


DOI: 10.12086/oe.2022.210409

深度迁移学习方法识别 轨道角动量光束

郑崇辉^{1,2}, 王天枢^{1,2*}, 刘哲琦^{1,2}, 杨翘楚^{1,2}, 刘显著^{1,2}¹长春理工大学空间光电技术国家地方联合工程研究中心,
吉林 长春 130022;²长春理工大学光电工程学院, 吉林 长春 130022

摘要: 为了加快基于深度学习的轨道角动量光束识别模型的训练速度, 提出使用迁移学习的方式识别轨道角动量光束, 并利用次谐波法生成大气湍流相位屏仿真大气湍流, 以空间光调制器加载相位屏的方式搭建模拟湍流环境, 基于迁移学习的轨道角动量光束识别系统在弱湍流和中湍流环境下均获得了 90% 以上的识别率。并与传统深度学习方式在模型训练速度、识别率等方面进行性能对比, 证明了在弱、中湍流环境中, 基于迁移学习的轨道角动量光束识别方法在保持较高识别率的前提下可以减少训练时间。

关键词: 轨道角动量; 迁移学习; 空间光调制器; 湍流相位屏

中图分类号: TN929.12

文献标志码: A

郑崇辉, 王天枢, 刘哲琦, 等. 深度迁移学习方法识别轨道角动量光束[J]. 光电工程, 2022, 49(6): 210409

Zheng C H, Wang T S, Liu Z Q, et al. Deep transfer learning method to identify orbital angular momentum beams[J]. *Opto-Electron Eng*, 2022, 49(6): 210409

Deep transfer learning method to identify orbital angular momentum beams

Zheng Chonghui^{1,2}, Wang Tianshu^{1,2*}, Liu Zheqi^{1,2}, Yang Qiaochu^{1,2}, Liu Xianzhu^{1,2}¹National and Local Joint Engineering Research Center of Space Optoelectronics Technology, Changchun University of Science and Technology, Changchun, Jilin 130022, China;²College of Opto-Electronic Engineering, Changchun University of Science and Technology, Changchun, Jilin 130022, China

Abstract: This paper proposes a transfer learning method to recognize the orbital angular momentum beam to speed up the training speed of the orbital angular momentum beam recognition model based on deep learning. In order to simulate the atmospheric turbulence, we generate the atmospheric turbulence phase screen by the sub-harmonic method and build the simulated turbulence environment by loading the phase screen on the spatial light modulator. The orbital angular momentum beam recognition system based on transfer learning has achieved a recognition rate of more than 90% in both weak and medium turbulent environments. Compared with the traditional deep learning method in the aspects of model training speed and recognition rate, it is proved that the orbital angular momentum beam recognition method based on transfer learning can reduce the training time while

收稿日期: 2021-12-22; 收到修改稿日期: 2022-02-18

基金项目: 国家自然科学基金青年基金资助项目 (62105042)

*通信作者: 王天枢, wangts@cust.edu.cn。

版权所有©2022 中国科学院光电技术研究所

maintaining a high recognition rate in the weak and medium turbulent environment.

Keywords: orbital angular momentum; transfer learning; spatial light modulator; turbulent phase screen

1 引言

轨道角动量 (Orbital angular momentum, OAM) 是涡旋光束 (vortex beam) 具有的特殊性质, 具有相位因子 $\exp(i l \theta)$ (θ 为方位角, l 为拓扑荷数)、不同拓扑荷数的 OAM 光束之间相互正交。因此 OAM 为光通信领域提供了波长、频率、时间、偏振态以外的新的自由度, 自 1992 年由 Allen 等人^[1] 提出, 就在自由空间光 (free space optical, FSO) 通信领域得到了广泛关注, 2012 年王健^[2] 等人利用 OAM 复用实现了 Tbit/s 级信道容量通信。在 FSO-OAM 通信系统中, 有一种 OAM 光束应用机制是将不同 OAM 光与特定二进制码直接对应, 令数字信号与 OAM 模式之间建立映射关系, 该方法称为 OAM 键控^[3-5] (OAM shift keying, OAM-SK)。OAM-SK 使 OAM 通信问题转化为了 OAM 光束的识别问题。

随着计算机与人工智能技术的发展, 出现了基于机器学习的 OAM-SK-FSO 系统解码方法。2014 年, Krenn 等人^[6] 使用人工神经网络 (artificial neural network, ANN) 对 16 种不同叠加态 OAM 光束进行识别, 每种光束代表特定 4 bit 二进制码, 在维也纳的 3 km 真实大气环境下对两幅图片进行数据传输, 分别得到 1.2% 与 0.8% 的误码率。利用机器学习的 OAM 解调方案具有结构简单、识别范围广、识别精度高等优势。而深度学习的发展使得 OAM 的识别精度进一步提高。2017 年, Doster 等人^[7] 使用叠加贝塞尔光束进行编码, 并利用卷积神经网络 (convolutional neural network, CNN) 中的 Alexnet 架构对其进行识别, 在强湍流环境下得到了 99% 以上的识别率, 由此开启了 CNN-OAM 解码方案的研究^[8-22]。

