

文章编号: 1002-1582(2025)04-0392-08

基于深度学习与FPGA的涡旋光束OAM模式识别

张尘, 吕宏*, 王鲲鹏, 刘艺柯, 吴彤桥, 邵睿康, 黄钉劲
(西安工业大学 光电工程学院, 陕西 西安 710021)

摘 要: 为提高结构化涡旋光束轨道角动量(OAM)的检测效率, 提出结合深度学习与FPGA加速的OAM模式识别方法。利用功率谱反演法生成随机相位屏, 通过空间光调制器模拟五种大气湍流环境, 采集涡旋光束经过随机相位屏后的光斑数据图像, 构建包含10000组样本的数据集, 采用ResNet18卷积神经网络(CNN), 对比分析不同湍流强度对涡旋光束OAM模式识别精度的影响, 并对模型的识别性能进行全面评估, 最终将训练后的ResNet18神经网络模型载入可编程门阵列(FPGA)硬件平台实现OAM模式识别。结果表明: 在弱、中湍流环境下的三种OAM模式识别准确率达100%, 强湍流环境下的两种OAM模式识别准确率仍保持99%, 相较于弱、中湍流环境下的OAM模式识别准确率略有下降。通过将CNN模型载入FPGA硬件平台, 实现了耗能2.844/W、能效比2.19GOPS/W、推理时间0.58s的涡旋光束OAM模式识别。

关 键 词: 光学测量; 涡旋光束; 轨道角动量; 大气湍流; 卷积神经网络

中图分类号: TN249

文献标识码: A

OAM mode recognition system of vortex beams based on deep learning and FPGA

ZHANG Chen, LV Hong*, WANG Kunpeng, LIU Yike, WU Tongqiao, SHAO Ruikang, HUANG Dingjin
(College of Photoelectric Engineering, Xi'an University of Technology, Xi'an 710021, China)

Abstract: To enhance the detection efficiency of structured vortex beams carrying Orbital Angular Momentum (OAM), a recognition method combining deep learning with FPGA acceleration is proposed. Random phase screens are generated using the power spectrum inversion method, and five types of atmospheric turbulence conditions are simulated via a spatial light modulator. Vortex beam spot images after passing through the random phase screens are collected to construct a dataset comprising 10,000 samples. A ResNet18 Convolutional Neural Network (CNN) is employed to analyze and compare the impact of different turbulence intensities on OAM mode recognition accuracy. The recognition performance of the model is comprehensively evaluated, and the trained ResNet18 model is subsequently deployed onto a Field-Programmable Gate Array (FPGA) hardware platform for real-time OAM mode recognition. Experimental results demonstrate that under weak and moderate turbulence conditions, the recognition accuracy for three OAM modes reaches 100%, while under strong turbulence, the accuracy for two OAM modes remains as high as 99%, showing a slight decrease compared to the weaker turbulence cases. By deploying the CNN model onto the FPGA platform, the system achieves an energy consumption of 2.844 W, an energy efficiency of 2.19 GOPS/W, and an inference time of 0.58 seconds for OAM mode recognition of vortex beams.

Keywords: optical measurement; vortex beam; orbital angular momentum; atmospheric turbulence; convolutional neural network

收稿日期: 2025-03-13; 收到修改稿日期: 2025-04-14

基金项目: 陕西省自然科学基金基础研究计划资助项目(2024JC-YBMS-536)

作者简介: 张尘(1998—), 女, 硕士研究生, 从事光场调控等方面的研究。1633825465@qq.com

吕宏(1975—), 男, 副教授, 博士, 从事光场调控, 激光大气传输及测控技术方面研究。

* 通讯作者: lvhong@xatu.edu.cn

0 引言

涡旋光束^[1]因具有螺旋相位波前特殊光场结构,以及携带轨道角动量 (Orbital Angular Momentum, OAM)^[2]的特性,近年来成为光学领域的研究热点。特别是针对快速准确的检测涡旋光束 OAM 模式的方法研究,受到学者广泛关注。基于深度学习的涡旋光束 OAM 模式识别方法在涡旋光束大气湍流传输中适应力更强、识别效率更高,可以有效地处理涡旋光束 OAM 在传输过程中受大气湍流相位扰动的影响^[3,4]。而可编程门阵列 (Field Programmable Gate Array, FPGA) 作为部署深度学习卷积神经网络 (Convolutional Neural Network, CNN) 模型的硬件平台,更加适应于各种复杂环境,且由于自身光学系统元件少,结构简单,同时适应长距离、长时间、湍流扰动情况^[5,6]。将深度学习和 FPGA 与涡旋光束 OAM 的模式识别结合应用,有望提高涡旋光束 OAM 模式识别准确率。

