

基于 CNN-Transformer 结合衍射的 分数阶轨道角动量模态识别*

周允城¹⁾ 张荣香^{1)†} 刘涛^{2)3)4)‡} 毕慧聪¹⁾ 侯芳¹⁾ 王新宇¹⁾

1) (河北大学物理科学与技术学院, 保定 071002)

2) (华北电力大学, 燕赵电力实验室, 保定 071003)

3) (华北电力大学电子与通信工程系, 保定 071003)

4) (华北电力大学, 河北省电力物联网技术重点实验室, 保定 071003)

(2025 年 8 月 1 日收到; 2025 年 9 月 11 日收到修改稿)

利用分数阶涡旋光束 (fractional vortex beams, FVBs) 作为信息载体可显著提高通信系统容量, 但由于相邻分数阶轨道角动量 (fractional orbital angular momentum, FOAM) 模态之间的间隔差异较小, 使得 FVBs 极易受到大气湍流影响, 因此精确地测量失真的 FOAM 模态对实际基于 FVBs 的通信系统而言至关重要. 本文提出了一种基于卷积神经网络-Transformer 混合架构的双通道深度学习模型, 通过学习并融合 FVBs 光强分布与其衍射图样的互补特征信息, 实现对大气湍流环境下 FOAM 模态的有效识别. 结果表明, 在 1000 m 传输距离之内, 本文构建模型在弱、中湍流强度下识别 101 个 FOAM 模态的准确率可达 100%, 强湍流时也能达到 98.12%, 并且在未知湍流强度下也表现出良好的泛化能力, 为准确识别 FOAM 模态提供了一种新方法.

关键词: 分数阶轨道角动量, 深度学习, 三角衍射, 大气湍流

PACS: 42.50.Tx, 42.60.Jf, 47.27.Gs, 07.05.Mh

DOI: 10.7498/aps.74.20251033

CSTR: 32037.14.aps.74.20251033

1 引言

1992 年 Allen 等^[1] 证明了携带相位因子 $\exp(i\ell\theta)$ 的拉盖尔-高斯 (Laguerre-Gaussian, LG) 涡旋光束具有轨道角动量 (orbital angular momentum, OAM), 其中 θ 代表方位角, ℓ 称为拓扑荷. 因不同拓扑荷值的 OAM 模态彼此之间具有正交特性, 当将其用于自由空间光通信中作为信息的载体时可以有效地提高通信容量, 因此具有较高的研究价值^[2-4]. 但是, 当涡旋光束在自由空间中传输时, 大气湍流 (atmospheric turbulence, AT) 会使光信号产生光

强闪烁、光束展宽、光束漂移等现象, 造成 OAM 模态识别困难, 并进而导致自由空间光通信性能下降. 因此, OAM 模态的准确识别对于提高自由空间光通信性能具有重要意义.

目前, 对涡旋光束进行 OAM 模态检测的方法主要包括传统光学方法和基于深度学习的方法, 后者凭借着其强大的图像信息提取能力, 在 OAM 模态检测领域受到了越来越多的关注^[5-8]. 与整数阶涡旋光束相比, 在最大拓扑荷值 ℓ 的限制下, 分数阶涡旋光束^[9-11] 可以通过减小相邻拓扑荷之间的间隔来增加 OAM 模态的数量, 因此利用分数阶涡

* 国家自然科学基金 (批准号: 62071180) 和河北省光电信息材料实验室绩效补贴基金项目 (批准号: 22567634H) 资助的课题.

† 通信作者. E-mail: zrx@hbu.edu.cn

‡ 通信作者. E-mail: taoliu@ncepu.edu.cn

旋光束能够更显著地提升通信容量,且在光学微粒操控和光学成像等领域中也展现出广泛的应用前景^[12,13].但由于分数阶涡旋光束的 OAM 模态之间的间隙差很小,这造成了对分数阶 OAM(fractional orbital angular momentum, FOAM) 模态进行识别比整数阶更困难^[14,15].Liu 等^[16]利用 DenseNet 网络对 $\Delta l = 0.01$ 的分数涡旋光束进行了识别,识别准确率达到 98%,但该结果是在没有考虑湍流的情况下得到的.Jing 等^[17]基于前馈神经网络在强湍流下对 $\Delta l = 0.1$ 的分数涡旋光束进行了识别,识别准确率为 85.2%.郭焱等^[18]基于残差网络实现了准确率为 99.69% 的 $\Delta l = 0.1$ 的分数涡旋光束模态识别,但他们只考虑了弱湍流情况,且传输距离很短,未超过 100 cm.由此可知,虽然利用深度学习方法进行 FOAM 模态检测取得了一定成功,但在强湍流、长传输距离情况下仍存在识别准确率不足的问题.此外,由于共轭 FOAM 模态具有相同的强度分布^[15],所以直接使用强度分布作为模式特征提取对象时将无法测量共轭的 FOAM 模态(即无法区分 l 的正负),这使得同时准确识别 FOAM 模态的大小和符号也成为亟需解决的问题.

针对上述问题,本文构建了一种双通道 CNN-Transformer 的自适应神经网络模型(简称为 DC-CNN-T)用于对传输通过大气湍流信道的 FOAM 模态进行高分辨率识别.该模型将 SENet 注意力机制嵌入到浅层卷积层之后组成第一条通道,并利用 Vision Transformer(ViT)组成第二条通道,随后将探测得到的受大气湍流扰动后的 FOAM 光场分布以及其经过三角孔衍射后的衍射图样分别输入两条通道,将两路进行特征融合之后再行模式识别,从而最终获得湍流扰动之前的 FOAM 模态.结果表明,对于本文研究采用的 101 个 FOAM 模态($l \in [-5, +5]$, $\Delta l = 0.1$),当传输距离在 1000 m

以内时,弱、中湍流情况下 DC-CNN-T 模型的识别准确率均可达 100%,强湍流时也能达到 98.12%;并且该模型具备良好的泛化能力,对于未知湍流强度情况识别准确率也超过 96.74%.本文研究内容可为提高复杂传输环境下的自由空间光通信性能提供新的解决思路.

