学基金 (批准号: 92365106, 12074299) 和湖北省自然科学基金杰出青年项目 (批准号: 2022CFA039) 资助的课题.

<sup>†</sup> 通信作者. E-mail: jrbqyj@foxmail.com

<sup>© 2025</sup> 中国物理学会 Chinese Physical Society

别,这对于一些复杂物理现象的研究非常有帮助<sup>[25,26]</sup>. 但是,上述研究主要处理的是普通分数阶涡旋光的 识别,并未涉及衍射的影响.实际上,衍射对涡旋 光束的传播影响十分明显,特别是对于分数阶涡旋 光束,螺旋相位的不连续性使其在实际应用中更容 易在长距离传输、存在大气湍流等条件下发生强衍 射,进而影响 OAM 阶次识别的准确度<sup>[23,27]</sup>.如何 实现有衍射条件下的分数阶涡旋机器学习识别,目 前仍是一个亟需解决但少见诸报道的问题.

本文针对含衍射分数阶涡旋光,从分数阶拓扑 荷数ℓ和传播距离 z 这两个自由度来识别 OAM 模 式.在大气湍流 (atmospheric turbulence, AT) 环境 下,采用基于残差网络 (residual network, ResNet) 的 101 层结构 (包括 100 个卷积层和一个全连接 层)对失真分数阶 OAM 模式进行检测.实验结果 表明,该方法可以准确识别传播距离为 100 cm,间 隔为 5 cm,模式间隔为 0.1 的 FOAM 模式,准确 率达到 99.69%.此外,该方法还具备良好的泛化能 力,在复杂传输环境下仍能有效抵抗干扰,为 FOAM 光束在多维编码和传感测量中的应用提供 了新的思路.

## 2 衍射条件下分数阶涡旋光束的生成

本节首先介绍涡旋光产生的理论, 然后介绍产 生涡旋光的实验.

## 2.1 产生分数阶涡旋光束的理论

把一束高斯光 exp  $\left(-r^2/\omega_0^2\right)$  打在空间光调制器 (spatial light modulator, SLM) 上, 并在 SLM 上 加载相位掩模 exp $\left(-i\ell\theta\right)$ ,则光束在 SLM 平面上的 光场可表示为<sup>[28]</sup>

$$E_1(r,\theta) = \exp\left(-\frac{r^2}{\omega_0^2}\right) \exp(-i\ell\theta), \qquad (1)$$

其中拓扑荷数*ℓ*是一个分数值, ω<sub>0</sub> 为高斯束腰, r和θ分别为径向坐标和方位角坐标. 对于 (1)式 表示的分数阶高斯涡旋光束, 我们通常将分数阶涡 旋相位项分解为整数阶涡旋相位项的基:

$$\exp\left(-\mathrm{i}\ell\theta\right) = \frac{1}{\pi} \exp\left(\mathrm{i}\pi\ell\right) \sin(\pi\ell) \sum_{n=-\infty}^{+\infty} \frac{\exp(\mathrm{i}\theta n)}{\ell - n}.$$
 (2)

在傍轴近似的框架下,利用 Collins 积分方程可以 计算 *E*<sub>1</sub>(*r*, *θ*) 在传播后的场分布<sup>[29]</sup>:

$$E_{2}(r_{1},\theta_{1},z) = \frac{\mathrm{i}}{\lambda B} \exp\left(-\mathrm{i}kz\right) \int_{0}^{2\pi} \int_{0}^{\infty} E_{1}(r,\theta)$$
$$\times \exp\left\{-\frac{\mathrm{i}k}{2B} \left[Ar^{2} - 2rr_{1}\cos\left(\theta_{1} - \theta\right) + Dr_{1}^{2}\right]\right\} r \mathrm{d}r \mathrm{d}\theta,$$
(3)

其中 $r_1$ 和 $\theta_1$ 是输出平面的径向坐标和方位角坐标, z为传播距离,  $k = 2\pi/\lambda$ 为波数,  $\lambda$ 为波长. 光在距 离 z的自由空间中传播的 *ABCD* 传递矩阵为

$$\begin{pmatrix} A & B \\ C & D \end{pmatrix} = \begin{pmatrix} 1 & z \\ 0 & 1 \end{pmatrix}.$$
 (4)