近年来, CNN 也被应用于涡旋光束 OAM 的识别及矫正。S.Lohani 等^[7]使用 DNN 模型同时对含 OAM 值为 1 到 100 的数字生成的涡旋光束图像进行分类,结果准确率达到 99%。Q.Zhao 等^[8]提出了一种改进的卷积神经网络结构,通过在不同角度采集特征图训练网络以提高深度学习技术在模式识别中的鲁棒性。P.Wang 等^[9]使涡旋光束经过圆柱形透镜产生衍射图案,采用 CNN 辅助识别衍射图案中的 OAM 模式特征,实现了 OAM 模式 -15 到 15 的分类识别。X.Ke 等^[10]使用 6 层 CNN 识别解复用后的 OAM 模式,实验采用功率谱反演方法生成随机相位屏模拟了涡旋光束大气传输,识别精度为 98%。郑崇辉等^[11]提出使用迁移学习的方式识别携带轨道角动量的光束,并利用次谐波法生成大气湍流相位屏仿真大气湍流,使基于迁移学习的轨道角动量光束识别结果获得了 90% 以上的识别率。王志远等^[12]在多模光纤传输环境下,使用 CNN 从散斑图案中实现对两个正交偏振轨道角动量模式的 100% 准确识别。Z.Zhang 等^[13]在非均匀介质海洋湍流环境下,提出了水下短距离通信方案,实现了模式范围 -8 到 8 的识别,在 25m 范围内弱湍流情况下的识别率可达 93%。刘雪莲等^[14]在强散射环境下,利用 LeNet-5 网络实现了强散射后涡旋光拓扑荷数的测量,且准确率达到 100%。M.Z.M.Khan 等^[15]在不同烟雾天气环境下,使用多个 OAM 模式图像作为 CNN 和 uNET 模型的输入进行可见性区域识别,其

有效性得到提高。孙立虎等^[16]提出了一种基于涡旋光束和 CNN 的信息编码方案,实现了信息的高质量加密编码、传输和解码。然而,鲜有基于深度学习结合 FPGA 对大气湍流中光束 OAM 模式识别以及权重信息提取的研究。

文中根据随机相位屏理论对大气湍流环境进行模拟,利用深度学习对大气湍流影响下涡旋光束 OAM 模式的识别问题进行了研究,采集光斑图像作为 CNN 数据集,随后构建了基于深度学习的 OAM 检测模型,并利用数据集进行模型测试,通过将模型载入 FPGA 检测平台实现了涡旋光束 OAM 模式的识别。

1 基本原理

柱坐标系中,拉盖尔-高斯 (Laguerre-Gaussian, LG) 光束光场表达式如下

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

式中, z 为光束的传播距离; k 是波数, $k=2\pi/\lambda$, λ 为光波波长, $z_R=(\pi w_0)/\lambda$ 是瑞利长度; $w(z)=w_0\sqrt{1+(z/z_R)^2}$ 为光束在传输距离 z 处的束径, w_0 为束腰径; L_p^l 为缔合拉盖尔多项式, p 和 l 分别径向模数和拓扑荷值; θ 为方位角; r 是柱坐标的径向分量。

将 $z=0$ 代入式 (1) 得 LG 光束在源平面处的光场表达式为

$$U_p^l(r, \theta, 0) = \sqrt{\frac{2p!}{\pi(|l|+p)!}} \frac{1}{w_0} \left(\frac{r\sqrt{2}}{w_0} \right)^{|l|} \exp \left(-\frac{r^2}{w_0^2} \right) \exp(-il\theta) \quad (2)$$

当传播距离 $z=0$ 且径向指数 $p=0$ 时, 式 (2) 可表示为

$$U_{p=0}^l(r, \theta, 0) = \sqrt{\frac{2}{\pi(|l|)!}} \frac{1}{w_0} \left(\frac{r\sqrt{2}}{w_0} \right)^{|l|} \exp \left(-\frac{r^2}{w_0^2} \right) \exp(-il\theta) \quad (3)$$

