

文章编号 1004-924X(2025)15-2331-11

深度学习融合模型共轭涡旋光干涉微位移测量

杨雪娇¹, 刘吉^{1*}, 武锦辉², 袁涛¹, 王仕杰², 姬翔峰¹,
于丽霞¹, 张博洋¹, 陈相³

(1. 中北大学 信息与通信工程学院, 山西 太原 030051;

2. 中北大学 仪器与电子学院, 山西 太原 030051;

3. 中国移动通信集团山西有限公司, 山西 太原 030051)

摘要:针对涡旋光干涉微位移测量技术中传统干涉条纹位移反演算法精度受限的问题,提出一种基于深度学习融合模型共轭涡旋光干涉微位移测量方法。采用集成FasterNet轻量化骨干网络与CARAFE动态上采样模块的YOLOv8s-Seg分割网络对干涉图像中的花瓣区域进行精确分割,以抑制相位信息提取过程中背景噪声和光束畸变的干扰。设计14层卷积神经网络架构对花瓣区域进行多尺度分层特征提取,构建花瓣形态变化与旋转角度的精准映射关系,实现亚纳米级位移的高精度检测。实验结果表明,在0~500 nm标准位移内,花瓣区域分割的平均精度(mAP)达96.5%,整体位移测量精度优于0.94 nm,平均绝对误差为0.63 nm。通过独特的双网络协同架构,该方法增强了对条纹畸变和噪声的抗干扰性能,在微位移测量的精度和稳定性方面具有明显的优势。

关键词:微位移测量;共轭涡旋光干涉;YOLOv8s-Seg分割网络;多尺度分层特征提取

中图分类号:O439 **文献标识码:**A

doi:10.37188/OPE.20253315.2331

CSTR:32169.14.OPE.20253315.2331

Conjugate vortex beam interferometry for micro-displacement measurement with deep learning fusion architecture

YANG Xuejiao¹, LIU Ji^{1*}, WU Jinhui², YUAN Tao¹, WANG Shijie², JI Xiangfeng¹, YU Lixia¹,
ZHANG Boyang¹, CHEN Xiang³

(1. School of Information and Communication Engineering, North University of China,
Taiyuan 030051, China;

2. School of Instrument and Electronics, North University of China, Taiyuan 030051, China;

3. China Mobile Communications Group Shanxi Co., LTD., Taiyuan 030051, China)

* Corresponding author, E-mail: liuji6@nuc.edu.cn

Abstract: To overcome the limitations of traditional fringe-based displacement inversion algorithms in vortex interferometry for micro-displacement measurement, a deep-learning fusion model based on conjugate vortex beam interference is proposed. A YOLOv8s-Seg segmentation network, incorporating a light-

收稿日期:2025-05-16;修订日期:2025-06-18.

基金项目:山西省基础研究计划资助项目(No. 202203021211087, No. 202203021221101, No. 202403021222181);山西省回国留学人员科研资助项目(No. 2023-141, No. 2024-117);山西省科技成果转化引导专项(No. 202404021301029)

weight FasterNet backbone and a CARAFE dynamic upsampling module, is employed to segment petal regions in interference images accurately, thereby reducing the influence of background noise and beam distortion on phase information extraction. A 14-layer convolutional neural network (CNN) is then used to perform multi-scale hierarchical feature extraction on the segmented petal regions, establishing a precise mapping between morphological variations and rotation angles to enable sub-nanometer displacement detection. Experimental results within a displacement range of (0-500) nm demonstrate a petal-region segmentation mean average precision (mAP) of 96.5%, overall displacement accuracy better than 0.94 nm, and a mean absolute error (MAE) of 0.63 nm. Owing to the dual-network collaborative architecture, the proposed method exhibits improved robustness to fringe distortion and noise, providing marked advantages in both precision and stability for micro-displacement measurement.

Key words: micro-displacement measurement; conjugate vortex light interferometry; YOLOv8s-Seg segmentation; multi-scale hierarchical feature extraction