2 理论分析

本文以分数阶拉盖尔-高斯(fractional Laguerre-Gaussian, FLG)光束为例进行研究.大气湍流环境下 FOAM 模态的传输与检测系统整体架构如图 1 所示,包括由激光器和空间光调制器(SLM)组成的 FOAM 模态生成部分;利用相位屏模拟大气湍流的 AT 信道传输部分;以及基于双通道 CNN-Transformer 混合架构结合三角屏衍射特性的 FOAM 模态检测部分.下面详细阐述图 1 中涉及的主要相关理论.

2.1 FLG 光束在大气湍流中的传输

在源平面上,FLG 涡旋光束的场振幅可表示为^[19]

$$E(r, \theta) = A \left(\frac{r}{w_0} \right)^{|l|} L_p^{|l|} \left(\frac{2r^2}{w_0^2} \right) \exp \left(-\frac{r^2}{w_0^2} \right) \exp(il\theta), \quad (1)$$

其中 A 是一个常数; w_0 表示光束的束腰半径; $L_p^{|l|}(\cdot)$ 表示缔合拉盖尔多项式, l 为拓扑荷, p 为径向指数.

FLG 光束在大气湍流中的传输过程可利用分布随机相位屏的方法进行模拟,其中大气湍流相位屏采用功率谱反演法生成.本文利用改进的 von Karman 谱模型描述大气折射率功率谱密度,其表达式为^[20-22]

$$\phi^2(\kappa) = 0.49 r_0^{-5/3} \frac{\exp(\kappa^2/\kappa_m^2)}{(\kappa^2 + \kappa_0^2)^{11/6}}, \quad (2)$$

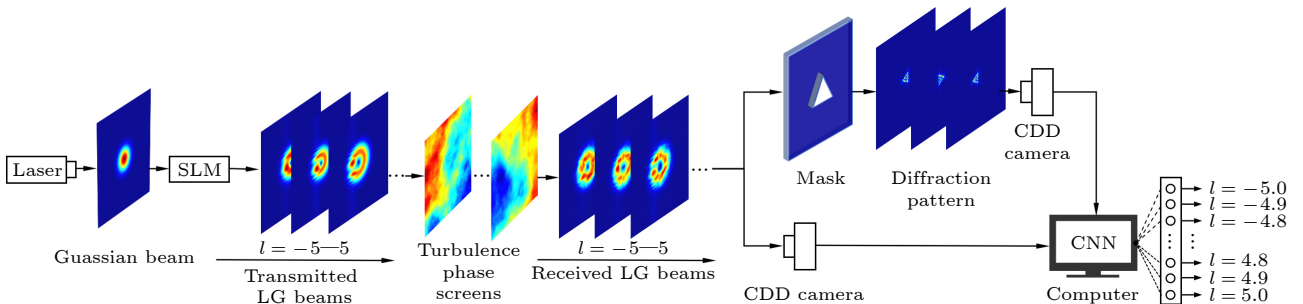


图 1 大气湍流环境下 FOAM 模态的传输与检测系统架构

Fig. 1. Architecture of propagation and detection system for FOAM modes in atmospheric turbulence.

其中 $r_0 = (0.423k^2 C_n^2 z)^{-3/5}$ 表示大气湍流相干长度, z 为光源到接收机之间的距离, C_n^2 为大气湍流折射率结构常数, $k = 2\pi/\lambda$ 为波数, λ 是光波长; κ 为空间波数, $\kappa_m = 5.92/l_0$, $\kappa_0 = 2\pi/L_0$, l_0 和 L_0 分别为湍流的内、外尺度, 它们的取值范围一般分别在毫米到厘米之间以及米到百米之间.

根据角谱法可得接收平面上 FLG 光束的场振幅为^[23]

$$E(x, y, z + \Delta z) = \text{FFT}^{-1}[\text{FFT}[\exp(i\varphi(x, y))E(x, y, z)]\mathbf{H}(k_x, k_y)], \quad (3)$$

其中 FFT 和 FFT^{-1} 分别表示傅里叶变换和傅里叶反变换; $\mathbf{H}(k_x, k_y)$ 为角谱传递函数, 是一个均值为 0、方差为 1 的复高斯随机矩阵, k_x 和 k_y 分别为 x 和 y 方向的空间频率; $\varphi(x, y) = \text{FFT}^{-1}\{\mathbf{M}\phi(\kappa)\}$ 表示相位屏上的相位, \mathbf{M} 为复随机矩阵.

2.2 FLG 光束三角衍射原理

为了同时准确识别 FLG 光束的拓扑荷大小和正负, 本文采用了三角屏衍射方法. 衍射屏使用边长为 a 的正三角孔, 其复振幅透过率函数为^[24]

$$t(x_0, y_0) = \begin{cases} 1, & 0 \leq y_0 \leq (a/2 - |x_0|)\sqrt{3}, |x_0| \leq a/2, \\ 0, & \text{others,} \end{cases} \quad (4)$$

其中 x_0 和 y_0 表示衍射屏上的直角坐标.

当 FLG 光束照射在三角孔衍射屏上之后可得复振幅分布为^[25]

$$o(x, y) = t(x_0, y_0)E(x, y, z + \Delta z). \quad (5)$$

在夫琅禾费极限下, 经三角孔后的 FLG 光束在探测平面形成的衍射图样的强度分布为

$$I_p^l \propto |\text{FFT}\{o(x, y)\}|^2. \quad (6)$$

基于上述理论模型, 我们仿真得到无湍流 (理想情况) 和强湍流 ($C_n^2 = 1 \times 10^{-14} \text{ m}^{-2/3}$) 条件下 FLG 光束传输 1000 m 之后的光强分布及对应衍射图样, 部分结果 ($l = \pm 2.4, \pm 2.5, \pm 2.6$ 和 ± 3) 如图 2 所示. 其中图 2(a) 和图 2(b) 为无湍流时的 FLG 光强分布及对应的衍射图样, 图 2(c) 和图 2(d) 为强湍流下的光强分布和衍射图样. 从图 2(a) 可以看出, 当拓扑荷 l 为绝对值相同的整数 ($l = \pm 3$) 时, 从 FLG 的光强分布无法区分 l 的正负; 而当 l 为绝对值相同的小数 ($l = \pm 2.4, \pm 2.5$ 和 ± 2.6) 时, 理想情况下可以从光强分布区分 l 的正负. 但再对比图 2(c) 不难发现, 经过大气湍流之后将很难仅从光强分布上来区分 l 的正负. 此外, 从图 2(a) 和图 2(c) 还可以看出, 相邻 OAM 模式 (如 $l = 2.4, 2.5$ 和 2.6) 的 FLG 光束在光强分布上呈现高度相似性, 因此直接从光强分布上来识别 FOAM 模态




图 2 无湍流时 FLG 光束的 (a) 光强分布和 (b) 对应的衍射图样, 以及强湍流时 FLG 光束的 (c) 光强分布和 (d) 对应的衍射图样
Fig. 2. (a) Intensity distribution and (b) its corresponding diffraction pattern of FLG in the absence of turbulence, as well as (c) intensity distribution and (d) its corresponding diffraction pattern of FLG in strong turbulence.