Doster 等人的工作表明了更大的训练集、更高的图片像素数对提高 CNN-OAM 识别系统的识别率有帮助, 并且为了映射 n 位二进制数据, 需要 2^n 种不同 OAM 光束与其对应, 这也需要层数更深、分类能力更强的 CNN 架构。而上述需求大大增加了 CNN-OAM 识别系统的时间复杂度和空间复杂度, 使建立识别模型的成本大幅上升。

针对上述问题, 本文提出将迁移学习应用到 CNN-OAM 识别方法中, 采用反射式液晶空间光调制

器 (liquid crystal spatial light modulator, LC-SLM) 生成 16 种不同叠加态 OAM 光束。利用次谐波法 (sub-harmonic method) 生成大气湍流相位屏, 以 SLM 加载相位屏的方式, 模拟叠加态 OAM 光束在弱湍流和中湍流环境下的传输。建立了基于 VGG16 架构的迁移学习模型, 对湍流环境下不同 OAM 光束进行识别, 并与未使用迁移学习的 VGG16 模型在识别率与模型训练速度等方面进行了性能对比。

2 理论推导

2.1 OAM 光束的选取与编码

本文选取拉盖尔高斯 (Laguerre-Gaussian, LG) 光束作为编码光束, LG 光束是一种 OAM 光束, 其光场表达式为

$$u(r, \theta, z) = \frac{\sqrt{2p!/\pi(|l+p|)!}}{\omega(z)} \left(\frac{r\sqrt{2}}{\omega(z)} \right)^{|l|} L_p^{|l|} \left(\frac{2r^2}{\omega(z)^2} \right) \cdot \exp \left[\frac{-r^2}{\omega(z)^2} \right] \exp \left[\frac{-ikr^2z}{2(z^2+z_R^2)} \right] \cdot \exp [i(2p+|l|+1)\arctan(z/z_R)] \exp(-il\theta), \quad (1)$$

其中: l 为拓扑荷数, p 为径向指数, k 为波数, $\omega(z) = \omega_0 \sqrt{1+z^2/z_R^2}$, $z_R = \pi\omega_0^2/\lambda$, ω_0 为束腰半径, z 为传播距离, $L_p^{|l|}$ 为缔合拉盖尔多项式。LG 光束在光强分布上表现为圆环状, 随着拓扑荷数的增大, 其圆环半径也随之增大, 图 1 所示分别为拓扑荷数 $l=+2$ 与 $l=+5$ 时的 LG 光束光强分布。

CNN-OAM 识别系统需要利用不同光强分布的光束映射不同的数据, 因此需要识别并分类不同光束的光强图。相较于单态 LG 光束相似度较高、不易区分的圆环状分布, 叠加态 LG 光束拥有特殊的光强分布, 更容易被识别。其中异号叠加态 LG 光束, 即具有拓扑荷数分别为 $+l$ 与 $-l$ 的两束 LG 光束的叠加光场, 该叠加态 OAM 光束具有独特且有规律的花瓣状光强分布, 每种叠加态光束具有的“花瓣”数目为 l 的二倍, 适宜利用 CNN 进行识别。本文利用 SLM 加载相位图的方式, 生成 $\{l=\pm 2, \pm 3, \pm 4, \pm 5, \pm 6, \pm 7, \pm 8, \pm 9, \pm 10, \pm 11, \pm 12, \pm 13, \pm 14, \pm 15, \pm 16, \pm 17\}$ 这 16 种叠加态 LG 光束, 可进行 4 bit 编码, 其具体映射关系如图 2 所示。



图 1 拓扑荷数为+2 与+5 的 LG 光束。

(a) 拓扑荷数为+2; (b) 拓扑荷数为+5

Fig. 1 LG beams with topological charges of +2 and +5.

(a) Topological charge is +2; (b) Topological charge is +5

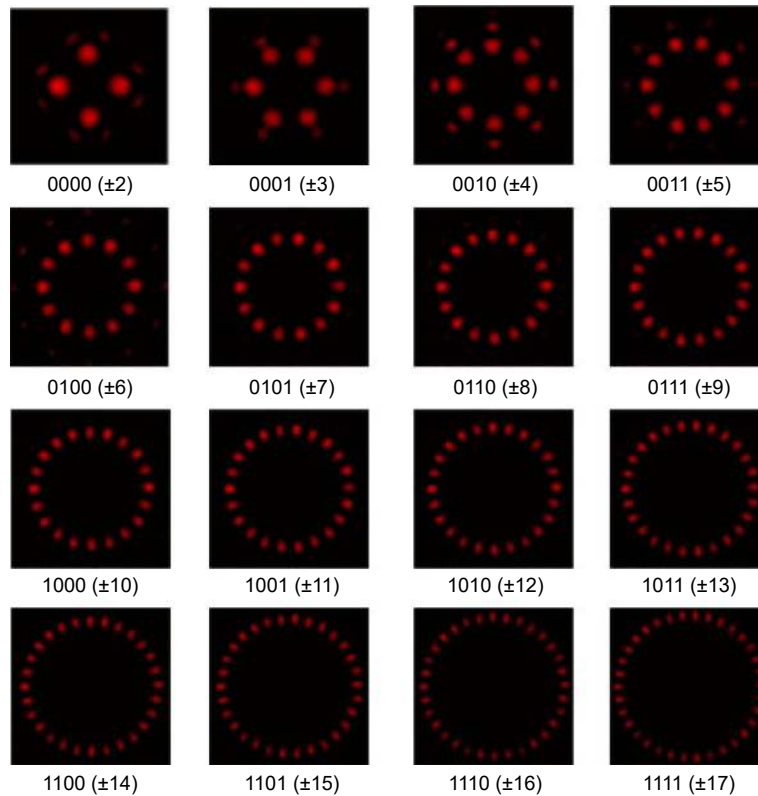


图 2 LG 光束与数据间的映射关系

Fig. 2 The mapping relationship between LG beam and data

2.2 大气湍流环境的模拟

湍流效应引起的大气折射率变化会导致在大气中传播的 LG 光束的波前发生变化, 从而影响 CNN-OAM 识别系统的识别效果。本文采取改进的 von Karman 功率谱描述大气湍流:

$$\Phi_n(\kappa) = 0.033C_n^2(\kappa^2 + \kappa_0^2)^{-11/6} \exp\left(-\frac{\kappa^2}{\kappa_m^2}\right), \quad (2)$$

其中: $\kappa_0 = 2\pi/L_0$, L_0 为湍流外尺度, $\kappa_m = 5.92/l_0$,

l_0 为湍流内尺度, C_n^2 为大气折射率结构常数, 其数值越大, 所代表的湍流强度便越大。认为当 $C_n^2 \geq 10^{-14} \text{ m}^{-2/3}$ 时为强湍流, 当 $10^{-16} \text{ m}^{-2/3} < C_n^2 < 10^{-14} \text{ m}^{-2/3}$ 时为中湍流, 当 $C_n^2 \leq 10^{-16} \text{ m}^{-2/3}$ 时为弱湍流。

大气相干长度 r_0 是更为常用的参数, 数学表达式为 (3), 其中 L 为传输距离:

$$r_0 = (0.423k^2 C_n^2 L)^{-3/5}. \quad (3)$$

由此, 还可以引入相对湍流强度的概念: 设湍流

中传输的光束直径为 D , 则 D 与大气相干长度 r_0 的比值 D/r_0 即可用来衡量湍流的大小, 一般认为当 $D/r_0 < 2$ 时为弱湍流, 当 $2 < D/r_0 < 8$ 时为中湍流, 当 $D/r_0 > 8$ 时为强湍流。

为了在实验室环境模拟大气湍流, 本文采用空间光调制器加载蒙特卡洛相位屏的方法模拟湍流对光束的影响, 本文使用 Lane 等人^[23] 提出的“次谐波法”生成所需相位屏: 首先基于功率谱反演法, 对式 (2) 中的 von Karman 功率谱进行二维傅里叶变换 (two-dimensional discrete Fourier transform, 2D-DFT), 生成一个相位屏, 傅里叶变换法生成的相位屏具有低频分量不足的缺点, 因此需要生成低频相位屏, 与 FT 方法生成的相位屏进行叠加, 以补充其低频分量。其数学表达式如下:

$$\phi_{LF}(x, y) = \sum_{p=1}^{N_p} \sum_{n=-1}^1 \sum_{m=-1}^1 C_{n,m} \exp[i2\pi(f_{x_n}x + f_{y_m}y)], \quad (4)$$

其中: $C_{n,m}$ 为傅里叶级数系数, f_{x_n} 和 f_{y_m} 分别为 x 与 y 方向的离散空间频率, N_p 为次谐波级数, 本文的次谐波级数 $N_p=3$ 。

叠加后即可生成较为准确的蒙特卡洛相位屏, 以描述大气湍流。本文选择 $r_0=0.24$ m 和 $r_0=0.09$ m 的大气相干长度。本文仿真的系统光源直径为 0.36 m, 因此, 当大气相干长度 $r_0=0.24$ m 时, 其 D/r_0 的值为 1.5, 对应的湍流强度为弱湍流。当 $r_0=0.09$ m 时, 其 D/r_0 的值为 4, 对应的湍流强度为中湍流。相位屏的内尺度 $l_0=0.01$ m, 外尺度 $L_0=10$ m, 模拟传输距离 $L=1000$ m 的大气信道。最后要注意相位屏在加载到 SLM 前需要归一化到 $[0, 2\pi]$ 之间。图 3 中的 3(a)、3(b) 分别为生成的 $r_0=0.24$ m 和 $r_0=0.09$ m 的相位屏, 3(c)、3(d) 分别为归一化后 $r_0=0.24$ m 和 $r_0=0.09$ m 的相位屏。

