

基于光学衍射神经网络的线性偏振光模式识别研究

付马标^{1,2,3}, 任若静^{1,2*}, 张启明^{1,2*}

¹上海理工大学智能科技学院, 上海

²上海理工大学光子芯片研究院, 上海

³上海理工大学理学院, 上海

收稿日期: 2025年5月11日; 录用日期: 2025年6月3日; 发布日期: 2025年6月11日

摘要

光模式识别在光通信、光学成像及传感等领域具有重要应用前景, 尤其在提高系统容量与处理效率方面扮演关键角色。传统识别方法主要依赖于数字信号处理或衍射光学元件, 存在计算复杂度高、功耗大等问题, 或缺乏泛化处理能力。本文提出一种基于衍射光学神经网络(Diffractive Neural Networks, DNNs)的光学光模式识别框架, 专注于线性偏振(LP)模式的识别任务。通过引入拉盖尔-高斯模式构建的大规模复振幅光场数据集(共2000组样本), 并设计四层衍射网络进行训练与优化, 系统对模式的识别准确率达到94.6%。仿真结果显示本方案具备优异的识别精度, 展示出良好的应用潜力。本文研究为下一代低功耗、高效率的全光学计算系统提供了理论依据与设计框架, 也为未来物理实现奠定了基础。

关键词

光场模式识别, 衍射神经网络, 线性偏振模式

Research on the Linearly Polarized Optical Mode Recognition Based on Optical Diffractive Neural Network

Mabiao Fu^{1,2,3}, Ruojing Ren^{1,2*}, Qiming Zhang^{1,2*}

¹School of Artificial Intelligence Science and Technology, University of Shanghai for Science and Technology, Shanghai

²Institute of Photonic Chips, University of Shanghai for Science and Technology, Shanghai

³College of Science, University of Shanghai for Science and Technology, Shanghai

Received: May 11th, 2025; accepted: Jun. 3rd, 2025; published: Jun. 11th, 2025

*通讯作者。

文章引用: 付马标, 任若静, 张启明. 基于光学衍射神经网络的线性偏振光模式识别研究[J]. 建模与仿真, 2025, 14(6): 58-66. DOI: 10.12677/mos.2025.146475

Abstract

Optical mode recognition has significant application prospects in fields such as optical communication, optical imaging, and sensing, especially in enhancing system capacity and processing efficiency. Traditional recognition methods mainly rely on digital signal processing or diffractive optical elements, which have problems such as high computational complexity and high power consumption, or lack of generalization processing capabilities. This paper proposes an optical mode recognition framework based on diffractive neural networks (DNNs), focusing on the recognition task of linearly polarized (LP) modes. By introducing a large-scale complex amplitude optical field dataset constructed from Laguerre-Gaussian modes (with a total of 2000 samples), and designing a four-layer diffractive network for training and optimization, the system achieves a recognition accuracy of 94.6% for the modes. Simulation results show that this scheme has excellent recognition accuracy and demonstrates good application potential. This research provides a theoretical basis and design framework for next-generation low-power, high-efficiency all-optical computing systems, and lays the foundation for future physical implementation.

Keywords

Optical Mode Recognition, Diffraction Neural Networks, Linearly Polarized Mode

Copyright © 2025 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

在光通信、光学成像和智能传感等前沿领域，光模式识别作为一种关键技术，承担着信息提取与解码的重要角色。特别是在多模态光通信系统中，不同空间模式通过模式分复用可显著扩展带宽容量，偏振分复用(PDM)可实现 100%增益，模式分复用(MDM)进一步提升，特别在 5G 网络中满足高带宽需求[1][2]。而在高精度传感和光场重构任务中，准确识别和追踪光模式更是决定系统感知精度与鲁棒性的核心因素[3][4]。