将 (1) 式和 (2) 式代入 (3) 式中, 可以得到光束振幅: *E*<sub>2</sub>(*r*<sub>1</sub>, *θ*<sub>1</sub>, *z*)

$$= \frac{1}{\lambda z} \exp\left(-ikz\right) \exp\left(-\frac{ikr_1^2}{2z}\right) \exp\left(i\pi\ell\right) \sin(\pi\ell)$$
$$\times \sum_{n=-\infty}^{+\infty} \frac{i^{n+1} \exp(in\theta_1)}{\ell - n} \frac{b_1^n}{\varepsilon_1^{1+\frac{n}{2}}} \frac{\Gamma(n/2+1)}{\Gamma(n+1)}$$
$$\times_1 F_1\left(\frac{n+2}{2}, n+1, -\frac{b_1^2}{\varepsilon_1}\right). \tag{5}$$

方程 (5) 表示超几何高斯模式,  $_1F_1(\alpha, \beta, z)$  是一个 合流超几何函数,  $\Gamma(n)$  是 Gamma 函数,  $b_1 \pi \varepsilon_1$ 定义为

$$b_1 = \frac{nr_1}{2z}, \quad \varepsilon_1 = \frac{1}{\omega_0^2} + \frac{\mathrm{i}n}{2z}.$$
 (6)

基于上述计算,可以得到在传播不同距离 z 后,不同 化值的涡旋光束的横向强度分布.

在实际通信中,由于大气湍流的存在,涡旋光 束的螺旋相位结构容易受到扭曲,从而导致模式分 散和强度分布的畸变.因此,本实验利用带有 von Karman 湍流谱的 Kolmogorov 模型来模拟空间光 调制器中受大气湍流影响的情况,从而实现了一种 具有失真特性的通信模式<sup>[30,31]</sup>,其失真程度可以通 过 Fried 参数进行量化.在 SLM 上添加的湍流相 位掩模的表达式为<sup>[32,33]</sup>

$$\Phi(x,y) = \mathbb{R}\left\{\mathcal{F}^{-1}\left(\mathbb{M}_{NN}\sqrt{\phi_{NN}(\kappa)}\right)\right\},\qquad(7)$$

其中 $\phi_{NN}(\kappa) = 0.023 r_0^{-5/3} (\kappa^2 + \kappa_0^2)^{-11/6} e^{-\kappa^2/\kappa_m^2}$ 和 Fried 参数 $r_0 = (0.423 k^2 C_n^2 z)^{-3/5}$ . ℝ表示复数域的 实部,  $\mathcal{F}^{-1}$ 表示傅里叶逆变换运算. 另外,  $\kappa$ ,  $\kappa_0$ 和 M<sub>NN</sub>分别表示空间频率、中心空间频率和编码随 机矩阵.  $C_n^2$ 是大气折射率结构常数, 其数值大小 用来表示湍流强度.

在 SLM 上同时添加分数阶涡旋相位和湍流相

位掩模后, 光束在 SLM 平面上的振幅变为

$$E_1'(r,\theta) = E_1(r,\theta) \exp(i\Phi(x,y)).$$
(8)

通过将 (8) 式代入 (5) 式, 可以得到经湍流畸变后 的光场分布 *E*<sub>2</sub>(*r*<sub>1</sub>, *θ*<sub>1</sub>, *z*).

根据 (8) 式,可以对涡旋光束进行模拟,得到 不同 *t* 值和 *z* 值条件下的涡旋光分布.图 2 展示了 无湍流和有湍流条件下的涡旋光束空间分布.