2.3 基于迁移学习的识别算法

迁移学习指的是在相似但不同的领域或任务中进

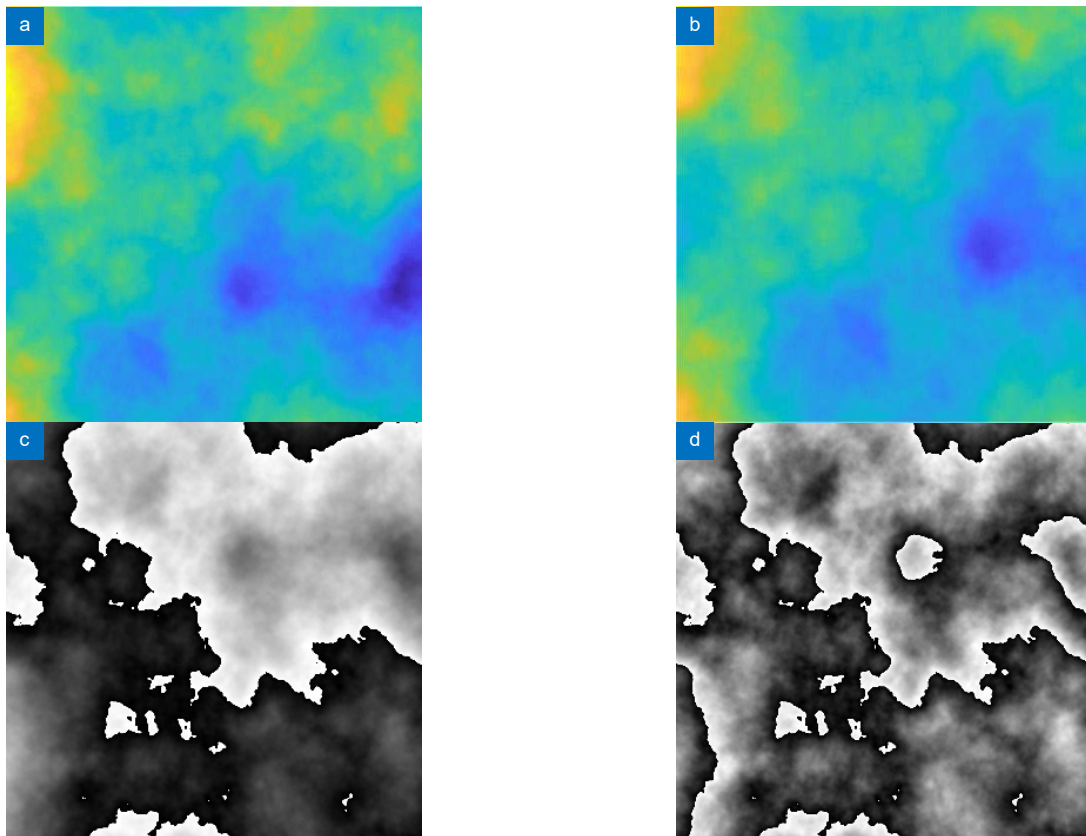


图 3 0.24 m 和 0.09 m 的相位屏与归一化后的相位屏。

(a) $r_0=0.24$ m 的相位屏; (b) $r_0=0.09$ m 的相位屏;

(c) 归一化后 $r_0=0.24$ m 的相位屏; (d) 归一化后 $r_0=0.09$ m 的相位屏

Fig. 3 Phase screen of $r_0=0.24$ m and $r_0=0.09$ m and normalized phase screen.

(a) Phase screen of $r_0=0.24$ m; (b) Phase screen of $r_0=0.09$ m;

(c) Normalized phase screen of $r_0=0.24$ m; (d) Normalized phase screen of $r_0=0.09$ m

行的知识迁移^[24]。也即利用已有的知识 (源域 (source domain)) 来学习新的知识 (目标域 (target domain))。在传统的深度学习方法中, 神经网络需要对每一个任务提取特征, 当数据的分布发生变化时, 通常需要从头训练, 当训练集数据量庞大或神经网络结构较复杂时, 其时间复杂度与空间复杂度大大增加, 往往依赖算力更强的图形处理器 (graphics processing unit, GPU)。而迁移学习则利用源域与目标域之间的相似性, 对已学习到的知识进行复用降低了训练模型的成本。但源域如果和目标域相似度不够, 迁移效果会不理想, 即所谓的“负迁移”现象。

迁移学习可以分为基于参数 (parameter)、特征 (feature)、实例 (instance)、结构关系 (relation) 这 4 类迁移方法。本文选用基于参数的迁移学习方法。

基于参数的迁移学习方法也被称为基于网络或基于模型的迁移学习方法, 是指利用已经在其他数据集训练好的网络, 即预训练网络 (pretrained network), 将其中的网络和权重应用于其他不相干的任务中, 使模型无需从头训练。

基于参数的迁移学习的原理是利用 CNN 所提取的特征的可移植性, 将预训练网络作为特征提取器, 从新数据集中提取特征, 然后将这些特征输入新的分类器, 开始训练。CNN 结构包含两部分: 第一部分是一系列卷积层与池化层, 称为卷积基 (convolutional

base), 第二部分是密集连接分类器。卷积层提取特征的通用性取决于该层在模型中的深度, 模型中浅层所提取的特征是局部的, 高度通用的, 如边缘、颜色、纹理等, 而深层能提取适用于该图像的特定特征。因此, 当原始模型与目标数据集差距较大时, 通常使用模型的前几层做特征提取, 当差距较小时, 可以使用整个卷积基。

本文使用在 ImageNet 上训练的 VGG16 网络的卷积基作为特征提取器, 之后添加适用于本文的分类器, 其架构如图 4 所示。其中 Convolution2D 代表卷积层。MaxPooling2D 代表最大池化层, 以对特征图进行下采样。利用 Flatten 层对多维输入一维化, Dense 为全连接层, 并添加了 Dropout 层以防止过拟合。