根据广义惠更斯-菲涅尔原理, 利用相位屏法研究湍流大气对光束的影响, 忽略复相位扰动中的振幅波动, 只考虑相位扰动, $\Psi(\mathbf{r}, s)$ 是湍流引起的复相位扰动, $\Psi(\mathbf{r}, s) = i\zeta(\mathbf{r}, s)$, 湍流中传输距离为 z 后的光束光场为

$$U(\mathbf{r}, z) = -\frac{ik}{2\pi z} \exp(ikz) \iint U(\mathbf{s}, 0) \exp\left[\frac{ik|\mathbf{s} - \mathbf{r}|}{2z} + i\zeta(\mathbf{r}, s)\right] d^2s \quad (4)$$

式中, 其中 $\zeta(\mathbf{r}, s)$ 是相位起伏; s 为传输距离 z 时的柱坐标分量。

随机相位屏进行叠加后, 光束光场为

$$U_r(s) = U_i(s) \exp[i\zeta(s)] \quad (5)$$

基于角谱衍射理论, 对式 (5) 进行傅里叶逆变换得

$$U_r(s) = \frac{1}{(2\pi)^2} \iint F(\kappa) \exp[i\kappa s] d^2\kappa \quad (6)$$

式中, $F(\kappa)$ 取傅里叶逆变换可以得到 $F(\kappa) = \iint U_r(s) \exp(-i\kappa s) d^2s$, κ 为波矢。波束在两个相位屏之间的传输可表示为

$$F_r(\kappa, z_2) = F_r(\kappa, z_1) \exp(i(z_2 - z_1)\kappa_z) \quad (7)$$

式中 $\kappa_z = \sqrt{\kappa^2 - \kappa_x^2 - \kappa_y^2}$, 因此在下一个接收面表示为

$$U_r(s, z_2) = \frac{1}{(2\pi)^2} \iint F(\kappa, z_2) \exp(i\kappa s) d^2\kappa \quad (8)$$

光束在湍流中的传输过程等效为通过多个相位屏, 以此是对上述过程的不断重复, 整个计算过程可以表示为

$$U(s, z) = F^{-1}\left\{\exp[i\kappa_z z] F[U(s) \exp(i\zeta(s))]\right\} \quad (9)$$

F 和 F^{-1} 分别表示傅里叶变换与傅里叶逆变换。

运用功率谱反演法来生成湍流大气中的随机相位屏。使用大气湍流相位起伏的功率谱作为滤波器, 对一个复高斯随机白噪声场进行滤波处理, 再对滤波后的相位折射率功率谱进行傅里叶逆变换, 得到等效大气湍流特性的相位屏

$$\phi(x, y) = (C_{(n,m)} \sqrt{\Phi_\phi(\kappa)}) \quad (10)$$

式中, $C_{(n,m)}$ 为傅里叶级数系数; $\Phi_\phi(\kappa)$ 为相位折射率功率谱密度 (Power Spectrum Density,

PSD)。柯尔莫哥洛夫 (Kolmogorov) 折射率功率谱的表达式为

$$\Phi_n(\kappa) = 0.033 C_n^2 \kappa^{-11/3} \quad (11)$$

$\Phi_n(\kappa)$ 与相位折射率 PSD $\Phi_\phi(\kappa)$ 的关系为

$$\Phi_\phi(\kappa) = 2\pi^2 k^2 \Delta z \Phi_n(\kappa) \quad (12)$$

式中, k 为波数, Δz 为传输距离。

2 仿真与实验

2.1 涡旋光束实验光斑图的生成及特性

根据式 (10) ~ (12) 理论分析, 得到不同湍流强度下的湍流相位屏如图 1 所示。




图 1 不同湍流强度下的随机相位屏

涡旋光束经模拟湍流扰动的随机相位屏, 得到如图 2 所示传输距离 $z=1000\text{m}$ 时, 光束通过自由空间 (Free Space, FS) 与不同湍流强度下的涡旋光斑仿真图。




图 2 不同拓扑荷数涡旋光束经湍流传输后的光斑仿真图

图 2 中, 在大气湍流影响下, 涡旋光束的空心环状边缘逐渐模糊, 光斑形状发生畸变, 且随着湍流强度的增大, 光束的畸变程度增加, 影响对涡旋光束 OAM 模式的检测。图 3 为拓扑荷值为 3 时, 光束在传输距离 1000m、2000m、3000m 通过自由空间与不同湍流强度下的涡旋光斑仿真图。