然而，尽管光模式识别技术在某些场景下已实现工程化应用，但现有的主流方法仍存在诸多局限。传统上，数字信号处理(DSP)技术被广泛采用，虽然其具备一定的灵活性，但依赖电-光转换来获取光场数据，进而进行复杂运算。这种方式在处理大规模输入时，往往因计算负担过重和能耗过高而难以满足实时性需求[5]-[8]。在光通信场景中，DSP 方法通常引入纳秒到微秒级别的处理延迟，可能影响高实时性要求的系统效率[9]。另一方面，基于光学元件的方法如光栅或光学滤波器，在特定模式选择上高效，但因其静态设计，缺乏对动态多模光场环境的适应性，难以满足复杂通信场景的需求[10]。近年来，全光计算范式的兴起为解决上述问题带来了新的希望。基于衍射结构的光学神经网络(Diffractive Neural Networks, DNNs)以其独特优势逐渐受到关注[11]-[13]。这种技术直接在光域内完成信息调控，展现出天然的并行性和低功耗特性。已有研究表明，DNNs 在图像识别和边缘检测等任务中取得了令人瞩目的成果，其核心在于对光场传播过程的精细调控能力，能够高效处理复杂的光学信息[14][15]。然而，针对复杂光场的研究多集中于 OAM 模式的识别[16][17]，而对线性偏振(LP)模式的研究相对较少，这主要源于其强度分布特性复杂、模式耦合和串扰严重，导致高效全光学识别方法匮乏，限制了其在高维信息编码中的应用[18]。

尽管如此, LP 模式作为光纤通信中常见的传输状态, 因其良好的正交性和模分复用能力, 仍被认为是下一代光通信技术的重要调制方式[19]-[21]。在纯光学域内准确识别具备复杂空间干涉特性的叠加模式, 对神经网络结构设计提出了更高要求。

基于此, 本文提出了一种基于 DNNs 的全光学光模式识别系统, 专注于 LP 模式的建模、仿真和分类识别任务。通过理论建模与数值仿真的结合, 本文首次构建了一个融合拉盖尔-高斯模式叠加的复数光场数据集, 并设计了包含四层衍射层的可训练网络结构, 以实现输入模式的精确判别。这项研究不仅验证了更灵活、低功耗全光计算系统的可行性, 也为未来光学智能信息处理硬件的设计提供了重要的技术参考。

本文的主要贡献可以概括为以下几点: 首先, 我们系统性地构建了一套全光域的识别流程, 利用多层衍射相位调控结构对输入光场进行调制与转换, 成功实现了对常见 LP 模式的高效分类识别, 避免了传统方法中繁琐的电光转换过程, 展现出低功耗与高并行度的优势; 其次, 针对 LP 模式的空间特性, 我们设计了一种结合广义拉盖尔多项式与随机相位叠加的复振幅建模方法, 真实模拟了多模光场干涉效果。这项工作不仅在仿真层面验证了系统的潜力, 也为未来硬件集成奠定了基础, 例如与现有光纤通信系统的兼容性提供了可能。

2. 仿真方法与系统设计

为了验证基于 DNNs 的光模式识别系统的可行性, 本文通过数值仿真构建并优化了一个专门针对 LP 模式识别的计算框架。本节将从理论基础、数据集构建以及模型架构与训练设计三个方面展开详细讨论。

2.1. 理论基础

光模式识别的核心在于精确描述和区分光场的空间分布特性。LP 模式作为光纤中常见的传输模式, 其复振幅分布在自由空间中可以通过拉盖尔-高斯(LG)模式进行近似表达。LP 模式的电场分布可以用以下公式表示:

$$\Psi_{l,p}(r,\theta) = \sqrt{\frac{2^{l+1} \cdot p!}{\pi \cdot (l+p)!}} \cdot \left(\frac{\sqrt{2}r}{\omega_0}\right)^l \cdot L_p^l\left(\frac{2r^2}{\omega_0^2}\right) \cdot \exp\left(-\frac{r^2}{\omega_0^2}\right) \cdot \cos(l\theta) \quad (1)$$

其中, l 和 p 分别表示角向和径向量子数, r 和 θ 为极坐标系下的径向和角向坐标, ω_0 为光束腰斑半径, L_p^l 为广义拉盖尔多项式。这一数学近似能够有效刻画自由空间中的光场分布特性。例如, 当 $l=0, p=0$ 时, LP₀₁ 模式的电场呈现出典型的高斯光束形状, 这为我们模拟基本传输状态提供了便利。

在 DNNs 框架中, 光场的传播模拟采用了基于菲涅耳衍射理论的角谱法。这种方法适用于自由空间光场传播的精确计算, 其基本原理是通过傅里叶变换实现光场从输入平面到输出平面的传播。对于输入光场 $U(x,y,0)$, 其在距离 z 处的输出光场 $U(x,y,z)$ 可通过以下关系式计算:

$$U(x,y,z) = F^{-1}\{F[U(x,y,z)] \cdot H(f_x, f_y, z)\} \quad (2)$$

其中, F 和 F^{-1} 分别表示傅里叶变换和逆傅里叶变换, $H(f_x, f_y, z)$ 为角谱传播的传递函数, 定义为:

$$H(f_x, f_y, z) = \exp\left(jkz\sqrt{1-(\lambda f_x)^2-(\lambda f_y)^2}\right) \quad (3)$$