架构中的卷积基经过了冻结 (freeze), 所谓“冻结”, 指的是在训练过程中, 令一个或多个层的权重保持不变。本文采用在 ImageNet 上训练好的权重代替随机初始化的权重, 若不进行冻结, 其权重会随着训练而进行更改, 使迁移学习方法失败。冻结后, 只有最后两个全连接层参与训练, 以对 16 种不同的叠加态 LG 光束进行分类。

2.4 实验结构

本文中的 CNN-OAM 识别系统结构简图如图 5 所示。采用半导体激光器作为光源, 其波长为 1550 nm, 激光器发出的高斯光束耦合到准直镜后发射到自由空




图 4 基于 VGG16 的迁移学习架构

Fig. 4 Transfer learning architecture based on VGG16




图 5 系统结构

Fig. 5 System structure

间中传播。首先经过半波片, 其作用是将光束的偏振态调整至入射光线和反射光线所组成的平面上, 以满足 SLM 的调制要求。之后利用偏振片对入射的线偏振光进行过滤, 提高消光比。获得的高质量线偏振光入射到第一个 SLM 上进行调制, 通过改变 SLM1 所加载的 $l=\pm 2$ 到 ± 17 的 LG 光束对应相位图, 其反射光即为 16 种不同叠加态 LG 光束。

本文选用的 SLM 为滨松公司的 X13138 型, 入射光束需照射到液晶靶面正中心, 同时要满足入射角小于 10° , 若入射角过大会导致光束两侧的相位差过大, 影响光束的调制。

高斯光经 SLM1 调制后变为叠加态 LG 光束, 再入射到 SLM2 上, SLM2 上加载湍流相位屏, 以模拟大气湍流对 LG 光束的扰动。本文利用 Matlab 生成了 $r_0=0.24$ m 和 $r_0=0.09$ m 两种湍流强度的相位屏, 在本系统中分别对应 $D/r_0=1.5$ 的弱湍流和 $D/r_0=4$ 的中湍流。在每种强度下生成 300 张随机湍流相位屏, 共 600 张。以代表随机的大气湍流。利用软件对加载到 SLM2 上的相位屏进行滚动播放, 播放切换间隔为每秒 10 张图片。切换 16 种不同 LG 光束分别通过 SLM2, 共计获得 9600 张光强分布图片。最后利用连接计算机的红外相机对通过湍流后的光束光强图片进行记录, 以完成识别模型的建立。图 6 为 $l=\pm 5$ 的叠加态 LG 光束分别经过 $D/r_0=1.5$ 和 $D/r_0=4$ 的湍流后的光强分布图。

3 分析与讨论

采集两种湍流强度下的 16 种 LG 光束, 所对应的 9600 张光强分布图片将划为训练集和验证集两部分, 具体划分方式如下:



图 6 D/r_0 为 1.5 与 4 时 ± 5 阶 LG 光束的光强图。

(a) $D/r_0=1.5$; (b) $D/r_0=4$

Fig. 6 Intensity diagram of ± 5 order LG beam when D/r_0 is 1.5 and 4.

(a) $D/r_0=1.5$; (b) $D/r_0=4$

在 $D/r_0=1.5$ 的湍流强度下, 16 种 LG 光束图片每种取 250 张, 同理在 $D/r_0=4$ 的条件下每种光束取 250 张光强图。将相同种类 LG 光束对应的不同湍流强度下的图片混合并标注为同一类, 即每种 LG 光束标签对应 500 张图片建立训练集, 训练集共计 8000 张图片。按上述选取规则, 每种 LG 光束对应 100 张图片混合并标注以建立验证集, 验证集共计 1600 张图片。

对数据集分类并标注后即可训练并建立模型, 本文实验的硬件条件为 Inter Core i5-421U 的 CPU, 主频为 2.40 GHz。GPU 为 NVIDIA GeForce 840M, 内存 4.00 GB (3.89 GB 可用)。操作系统为 Windows 10 x64。运行环境为 tensorflow2.2.2, 编程语言为 Python3.7.6。

模型共训练 20 个轮次, 本文同时利用相同数据集, 对未使用迁移学习的 VGG16 模型进行了建立与训练, 以进行性能对比, 其训练精度与验证精度如图 7 所示。

在本文的分类任务中, 两个模型的拟合速度相近, 在第 7 轮时便保持了 90% 以上的验证精度, 保存验证精度最高时的模型。本文首先选取了最高验证精度, 网络的参数 (param) 总量, 训练总时长, 平均每轮训练时长这 4 个指标, 对比评价迁移学习模型和原始 VGG16 模型对此分类任务的表现, 如表 1 所示。

由表 1 可知, 利用迁移学习的模型可大大缩减训练时长及参与训练的参数总量, 但在验证集的精度上有一定下降。文中的验证集数据量相对较小, 为了使精确度更具有普遍意义, 也为了更准确了解两种模型对不同湍流强度下不同 LG 光束的识别表现, 本文在弱湍流和中湍流条件下分别生成 500 张随机湍流相位




图 7 不同识别模型的训练精度与验证精度。

(a) 基于迁移学习的识别模型; (b) 基于原始 VGG16 的识别模型

Fig. 7 Training accuracy and validation accuracy of different recognition models.