1 引言

激光干涉测量技术凭借非接触性、高分辨率和宽动态范围等显著优势,广泛应用于精密测量领域,并成为高精度测量任务的首选方法^[1]。携带轨道角动量(Orbital Angular Momentum, OAM)的涡旋光束因其独特的螺旋相位波前分布和依赖拓扑荷数的干涉特性,为解决传统干涉条纹位移反演算法中计算复杂、精度受限的问题提供了新思路。国内外众多科研团队已将其应用于位移测量的干涉系统研究中^[2-8]。目前,针对涡旋光干涉图案旋转角度识别这一核心问题,研究人员相继提出多种解决方法。在早期研究中,Webster等通过连接两个相对花瓣质心形成向量计算旋转角度,实现了 0.5° 的测量精度^[9]。2020年,夏豪杰等通过定位全部花瓣质心并确定干涉图中心来解算旋转角度,位移分辨率得到了提升^[10]。2022年,Zhu等提出了质心向量与水平向量之间夹角变化的分析方法,其测量精度为 $\pm 16.6 \text{ nm}$ ^[11]。此外,Lu等通过将循环互相关算法与空间强度分布的周期性相结合,实现了宽动态范围内旋转角度的高灵敏度检测^[12]。现有测量方法的实现效果高度依赖于干涉图案的理想质量。然而,散斑噪声、光束畸变和环境扰动等干扰因素会引起光束失准,导致干涉图案质量下降,这严重影响花瓣质心和峰值定位的准确性,限制了测量精度的进一步提升。

随着深度学习技术的发展,光学计量领域正

逐步由传统物理模型向数据驱动的智能方法转变^[13],为解决复杂干涉图像分析难题和超高精度测量提供了新思路。Cheng等总结出卷积神经网络(Convolutional Neural Network, CNN)可有效解析涡旋光束轨道角动量的动态特性,揭示出数据驱动方法在光场分析中的潜力^[14]。Yuan等将CNN多尺度特征提取与共轭涡旋干涉系统的相位梯度敏感性相结合,验证了数据驱动方法在纳米级空间分辨测量中的可靠性^[15]。基于上述进展,本文提出了一种深度学习融合模型共轭涡旋光干涉微位移测量方法,采用改进型YOLOv8s-Seg网络对干涉图像中的花瓣区域进行精确分割,旨在抑制相位信息提取过程中光束畸变与背景噪声的干扰;再构建卷积神经网络对花瓣区域进行分层特征提取,捕获其在不同旋转状态下的形态变化,从而建立特征空间与旋转角度之间的精准映射关系,最终实现亚纳米级位移的高精度检测。

2 理论基础与模型构建

2.1 共轭涡旋光干涉的微位移测量原理

涡旋光束干涉技术利用其特有的螺旋相位结构,将待测位移量线性地转化为干涉条纹的旋转角度^[16]。与此同时,干涉条纹的 2π 相位周期性为微位移测量提供了基准,仅需分析单帧干涉图,便可直接解算出位移量,显著提升了动态微位移测量的实时性与抗干扰能力。

共轭涡旋光束干涉微位移测量原理如图 1

所示。激光源发射的光束依次经过可调衰减片、准直扩束系统处理后,垂直入射至空间光调制器(Spatial Light Modulator, SLM)表面,生成拓扑电荷数为 l 的涡旋光束。经反射后的涡旋光束进入50:50分束器(BS1)完成初次分光,接着通过分束器(BS2)实现路径分离:参考臂和测试臂。参考光束经两个平面镜共反射3次,而测试光束仅反射两次,两者之间奇数次反射差,导致拓扑电荷呈现 $-l$ 与 $+l$ 的反号特性。经严格调控,两束光仅在拓扑荷数符号上存在差异,其余参数保持一致。其中,参考光的电场强度可以表示为:

$$E_{\text{ref}}(r, \theta) = E \exp(-il\theta + ikz_r), \quad (1)$$

式中: E 为振幅; l 为拓扑荷数; θ 为方位角;波数 $k=2\pi/\lambda$; z_r 为参考臂初始长度。




图1 共轭涡旋光束干涉微位移测量系统原理

Fig.1 Schematic diagram of micro-displacement measurement system with conjugate vortex beam interferometry

测试光与参考光拓扑荷数互为相反数,其对应的电场强度可以表示为:

$$E_{\text{before}}(r, \theta) = E \exp(il\theta + ikz_t), \quad (2)$$

式中 z_t 为测试臂初始长度。因此,位移前的共轭涡旋光干涉电场强度为:

$$I_{\text{before}} = |E_{\text{ref}}(r, \theta) + E_{\text{before}}(r, \theta)|^2 = 2E^2 \{1 + \cos[2l\theta + k(z_t - z_r)]\}. \quad (3)$$

当待测物体轴向发生位移 d 时,测试臂相应产生 $2d$ 的光程差,此时测试光束电场强度与位移后的共轭涡旋光干涉电场强度分别为:

$$E_{\text{after}}(r, \theta) = E \exp(il\theta + ikz_t) \exp(ik2d), \quad (4)$$

$$I_{\text{after}} = |E_{\text{ref}}(r, \theta) + E_{\text{after}}(r, \theta)|^2 = 2E^2 \{1 + \cos[2l\theta + k(z_t - z_r) - 2kd]\}. \quad (5)$$