的大小也是较难的. 然而, 当 FLG 光束通过三角孔衍射之后, 从衍射图样中将可以有效地提取出模态信息. 以图 2(b) 所示结果为例, 当 l 为正值时, 衍射图样的三角形指向右侧, 为负值时则指向左侧, 这一特点可以很方便地用来区分 FOAM 模态的正负. 此外, 对于相邻的模态, 当 l 为正值时, 随着 l 的增加, 三角衍射图样的上斜边将呈现出较明显的变化, 这会使三角形光斑逐渐变大; 而当 l 为负值时, 随着 l 的减小 (即绝对值增加), 三角衍射图样的下斜边将呈现出较明显的变化, 这同样会使三角形光斑逐渐变大. 从图 2(d) 可以看出, 经过强湍流之后上述三角衍射图样的特征还能够保留, 因此该特征与 FLG 光束的光强分布形成互补信息维度, 这将有助于提高 FOAM 模态的识别准确率.

2.3 双通道 CNN-Transformer 模型的构建

CNN 可以通过多层的卷积和池化操作自动从数据中学习并提取特征, 对单目标的识别分类具有很好的效果. 在 CNN 的结构设计中, 如果 CNN 网络层数过多, 计算复杂度会很大, 可能会产生严重的过拟合; 如果 CNN 网络层数过少, 则将无法有效地提取图像的特征, 从而造成识别准确率较差. 在保证能够获得较好的 FOAM 模态识别准确率前提下, 为了有效地降低计算复杂度并防止严重的过拟合, 本文构建了双通道 CNN-Transformer(DC-CNN-T) 架构识别模型, 如图 3 所示. “Fusion”模块

的左侧为第一个通道, 在该通道中, 设计了一个仅含 3 个卷积层的浅层 CNN 并嵌入了一种轻量级注意力机制 SENet(squeeze and excitation networks) 模块^[26], SENet 模块结构简单计算量相对较小, 引入的计算开销可忽略不计, 其通道注意力机制通过自适应特征重校准, 可以抑制无关或噪声通道, 提升模型对重要特征的敏感度. 该通道的输入为 FLG 光束的光强分布, 先通过浅层 CNN 进行光强图像特征数据处理, 再经过 SENet 注意力机制对 FOAM 特征进行自适应重校准. “Fusion”模块的右侧为第二个通道, 在该通道中我们使用了 ViT(Vision Transformer) 模型^[27], 其核心思想来源于 Transformer 架构. 该通道的输入为 FLG 光束的三角衍射图样, ViT 模型的自注意力算法直接建模图像中任意两个区域 (图像块) 之间的长程依赖关系, 利用 ViT 模型能够有效地捕捉相邻 FOAM 模态三角衍射图样之间的细微区别.

在利用图 3 所示 DC-CNN-T 模型进行 FOAM 模态识别时, 先将原始 500 pixel×500 pixel 的光强分布图与衍射图样统一降采样至 128 pixel×128 pixel, 随后分别输入两个独立通道从不同角度学习输入数据的特征, 捕获更丰富的信息. 双通道在分别提取高级特征之后再经过“Fusion”模块进行信息融合, 使模型能够从更全面的视角进行学习. 这种多源信息的融合也可以帮助模型在面对多样化输入时拥有更好的泛化能力, 避免过拟合,

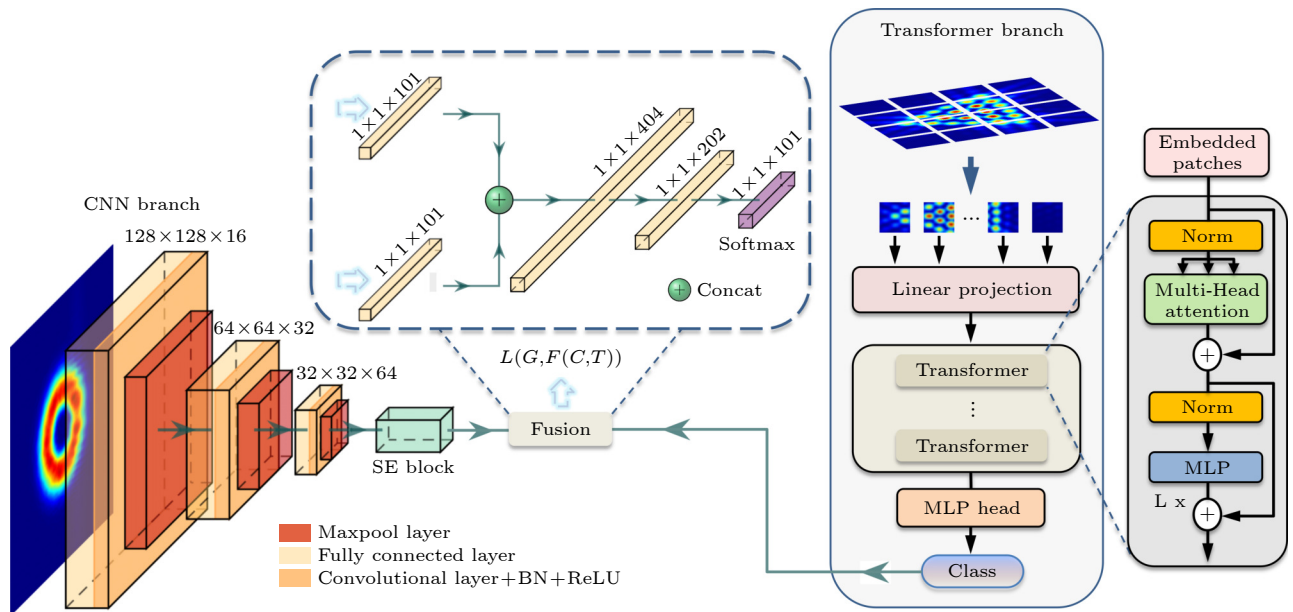


图 3 双通道 CNN-Transformer 模型结构示意图

Fig. 3. Schematic diagram of the dual channel CNN-Transformer network structure.