(a) Based on transfer learning; (b) Based on VGG16

表 1 模型评价指标

Table 1 Model evaluation indicators

Indicators	Transfer learning model	VGG16 model
Highest validation accuracy/%	96.56	98.25
Total parameters	6426896	134301520
Total training time/s	13887	32022
Average epoch training time/s	694.35	1601.1

屏, 为了体现大气湍流的随机性, 这 500 张相位屏不能包含建立模型所用的相位屏, 需重新生成。之后在图 5 所示的链路中, 分别利用迁移学习模型和 VGG16 模型对 16 种叠加 OAM 光束进行识别, 每种湍流强度下包含 8000 种不同光强分布的光束。并利用混淆矩阵 (confusion matrix) 可视化识别结果。

混淆矩阵的纵坐标为真实标签, 即实际的图片分类; 横坐标为预测标签, 即模型对图片的分类结果。横纵坐标值从左至右、从上至下为 2 到 17, 对应本文的±2 到±17 的叠加光束。若一张图片属于±2 的光束, 模型将其分类为±5, 则在 2 所在行、5 所在列记录数据。矩阵对角线上的数据为正确识别结果数。

由图 8 和图 9 可以看出, 当湍流强度为 $D/r_0=1.5$ 的弱湍流时, 迁移学习模型识别率为 98.62%, 在本文的编码规则下的系统误比特率为 0.00666; VGG16 模型识别率为 99.39%, 误比特率为 0.00303。当湍流强度为 $D/r_0=4$ 的中湍流时, 迁移学习模型识别率为 94.37%, 误比特率为 0.0232; VGG16 模型识别率为 94.81%, 误比特率为 0.0213。随着湍流强度的增强, 两个模型的识别率均有下降。相比于原始 VGG16 网

络建立的识别模型, 利用迁移学习建立的模型的识别率有微小下降, 在两种湍流强度下识别率下降幅度均小于 1%。而建立迁移学习模型所需的训练时间为 13887 s, 远远少于建立原始 VGG16 模型所需的 32022 s, 训练速度提升约 2.3 倍。

4 结 论

本文利用深度迁移学习方法建立了 CNN-OAM 识别系统, 并在弱湍流和中湍流环境下进行了识别任务, 分别获得了 98.62%、94.37% 的较高识别率。证明了基于迁移学习的 OAM 识别系统的可行性。同时与传统深度学习方法做对比, 证明了迁移学习系统可在维持较高识别率的条件下, 大幅减少模型训练所需时间, 为未来快速构建 CNN-OAM-SK 系统提供了一种思路。

下一阶段的工作可以集中在: 1) 对湍流强度进行细分, 详细对比迁移学习模型在弱、中、强湍流下的表现。2) 将迁移学习中的特征提取方法与其他算法如支持向量机等结合, 进一步减少模型训练时间或提高识别精度等。

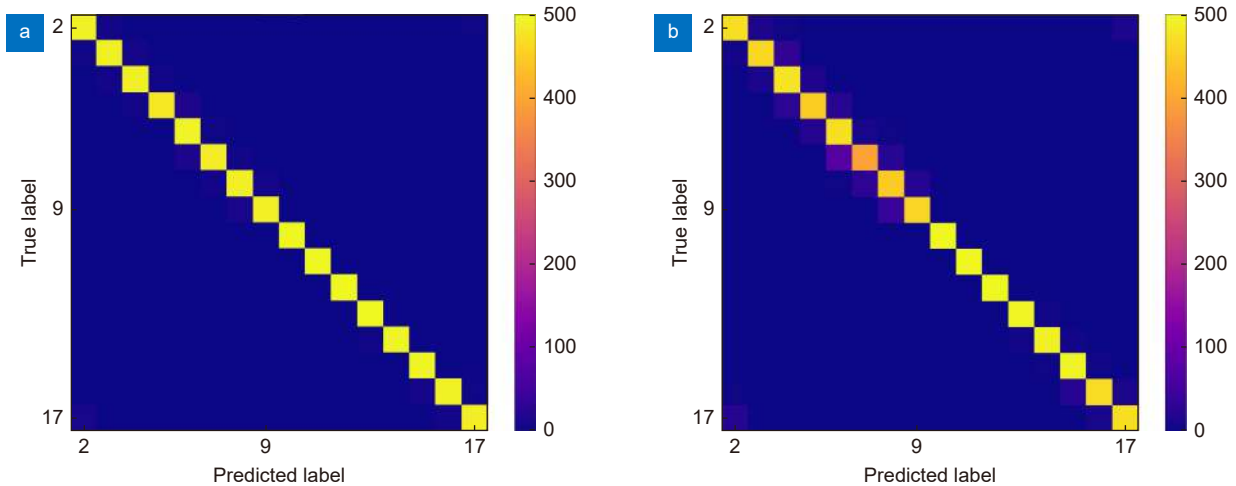


图 8 迁移学习模型在不同湍流环境下的混淆矩阵。

(a) $D/r_0=1.5$; (b) $D/r_0=4$

Fig. 8 Confusion matrix of transfer learning model in different turbulent environment.