## 2.2 产生分数阶涡旋光束的实验

制备衍射条件下分数阶涡旋光的实验装置见 图 1. 首先,将波长为 632.8 nm 的 He-Ne 激光束通 过半波片 (HWP) 和四分之一波片 (QWP) 调节偏 振, 然后, 将其耦合到单模光纤中, 使其空间模式 变为纯净的高斯分布. 接着, 使用放大率为 10×、 有效焦距为 17 mm 的物镜来实现光束准直, 准直 后的束腰约为 2 mm. 把准直后的高斯光束打在 SLM上, 转换为涡旋光束. 其中, SLM上加载了计 算机生成的相位全息图, 为了模拟大气传输过程中 的湍流, 可以在全息图中增加一个湍流相位. 最后, 利用 CCD 相机采集涡旋光束的强度图像并发送到 计算机进行训练. 移动 CCD 的位置来控制传播距 离. 其中  $\ell$  的取值范围为 1.0—9.9,  $\Delta \ell = 0.1$ , 传 播距离 z的范围为 50—100 cm, 步长为 5 cm, 湍 流强度系数  $C_n^2$  为 5 × 10<sup>-10</sup> mm<sup>-2/3</sup>.



图 1 实验装置图 Fig. 1. Diagram of experimental setup.



图 2 不同拓扑荷数 ℓ和不同传播距离 z的涡旋光束空间分布 (a) 无湍流影响的无畸变模态的空间分布; (b) 大气湍流影响的 畸变模态的空间分布. 第一行和第三行是实验获得的图像, 第二行和第四行是理论模拟的图像

Fig. 2. Spatial profiles of vortex beams with different topological charges  $\ell$  and different propagation distances z (a) Spatial distribution of distortionless modes without turbulence; (b) the spatial distribution of distortion modes affected by atmospheric turbulence. The first and third rows are the images acquired from the experiment, and the second and fourth rows represent the theoretically simulate.

分数阶涡旋光不仅在相位上呈现出奇异性, 而 且在径向方向发生了错位. 该错位现象将导致衍射 图案的中心对称性遭到破坏, 从而产生一系列影 响. 不同拓扑荷数ℓ和不同传播距离 z 的情况下的 空间分布如图 2 所示, 其中图 2(a) 为无湍流的无 畸变模态的空间分布, 图 2(b) 为受大气湍流影响 下畸变模态的空间分布. 第一行和第三行是实验获 得的图像, 第二行和第四行是理论模拟的图像. 通 过对比实验结果和理论模拟, 发现它们之间的空间 轮廓十分相似, 从而验证了我们的理论模型的正确 性. 从图 2 可以看到, 中心孔径和衍射孔径的大小 均随涡旋光束拓扑荷数和传播距离的增大而增大. 当拓扑荷数接近半整数时, 径向间隙更明显, 径向 间隙两侧的光强明显大于其他位置.

3 分数阶涡旋光束的识别

#### 3.1 深度学习算法设计

本文采用 ResNet 迁移学习方法, 网络结构如 图 3 所示. 首先利用之前的网络模型参数作为涡旋 光图像训练网络模型的初始化值. ResNet-101 以 一个普通的卷积层开始, 该层负责对输入图像进行 特征提取,通常使用 3×3 的卷积核. 在卷积层后 面,每个卷积操作结果都会经过批量归一化(batch normalization, BN) 层实现在每个小批量 (minibatch) 数据上进行归一化处理. 随后针对分数阶涡 旋光图像识别的特点,采用线性整流函数 (rectified linear unit, ReLU)作为激活函数,引入非线 性变换, 增加模型的表达能力, 加快网络的训练和 收敛速度,抑制过拟合并提高模型的鲁棒性. ReLU 函数具有计算简单、无梯度饱和的优点,且 具有单边抑制的特点,能更好地提取图像特征.该 模型通过5个残差模块实现更深层的训练,提取更 高层次的特征.每个残差块由多个卷积层、批量归 一化层和激活函数层组成,使用跳跃连接(skip connection)和残差学习,残差块能够解决深度网 络中的梯度消失和梯度爆炸问题,从而使得网络更 易于训练和优化.在最后一个残差块之后,本模型 增加全局最大池化层,将特征图压缩为一个向量, 减少参数,提高计算速度,在此之后,加入一个全 连接网络,该网络由两个全连接层组成,在每个全 连接层之前加入一个随机丢弃 (dropout) 层, 随机 删除一些参数以最小化过拟合,并将预训练网络 的最后一层完全连接. 最后将该层的输出设定为本



图 3 深度学习算法.深度学习网络由未改变的 ResNet-101 底层和重新设计的顶层组成

Fig. 3. The deep learning algorithm. The deep learning network consists of the unaltered ResNet-101 bottom layer and our redesigned top layer.