从而增强了分类的能力. 最后, 该模型通过具有 404 和 202 个节点的全连接层进行降维处理, 输出层维度与本文研究采用的 101 个 FOAM 模态 (-5 — $+5$, 间隔 0.1) 类别对应.

本文使用分类交叉熵损失函数^[28]来评估每个轮次 (epoch) 的训练结果:

$$L = - \sum_{i=1}^C y_i \log(p_i) \quad (7)$$

其中 y_i 表示真实标签的独热编码 (值为 0 或 1), p_i 为神经网络给出的第 i 类的预测值. 分类交叉熵损失函数能够充分利用标签信息, 具有很强的泛化能力, 并且在加快模型训练收敛的同时又可避免陷入局部极小值. 此外, 采用自适应矩估计 (adaptive moment estimation, Adam) 优化器^[29]更新权重和偏差参数, 使损失函数最小化.

3 结果分析与讨论

3.1 实验环境与数据集构建

操作系统为 Windows 系统, 硬件平台为配置 13th Gen Intel(R) Core(TM) i9-13900 KF 3.00 GHz 处理器和 Nvidia GeForce RTX 4090 GPU(显存 24 GB) 的计算机. 利用 MatlabR2023b 构建仿真数据集, 利用 Python 3.9 和 Pytorch 2.5.3 实现网络模型的构建、训练和评估.

除另有说明, 本文 FLG 光束仿真与模态识别时采用的主要参数设置如下: 波长 $\lambda = 1550$ nm; 束腰半径 $w_0 = 0.002$ m; 径向指数 $p = 0$; 拓扑荷 $l \in [-5, +5]$, 间隔 $\Delta l = 0.1$; 传输距离 z 分别为 500, 750, 1000, 1250 和 1500 m; 相位屏分辨率 $N = 500$; 根据采样约束条件^[20], 每隔 200 m 设置一个相位屏; 大气折射率结构常数 C_n^2 为 1×10^{-14} , 1×10^{-15} , $1 \times 10^{-16} \text{ m}^{-2/3}$, 分别对应强、中、弱三种 AT 强度. 根据大气相干长度计算公式 $r_0 = (0.423k^2 C_n^2 z)^{-3/5}$ 及上述相关参数设置, 可计算出 r_0 的最小值约为 0.062 m, 最大值约为 1.88 m. 又因为大气相干长度 r_0 要满足 $l_0 \ll r_0 \ll L_0$, 再结合湍流内、外尺度 l_0 和 L_0 的取值范围, 本文分别将 l_0 和 L_0 设置为 0.003 m 和 50 m. 初始学习率 (learning rate) 设置为 0.0001, 权重参数 (weight) 使用 Adam 优化器, 批大小 (batch size) 为 16, epoch 数为 80.

在构建 DC-CNN-T 模型之后, 利用第 2 节中

相关理论仿真得到不同 FOAM 模态的光强分布和对应的三角衍射图样, 随后进行训练和识别效果验证. 由于大气湍流的随机性, 为了使模型具有普遍适应性, 在每个湍流强度下分别多次随机模拟 FOAM 模态的光强图像和衍射图样. 强湍流情况下, 每个 FOAM 模态训练集样本数量为 400, 而在弱、中湍流情况下, 每个 FOAM 模态的训练集样本数量只需 100, DC-CNN-T 模型的准确率就能收敛. 与已报道的 FOAM 识别模型相比^[17,30,31], 本文构建的 DC-CNN-T 模型所需训练集样本较少, 这有助于减小训练集的生成和模型训练的工作量, 从而更利于发挥 FOAM 大模态空间的潜在应用优势.

3.2 FOAM 模态识别与分析

为评估构建的 DC-CNN-T 模型的识别性能, 本节对测试数据集进行了模态检测分析. 图 4 所示为不同 AT 强度、传输距离为 1500 m 时的 FOAM 模态识别准确率及混淆矩阵. 从图 4(a) 可以看出, 在弱、中大气湍流情况时, DC-CNN-T 模型的训练收敛速度较快且准确率超过 99.95%; 而在强湍流时, DC-CNN-T 模型在 60 轮后也接近收敛, 准确率可达 92.62%. 图 4(b)—(d) 所示为 FOAM 模态 (每个模态包含 20 个数据点) 混淆矩阵的横轴表示模型预测的模态类别, 纵轴表示输入的真实模态类别, 矩阵对角线元素代表模态识别正确的样本数量 (即预测类别与真实类别一致), 而非对角线位置的非零元素则表征识别错误的样本数量. 图 4(b)—(d) 所示的混淆矩阵结果直观展示了在弱、中大气湍流情况下 DC-CNN-T 模型的识别效果极好, 而强湍流时发生的错误分类主要集中在模态 $l = \pm 0.5, \pm 1.5, \pm 2.5, \pm 3.5, \pm 4.5$ 的邻域. 上述现象的产生主要是因为 $l = \pm 0.5, \pm 1.5, \pm 2.5, \pm 3.5, \pm 4.5$ 附近相邻的 FOAM 模态之间的特征相似度较高, 虽然本文使用了三角屏衍射方法来帮助解决问题, 但在经过长距离的强大湍流信道传输之后, 相邻 FOAM 模态三角衍射图样之间的特征区别也将下降, 从而导致错误分类增加.