由式(5)可知,当待测物体产生位移时,相对光程会发生变化,进而导致花瓣状干涉条纹沿方位角旋转。因此,干涉图案旋转角度 $\Delta\theta$ 与位移 d 的关系如下:

$$d = \frac{l\Delta\theta}{k} = \frac{\lambda l\Delta\theta}{2\pi}, \quad (6)$$

其中: λ, l 均为已知量,即位移 d 和旋转角度 $\Delta\theta$ 之间存在严格的线性关系,故对位移 d 的测量可转换为对 $\Delta\theta$ 的精确提取。通过优化角度解调方法,可以进一步提高角度检测的精度,减少位移测量误差,从而全面提高系统性能。

2.2 改进型YOLOv8s-Seg分割网络

为抑制干涉图像中背景噪声、光束畸变等因素对花瓣形变特征提取的干扰,预先对目标花瓣区域进行分割提取。以经典的大津法(OTSU)为例,该类传统的阈值分割方法通过最大化类间方差自动确定全局阈值,其效果依赖于图像灰度直方图的双峰特性。然而,涡旋光干涉图像存在光强分布不均及高频噪声干扰,因此该方法对此类图像的处理效果不佳,尤其在光强变化复杂的条纹边缘区域,极易出现过分割或欠分割,破坏花瓣轮廓的完整性,导致关键相位信息丢失,影响后续的测量精度。而YOLO系列算法采用无锚框设计,直接通过图像整体特征推断出目标位置和分割区域^[17]。在对于干涉图像花瓣区域分割时,该算法不仅可以避免检测框反复调整导致的效率损失问题,还能完整保留花瓣条纹中细微相位变化的特征。分割结果如图2所示,相较于OTSU存在的轮廓残缺、细节丢失的问题,YOLOv8s-Seg算法能够有效实现对目标区域精确且完整的分割。

采用YOLOv8s-Seg为基准模型,通过重构骨干网络与优化上采样机制,构建出适合涡旋光干涉图像的改进型分割网络模型。该模型由轻量化骨干网络、特征融合颈部、分割头部及原型生成网络四部分构成。如图3(a)所示,骨干网络由嵌入层、多级融合层、多个FasterNet模块和空间金字塔池化融合(SPPF)模块构成。其中,嵌入层采用 4×4 卷积实现空间下采样,将原始图像尺寸压缩至 $1/4$;融合层通过 2×2




图 2 OTSU 与 YOLOv8s-Seg 的分割结果对比

Fig. 2 Comparison of segmentation results using OTSU and YOLOv8s-Seg




图 3 网络整体结构及模块细节

Fig. 3 Overall network architecture and module details

针对基准模型在上采样过程中因高频细节重建不足导致的边缘模糊问题,把 CARAFE 上采样模块集成到颈部。该模块采用核预测与内容感知重组的双阶段机制实现自适应特征上采样,如图 3(c)所示。通过 1×1 卷积压缩输入特征通道以降低计算负荷,再利用 3×3 卷积对压缩特征进行空间内容编码,动态生成与目标位置相关的上采样核;在内容感知重组阶段,通过特征图像素映射定位到输入特征邻域窗口,并将预测核的归一化权重应用于特征加权融合^[19]。这种

卷积逐步扩展通道维度,构建深层特征空间;作为骨干核心,图 3(b)所示的 FasterNet 模块通过部分卷积(PConv)对输入特征进行选择通道处理,将运算复杂度降低至常规卷积的 $1/4$,随后通过两个逐点卷积层(PWConv)、批归一化(Batch Normalization, BN)与 ReLU 激活函数,在减少存储访问频率的同时维持特征的多样性表达^[18]。骨干末端的 SPPF 模块保留多尺度池化设计,与 FasterNet 的高效局部特征提取形成互补。

位置自适应的重组策略使算法能够根据局部纹理复杂度动态调整特征聚合方式,增强条纹交界处的细节恢复能力。联合轻量化的 FasterNet 骨干网络,使整体结构在涡旋光干涉图像的复杂纹理解析中,既能保障实时性,又能凭借动态特征重组优化分割精度,为后续的 CNN 回归网络提供高质量的形态输入。

2.3 基于 CNN 的旋转角度预测模型

CNN 通过局部感受野、权重共享和分层特征提取的协同机制,在提取输入数据的空间特

征时,可显著降低参数复杂度^[20]。这种参数优化策略在提升计算效率的同时,还可以提高模型的泛化能力。对于图像回归任务,CNN通过端到端学习可以直接构建原始像素与连续数值的映射关系,实现从图像到目标变量的精准