文分数阶涡旋光图像数据集的分类数 99,并通 过对训练集进行识别,得到训练精度.在整个算法 中使用了迁移学习技术 (transfer learning toolkit, TLT)<sup>[34]</sup>, 它利用预训练的模型,使得我们可以仅通 过少量的数据集即可实现准确的识别结果,效率非 常高<sup>[22,35]</sup>.

针对迁移学习中多类别分类的目标任务特点, 选择分类交叉熵损失函数<sup>[36]</sup>来评估每个轮次 (epoch) 的训练结果:

Loss = 
$$-\sum_{i=1}^{n} (\hat{y}_{i1} \ln y_{i1} + \hat{y}_{i2} \ln y_{i2} + \cdots + \hat{y}_{im} \ln y_{im}),$$
 (9)

其中 n 为样本数, m 为分类数, ŷ<sub>im</sub> 表示真标签 (值为 0 或 1), y<sub>im</sub> 为神经网络给出的第 m 类的预 测值. 在训练过程中, 采用自适应矩估计 (adaptive moment estimation, Adam) 优化器<sup>[37]</sup> 更新权重和 偏差参数, 使损失函数最小化. 分类交叉熵损失函数 能够充分利用标签信息, 对每个类别的预测概率进 行建模, 最大化正确类别的预测概率,并对于错误分 类的样本会给予较大的惩罚, 从而促使模型更加关 注难以分类的样本. 交叉熵损失函数具有很强的泛 化能力, 即使在未知数据集上, 也能够很好地预测. 此 外, 它还有良好的凸优化性, 即当模型预测的概率 值接近真实标签值时, 损失函数的值会越来越小, 而当模型预测的概率值远离真实标签值时, 损失函 数的值会越来越大, 从而有助于模型训练的收敛.

## 3.2 基于深度学习算法的分数阶涡旋光束 识别

在构建了机器学习模型之后,下面把2.2节中得到的实验光强分布图和理论模拟光强分布图 进行训练,其中实验光强分布图和理论模拟光强分布图 进行训练,其中实验光强分布图和理论模拟光强分 布图按7:3构成整个数据集,训练集样本数量为 7920,验证集数量为1980,测试集样本数量为990, 每张图像的分辨率为480像素×360像素.本次 实验的硬件平台为一台配备Intel(R) Core (TM) i5-7300 HQ @2.5 GHz处理器和一块 Nvidia GeForce GTX 1050 Ti GPU (显存4 GB)的计算机, 编译环境为 Python 3.9,深度学习平台为 Tensor-Flow 1. 初始学习率 (learning rate) 设置为0.001, 权重参数 (weight)使用 Adam 优化器, 批量大小 (batch size)为16, epoch 数为100.在迭代训练和 验证过程中的准确度结果如图 4 所示,其中淡蓝色 实细线、橙色实粗线和黑色点虚线分别表示训练集 的准确率、平滑处理后的训练集准确率和验证集准 确率.从图 4 可以看到,在大约 10 个 epoch 的时 间内,有一个快速上升的趋势,准确度值明显增加. 经过 40 个 epoch 后,准确度曲线趋于稳定,100 个 epoch 之后,在识别具有不同 *t* 值和不同 *z* 值的涡旋 光束时,准确率高达 99.69%.结果表明该模型具有 较强的预测性能.由于训练过程中湍流相位更新的 变化,图中的准确率曲线呈现出非光滑性.



图 4 训练后的深度学习算法的准确率 Fig. 4. Accuracy of our trained deep learning algorithm.