除湍流强度之外, 传输距离也是影响识别准确率的一个重要因素. 因此, 我们又对不同传输距离和湍流强度下的 FOAM 模态识别效果进行了分析, 结果如图 5 所示. 由图 5 可以看出, 弱湍流时, 不同传输距离下识别准确率都达到了 100%; 在中等

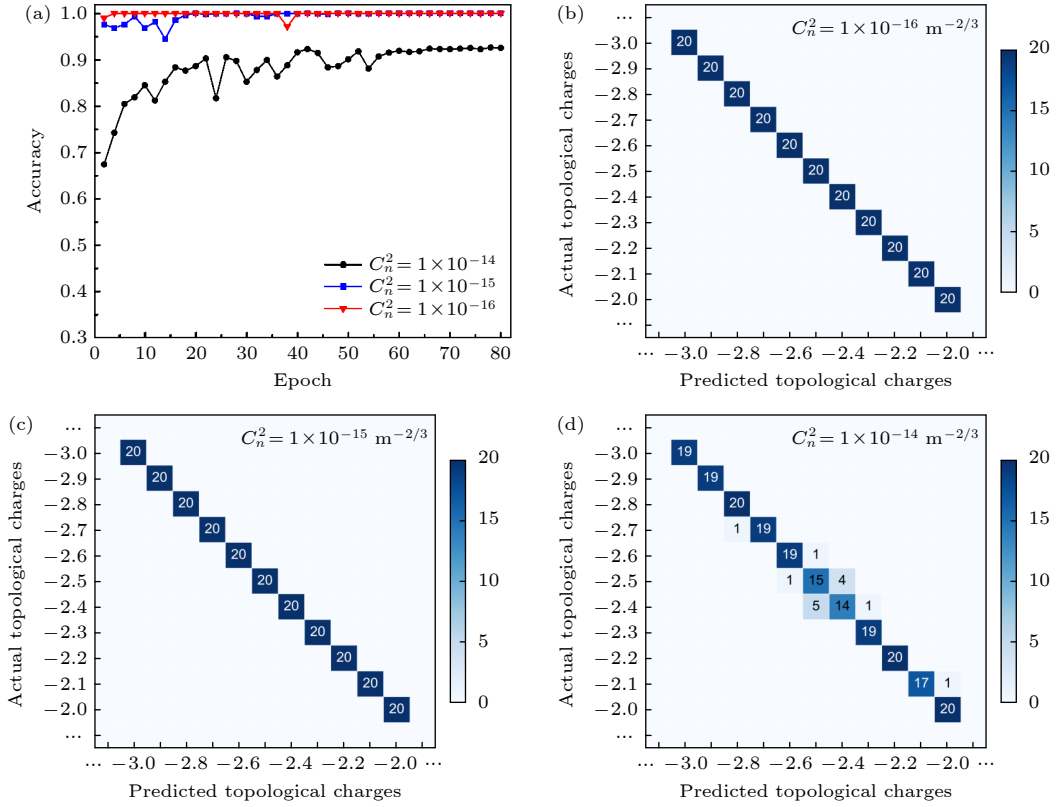


图 4 (a) 不同湍流情况下的识别准确率以及 (b) 弱、(c) 中、(d) 强湍流时的混淆矩阵

Fig. 4. (a) Recognition accuracy of the DC-CNN-T model under different turbulence conditions, and confusion matrices for (b) weak, (c) moderate, and (d) strong turbulences.

湍流强度下, 传输 500, 750, 1000 和 1250 m 时识别准确率也都为 100%, 但随着传输距离的进一步增加准确率将下降, 但降幅较小, 1500 m 时准确率为 99.95%, 接近 100%. 上述结果表明, 本文构建的模型在弱、中湍流情况下都能够准确识别 FOAM 模态的大小和正负. 对于强湍流的情况, 随着传输距离的增加准确率将呈现出较明显的下降趋势, 但传

输 1500 m 时准确率仍能超过 90%, 达到了 92.62%. 强湍流下识别准确率较差的原因是, 强湍流不仅会使 FLG 光束的光强分布产生较严重的畸变, 同时也会导致三角形衍射图样的特征变差乃至消失, 即造成关键识别特征丢失, 并且传输距离越长强湍流的影响就越大, 特征丢失得越明显, 因此识别准确率也越差.

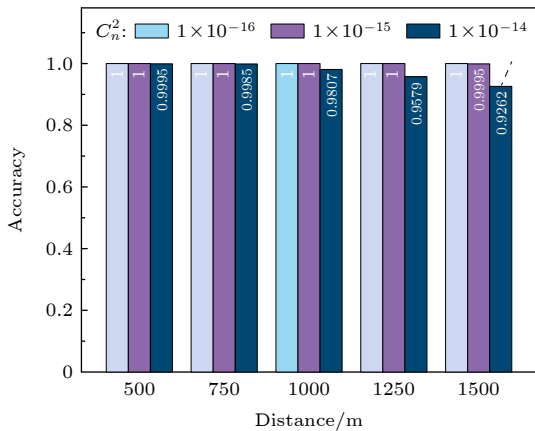


图 5 不同传输距离和湍流强度下的识别准确率

Fig. 5. Recognition accuracy for different transmission distances and turbulence intensities.

为了验证本文构建的双通道 CNN-Transformer 混合架构模型在 FOAM 模态识别上比只使用 CNN 模型或 Transformer 模型更具优势, 我们以强湍流情况为例仿真得到三种模型在不同传输距离下的识别准确率, 结果如图 6 所示. 从图 6 可以看出, 当传输距离较短时, 如 $z = 500$ m, 此时使用 DC-CNN-T 模型与使用 CNN 模型可以获得相同的准确率, 都能达到 100%, 但 Transformer 模型的准确率只有 91%. 随着传输距离的增加, 三种模型的识别准确率都会随之下降, 但与只使用 CNN 模型或 Transformer 模型相比, DC-CNN-T 模型的准确率都较高, 因此可以验证本文构建的双通道 CNN-Transformer 模型在 FOAM 模态识别方面具有优势.

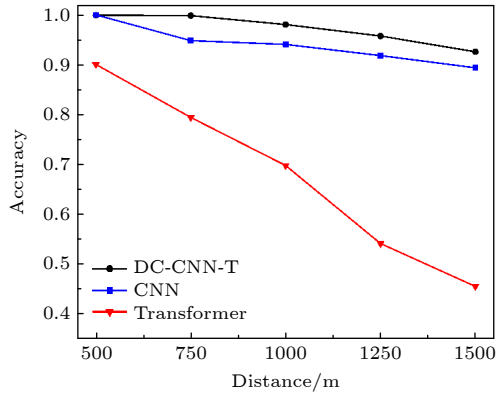


图 6 不同模型在不同传输距离下的识别准确率

Fig. 6. Recognition accuracy of DC-CNN-T, CNN and Transformer models under different transmission distances.