预测。

基于CNN的涡旋光干涉图像旋转角度预测模型如图4所示。它由输入层、五组卷积-池化模块(C1-P1, C2-P2, C3-P3, C4-P4,C5-P5)、全连接层(FC)和输出层组成,具体参数如表1所示。




图4 卷积神经网络结构

Fig. 4 Architecture of convolutional neural network (CNN)

表 1 CNN 模型参数				
Tab. 1 Parameters of CNN architecture				
Layer index	Layer name	Number of channels	Kernel size	Output size
1	Input	1	—	256×256×1
2	Conv1	32	3×3	256×256×32
3	MaxPool1	32	2×2	128×128×32
4	Conv2	64	3×3	128×128×64
5	MaxPool2	64	2×2	64×64×64
6	Conv3	128	3×3	64×64×128
7	MaxPool3	128	2×2	32×32×128
8	Conv4	256	3×3	32×32×256
9	MaxPool4	256	2×2	16×16×256
10	Conv5	512	3×3	16×16×512
11	GlobalAvgPool	512	—	1×1×512
12	Flatten	—	—	512
13	FC	512	—	512
14	Output	1	—	1

该网络采用层次化特征提取机制,实现从基础细节到深层特征的递进式分析。初始的C1层捕捉图像中的低级边缘特征和方向梯度,提供基本的空间信息;P1层通过下采样操作,降低特征图的空间分辨率,增强模型对微小位移所引起局部形变的稳定性。随着网络的深入,C2~C4层逐步深化特征的提取模式,获取更复杂的纹理和

结构信息。在特征汇聚阶段,GAP将多通道特征图压缩为 $1\times1\times512$ 的向量,在减少参数数量避免过拟合的同时,还保留了整个特征图的关键信息。接着由全连接层FC对该向量进行跨通道特征融合,将多尺度特征映射至回归空间,通过输出层的线性激活直接生成预测的旋转角度。网络采用ReLU激活函数,其单侧抑制特性使50%以上神经元进入非激活状态,同时正区间导数为1的特性,不仅可以抑制梯度消失,还能维持干涉图像微小位移特征的梯度传播。

3 实 验

3.1 实验装置

实验系统如图5所示。通过在空间光调制器(SLM)上加载相位全息图以生成拓扑荷数可灵活调控的涡旋光束,简化了实验装置。测试对象为Nano-HS3M压电纳米定位系统,该系统可通过软件在微米级行程内实现皮米级分辨率的精确定位控制。波长 $\lambda=532\text{ nm}$ 的激光经准直扩束后垂直照射到SLM表面,生成拓扑电荷数为 l 的涡旋光束。该调制光束经反射后进入分束器(BS1)进行初次分光,接着通过二级分束器(BS2)实现路径分离,其中参考光束经两个平面镜共反射3次后,拓扑荷数由 $+l$ 转换为 $-l$;测量光束与亚纳米级定位器相互作用并反射后经过

分束器(BS3),由于仅发生两次反射,其拓扑电荷数仍保持为 $+l$ 。这种反射次数的差异使得输出端产生花瓣状干涉图像,且花瓣数量是拓扑电荷 l 的两倍。

为兼顾测量灵敏度、测量范围及算法稳定性,这里采用拓扑荷数 $l=\pm 6$ 的涡旋光束。尽管较小的拓扑荷数具备更高的理论敏感度,但在大

位移下其干涉条纹易出现模糊与误差跳变;而更高的拓扑荷数则因干涉花瓣过于密集,增加了特征点提取的难度和误差。相较之下, $l=\pm 6$ 所形成的干涉图样密度适中、特征清晰,在保证高灵敏度的同时兼顾了算法的稳定性。为确保实验结果的准确性和可重复性,整个实验系统搭建在隔振光学平台上,且实验全程在恒温环境中进行。采用内置高精度传感器的闭环控制精密位移平台进行位移量调控,其分辨率可达 0.01 nm ;同时,由高分辨率CCD相机实时捕获干涉条纹的变化,在每个位移步长下连续采集20帧干涉图像,以有效抑制随机噪声,用于后续位移量的反演计算。

3.2 模型训练与性能指标

位移预测模型整体框架如图6所示,主要包含花瓣形态分割和多尺度特征与旋转角度映射两个阶段。采用改进YOLOv8s-Seg网络处理CCD采集的干涉图像,提取花瓣区域后,利用CNN进行分层特征学习,捕获花瓣在不同旋转状态下的形态变化规律,构建特征空间与旋转角度之间的精准映射。最终基于旋转角度与位移量之间的线性关系,实现高精度位移预测。