由图 3 可知, 不同湍流强度下, 随着涡旋光束传输距离增加, 光斑畸变愈发明显, 光斑边缘越发不清晰。则湍流强度和光束传输距离都会影响涡旋光束的传输, 影响对涡旋光束 OAM 模式的检测。图 4 为拓扑荷值 $l=3$ 时不同传输距离涡旋光束湍流实验的实验光路如图 4 所示。




图3 不同传输距离下涡旋光束经湍流强度传输后的光斑仿真图




图4 涡旋光束湍流实验的实验光路

图4中实验光路由激光器 (Laser)、透镜 (L)、空间光调制器 (SLM)、半波片 (HWP)、偏振片 (P)、圆形光阑 (CA) 和 CCD 光斑图像采集系统组成。激光器出射的激光光束经 L 准直后, 经半波片和偏振片形成线偏振光束, 经加载有叉形光栅的透射式空间光调制器 (Spatial Light Modulator, SLM) 加载相位信息, 通过改变叉形光栅中心的 Y 型结构产生不同拓扑荷的涡旋光束, 接着利用圆形光阑选择 1 级衍射光束, 通过加载湍流相位屏的反射式 SLM, 模拟涡旋光束在大气湍流中传输, 最后利用 CCD 相机采集经过湍流传输后的涡旋光束光斑图, 以完成训练数据集的建立。

图5为根据图4搭建的涡旋光束湍流实验光路实物图, 在实验室环境下模拟大气湍流影响下涡旋光束的传输。图5中, 使用透射式 SLM 加载叉形光栅产生不同拓扑荷数的涡旋光束, 使用反射式 SLM 加载随机相位屏模拟光束在大气湍流环境下传输, 通过调节 CCD 曝光时间使光强分布图便于观察。采用的深度学习识别涡旋光束 OAM 模式, 需要大量不同湍流强度下不同模式的光斑数据。因此在图5所示的结构实际操作中, 利用软件对加载到反射式 SLM 上的相位屏进行滚动播放, 每三秒切换一次相位屏, 同时在透射式 SLM 上切换不同阶段的光栅, 产生的不同拓扑荷数的涡旋光束分别通过反射式 SLM, 模拟大气湍流对涡旋光束的扰动。最后利用 CCD 每三秒采集一次光斑, 完成光斑图

数据集的构建。图6为拓扑荷数取 1、2、3 的涡旋光束经 $C_n^2 = 1.0 \times 10^{-18} m^{-2/3}$ 、 $C_n^2 = 1.0 \times 10^{-16} m^{-2/3}$ 、 $C_n^2 = 1.0 \times 10^{-15} m^{-2/3}$ 、 $C_n^2 = 1.0 \times 10^{-14} m^{-2/3}$ 和 $C_n^2 = 2.5 \times 10^{-13} m^{-2/3}$ 的湍流环境传输后的光斑实验图。



图5 涡旋光束湍流实验光路实物图




图6 涡旋光束经湍流传输后的光斑实验图

由图6可知, 在大气传输过程中涡旋光束光强呈空心环状, 随着涡旋光束拓扑荷数增大, 光斑图中心暗斑尺寸逐渐增大。受大气湍流强度影响, 涡旋光束的空心环状结构边缘逐渐模糊, 光斑形状发生畸变, 畸变程度随着湍流强度的增大愈加剧烈, 导致在传输过程中引起 OAM 模式间的串扰, 影响对涡旋光束 OAM 模式的检测。理论仿真实验得到验证。

2.2 涡旋光束光斑图像数据集训练及验证

图7为涡旋光束 OAM 模式识别模型总体框图, 图中选用 ResNet18 残差网络, 可以在缺少光学元件的情况下有效提取光斑图像特征, 且体积轻巧方便携带, 比 PC 端具有更小的能耗比。任务可操纵时间更长。ResNet18 结构共有 20 层, 其中 17 层卷积层、2 层池化层和 1 层全连接层, 18 层网络权重层。输入图片的尺寸大小为 224×224 , 卷积层含有 64 个大小为 7×7 的卷积核。卷积后进行首次池化操作, 池化核大小为 3×3 , 步长为 2, 利用最大池化操作进行池化, 单次移动的步长小于池化核窗口大小, 使池化区发生重叠, 池化重叠能再次避免过拟合。二次卷积层卷积核大小为 3×3 , 步长为 2, 共有 13 层。二次池化操作使用平均池化, 7×7 平均池化将每一个通道的所有数相加求平均值, 最后得到与通道数相符的数。二次池化后图像进入全连接层, 最终于输出层分类输出。