由于实际中的大气湍流强度具有不确定性, 因此要求 DC-CNN-T 模型要具有良好的泛化能力. 为了测试不同湍流强度下 DC-CNN-T 模型的泛化能力, 我们分别使用在 $C_n^2 = 1 \times 10^{-14}$, 1×10^{-15} , $1 \times 10^{-16} \text{ m}^{-2/3}$ 条件下 (记作 1-AT) 训练得到的 DC-CNN-T 模型, 对不同大气湍流强度条件下测试集的 FLG 光强图像和衍射图样进行交叉测试, 距离设置为 1000 m, 所得结果如图 7 所示. 图 7 中非对角线位置上的元素为交叉测试结果, 可以看出在 1-AT 训练集下 DC-CNN-T 模型的泛化能力较弱, 当遇到与训练集湍流强度不同的 FLG 光强图像和衍射图样时, 识别效果将显著下降. 例如, $C_n^2 = 1 \times 10^{-16} \text{ m}^{-2/3}$ 训练集下的 DC-CNN-T 模型在识别 $C_n^2 = 1 \times 10^{-15} \text{ m}^{-2/3}$ 下的 FOAM 模态时准确率降为 94.35%, 若识别 $C_n^2 = 1 \times 10^{-14} \text{ m}^{-2/3}$ 下的 FOAM 模态, 准确率将降至 22.43%.

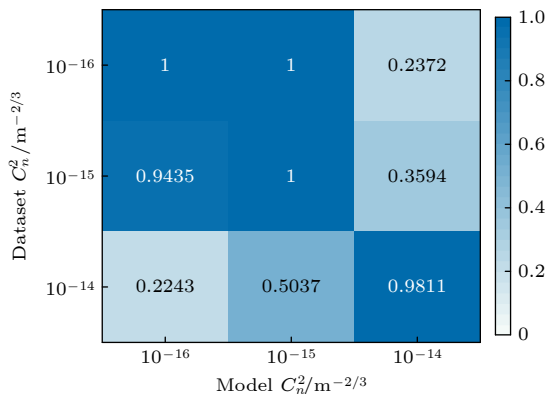


图 7 不同训练集下 DC-CNN-T 模型在各种大气湍流强度下的交叉测试结果

Fig. 7. Cross-test results of the DC-CNN-T model under different training sets and various atmospheric turbulence intensities.

为了使 DC-CNN-T 模型能够具有更好的泛化能力, 将图 7 中不同 C_n^2 的数据集组合起来, 构成包括弱、中、强三种湍流强度 (记作 3-AT) 的混合数据集. 针对每个湍流强度等级, 采用随机抽样方法按 1:1:4 的比例 (对应弱、中、强三种湍流强度) 分别选取 50, 50 和 200 个样本构成训练集, 即每个 FOAM 模态下包含 300 张训练图像样本, 总计 30300 张图像样本. 基于此 3-AT 混合数据集进行训练, 可以得到如图 8 所示的识别准确率, 其中 1-AT 为单一 AT 强度训练集下 DC-CNN-T 模型在对应 AT 强度测试集上的识别准确率 (即图 7 中对角线上的结果). 对比图 8 和图 7 可以看出, 在 3-AT 混合数据集上训练的模型比在单一 AT 强度数据集上训练的模型具有更强的泛化能力, 表现为弱、中湍流下准确率几乎为 100%, 在强湍流下准确率略微下降, 为 96.74%. 此外, 对比图 8 中 1-AT 和 3-AT 的结果还可以看出, 3-AT 混合数据集上训练的 DC-CNN-T 模型的识别准确率十分接近 1-AT 情况下的结果, 即使遇到强湍流也能保持高精度模态检测. 综上所述, 本文构建的 DC-CNN-T 模型能够以极小的准确率损失为代价来扩展湍流强度检测范围, 实现对未知湍流强度情况下 FOAM 模态的高精度检测, 这在实际应用中将可以极大改善自由空间光通信系统的性能.




图 8 在 1-AT 和 3-AT 数据集下训练的 DC-CNN-T 模型的识别准确率

Fig. 8. Recognition accuracy of the DC-CNN-T model trained on the 1-AT and 3-AT datasets.

4 结论

本文提出了一种 CNN-Transformer 混合架构与三角衍射相结合的 FOAM 模态识别方法, 通过

多源信息融合, 学习受大气湍流扰动之后的 FLG 光束的光强图像及其三角衍射图样的特征信息, 可以实现对不同湍流强度和传播距离下 FOAM 模态大小和正负的准确识别. 例如, 当传输距离在 1000 m 以内时, 弱、中湍流强度下该方法的 FOAM 模态 ($l \in [-5, +5]$, $C_n^2 = 0.1$) 识别准确率均为 100%, 强湍流下也能达到 98.12%. 当传输距离增加到 1500 m 时, 弱湍流下准确率仍为 100%; 中湍流时略有下降, 为 99.95%; 强湍流时下降稍多, 但也达到了 92.62%. 此外, 该方法还具备良好的泛化能力, 能够实现未知大气湍流强度情况下 FOAM 模态的高精度检测, 因此在自由空间光通信等方面具有很好的应用潜力.