使用训练好的模型对测试集中的图片进行识 别,得到的混淆矩阵如图5所示,纵坐标表示输入 的角动量拓扑荷数和距离,横坐标表示机器学习识 别的角动量拓扑荷数和距离. 当识别出的轨道角动 量拓扑荷数和距离等于光强分布图的真实轨道角 动量拓扑荷数和距离时,该值将落在对角线上的相 应位置上. 若除对角线外, 矩阵元素中出现大于 0 的值,则表示对这些图像的轨道角动量拓扑荷数识 别存在偏差. 图 5(a) 为 $\ell = 3.5$  时预测传播距离与 真实传播距离之间的归一化混淆矩阵. 图 5(b) 显示了z = 75 cm 时 $\ell$ 预测值与 $\ell$ 真实值之间的归 一化混淆矩阵. 可以看到, 几乎所有测试的 OAM 模式都被正确识别,只有一个错误的预测位于相邻 的 OAM 状态, 这表明在本实验中也可以清楚地识 别出微小的差异.并且该方法具有良好的泛化能力 和鲁棒性.

## 4 讨 论

本工作只是对湍流环境中不同传播距离下 FOAM模式识别的初步探索.模拟的湍流属于弱



图 5 训练后的深度学习算法的混淆矩阵 (a)  $\ell = 3.5$  时, 预测传播距离与真实传播距离之间的归一化混淆矩阵; (b) z = 75 cm 时  $\ell$ 的预测值和  $\ell$  的真实值之间的归一化混淆矩阵

Fig. 5. The confusion matrix of our trained deep learning algorithm: (a) The normalized confusion matrix between the predicted propagation distance and the true propagation distance for  $\ell = 3.5$ ; (b) normalized confusion matrix between predicted  $\ell$  values and true  $\ell$  values for z = 75 cm.

湍流范围, 在强湍流中准确识别 FOAM 模态与传 输距离还需进一步探索. 可以考虑通过湍流补偿或 图像重构等方法改善湍流的影响.

本文距离测量范围是 50—100 cm, 距离比较 短, 这个距离下大气湍流效应对光束传播影响有 限, 和实际通信情况差异较大, 但是本文的实验结 果证明了我们方法的可行性. 在后续的工作中我们 会深入研究远距离情况下分数阶涡旋光衍射过程 的机器学习识别问题.

面向未来,本工作有望在多种场景中获得应 用.首先,在测距方面,分数阶涡旋光束的衍射特 征可用于测量光束的传输距离.通过分析涡旋光拓 扑荷数和衍射距离,可以精准地实现物体位置的测 量.其次,在空间光通信方面,分数阶涡旋光的拓 扑荷数可以实现更高的模式复用,提高通信容量; 在通信接收端做衍射的检测则有助于提高通信系 统的稳定性.最后,在光镊应用方面,分数阶涡旋 光镊能够操纵粒子的空间位置,通过考虑衍射效 应,可以更加准确地实现涡旋光对粒子的控制.

5 结 论

本文提出并设计了一个基于 ResNet 的深度学 习方法.通过训练 ResNet 模型学习 FOAM 模式 与衍射强度剖面之间的映射关系,从而实现对不同 传播距离下 FOAM 模式的准确识别.该方法考虑 了空间传输过程中大气湍流等因素的影响,因此该 识别方案在特殊环境下也能实现高精度识别,具有 传统方法无法实现的超细 FOAM 模式和传播距离 的区分能力. 该模型为高精度识别具有较强抗扰性 的 FOAM 模式提供了一种可行的方法, 同时能够 实现对传播距离的识别, 其识别传播距离间隔为 5 cm, 模式间隔为 0.1 的 FOAM 模式, 准确率达到 99.69%. 这将有助于推动 FOAM 模式在测距、光 通信、微粒子操作等领域的实际应用.

感谢美国路易斯安那州立大学由成龙博士的讨论.