其中, k 为波数, λ 为波长, f_x 和 f_y 为空间频率。角谱法通过快速傅里叶变换实现高效计算, 在光学仿真领域应用广泛。在本文的研究中, 波长设定为 632 nm (氦氖激光的典型波长), 传播距离 z 为 4 mm。角谱法的计算效率优势在于其频域滤波机制, 避免了空间域直接卷积的高计算成本, 尤其在处理高分辨率光场数据时表现尤为突出。

2.2. 数据集构建

为了研究 LP 模式的识别问题,我们通过数值模拟构建了一个大规模数据集。本文选取了 LP01、LP02、LP11 和 LP12 四种模式,通过随机叠加 2 到 4 个模式生成复振幅光场作为输入信号,每个样本包含振幅和相位两部分信息。复光场的数学表达为:

$$\Psi_{super}(r, \theta) = \sum_{i=1}^N \Psi_{l_i, p_i}(r, \theta) \cdot e^{j\phi_i} \quad (4)$$

其中, N 为叠加模式数量, ϕ_i 为随机相位, 均匀分布在 $(0, 2\pi)$ 范围内。数据集总规模为 2000 个样本, 其中 1500 个用于训练, 500 个用于测试。样本图像的分辨率为 600×600 像素, 像素大小为 $1 \mu\text{m}$, 波长设定为 632.8 nm 。选择此波长是考虑到其在实验室中常见的氦氖激光器波长, 确保仿真结果与实际光学系统的兼容性。通过随机叠加不同 LP 模式, 我们模拟了实际应用中可能遇到的复杂光场分布, 为模型训练提供了多样化的输入条件。

数据集的生成过程包括以下步骤: 首先, 基于上述公式(1)计算单个 LP 模式的复振幅分布, 其中径向部分通过拉盖尔多项式近似, 角向部分采用余弦函数表示; 随后, 为每个模式引入随机相位并进行叠加, 确保模拟真实干涉效果; 最后, 对叠加后的光场进行功率归一化, 提取振幅和相位分布, 并保存为图像文件。为了进一步贴近实际场景, 我们在生成输出光场时, 考虑了不同模式的空间分布特性, 例如 LP01 模式能量集中在中心区域, 而 LP11 模式则呈现角向双瓣的对称分布。这种设计确保了训练数据覆盖了多种可能的模式组合特征, 有效增强了模型的泛化能力。数据集通过多次迭代生成累计达到 2000 组样本, 确保了数据的多样性和代表性。LP 模式的选择涵盖了从低阶到高阶的多种特征, 同时随机相位的引入模拟了真实环境中的噪声干扰, 进一步提升了数据集的实用价值。

值得一提的是, 尽管光纤中的 LP 模式通常可用贝塞尔函数更精确地描述, 但考虑到本研究聚焦于自由空间传播场景, 本文采用了拉盖尔多项式的近似方法。这一选择在计算复杂度上更具优势, 尤其是在大规模数据集生成中, 能够显著提高效率。此外, 本文还对生成的样本进行了强度和相位分布的可视化验证, 确保模式叠加后形成的复杂干涉图案与理论预期一致, 例如高阶模式呈现出更多的空间振荡特征, 而低阶模式则表现出更集中的能量分布。这种验证过程为数据质量提供了保障。

2.3. 模型设计与训练

在模型设计上, 本文构建了一个包含四层衍射层的 DNNs 架构(如图 1), 每层衍射层都包含可训练的相位调制参数, 参数范围设定为 0 到 2π , 通过优化调整实现对光场的精确调控。光场在层间的传播基于角谱法计算, 传播距离统一设为 4 mm , 以确保衍射特征的充分展开。最终, 在最后一层的输出层提取输出光场的振幅和相位信息, 作为模式识别的依据。这样的分层结构设计, 模拟了实际光学系统中光场通过多层衍射元件传播的过程, 充分利用了光学的并行计算特性, 能够高效处理复杂光场信息。

训练的目标是让 DNNs 准确识别输入 LP 模式的特征。为此, 本文设计振幅损失采用均方误差(MSE)计算, 并且乘以 100 的权重, 以快速优化强度分布的匹配。训练过程中, 我们选用了 Adam 优化器, 初始学习率设为 0.01, 批量大小为 10, 总共迭代 7 个 epochs。Adam 优化器通过自适应地调整梯度均值和方差的估计, 显著提高收敛速度, 尤其适合光学数据这种具有复杂特征的场景。7 个 epochs 的迭代次数则是通过试验确定的, 既避免了过拟合, 又确保了模型具备足够的泛化能力。训练过程中, 每完成一个 epoch 即进行一次测试, 以监控模型的收敛性和性能表现, 同时记录损失变化趋势, 便于后续分析模型的学习动态。