参考文献

- [1] Allen L, Beijersbergen M W, Spreeuw R J C, Woerdman J P 1992 *Phys. Rev. A* **45** 8185
- [2] Lei T, Zhang M, Li Y R, Jia P, Liu G N, Xu X G, Li Z H, Min C J, Lin J, Yu C Y, Niu H B, Yuan X C 2015 *Light Sci. Appl.* **4** e257
- [3] Fu S Y, Zhai Y W, Zhou H, Zhang J Q, Wang T L, Yin C, Gao C Q 2019 *Opt. Lett.* **44** 4753
- [4] Nape I, Sephton B, Huang Y W, Vallés A, Forbes A 2020 *APL Photonics* **5** 070801
- [5] Krizhevsky A, Sutskever I, Hinton G E 2017 *Commun. ACM* **60** 84
- [6] Knutson E M, Lohani S, Danaci O, Huver S D, Glasser R T 2016 *Proc. SPIE* **9970** 997013
- [7] Park S R, Cattell L, Nichols J M, Watnik A, Doster T, Rohde G K 2018 *Opt. Express* **26** 4004
- [8] Fan W Q, Gao F L, Xue F C, Guo J J, Xiao Y, Gu Y J 2024 *Appl. Opt.* **63** 982
- [9] Berry M V 2004 *J. Opt. A: Pure Appl. Opt.* **6** 259
- [10] Phillips R L, Andrews L C 1983 *Appl. Opt.* **22** 643
- [11] Zhao Z, Zhang R Z, Song H, Pang K, Alnaiman A, Zhou H B, Song H Q, Liu C, Hu N Z, Su X Z, Minoofar A, Sasaki H, Lee D, Tur M, Molisch A F, Willner A E 2021 *Sci. Rep.* **11** 2110
- [12] Zhu L H, Tang M M, Li H H 2021 *Nanophotonics* **10** 2487
- [13] Bu X, Zhang Z, Chen L 2018 *IEEE Antennas Wirel. Propag. Lett.* **17** 764
- [14] Zhou J, Zhang W H, Chen L X 2016 *Appl. Phys. Lett.* **108** 111108
- [15] Deng D, Lin M C, Li Y, Zhao H 2019 *Phys. Rev. Appl.* **12** 014048
- [16] Liu Z W, Yan S, Liu H G, Chen X F 2019 *Phys. Rev. Lett.* **123** 183902
- [17] Jing G Q, Chen L Z, Wang P P, Xiong W J, Huang Z B, Liu J M, Chen Y, Li Y, Fan D Y, Chen S Q 2021 *Results Phys.* **28** 104619
- [18] Guo Y, LYU H, Ding C L, Yuan C Z, Jin R B 2025 *Acta Phys. Sin.* **74** 014203 (in Chinese) [郭焱, 吕恒, 丁春玲, 袁晨智, 金锐博 2025 物理学报 **74** 014203]
- [19] Zhang H, Zeng J, Lu X, Wang Z, Zhao C, Cai Y 2022 *Nanophotonics* **11** 241
- [20] Hill R J 1978 *J. Fluid Mech.* **88** 541
- [21] Andrews L, Phillips R 2005 *Laser Beam Propagation Through Random Media* (Bellingham: SPIE) p135
- [22] Schmidt J D 2010 *Numerical Simulation of Optical Wave Propagation with examples in MATLAB* (Bellingham: SPIE) p149
- [23] Yang T, Zhao S 2017 *Acta Opt. Sin.* **37** 1201001 (in Chinese) [杨天星, 赵生妹 2017 光学学报 **37** 1201001]
- [24] Liu Y, Sun S, Pu J, LYU B 2013 *Opt. Laser Technol.* **45** 473
- [25] Zhao Q, Dong M, Bai Y H, Yang Y J 2020 *Photonics Res.* **8** 745
- [26] Hu J, Shen L, Albanie S, Sun G 2020 *IEEE Trans. Pattern Anal. Mach. Intell.* **42** 2011
- [27] Dosovitskiy A, Beyer L, Kolesnikov A, Weissenborn D, Zhai X H, Unterthiner T, Dehghani M, Minderer M, Heigold G, Gelly S, Uszkoreit J, Houslsby N 2021 arXiv: 2010.11929 [cs.CV]
- [28] Zhang Z, Sabuncu M 2018 arXiv: 1805.07836 [cs.LG]
- [29] Kingma D P, Ba J 2014 arXiv: 1412.6980 [cs.LG]
- [30] Wei D M, Du Q, Liu F N, Wang K, Zhao Y F 2023 *Acta Opt. Sin.* **43** 2326001 (in Chinese) [魏冬梅, 杜乾, 刘芳宁, 王珂, 赵曰峰 2023 光学学报 **43** 2326001]
- [31] Na Y, Ko D K 2021 *Sci. Rep.* **11** 23505

Recognition of fractional orbital angular momentum modes based on convolutional neural network-transformer model combined with triangular diffraction*

ZHOU Yuncheng¹⁾ ZHANG Rongxiang^{1)†} LIU Tao^{2)3)4)‡}

BI Huicong¹⁾ HOU Fang¹⁾ WANG Xinyu¹⁾

1) (College of Physics Science and Technology, Hebei University, Baoding 071002, China)

2) (Yanzhao Electric Power Laboratory of North China Electric Power University, Baoding 071003, China)

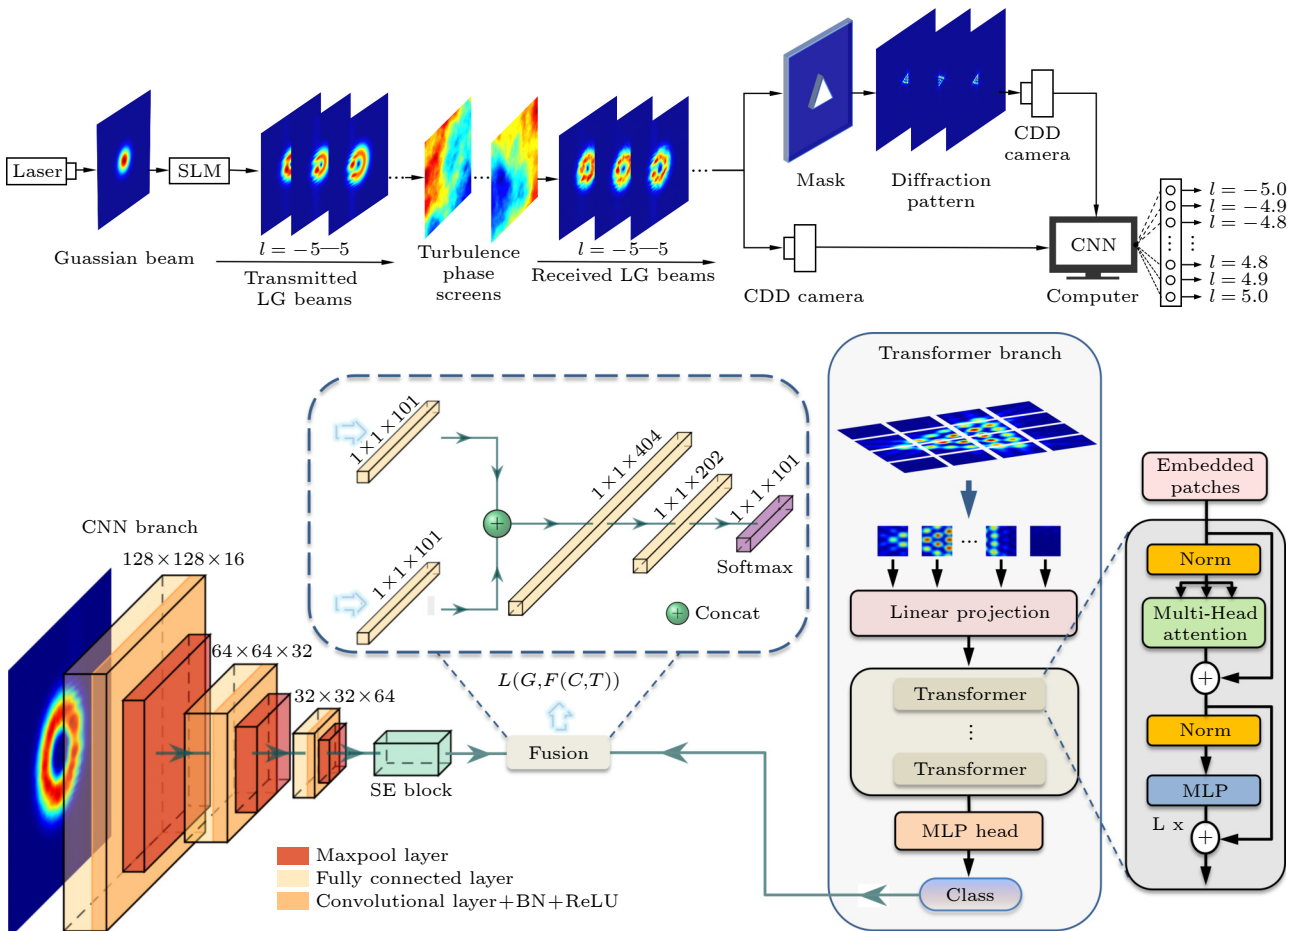
3) (Department of Electronic and Communication Engineering, North China Electric Power University, Baoding 071003, China)