(a) $D/r_0=1.5$; (b) $D/r_0=4$

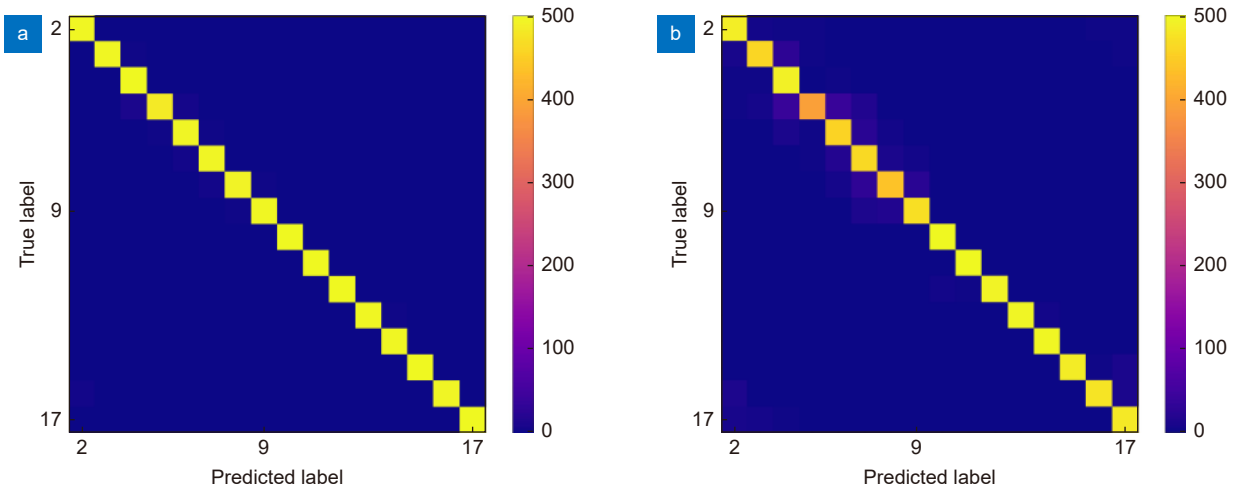


图 9 VGG16 模型在不同湍流环境下的混淆矩阵。

(a) $D/r_0=1.5$; (b) $D/r_0=4$

Fig. 9 Confusion matrix of VGG16 model in different turbulent environment.

(a) $D/r_0=1.5$; (b) $D/r_0=4$

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]. *Phys Rev A*, 1992, **45**(11): 8185–8189.
- [2] Wang J, Yang J Y, Fazal I M, et al. Terabit free-space data transmission employing orbital angular momentum multiplexing[J]. *Nat Photonics*, 2012, **6**(7): 488–496.
- [3] Fu S Y, Zhai Y W, Zhou H, et al. Experimental demonstration of free-space multi-state orbital angular momentum shift keying[J]. *Opt Express*, 2019, **27**(23): 33111–33119.
- [4] Fu S Y, Zhai Y W, Zhou H, et al. Demonstration of free-space one-to-many multicasting link from orbital angular momentum encoding[J]. *Opt Lett*, 2019, **44**(19): 4753–4756.
- [5] Fu S Y, Zhai Y W, Zhou H, et al. Demonstration of high-dimensional free-space data coding/decoding through multi-ring optical vortices[J]. *Chin Opt Lett*, 2019, **17**(8): 080602.
- [6] Krenn M, Fickler R, Fink M, et al. Communication with spatially modulated light through turbulent air across Vienna[J]. *New J Phys*, 2014, **16**(11): 113028.
- [7] Doster T, Watnik A T. Machine learning approach to OAM beam demultiplexing via convolutional neural networks[J]. *Appl Opt*, 2017, **56**(12): 3386–3396.
- [8] Li J, Zhang M, Wang D S. Adaptive demodulator using machine learning for orbital angular momentum shift keying[J]. *IEEE Photonics Technol Lett*, 2017, **29**(17): 1455–1458.
- [9] 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]. *Opt Express*, 2018, **26**(8):