图5 基于共轭涡旋光干涉位移测量的实验装置
Fig. 5 Experimental setup for conjugate vortex beam interferometry-based displacement measurement




图6 位移预测整体框架
Fig. 6 Overall framework for displacement prediction

3.2.1 干涉花瓣区域的高精度分割

数据集由3.1节所述实验装置中CCD采集的20 000张干涉图像构成,清晰记录了不同位移

量对应的多花瓣干涉条纹分布。在图像采集完成后,使用Labelme软件中多边形工具对干涉图像各花瓣进行手动标注,生成相应的Mask标签,

以满足模型训练需求。按 7:2:1 的比例把数据集划分为训练集、验证集和测试集,以确保各阶段数据的独立性。为保证模型的训练效果,训练阶段的各项参数设置详见表 2。

表 2 实验参数设置

Tab. 2 Experimental parameter configuration

Parameter	Value
Epochs	150
lr0	0.01
lrf	0.000 1
Batch size	16
Weight-decay	0.000 5
Momentum	0.937
Input image size	640×640

常见的模型评估指标包括精度(P)、召回率(R)和平均精度均值(mAP)^[21]。 P, R 用于量化花瓣检测的查准率与查全率。mAP则是通过计算不同交并比(Intersection Over Union, IoU)阈值下的精度-召回率曲线积分面积,综合反映分割边界与真实标注的匹配精度。这 3 个参数越高,表示分割结果越好。其公式分别为:

$$P = \frac{TP}{TP + FP}, \quad (7)$$

$$R = \frac{TP}{TP + FN}, \quad (8)$$

$$AP = \int_0^1 P(R) dR, \quad (9)$$

$$mAP = \frac{\sum_{i=1}^n AP_i}{n}, \quad (10)$$

其中:真阳性(TP)为预测掩膜与真实掩膜 IoU 超过预设阈值的有效正类预测结果;假阳性(FP)表示将背景区域误判为花瓣的虚假预测;假阴性(FN)为真实花瓣未被模型检测的漏检实例;AP 表示单类别下不同置信度阈值对应的 P - R 曲线积分面积,值越高表示模型对该类别的分割越准确; n 表示数据集中目标类别的总数,本实验针对单一花瓣类别,故 AP 值等同于 mAP 值。

此外,每秒帧数(FPS)是对象检测算法中的关键性能指标,用于反映算法每秒能处理的图像

帧数量。其公式如下:

$$FPS = \frac{1}{T}. \quad (11)$$

3.2.2 形变-旋转关系的多尺度特征学习

采用改进型 YOLOv8s-Seg 网络提取的花瓣区域作为输入数据,每个位移标签对应 20 组干涉图像对。通过分层抽样策略将数据集按 7:2:1 的比例划分为训练集、验证集和测试集。选取均方误差作为损失函数,用于量化模型预测角度与真实角度之间的差异。训练过程中,使用 Adam 优化器对每个参数学习率进行动态自适应调整,加速模型收敛的同时缓解梯度方向振荡问题。同时引入基于验证集性能的早停机制,当验证指标在连续多个训练周期内未显著提升时,自动终止训练并恢复至最佳权重状态,以提高模型泛化能力并避免资源浪费。

为全面评估模型性能,分别从预测误差、误差敏感性和统计解释能力三方面构建评估体系。对应采用平均绝对误差(Mean Absolute Error, MAE)、均方误差(Mean Square Error, MSE)和决定系数(R^2)进行量化评估^[22],公式如下:

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_{\text{true}, i} - y_{\text{predict}, i}|, \quad (12)$$

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_{\text{true}, i} - y_{\text{predict}, i})^2, \quad (13)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_{\text{true}, i} - y_{\text{predict}, i})^2}{\sum_{i=1}^n (\overline{y_{\text{true}}} - y_{\text{true}, i})^2}, \quad (14)$$

其中:MAE 反映预测值与真实值的平均偏差程度,其数值越小说明模型预测精度越高;MSE 通过平方项放大异常误差的影响,能更敏感地反映模型在极端情况下的表现; R^2 从统计学角度评估模型对数据变化的解释能力, R^2 接近 1 时表示模型能准确捕捉输入与输出间的物理关联。