图 7 涡旋光束 OAM 模式识别模型

数据集的构建需按湍流强度和光束拓扑荷分类选取，利用透射式SLM加载叉形光栅的方式，生成拓扑荷范围为 $[-4, 4]$ 的8种涡旋光束。利用仿真生成 $C_n^2=1.0 \times 10^{-18} m^{-2/3}$ 、 $C_n^2=1.0 \times 10^{-16} m^{-2/3}$ 、 $C_n^2=1.0 \times 10^{-15} m^{-2/3}$ 、 $C_n^2=1.0 \times 10^{-14} m^{-2/3}$ 和 $C_n^2=2.5 \times 10^{-13} m^{-2/3}$ 五种湍流强度的相位屏，同时切换8种不同的拓扑荷数的涡旋光束，根据数据集8: 2划分训练集和验证集，每种湍流类别生成250张随机相位屏，获得10000张不同的光斑图。将相同拓扑荷数的涡旋光束对应的不同湍流强度下的图片混合并标注为同一类别，即每种类别的涡旋光束标签对应1000张图片建立训练集，训练集共计8000张图片，将数据集的20%分割给验证集，验证集共计2000张图片。图8为混合数据集的模型准确率变化曲线。

图8中的曲线图横坐标代表迭代次数，左侧纵坐标代表识别准确率，右侧纵坐标代表识别损失值。由图可知，模型共迭代了50次，随着迭代次数的增加，模型的训练准确度与验证准确度总体呈上升趋势，训练损失度与验证损失度总体呈下降趋势，第5次迭代时，训练准确率和验证准确率都超过了90%，训练损失值和验证损失值都下降到0.01。在第10次迭代后验证精确度与验证损失度逐渐趋于稳定，分别达到了96.6%和0.004。精确度在第10次迭代后上升速度逐渐减慢，损失度下降速度也逐渐减缓，在第20次迭代后逐渐平稳，精确度最高达到了97%，损失度最低达到0.003。

为探究网络模型在不同湍流强度下的具体表现，在 $C_n^2=1.0 \times 10^{-18} m^{-2/3}$ 、 $C_n^2=1.0 \times 10^{-16} m^{-2/3}$ 、 $C_n^2=1.0 \times 10^{-15} m^{-2/3}$ 、 $C_n^2=1.0 \times 10^{-14} m^{-2/3}$ 、 $C_n^2=2.5 \times 10^{-13} m^{-2/3}$ 的湍流环境下，对拓扑荷范围为 $[-4, 4]$ 这8种涡旋光束每种取250张光斑图组成数据集，每种湍流强度的数据集各有2000张图片。






图 8 模型准确率随迭代次数变化曲线

图9为网络模型分别在传输距离1000m的五种湍流环境下对涡旋光束OAM模式识别准确率与损失率变化曲线。图9(a)是准确率随迭代次数的变化趋势，图9(b)是损失率随迭代次数的变化趋势。图9(a)中， $C_n^2=1.0 \times 10^{-18} m^{-2/3}$ 湍流环境下，验证集准确率在第1次迭代时就达到100%，随着湍流强度增大，验证集的初次迭代准确率下降，在 $C_n^2=1.0 \times 10^{-15} m^{-2/3}$ 湍流环境下，验证集准确率在迭代5次左右时达到100%，并保持稳定，在 $C_n^2=2.5 \times 10^{-13} m^{-2/3}$ 湍流环境下，需要迭代20次左右才能稳定，最终准确率达到99%。图9(b)中，五种湍流环境下，损失函数在初始时较高，这是由于网络参数并未训练完备，未找到最优解，在迭代近30次左右损失函数达到收敛，表明网络的检测性能稳定，能有效识别涡旋光束OAM模式。在损失函数达到收敛之后，观察发现损失收敛值随湍流强度的增加而增大。说明随着湍流强度增大，网络模型识别能力受干扰的程度增加，湍流强度越大影响越大。

为了更全面的评估模型的识别能力，在弱湍流、中湍流和强湍流环境下，根据数据集8: 2划分训练集和验证集，总计2000张光斑图，平均每种湍流环境下共有400张光斑图，组成五组测试集，对