#### 参考文献

- Shen Y, Wang X, Xie Z, Min C, Fu X, Liu Q, Gong M, Yuan X 2019 Light Sci. Appl. 8 90
- [2] Bai Y, Lü H, Fu X, Yang Y 2022 Chin. Opt. Lett. 20 012601
- [3] Zhang H, Zeng J, Lu X, Wang Z, Zhao C, Cai Y 2022 Nanophotonics 11 241
- [4] Chen X, Wang S, You C, Magaña-Loaiza O S, Jin R B 2022 *Phys. Rev. A* 106 033521
- [5] Guo Z, Chang Z, Meng J, An M, Jia J, Zhao Z, Wang X, Zhang P 2022 *Appl. Opt.* **61** 5269
- [6] Nye J F, Berry M V 1974 Proc. R. Soc. London, Ser. A 336 165
- [7] Brygndahl O 1973 J. Opt. Soc. Am. 63 1098
- [8] Allen L, Beijersbergen M W, Spreeuw R J C, Woerdman J P 1992 Phys. Rev. A 45 8185
- [9] Senthilkumaran P, Sato S, Masajada J 2012 Int. J. Opt. 2012
  1
- [10] Wang J, Yang J Y, Fazal I M, et al. 2012 Nat. Photonics 6 488
- [11] Kotlyar V V, Kovalev A A, Nalimov A G, Porfirev A P 2020 *Phys. Rev. A* **102** 023516
- [12] Zhu L, Tang M, Li H, Tai Y, Li X 2021 Nanophotonics 10 2487
- [13] Nicolas A, Veissier L, Giner L, Giacobino E, Maxein D,

Laurat J 2014 Nat. Photonics 8 234

- [14] Otte E, Rosales-Guzmán C, Ndagano B, Denz C, Forbes A 2018 Light Sci. Appl. 7 18009
- [15] Bu X, Zhang Z, Chen L, Liang X, Tang H, Wang X 2018 IEEE Antennas Wirel. Propag. Lett. 17 764
- [16] Li X, Tai Y, Lü F, Nie Z 2015 Opt. Commun. 334 235
- [17] Leach J, Courtial J, Skeldon K, Barnett S M, Franke-Arnold S, Padgett M J 2004 *Phys. Rev. Lett.* **92** 013601
- [18] Beijersbergen M W, Allen L, Van der Veen H, Woerdman J 1993 Opt. Commun. 96 123
- [19] Zhou J, Zhang W, Chen L 2016 Appl. Phys. Lett. 108 111108
- [20] Krenn M, Fickler R, Fink M, Handsteiner J, Malik M, Scheidl T, Ursin R, Zeilinger A 2014 New J. Phys. 16 113028
- [21] Doster T, Watnik A T 2017 Appl. Opt. 56 3386
- [22] Liu Z, Yan S, Liu H, Chen X 2019 Phys. Rev. Lett. 123 183902
- [23] Jing G, Chen L, Wang P, Xiong W, Huang Z, Liu J, Chen Y, Li Y, Fan D, Chen S 2021 *Results Phys.* 28 104619
- [24] Guo H, Qiu X, Chen L 2022 Phys. Rev. Appl. 17 054019
- [25] Gao H, Zhang Z, Yang Y 2023 Appl. Opt. 62 5707
- [26] Wu Y, Wang A, Zhu L 2023 Opt. Express 31 36078

- [27] Zhao Y, Zhong X, Ren G, He S, Wu Z 2017 Opt. Commun. 387 432
- [28] Zhou Z Y, Zhu Z H, Shi B S 2023 Quantum Eng. 2023 4589181
- [29] Collins S A 1970 J. Opt. Soc. Am. 60 1168
- [30] Bos J P, Roggemann M C, Gudimetla V S R 2015 Appl. Opt. 54 2039
- [31] Glindemann A, Lane R, Dainty J 1993 J. Mod. Opt. 40 2381
- [32] Bhusal N, Lohani S, You C, Hong M, Fabre J, Zhao P, Knutson E M, Glasser R T, Magaña-Loaiza O S 2021 Adv. Quantum Technol. 4 2000103
- [33] Lü H, Guo Y, Yang Z X, Ding C, Cai W H, You C, Jin R B 2022 Front. Phys. 10 843932
- [34] Fernando B, Habrard A, Sebban M, Tuytelaars T 2014 arXiv: 1409.5241 [cs.CV]
- [35] Krizhevsky A, Sutskever I, Hinton G E 2017 Commun. ACM 60 84
- [36] Zhang Z, Sabuncu M 2018 Advances in Neural Information Processing Systems 31 8778
- [37] Kingma D P, Ba J 2014 arXiv: 1412.6980 [cs.LG]

## Machine learning identification of fractional-order vortex beam diffraction process<sup>\*</sup>

GUO Yan LYU Heng DING Chunling YUAN Chenzhi JIN Ruibo<sup>†</sup>

(Hubei Key Laboratory of Optical Information and Pattern Recognition, Wuhan Institute of Technology, Wuhan 430205, China)