4 结果与讨论

4.1 改进型 YOLOv8s-Seg 分割性能分析

为验证各优化模块对模型性能的有效性和兼容性,进行了消融对比实验。所有实验均在统一硬件平台和训练参数下完成,以确保实验结果具有可比性。

表 3 添加不同模块的消融实验结果

Tab. 3 Ablation experiment with different module combinations

Experiment	YOLOv8s-Seg	FasterNet	CARAPE	Precision(%)	Recall(%)	mAP(%)	FPS
1	✓			84.3	82.7	89.3	115.2
2	✓	✓		89.6	80.4	90.7	126.7
3	✓		✓	90.7	84.6	92.4	120.3
4	✓	✓	✓	93.5	87.9	96.5	122.7

如表 3 所示,实验以原始 YOLOv8s-Seg 为基准模型,其后按研究序列依次叠加改进模块。先将骨干网络替换为 FasterNet 模块, mAP 提升 1.4%, 单帧推理时间缩短了 0.79 ms, 但召回率 R 有所下降。接着, 在颈部单独引入 CARAFE 上采样模块, mAP 和召回率 R 相较于基准模型分别提升了 3.1% 和 1.9%。最后, 把 FasterNet 和 CARAFE 模块协同整合到基准模型中, 整体 mAP 可达 96.5%。上述不同模型训练过程中 mAP 的变化曲线如图 7 所示, 验证了改进方案的协同优化效果。





图 7 mAP50, mAP50-95 的变化曲线

Fig. 7 Variation curves of mAP50 and mAP50-95

YOLOv8s-Seg 模型与改进型 YOLOv8s-Seg 模型对花瓣区域分割效果的对比如图 8 所示。YOLOv8s-Seg 模型虽然具备了识别花瓣区域的能力, 但其分割掩码存在漏检、不完整等问题, 且置信度在 0.72~0.98 之间剧烈波动。相比之下, 改进模型的置信度值更为集中且普遍较高, 其生成的掩码完整覆盖了全部目标实例, 无任何遗漏或空洞, 并且边缘轮廓平滑、精准。改进型 YOLOv8s-Seg 模型在花瓣区域分割任务上, 展现出更高的精度和更强的泛化能力。


4.2 旋转角度预测模型的精度验证

在模型训练过程中, 损失函数 (MSE) 的变化趋势如图 9 所示。随着训练轮数的增加, 训练集与验证集的损失函数值均呈现逐渐下降的趋势,



(a) YOLOv8s-Seg 模型

(a) YOLOv8s-Seg model



(b) 改进型 YOLOv8s-Seg

(b) Improved YOLOv8s-Seg

图 8 YOLOv8s-Seg 与改进型 YOLOv8s-Seg 的分割结果对比

Fig. 8 Comparison of segmentation results between YOLOv8s-Seg and improved YOLOv8s-Seg models

这表明模型在拟合能力和泛化性能上同步提升。在大约第 122 轮, 验证损失达到全局最小值, 此后在连续 10 轮的时间内未出现更低损失值, 即认为模型已经进入过拟合状态, 此时便通过动态验证集监控机制触发早期停止策略, 将模型参数锁定在最优泛化状态, 有效规避因过度学习训练样本中特异性特征导致的性能衰退问题。整体来看, 双损失曲线的平滑下降趋势表明模型的训练过程稳定, 超参数设置合理, 证明了该模型在旋转角度预测任务中的有效性和可靠性。

为评估模型在整个测量范围内的稳定性, 采取逐位移量训练策略获得关键性能指标。随机抽取的位移量训练结果如表 4 所示, 虽然 MAE




图9 损失函数曲线

Fig. 9 Loss function curves

表 4 模型在一定位移量下的评估结果

Tab. 4 Model evaluation results at certain displacement values

Displacement/nm	MAE/nm	MSE/nm ²	R ²
1	0.327	0.254	0.926
10	0.346	0.328	0.903
100	0.332	0.316	0.895
500	0.427	0.403	0.855

和MSE值随位移量变化存在微小波动,但决定系数 R^2 值均保持在0.85以上。这充分证明了模型的预测结果与真实值之间具备良好的一致性,且其特征提取与角度感知机制在不同位移下均能有效配合,反映出模型良好的稳定性。

4.3 微位移测量方法性能比较

为验证所提深度学习融合算法在微位移测量中的优势,将它与传统的质心法、循环互相关法进行了实验对比。实验采用 Nano-HS3M 压电纳米定位系统作为测试对象,其位移量为理论参考值。在0~500 nm的标准测量范围内,以1 nm为步进间隔驱动位移台,待各目标位移点稳定后,由高分辨率CCD相机采集对应的干涉图像,并针对每一位移增量分别采用3种方法独立重复测量20次,计算其MAE与MSE。各方法在不同位移量下的误差对比结果如图10所示。由图可知,深度学习融合方法在所有位移量的误差值均显著低于两种传统方法,且其最大测量误差未超过0.94 nm。