(a) 准确率变化曲线




(b) 损失率变化曲线


图9 不同湍流环境下的OAM模式识别
准确率与损失率随迭代次数变化曲线

拓扑荷范围为 $[-4, 4]$ 的8种涡旋光束进行验证。采用混淆矩阵对模型识别结果进行度展示,混淆矩阵的行为预测标签,表示模型的识别结果,混淆矩阵的列为真是标签,表示模型的真实结果。行和列的标签为涡旋光束的OAM模式,混淆矩阵的对角线上的图片个数为正确识别个数,未在对角线的图片个数为识别错误个数。具体结果如图10所示。

图10(a)为模型在 $C_n^2 = 1.0 \times 10^{-18} m^{-2/3}$ 、 $C_n^2 = 1.0 \times 10^{-16} m^{-2/3}$ 、 $C_n^2 = 1.0 \times 10^{-15} m^{-2/3}$ 湍流环境下的识别结果混淆矩阵图,表示模型的识别结果和真实结果是一致的,识别准确率为100%,正确识别结果的计算概率为0.990以上,平均计算概率为0.995。模型在 $C_n^2 = 1.0 \times 10^{-18} m^{-2/3}$ 、 $C_n^2 = 1.0 \times 10^{-16} m^{-2/3}$ 、 $C_n^2 = 1.0 \times 10^{-15} m^{-2/3}$ 湍流环境下的识别表现极佳。图10(b)为模型在 $C_n^2 = 1.0 \times 10^{-14} m^{-2/3}$ 和 $C_n^2 = 2.5 \times 10^{-13} m^{-2/3}$ 湍流环境下的识别结果混淆矩阵图,识别正确的光斑图有794张,识别错误的光斑图有6张,识别准确率为99.2%。OAM模式为 ± 2 、 ± 3 和 ± 4 的光斑图识别效果较差,容易发生模间串扰,除此之外其它模式的识别数量均为100张,识别全部正确,800张光斑图正确识别的概率整体平均为0.975。测试表明模型在湍流强度高环



(a) $C_n^2 = 1.0 \times 10^{-18} m^{-2/3}$ 、 $C_n^2 = 1.0 \times 10^{-16} m^{-2/3}$ 、 $C_n^2 = 1.0 \times 10^{-15} m^{-2/3}$ 湍流环境下的混淆矩阵



(b) $C_n^2 = 1.0 \times 10^{-14} m^{-2/3}$ 、 $C_n^2 = 2.5 \times 10^{-13} m^{-2/3}$ 湍流环境下的混淆矩阵

图10 不同环境下的混淆矩阵识别结果

境下的识别表现低于湍流强度低的环境下。

2.3 FPGA加速器设计

在FPGA实现中,使用定点量化、数组分割、循环优化和乒乓缓冲的优化策略实现OAM模式识别模型加速器设计,加速器系统框架如图11所示。




图11 加速器设计系统框架

由图11知,加速器系统框架PS端主要进行读写SD卡图像数据、调用算子IP核进行前向推理等工作,PL端主要通过AXI总线与片外存储器进行数据交互,在BRAM上完成数据缓存,辅助PS端进行数据计算。加速器设计使用的是重叠式架构,为每个算子设计独立的数据处理引擎,可以跨层复用,使加速器具有一定的兼容性。

数据定点量化。由于FPGA上没有专门的浮

点数计算单元，建立浮点数计算单元需要消耗大量的逻辑资源，需对浮点数进行定点数转换。使用16位定点数计算，数据的存储大小约减小了二分之一，虽然计算精度有微小下降，但损失可以忽略不计，反映到深度神经网络的检测精度上，对检测精度没有影响。

数组分割。使用ARRAY_PARTITION指令对数组进行分割，利用完全分区complete方法将数组分解为多个独立的数据，即数组的每个数据都被分割开来，使每个数据都能被独立访问，最大化了数据并行访问能力。

循环优化。循环流水方法是使用#pragma HLS PIPELINE II=1指令对循环进行流水线优化，II=1指定了流水线的初始化间隔为1，指每次循环之间的最小周期数，意味着在每个周期开始都会进行一个新的循环。循环展开方法是使用#pragma HLS UNROLL指令对循环体进行展开，展开因子factor默认是完全展开，即创建总循环次数N个循环体并行执行，提高了系统数据吞吐量，减小了计算时延。

乒乓缓冲。使用两个buffer实现数据的无缝传输和处理的，在首个周期，数据被写入到第一个buffer，在第二个周期，下一组数据被写入第二个buffer的同时读出第一个buffer的数据，使输入和读出同时进行，从而覆盖了输入时间，达到提高吞吐量的目的。将本文设计的OAM识别模型在FPGA平台上的加速器性能分别与CPU和GPU平台实验进行对比，通过实验得到识别模型在不同平台上的性能如表1所示。