4) (Hebei Key Laboratory of Power Internet of Things Technology, North China Electric Power University, Baoding 071003, China)

(Received 1 August 2025; revised manuscript received 11 September 2025)

Abstract

Utilizing fractional vortex beams (FVBs) as information carriers can significantly enhance the capacity of communication systems. However, the small gap difference between adjacent fractional orbital angular momentum (FOAM) modes makes FVBs highly sensitive to atmospheric turbulence. Therefore, precise measurement of distorted FOAM modes is crucial for practical FVBs-based communication systems. To fully utilize the beam intensity information and the triangular diffraction pattern information, we propose a dual-



channel deep learning model with a hybrid architecture combining convolutional neural network (CNN) and vision transformer (ViT). The beam intensity information is extracted using the CNN, while the diffraction pattern information is extracted using the ViT. Then, by combining the complementary feature information from the intensity distribution of FVBs and their triangular diffraction patterns, this model can effectively identify the FOAM modes. The results show that the proposed model only requires a relatively small number of samples to reach convergence, namely 100 sets of data under weak turbulence and 400 sets of data under strong turbulence. Moreover, within a transmission distance of 1000 m, the proposed model can identify 101 FOAM modes with a mode spacing of 0.1 with an accuracy of 100% under weak and moderate turbulences, and maintains 98.12% accuracy under strong turbulence. Furthermore, the model can expand the detection range of turbulence intensity with only a minimal loss in accuracy, exhibiting strong generalization ability under unknown atmospheric turbulence strengths, thus providing a novel approach for accurately identifying FOAM modes.

Keywords: fractional orbital angular momentum, deep learning, triangular diffraction, atmospheric turbulence

PACS: 42.50.Tx, 42.60.Jf, 47.27.Gs, 07.05.Mh

DOI: [10.7498/aps.74.20251033](https://doi.org/10.7498/aps.74.20251033)

CSTR: [32037.14.aps.74.20251033](https://cstr.net.cn/resultDetail.action?cid=32037.14.aps.74.20251033)

* Project supported by the National Natural Science Foundation of China (Grant No. 62071180) and the Hebei Province Optoelectronic Information Materials Laboratory Performance Subsidy Fund Project, China (Grant No. 22567634H).

† Corresponding author. E-mail: zrx@hbu.edu.cn

‡ Corresponding author. E-mail: taoliu@ncepu.edu.cn



基于CNN-Transformer结合衍射的分数阶轨道角动量模态识别

周允城 张荣香 刘涛 毕慧聪 侯芳 王新宇

Recognition of fractional orbital angular momentum modes based on convolutional neural network-transformer model combined with triangular diffraction

ZHOU Yuncheng ZHANG Rongxiang LIU Tao BI Huicong HOU Fang WANG Xinyu

引用信息 Citation: *Acta Physica Sinica*, 74, 244202 (2025) DOI: 10.7498/aps.74.20251033

CSTR: 32037.14.aps.74.20251033

在线阅读 View online: <https://doi.org/10.7498/aps.74.20251033>

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

分数阶涡旋光衍射过程的机器学习识别

Machine learning identification of fractional-order vortex beam diffraction process

物理学报. 2025, 74(1): 014203 <https://doi.org/10.7498/aps.74.20241458>

基于旋转多普勒效应的自旋目标转速估计方法

Rotating speed estimation of spinning objects based on rotational Doppler effect

物理学报. 2023, 72(17): 174203 <https://doi.org/10.7498/aps.72.20230807>

海洋湍流对光子轨道角动量量子通信的影响

Effects of ocean turbulence on photon orbital angular momentum quantum communication

物理学报. 2022, 71(1): 010304 <https://doi.org/10.7498/aps.71.20211146>

基于飞秒激光加工长周期光栅的全光纤三阶轨道角动量模式的产生

Generation of all-fiber third-order orbital angular momentum modes based on femtosecond laser processing of long-period grating

物理学报. 2023, 72(4): 044201 <https://doi.org/10.7498/aps.72.20221928>

三维空间轨道角动量全息

Three-dimensional spatial orbital angular momentum holography

物理学报. 2024, 73(9): 094202 <https://doi.org/10.7498/aps.73.20231822>

基于光束偏移器的光的轨道角动量分束器

Orbital angular momentum splitter of light based on beam displacer

物理学报. 2024, 73(7): 074201 <https://doi.org/10.7498/aps.73.20231874>