图10 三种微位移测量方法的MAE对比

Fig. 10 Comparison of MAE for three micro-displacement measurement methods

为进一步分析各方法在测量范围内的整体性能,表5给出了其整体的MAE和MSE,分别用于评估各模型的整体精度和误差离散程度。数据显示,深度学习融合方法的MAE与MSE数值均为最低。此结果表明,所提出的双网络协同架构可有效抑制由噪声及光束畸变所引入的测量不确定性。相较于依赖特定几何关键点定位的传统算法,该方法通过学习干涉条纹的整体形态特征,在测量精度和稳定性方面表现出显著优势。

表 5 三种微位移测量方法的性能比较

Tab. 5 Performance comparison of three micro-displacement measurement methods

Method	MAE/nm	MSE/nm ²
Cyclic cross-correlation	2.015	5.028
Centroid	1.263	3.152
Deep learning fusion	0.630	0.549

5 结 论

针对传统涡旋光干涉技术中位移反演算法精度受限的难题,本文提出了一种深度学习融合模型共轭涡旋光干涉微位移测量方法。基于涡旋光束的螺旋相位特性及其衍生的干涉图像旋转角度与位移的线性关系,利用YOLOv8s-Seg实例分割能力来抑制噪声和畸变干扰,并结合CNN多层级特征提取的优势,实现了对干涉花

瓣旋转角度的高分辨率测量,显著提升了位移测量的精度。实验结果表明,该系统在 0~500 nm 的标准位移内,干涉条纹分割的 mAP 达 96.5%,整体位移测量精度优于 0.94 nm,MAE 为 0.63 nm,且在扩展的测量范围内可保持较高的分辨率。未来的研究将进一步探索高阶拓扑荷数涡旋光与测量精度的映射规律,同时基于轻量化神经网络架构优化模型的计算效率,旨在为精密制造、微纳传感等领域提供普适性更强的亚纳米级位移测量解决方案。

参考文献:

- [1] 张智超,海澜,张书瑞,等. 复杂结构光场的多自由度协同调控技术研究进展[J]. 光电工程, 2024, 51(8): 240079.
ZHANG ZH CH, HAI L, ZHANG SH R, *et al.* Advances on the manipulation of structured beams with multiple degrees of freedom[J]. *Opto-Electronic Engineering*, 2024, 51(8): 240079. (in Chinese)
- [2] 赵冬娥,王思育,马亚云,等. 基于涡旋光与球面波干涉的微位移测量研究[J]. 红外与激光工程, 2020, 49(4): 0413005.
ZHAO D E, WANG S Y, MA Y Y, *et al.* Measurement of micro-displacement based on the interference of vortex beams and spherical wave[J]. *Infrared and Laser Engineering*, 2020, 49(4): 0413005. (in Chinese)
- [3] MA J B, LI P, GU Y Z. Characteristics of spiral patterns formed by coaxial interference between two vortex beams with different radii of wavefront curvatures[J]. *Photonics*, 2021, 8(9): 393.
- [4] XIAO M C, YANG D, XIONG J W. Non-contact measurement for cone angle of axicon lens based on vortex interference [J]. *Optics Communications*, 2021, 499: 127267.
- [5] YANG D, YANG Z M, ZHAO Z G, *et al.* Radius of curvature of spherical wave measurement based on vortex beam interference[J]. *Optics and Lasers in Engineering*, 2021, 142: 106592.
- [6] 韩世泽,杨栋,胡晓宁,等. 基于涡旋光与平面波干涉的微位移测量[J]. 光学精密工程, 2022, 30(17): 2058-2066.
HAN SH Z, YANG D, HU X N, *et al.* Micro-displacement measurement based on interference of vortex beams and plane wave [J]. *Opt. Precision Eng.*, 2022, 30(17): 2058-2066. (in Chinese)
- [7] 胡晓宁,杨栋,杨忠明,等. 共轭涡旋光干涉精密位移测量方法与系统[J]. 光学学报, 2023, 43(2): 77-87.
HU X N, YANG D, YANG ZH M, *et al.* Method and system for precision displacement measurement with interference of conjugated vortex beams[J]. *Acta Optica Sinica*, 2023, 43(2): 77-87. (in Chinese)
- [8] 方涵宇,张冬凯,陈理想. 从平面波的线性干涉到涡旋光的角向干涉[J]. 物理实验, 2023, 43(3): 29-35.
FANG H Y, ZHANG D K, CHEN L X. From linear interference to angular interference [J]. *Physics Experimentation*, 2023, 43(3): 29-35. (in Chinese)
- [9] WEBSTER J, ROSALES-GUZMÁN C, FORBES A. Radially dependent angular acceleration of twisted light[J]. *Optics Letters*, 2017, 42(4): 675.
- [10] 夏豪杰,谷容睿,潘成亮,等. 涡旋光位移干涉测量方法与信号处理[J]. 光学精密工程, 2020, 28(9): 1905-1912.
XIA H J, GU R R, PAN CH L, *et al.* Signal processing method for displacement measurement interferometry using vortex beams[J]. *Opt. Precision Eng.*, 2020, 28(9): 1905-1912. (in Chinese)
- [11] ZHU J L, WANG L, JI J Y, *et al.* Real-time measurement of dynamic micro-displacement and direction using light's orbital angular momentum [J]. *Applied Physics Letters*, 2022, 120(25): 251104.
- [12] LU H L, HAO Y Y, GUO C J, *et al.* Nano-displacement measurement system using a modified orbital angular momentum interferometer [J]. *IEEE Journal of Quantum Electronics*, 2022, 58