表 1 各平台加速性能对比

实验平台	CPU (I5-1140F)	GPU RTX3060	FPGA ZYNQ7020
数据精度/bit	32	32	16
推理时间/s	3.5	0.29	0.58
平均性能/GOPS	6.05	38.15	6.23
功耗/W	61.63	161.16	2.844
能效比(GOPS/W)	0.10	0.24	2.19

如表1所示，系统设计的加速器使用的FPGA平台型号为ZYNQ7020，与CPU和GPU相比，FPGA平台的数据精度仅16bit，FPGA的功耗仅2.844W，且能效比均高于CPU和GPU，分别为CPU和GPU的22倍和9倍。加速器系统整体资源利用占比和使用数量如表2所示。

由表2可知，卷积模块大量的使用LUT中的逻辑单元，使得LUT的使用率为81%。BRAM用于

表 2 加速器系统整体资源利用占比表

资源	已利用	可利用	利用占比/%
LUT	43142	53200	81.09
LUTRAM	7536	17400	43.31
FF	40207	106400	37.79
BRAM	100.50	140	71.79
DSP	220	220	100.00
BUFG	1	32	3.13

存储各计算模块的计算结果，因此当LUT使用率很高时，BRAM的资源占比也会很高，使用率为72%。执行各计算模块中的乘累加操作的DSP资源利用占比最高，达到了100%。在测试中发现系统的整体资源利用达到了最大化，220个DSP全部使用，虽然LUT，BRAM等资源未全部使用完毕，但继续增加卷积的计算能力，系统将无法完成布局布线。

加速器设计完成后，将模型训练阶段导出的权重和待检测光斑图文件存放在SD卡中，将SD卡插入FPGA卡槽，接通电源，加速器计算完成后，再将计算结果文件保存到SD卡中，最终对计算结果进行处理后得到每张涡旋光斑图像的OAM模式分类和分类概率，如图12为八种不同OAM模式涡旋光斑的识别结果，结果表明实际测量结果与模拟结果一致。

3 结 论

本文利用空间光调制器实现随机相位屏模拟湍流环境，结合深度学习研究方法研究涡旋光束在湍流中传输的轨道角动量特性，将构建的神经卷积网络模型加载到FPGA测试平台进行涡旋光束OAM模式识别，并分析了湍流强度对涡旋光束OAM模式识别的影响。

仿真计算及实验研究发现，涡旋光束在传输中，随着湍流强度增大，光束的环状空心结构逐渐模糊，光斑形状发生畸变，且畸变程度随湍流强度的增大而增加；随着传输距离增大，光斑畸变愈发明显，光斑边缘越发不清晰，湍流强度和传输距离均能影响光束传输。实验表明，在8000张光斑图的训练下产生的训练集，在2000张光斑图进行检测时，涡旋光束OAM在 $C_n^2 = 1.0 \times 10^{-18} m^{-2/3}$ 、 $C_n^2 = 1.0 \times 10^{-16} m^{-2/3}$ 、 $C_n^2 = 1.0 \times 10^{-15} m^{-2/3}$ 湍流环境下，模型识别准确率稳定在100%，在 $C_n^2 = 1.0 \times 10^{-14} m^{-2/3}$ 和 $C_n^2 = 2.5 \times 10^{-13} m^{-2/3}$ 湍流环境下，模型识别精确度最终稳定于99%，网络模型的识别能力随着湍流强度的增大而有所减弱。经测试




图12 涡旋光斑识别结果

数据集验证模型, 在 $C_n^2 = 1.0 \times 10^{-18} m^{-2/3}$ 、 $C_n^2 = 1.0 \times 10^{-16} m^{-2/3}$ 、 $C_n^2 = 1.0 \times 10^{-15} m^{-2/3}$ 湍流环境下的1200张光斑图的OAM模式全部成功识别, 在 $C_n^2 = 1.0 \times 10^{-14} m^{-2/3}$ 和 $C_n^2 = 2.5 \times 10^{-13} m^{-2/3}$ 湍流环境下的800张光斑图中, 有794张识别成功, 成功准确率99.2%, 说明涡旋光束OAM模式识别模型对光束识别能力及准确率在强湍流环境下会受到影响。构建的神经卷积网络模型可载入FPGA硬件测试平台, 实现了对光斑数据的处理及涡旋光束OAM模式的识别。