这种损失函数的设计在处理复杂叠加模式时, 能够有效捕捉光场的空间特征。此外, 我们还对模型参数的变化进行了监控, 通过可视化手段分析各层相位调制参数的分布和变化趋势。此模型的训练周期

的耗时约 30 min (CPU: Intel(R) Xeon(R) Platinum 8474C; GPU: RTX 4090D), 如果减少迭代周期至 4 个 epochs 以下, 则可以在 20 min 左右完成。




Figure 1. Schematic diagram of multi-layer diffractive neural network for optical mode recognition tasks
图 1. 用于光学模式识别任务的多层衍射神经网络示意图

3. 实验结果与讨论

我们评估了 DNN 系统在 LP 模式识别任务中的性能, 分析了损失函数变化和识别准确率。训练和测试过程中的振幅损失函数变化显示, 模型在前 2 个 epochs 内快速收敛, 随后逐渐趋于稳定。具体而言, 振幅损失从初始值 0.63 下降至 0.018 左右。这表明模型对 LP 模式强度分布的学习能力较强。图 2 展示了




Figure 2. The trend of MSE loss with the training epoch
图 2. 均方差损失随训练周期的变化趋势

损失随 epoch 的变化趋势, 直观呈现了模型的收敛过程。进一步分析损失变化的原因, 进一步分析损失变化的原因, 我们认为损失函数的快速下降得益于模型对低阶模式特征的快速学习, 以及优化器的高效收敛性能, 使得强度分布的匹配得以优先优化。值得注意的是, 训练和测试损失在后期趋于一致, 表明模型未出现明显过拟合, 具备较好的泛化能力。

在光场模式识别性能的评估中, 本文通过仿真实验对系统进行了详细分析。实验中, 输入光场由四种不同的 LP 模式(LP01、LP02、LP11、LP12)随机叠加而成。如图 3 所示, 实验结果表明, 模型在 500 个测试样本上的识别精度非常高, 约 94.6% 的样本振幅损失低于预设的 0.03 阈值, 平均振幅损失为 0.01568, 表明大多数样本的识别误差较小, 模型能够准确识别输入光场中的光学模式。




Figure 3. Distribution of mean square error loss of the test set

图 3. 测试集中均方差损失分布

具体来说, 低阶模式(如 LP01)的识别效果尤其突出, 其振幅分布与目标几乎完全一致, 主要能量分布区域与目标高度吻合。尽管高阶模式(如 LP11)存在轻微的偏差, 整体性能依然令人满意。进一步分析不同模式的识别性能差异时, 我们发现, 低阶模式(如 LP01)具有相对简单的空间分布(呈高斯形状), 因此模型能够较为迅速地捕捉其特征。而高阶模式(如 LP12)则包含更多复杂的空间振荡和干涉特征, 这使得模型在相位匹配方面表现略逊, 导致在边缘区域出现轻微的失真。图 4 展示了部分输入信号、输出结果和目标结果的强度分布对比。如图 4(a)~(f)我们列举了对两种模式的复光场进行识别的结果可以明显看到, 低阶模式的预测结果与目标几乎完全一致, 而小部分高阶模式的预测在边缘区域存在轻微失真。图 4(g)~(j)为对三种模式叠加的复光场识别的结果与目标结果的对比, 图 4(k)与(l)是不同引入随机相位的四种模式叠加的复光场的识别结果。此现象进一步验证了模型在处理不同模式时的性能差异, 尤其是在高阶模式的处理上, 仍有进一步优化相位匹配策略的空间。

与传统方法相比, DNNs 系统展现出显著优势。其全光学计算框架完全避免了电-光转换, 直接在光域内完成模式识别, 不仅大幅降低了功耗和延迟, 还展现出更高的灵活性。通过训练优化相位参数, DNNs

能够自适应处理不同模式的输入光场, 相比基于固定光学元件的方法, DNNs 具有更广泛的适应性。模型的训练周期的耗时约 30 min (CPU: Intel(R) Xeon(R) Platinum 8474C; GPU: RTX 4090D), 这展现了 DNNs 在处理大规模光场数据时的效率潜力。相比之下, DSP 方法因需要频繁的电-光转换和复杂后处理, 而 DNNs 直接在光域操作的优势则显得尤为突出。1500 个训练样本的大规模数据集进一步增强了模型的泛化能力, 使其在测试集上保持了高识别精度。