作者贡献声明:

杨雪娇:测量方法提出,论文构思和撰写;
刘吉:技术指导,项目管理;
武锦辉:验证,获取资助;
袁涛:可视化呈现;
王仕杰:实验数据获取及整理;
姬翔峰:实验数据分析;
于丽霞:论文审核;
张博洋:测量方法论证;
陈相:论文审核。

- (2): 7500105.
- [13] GAO H W, YANG D, HU X N, *et al.* High-precision micro-displacement measurement in a modified reversal shearing interferometer using vortex beams [J]. *Optics Communications*, 2023, 537: 129454.
- [14] CHENG M J, JIANG W J, GUO L X, *et al.* Metrology with a twist: probing and sensing with vortex light [J]. *Light: Science & Applications*, 2025, 14: 4.
- [15] YUAN T, LIU J, WU J H, *et al.* Advanced vortex beam interference system enhanced by CNN for micro-displacement detection [J]. *Optics and Lasers in Engineering*, 2025, 191: 108987.
- [16] YE G Y, YUAN T, ZHANG Y L, *et al.* Recent progress on laser interferometry based on vortex beams: Status, challenges, and perspectives [J]. *Optics and Lasers in Engineering*, 2024, 172: 107871.
- [17] 黄啸, 吴龙, 黎尧, 等. 基于改进 YOLOX-s 的轻量级型钢表面缺陷检测算法 [J]. *计算机应用*, 2023, 43(S2): 201-208.
- HUANG X, WU L, LI Y, *et al.* Lightweight steel surface defect detection algorithm based on improved YOLOX-s [J]. *Journal of Computer Applications*, 2023, 43(S2): 201-208. (in Chinese)
- [18] CHEN J R, KAO S H, HE H, *et al.* Run, don't walk: chasing higher FLOPS for faster neural networks [C]. 2023 *IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*. June 17-24, 2023, Vancouver, BC, Canada. IEEE, 2023: 12021-12031.
- [19] WANG J Q, CHEN K, XU R, *et al.* CARAFE: content-aware ReAssembly of FEatures [C]. 2019 *IEEE/CVF International Conference on Computer Vision (ICCV)*. October 27-November 2, 2019. Seoul, Korea. IEEE, 2019: 3007-3016.
- [20] KUMAR V, SINGH R S, DUA Y. Morphologically dilated convolutional neural network for hyperspectral image classification [J]. *Signal Processing: Image Communication*, 2022, 101: 116549.
- [21] ZUO C, QIAN J M, FENG S J, *et al.* Deep learning in optical metrology: a review [J]. *Light: Science & Applications*, 2022, 11: 39.
- [22] 赵佳蕊, 王玲芝, 李晨阳. 基于 LEA-LSTM 的光伏发电功率短期预测方法 [J]. *电力信息与通信技术*, 2024, 22(11): 34-42.
- ZHAO J R, WANG L ZH, LI CH Y. A short-term prediction method of photovoltaic power generation based on LEA-LSTM [J]. *Electric Power Information and Communication Technology*, 2024, 22(11): 34-42. (in Chinese)

作者简介:



杨雪娇(2002—),女,山西朔州人,硕士研究生,主要从事信息探测与处理方面的研究。E-mail: xuejiao_yang0328@163.com

通讯作者:



刘吉(1980—),男,黑龙江哈尔滨人,博士,教授,2011年于中北大学获得博士学位,主要从事特种环境智能光电感知技术与仪器、光电成像与处理技术等方向的研究。E-mail: liuji6@nuc.edu.cn