参考文献:

- [1] 娄岩, 陈纯毅, 赵义武, 等. 高斯涡旋光束在大气湍流传输中的特性研究[J]. 中国光学(中英文), 2017, 10(6): 768—776.
Lou Yan, Chen Chunyi, Zhao Yiwu, et al. Characteristics of gaussian vortex beam in atmospheric turbulence transmission[J]. Chinese Optics, 2017, 10(6): 768—776.
- [2] 吕燕来, 黄磊, 高春清. 光学坐标变换实现光束轨道角动量模式分束的技术研究[J]. 光学技术, 2022, 48(06): 679—683.
Lv Yanlai, Huang Lei, Gao Chunqing. Optical coordinate transformation-based technique for orbital angular momentum (OAM) mode beam splitting[J]. Optical Technique, 2022, 48(06): 679—683.
- [3] 柯熙政, 吴加丽, 杨尚君. 面向无线光通信的大气湍流研究进展与展望[J]. 电波科学学报, 2021, 36(03): 323—339.
Ke Xizheng, Wu Jiali, Shang jun. Research progress and prospects of atmospheric turbulence for wireless optical communication[J]. Journal of Radio Science, 2021, 36(03): 323—339.
- [4] Ming Z, Xindi T, Weixian W, et al. A novel deep-learning model compression based on filter-stripe group pruning and its IoT application[J]. Sensors, 2022, 22(15): 5623—5623.
- [5] 吕浩, 张盛兵, 王佳, 等. 卷积神经网络SIP微系统实现[J]. 计算机工程与应用, 2021, 57(05): 216—221.
Lv Hao, Zhang Shengbing, Wang Jia, et al. Implementation of convolutional neural networks on a system-in-package (SiP) micro-system[J]. Computer Engineering and Applications, 2021, 57(05): 216—221.
- [6] Odetola T A, Groves K M, Mohammed Y, et al. 2L-3W: 2-Level 3-Way hardware-software co-verification for the mapping of convolutional neural network (CNN) onto FPGA boards[J]. SN Computer Science, 2021, 3(1): 60.
- [7] 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.
- [8] Qingsong Z, Shiqi H, Yong W, et al. Mode detection of misaligned orbital angular momentum beams based on convolutional neural network[J]. Applied Optics, 2018, 57(35): 10152—10158.
- [9] Wang P, Zhang X, Fan D, et al. Convolutional neural network-assisted optical orbital angular momentum recognition and communication[J]. IEEE Access, 2019, 7: 162025—162035.
- [10] Xizheng K, Meng C. Recognition of orbital angular momentum vortex beam based on convolutional neural network[J]. Microwave and Optical Technology Letters, 2021, 63(7): 1960—1964.
- [11] 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(06): 45—54.
Zheng Conghui, Wang Tianshu, Liu Zheqi, et al. Recognition of orbital angular momentum beams using deep transfer learning methods[J]. Opto-Electronic Engineering, 2022, 49(06): 45—54.
- [12] Wang Z, Lai X, Huang H, et al. Recognizing the orbital angular momentum (OAM) of vortex beams from speckle patterns[J]. Science China (Physics, Mechanics & Astronomy), 2022, 65(04): 59—65.
- [13] Zhang Z, Yin X, Cui X, et al. Performance analysis of modulating retro-reflector link based on orbital angular momentum coding in underwater channels[J]. Optics Communications, 2022, 510: 127903.
- [14] 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): 209—215.
Liu Xuelian, Chen Xundong, Lin Zhili, et al. Deep learning-assisted measurement of topological charge in strongly scattered vortex beams[J]. Acta Optica Sinica, 2022, 42(14): 209—215.
- [15] M Z M K, A M R, M M, et al. L-band InAs/InP quantum dash laser spatial OAM light modes classification under smoke environment: an image processing enhanced deep learning approach[J]. Optics and Laser Technology, 2024, 168: 109933.
- [16] 孙立虎, 李萍萍, 刘素娟, 等. 基于矢量涡旋光束和深度学习的图像信息编解码[J]. 激光与光电子学进展, 2025, 62(10): 1007001.
Lihu Sun, Pingping Li, Sujuan Liu, et al. Image information encoding and decoding based on vector vortex beam and deep learning[J]. Laser & Optoelectronics Progress, 2025, 62(10): 1007001.