Figure 4. Comparison of recognition results of modes in complex light fields using DNNs

图 4. 使用 DNNs 对复杂光场中的模式进行识别结果对比

至于数据集生成方法的选择, 我们采用拉盖尔多项式结合 $\cos(l\theta)$ 来生成 LP 模式的复振幅分布, 主要基于自由空间传播场景的考虑。拉盖尔多项式结合高斯衰减项能够有效描述自由空间中的光场分布, 同时计算复杂度较低, 非常适合快速生成大规模数据集。我们的设计充分考虑了实际光场干涉的随机性, 例如通过随机选择模式数量和相位, 为模型训练提供了多样化的输入条件。未来, 我们计划结合贝塞尔函数生成更贴近光纤环境的模场数据, 以进一步验证模型的适应性。

当然, 当前研究也存在一些局限性。仿真中未考虑实际光学系统中的噪声影响, 这可能会对系统的鲁棒性构成挑战。后续可以在输入信号中引入噪声, 可以在数据集生成阶段添加随机噪声项, 模拟实际光学系统中的散射或热噪声影响, 从而增强模型在真实环境下的适应性和对噪声的鲁棒性。此外, 我们还考虑对损失函数进行动态调整, 例如根据训练阶段调整振幅和相位损失的权重, 以更好地平衡两者的优化过程。这些改进方向将进一步推动 DNNs 在光模式识别领域的实用化进程。

4. 总结与展望

通过本研究, 本文提出了一种基于衍射光学神经网络的光模式识别系统, 并通过仿真实验验证了其在 LP 模式识别中的应用潜力。实验结果表明, 基于 1500 个训练样本和 500 个测试样本的训练, 系统在测试集上的有 94.6% 的数据振幅损失小于 0.03 (100 倍均方误差), 充分展现了其高效、准确以及高适应性的特性。这项作为全光学信息处理提供了一种全新的解决方案, 尤其在光通信领域具有重要的潜在应用价值。

尽管当前研究主要基于仿真验证, 但为后续的实验研究和实际应用奠定了基础。首先, 我们计划接下来继续引入噪声模型以优化系统在复杂环境下的鲁棒性。此外, 我们还希望将系统扩展到其他光模式 (如 Hermite-Gaussian 模式) 的识别任务中, 进一步拓宽其应用范围。我们相信 DNNs 将在光模式识别领域实现更广泛的实用化, 为下一代低功耗、高效率的光学计算系统开辟新的可能性。

致 谢

本论文的完成离不开导师与同门的帮助和支持, 在此谨致以最诚挚的谢意。

基金项目

本研究由中国国家自然科学基金(12304400)、上海市教师专业发展项目——上海市青年教师培养资助项目、上海市科技重大专项、上海市前沿科学中心计划(2021~2025 年第 20 号)、上海市科技创新行动计划(23JC1403100 和 24JD1402700)资助。