- 10494–10508.
- [10] Park S R, Cattell L, Nichols J M, et al. De-multiplexing vortex modes in optical communications using transport-based pattern recognition[J]. *Opt Express*, 2018, **26**(4): 4004–4022.
- [11] Cui X Z, Yin X L, Chang H, et al. Analysis of an adaptive orbital angular momentum shift keying decoder based on machine learning under oceanic turbulence channels[J]. *Opt Commun*, 2018, **429**: 138–143.
- [12] Zhao Q S, Hao S Q, Wang Y, et al. Mode detection of misaligned orbital angular momentum beams based on convolutional neural network[J]. *Appl Opt*, 2018, **57**(35): 10152–10158.
- [13] 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]. *Opt Express*, 2018, **26**(21): 27849–27864.
- [14] Wang Z K, Dedo M I, Guo K, et al. Efficient recognition of the propagated orbital angular momentum modes in turbulences with the convolutional neural network[J]. *IEEE Photonics J*, 2019, **11**(3): 7903614.
- [15] Li S H, Chen S, Gao C Q, et al. Atmospheric turbulence compensation in orbital angular momentum communications: advances and perspectives[J]. *Opt Commun*, 2018, **408**: 68–81.
- [16] Li J, Chen X, McDuffie S, et al. Mitigation of atmospheric turbulence with random light carrying OAM[J]. *Opt Commun*, 2019, **446**: 178–185.
- [17] Jiang S Q, Chi H, Yu X B, et al. Coherently demodulated orbital angular momentum shift keying system using a CNN-based image identifier as demodulator[J]. *Opt Commun*, 2019, **435**: 367–373.
- [18] Chi H, Jiang S Q, Ou J, et al. Comprehensive study of orbital angular momentum shift keying systems with a CNN-based image identifier[J]. *Opt Commun*, 2020, **454**: 124518.
- [19] Guo Z Y, Gong C F, Liu H J, et al. Research advances of orbital angular momentum based optical communication technology[J]. *Opto-Electron Eng*, 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] Zhang L H, Shen F, Lan B. Characteristic analysis of orbital angular momentum of vortex beam propagating in atmospheric turbulent[J]. *Opto-Electron Eng*, 2020, **47**(4): 190272. 张利宏, 沈锋, 兰斌. 涡旋光束轨道角动量在大气湍流传输下的特性分析[J]. *光电工程*, 2020, **47**(4): 190272.
- [21] He F T, Fang W, Zhang J L, et al. Analysis of the transmission characteristics of Hank-Bessel beam in anisotropic ocean turbulence[J]. *Opto-Electron Eng*, 2020, **47**(6): 190591. 贺锋涛, 房伟, 张建磊, 等. 汉克-贝塞尔光束在各向异性海洋湍流中轨道角动量传输特性分析[J]. *光电工程*, 2020, **47**(6): 190591.
- [22] Lin P, Wang T S, Ma W Z, et al. Propagation characteristics of 2.07 μm fiber laser in weak turbulence condition[J]. *Opto-Electron Eng*, 2020, **47**(3): 190588. 林鹏, 王天枢, 马万卓, 等. 2.07 μm 光纤激光在弱湍流条件下的传输特性研究[J]. *光电工程*, 2020, **47**(3): 190588.
- [23] Lane R G, Glindemann A, Dainty J C. Simulation of a Kolmogorov phase screen[J]. *Waves Random Media*, 1992, **2**(3): 209–224.
- [24] Pan S J, Yang Q. A survey on transfer learning[J]. *IEEE Trans Knowl Data Eng*, 2010, **22**(10): 1345–1359.

作者简介



郑崇辉 (1995-), 男, 硕士, 主要从事空间激光通信技术方面的研究。

E-mail: 2019100151@mails.cust.edu.cn




【通信作者】王天枢 (1975-), 男, 博士, 教授, 主要从事高速空间激光通信、光纤通信技术、超快激光技术等方面的研究。

E-mail: wangts@cust.edu.cn

Deep transfer learning method to identify orbital angular momentum beams

Zheng Chonghui^{1,2}, Wang Tianshu^{1,2*}, Liu Zheqi^{1,2}, Yang Qiaochu^{1,2}, Liu Xianzhu^{1,2}



Confusion matrix of transfer learning model in turbulent environment

Overview: With the development of the computer and the artificial intelligence technology, the orbital angular momentum shift keying system decoding method based on the machine learning has emerged. The orbital angular momentum demodulation scheme using machine learning has advantages of the simple structure, wide recognition range and high recognition accuracy. The development of deep learning has further improved the recognition accuracy of orbital angular momentum. And the development of deep learning has further improved the recognition accuracy of orbital angular momentum. In order to speed up the training speed of the orbital angular momentum beam recognition model based on deep learning, this paper proposes to use the transfer learning method to identify the orbital angular momentum beam, and build the transfer learning recognition model based on the VGG16 architecture. To simulate the transmission of orbital angular momentum beams in a turbulent environment, this paper use the sub-harmonic method to generate an atmospheric turbulence phase screen and build a simulated turbulent environment by loading the phase screen with the spatial light modulator. The orbital angular momentum recognition task was carried out in a weakly turbulent environment with $D/r_0=1.5$ and a medium turbulent environment with $D/r_0=4$. And high recognition rates of 98.62% and 94.37% were obtained in weak turbulence environment with $D/r_0=1.5$ and a medium turbulence environment with $D/r_0=4$, respectively. The feasibility of an orbital angular momentum recognition system based on the transfer learning is proved. At the same time, in terms of the model training speed and recognition rate, this paper compares the performance of the transfer learning model and the original VGG16 model, and visualizes the recognition results of each beam by using the confusion matrix. The VGG16 model obtains the recognition rates of 99.39% and 94.81% in the weak turbulence environment with $D/r_0=1.5$ and the medium turbulence environment with $D/r_0=4$, respectively. The recognition rate is reduced by less than 1%, but the model training speed is improved by 2.3 times. This paper proves the feasibility of the orbital angular momentum recognition system based on transfer learning. At the same time, it is proved that the orbital angular momentum recognition system based on transfer learning model can greatly reduce the time required for model training under the condition of maintaining high recognition rate. This paper provides an idea for the rapid construction of orbital angular momentum shift keying system which based on convolutional neural network in the future.

Zheng C H, Wang T S, Liu Z Q, et al. Deep transfer learning method to identify orbital angular momentum beams[J]. *Opto-Electron Eng*, 2022, 49(6): 210409; DOI: 10.12086/oe.2022.210409

Foundation item: National Natural Science Foundation of China Youth Fund (62105042)

¹National and Local Joint Engineering Research Center of Space Optoelectronics Technology, Changchun University of Science and Technology, Changchun, Jilin 130022, China; ²College of Opto-Electronic Engineering, Changchun University of Science and Technology, Changchun, Jilin 130022, China

* E-mail: wangts@cust.edu.cn