(Received 18 October 2024; revised manuscript received 8 November 2024)

#### Abstract

Fractional-order vortex beams possess fractional orbital angular momentum (FOAM) modes, which theoretically have the potential to increase transmission capacity infinitely. Therefore, they have significant application prospects in the fields of measurement, optical communication and microparticle manipulation. However, when fractional-order vortex beams propagate in free space, the discontinuity of the helical phase makes them susceptible to diffraction in practical applications, thereby affecting the accuracy of OAM mode recognition and severely limiting the use of FOAM-based optical communication. Achieving machine learning recognition of fractional-order vortex beams under diffraction conditions is currently an urgent and unreported issue. Based on ResNetA, a deep learning (DL) method of accurately recognizing the propagation distance and topological charge of fractional-order vortex beam diffraction process is proposed in this work. Utilizing both experimentally measured and numerically simulated intensity distributions, a dataset of vortex beam diffraction intensity patterns in atmospheric turbulence environments is created. An improved 101-layer ResNet structure based on transfer learning is employed to achieve accurate and efficient recognition of the FOAM model at different propagation distances. Experimental results show that the proposed method can accurately recognize FOAM modes with a propagation distance of 100 cm, a spacing of 5 cm, and a mode spacing of 0.1 under turbulent conditions, with an accuracy of 99.69%. This method considers the effect of atmospheric turbulence during spatial transmission, allowing the recognition scheme to achieve high accuracy even in special

<sup>\*</sup> Project supported by the National Natural Science Foundations of China (Grant Nos. 92365106, 12074299) and the Distinguished Young Scholars Fund of the Natural Science Foundation of Hubei Province, China (Grant No. 2022CFA039).

<sup>†</sup> Corresponding author. E-mail: jrbqyj@foxmail.com

environments. It has the ability to distinguish ultra-fine FOAM modes and propagation distances, which cannot be achieved by traditional methods. This technology can be applied to multidimensional encoding and sensing measurements based on FOAM beam.



Keywords: fractional vortex beams, machine learning, atmosphere turbulence, residual network

PACS: 42.50.Tx, 42.25.Fx, 07.05.Mh

**DOI:** 10.7498/aps.74.20241458

**CSTR:** 32037.14.aps.74.20241458





Institute of Physics, CAS

#### 分数阶涡旋光衍射过程的机器学习识别

郭焱 吕恒 丁春玲 袁晨智 金锐博

Machine learning identification of fractional-order vortex beam diffraction process GUO Yan LYU Heng DING Chunling YUAN Chenzhi JIN Ruibo 引用信息 Citation: Acta Physica Sinica, 74, 014203 (2025) DOI: 10.7498/aps.74.20241458 在线阅读 View online: https://doi.org/10.7498/aps.74.20241458 当期内容 View table of contents: http://wulixb.iphy.ac.cn

#### 您可能感兴趣的其他文章

#### Articles you may be interested in

机器学习在宇宙线粒子鉴别中的应用

Application of machine learning in cosmic ray particle identification 物理学报. 2023, 72(14): 140202 https://doi.org/10.7498/aps.72.20230334

#### 基于机器学习的激光匀光整形方法

Machine learning based laser homogenization method 物理学报. 2024, 73(16): 164205 https://doi.org/10.7498/aps.73.20240747

蛋白质计算中的机器学习

Machine learning for *in silico* protein research 物理学报. 2024, 73(6): 069301 https://doi.org/10.7498/aps.73.20231618

生物分子模拟中的机器学习方法

Machine learning in molecular simulations of biomolecules 物理学报. 2023, 72(24): 248708 https://doi.org/10.7498/aps.72.20231624

#### 基于波动与扩散物理系统的机器学习

Machine learning based on wave and diffusion physical systems 物理学报. 2021, 70(14): 144204 https://doi.org/10.7498/aps.70.20210879

结合机器学习的大气压介质阻挡放电数值模拟研究

Numerical study of discharge characteristics of atmospheric dielectric barrier discharges by integrating machine learning 物理学报. 2022, 71(24): 245201 https://doi.org/10.7498/aps.71.20221555