参考文献

- [1] Badraoui, N. and Berceci, T. (2019) Enhancing Capacity of Optical Links Using Polarization Multiplexing. *Optical and Quantum Electronics*, **51**, Article No. 310. <https://doi.org/10.1007/s11082-019-2017-3>
- [2] Zou, K., Pang, K., Song, H., Fan, J., Zhao, Z., Song, H., *et al.* (2022) High-Capacity Free-Space Optical Communications Using Wavelength- and Mode-Division-Multiplexing in the Mid-Infrared Region. *Nature Communications*, **13**, Article No. 7662. <https://doi.org/10.1038/s41467-022-35327-w>
- [3] Jeon, H., Park, J., Choe, G., Park, J., Bok, Y., Tai, Y., *et al.* (2015) Accurate Depth Map Estimation from a Lenslet Light Field Camera. 2015 *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Boston, 7-12 June 2015, 1547-1555. <https://doi.org/10.1109/cvpr.2015.7298762>
- [4] Williem, W. and Park, I.K. (2016) Robust Light Field Depth Estimation for Noisy Scene with Occlusion. 2016 *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Las Vegas, 27-30 June 2016, 4396-4404. <https://doi.org/10.1109/cvpr.2016.476>
- [5] Niu, Z., Yang, H., Li, L., Shi, M., Xu, G., Hu, W., *et al.* (2024) Learnable Digital Signal Processing: A New Benchmark of Linearity Compensation for Optical Fiber Communications. *Light: Science & Applications*, **13**, Article No. 188. <https://doi.org/10.1038/s41377-024-01556-5>
- [6] Shao, C., Giacomidis, E., Billah, S.M., Li, S., Li, J., Sahu, P., *et al.* (2024) Machine Learning in Short-Reach Optical Systems: A Comprehensive Survey. *Photonics*, **11**, Article 613. <https://doi.org/10.3390/photonics11070613>
- [7] Pileri, D. (2019) Advanced Digital Signal Processing Techniques for High-Speed Optical Communications Links. arXiv:1903.12260. <https://doi.org/10.48550/arXiv.1903.12260>
- [8] Zhong, K., Zhou, X., Huo, J., Yu, C., Lu, C. and Lau, A.P.T. (2018) Digital Signal Processing for Short-Reach Optical Communications: A Review of Current Technologies and Future Trends. *Journal of Lightwave Technology*, **36**, 377-400. <https://doi.org/10.1109/jlt.2018.2793881>
- [9] Vitex (2025) Latency in Optical Transceivers. Vitex Tech.
- [10] Ruffato, G., Massari, M. and Romanato, F. (2016) Diffractive Optics for Combined Spatial- and Mode- Division Demultiplexing of Optical Vortices: Design, Fabrication and Optical Characterization. *Scientific Reports*, **6**, Article No. 24760. <https://doi.org/10.1038/srep24760>
- [11] Lin, X., Rivenson, Y., Yardimci, N.T., Veli, M., Luo, Y., Jarrahi, M., *et al.* (2018) All-Optical Machine Learning Using Diffractive Deep Neural Networks. *Science*, **361**, 1004-1008. <https://doi.org/10.1126/science.aat8084>

-
- [12] Luo, Y., Mengu, D., Yardimci, N.T., Rivenson, Y., Veli, M., Jarrahi, M., *et al.* (2019) Design of Task-Specific Optical Systems Using Broadband Diffractive Neural Networks. *Light: Science & Applications*, **8**, Article No. 112. <https://doi.org/10.1038/s41377-019-0223-1>
- [13] Fu, T., Zang, Y., Huang, H., Du, Z., Hu, C., Chen, M., *et al.* (2021) On-Chip Photonic Diffractive Optical Neural Network Based on a Spatial Domain Electromagnetic Propagation Model. *Optics Express*, **29**, 31924-31940. <https://doi.org/10.1364/oe.435183>
- [14] 项水英, 宋紫薇, 张雅慧, 等. 光子神经网络研究进展[J]. 光电工程, 2024, 51(7): 29-52.
- [15] Chen, H., Feng, J., Jiang, M., Wang, Y., Lin, J., Tan, J., *et al.* (2021) Diffractive Deep Neural Networks at Visible Wavelengths. *Engineering*, **7**, 1483-1491. <https://doi.org/10.1016/j.eng.2020.07.032>
- [16] Ruan, Z., Wang, B., Zhang, J., Cao, H., Yang, M., Ma, W., *et al.* (2024) Optical Mode Manipulation Using Deep Spatial Diffractive Neural Networks. *Optics Express*, **32**, 16212-16234. <https://doi.org/10.1364/oe.516593>
- [17] Wang, P., Xiong, W., Huang, Z., He, Y., Xie, Z., Liu, J., *et al.* (2021) Orbital Angular Momentum Mode Logical Operation Using Optical Diffractive Neural Network. *Photonics Research*, **9**, 2116-2124. <https://doi.org/10.1364/prj.432919>
- [18] Rjeb, A., Fathallah, H. and Machhout, M. (2021) OAM Modes in Optical Fibers for Next Generation Space Division Multiplexing (SDM) Systems. In: Huerta-Cuellar, G., Ed., *Fiber Optics-Technology and Applications*, IntechOpen, 7. <https://doi.org/10.5772/intechopen.97773>
- [19] 张振鹤, 刘丰年, 夏志鸿, 等. 光纤线性偏振模式组合对模分复用系统的影响研究[J]. 湖南工业大学学报, 2024, 38(1): 55-61.
- [20] 刘丰年, 翁艳彬, 刘志, 等. 基于模分与波分混合复用的直接检测光纤传输系统研究[J]. 光通信技术, 2022, 46(5): 64-69.
- [21] 张双熙. 少模光纤模式复用系统的均衡算法研究[D]: [硕士学位论文]. 天津: 河北工业大学, 2018.