

文章编号 1004-924X(2026)13-1981-12

基于深度学习单帧干涉解耦的平行平板 光学均匀性高精度测量

周顺业, 汤 亮*, 崔 晗, 邱丽荣, 赵维谦
(北京理工大学 光电学院, 北京 100081)

摘要: 平行平板作为典型透射光学元件, 广泛应用于光学检测、半导体制造及国防装备等领域, 其光学均匀性对系统性能具有重要影响。针对现有光学均匀性高精度测量中存在的干涉混叠难以解耦、多帧采集耗时较长及环境噪声抑制困难等问题, 提出一种基于深度学习单帧干涉解耦的平行平板光学均匀性高精度测量方法。通过构建混叠干涉图与单面干涉图之间的映射模型对单帧混叠干涉图进行解耦, 从而获得前后表面各自的单表面干涉图, 以实现干涉条纹有效分离。通过虚拟移相重构由单帧干涉图生成的等移相间隔序列, 结合传统五步移相法进行相位提取与面形重建, 进而实现平行平板光学均匀性高精度检测。构建了两阶段卷积神经网络模型, 第一阶段网络用于实现混叠条纹到单面条纹的映射, 第二阶段网络完成五步移相序列生成及前后表面面形解算, 搭建了基于深度学习单帧干涉解耦的平行平板光学均匀性测量装置, 并采用 $\Phi 75$ mm 和 $\Phi 50$ mm 平行平板样品进行了实验验证。实验结果表明, 该方法测得的光学均匀性结果与 ZYGO 干涉仪测量结果一致性较好, 绝对偏差达到 10^{-7} 量级, 仅需采集单帧混叠干涉图即可实现平行平板光学均匀性的高精度、快速测量, 可为光学元件的高通量和现场化检测提供技术支撑。

关键词: 平行平板; 光学均匀性; 深度学习; 干涉解耦; 高精度

中图分类号: TH741; TP183 **文献标识码:** A

doi: 10. 37188/OPE. 20263413. 1981 **CSTR:** 32169. 14. OPE. 20263413. 1981

High-precision deep learning-based single-frame interferometric decoupling for measuring optical homogeneity of parallel plates

ZHOU Shunye, TANG Liang*, CUI Han, QIU Lirong, ZHAO Weiqian

(School of Optics and Photonics, Beijing Institute of Technology, Beijing 100081, China)

* Corresponding author, E-mail: 7520240174@bit.edu.cn

Abstract: Parallel plates, as typical transmission optical components, are widely employed in optical detection, semiconductor manufacturing, and defense applications. Their optical homogeneity has a significant impact on overall system performance. However, existing high-precision measurement methods face challenges, including difficulty in decoupling interference aliasing, time-consuming multi-frame acquisition, and limited capability in suppressing environmental noise. To address these limitations, a high-precision, deep learning-based single-frame interferometric decoupling method for measuring the optical homogeneity of parallel plates is proposed. First, a mapping model between aliased and single-sided interferograms is constructed to decouple the single-frame aliased interferogram, enabling the retrieval of single-sided

收稿日期: 2026-04-14; 修订日期: 2026-04-17.

基金项目: 国家自然科学基金青年科学基金资助项目 (No. 62505021)

ed interferograms for the front and back surfaces and effective separation of interference fringes. Subsequently, a virtual phase-shifting reconstruction is performed to generate a sequence with equal phase-shift intervals from the single-frame interferogram. In combination with the conventional five-step phase-shifting method, phase extraction and surface profile reconstruction are achieved, enabling high-precision evaluation of optical homogeneity. A two-stage convolutional neural network is developed, in which the first stage performs the mapping from aliased fringes to single-sided fringes, and the second stage generates the five-step phase-shifting sequence and reconstructs the surface profiles of the front and back surfaces. In addition, a deep learning-based single-frame interferometric decoupling experimental system is established for optical homogeneity measurement. Experiments conducted on $\Phi 75$ mm and $\Phi 50$ mm parallel plate samples demonstrate that the proposed method yields results in good agreement with those obtained using a ZYGO interferometer, with absolute deviations on the order of 10^{-7} . The proposed approach enables high-precision and rapid measurement of optical homogeneity using only a single-frame aliased interferogram, providing an effective solution for high-throughput and in situ inspection of optical components.

Key words: parallel plates; optical homogeneity; deep learning; interferometric decoupling; high-precision

1 引 言

光学均匀性(Homogeneity)是评价光学材料品质的核心指标之一,用于定量表征材料内部折射率分布的空间一致性^[1-2]。该参数直接决定光学元件的透射波前质量,制约系统的成像分辨率、光束质量及能量负载能力。在高功率激光系统、引力波探测、极紫外光刻等前沿应用中,光学均匀性的提升已达瓶颈。美国国家点火装置(National Ignition Facility, NIF)终端光学组件要求均匀性优于 10^{-6} 量级,而惯性约束聚变(Inertial Confinement Fusion, ICF)的下一代驱动器要求光学均匀性达到 10^{-7} 量级^[3-4]。平行平板是光学材料中的一个重要组成部分^[5-6],其厚度-口径比通常小于 1:10,故前后表面反射光程差极小,会引起干涉混叠现象^[7]。这种混叠现象使传统移相干涉术(Phase-Shifting Interferometry, PSI)难以直接应用于平行平板的光学均匀性测量,成为高精度检测的技术瓶颈。

现有光学均匀性测量方法主要基于移相干涉原理。其中,机械移相法(如传统四步绝对测量法^[8])利用压电陶瓷(PZT)实现精密位移,该方法成熟度高,测量精度可达 10^{-5} 量级,但提取相位通常需采集至少 4 帧干涉图。此外,机械移相法极易受机械迟滞误差和环境振动影响,必

须在超隔振平台上工作,且无法实现混叠条纹的有效分离。波长调谐法^[9]通过改变光源波长实现移相,无需移动参考镜即可实现面形检测。其理论精度可达 10^{-6} 量级,但需平衡采样总数与每周期采样点数,一般需采集 256 帧干涉图,且测量过程中的气流扰动会导致波长变化量与预期移相量偏离,受环境因素影响显著。点源异位同步移相法^[10]通过放置 4 个相对光轴不同偏移量的点光源引入不同的移相量,以实现 4 幅干涉图的同步移相,这解决了传统机械移相法无法在单独测量平行平板前后表面时引入移相的缺陷,仅需三步便能完成光学均匀性的动态测量。该方法可实现 10^{-6} 量级的测量精度,每步需采集 4 帧干涉图进行动态干涉测量,可有效抑制环境振动的影响,但存在结构复杂、光源偏离光轴使干涉图位置产生偏移引入错位等问题。上述方法的共性问题都是都需采集多幅干涉图来获取相位信息最终解算面形,容易受到外界干扰和振动的影响。

近年来,深度学习作为一种机器学习技术,其强大的数据驱动能力受到了光学测量领域的广泛关注,在条纹分析^[11-14]、条纹去噪^[15-16]、相位恢复^[17-20]以及三维重建^[21-24]等领域展现出超越传统方法的精度与稳定性。其中,单帧干涉测量已成为当前研究的热点之一。Wang 等^[25]提出了基

于物理信息神经网络(Physics-Informed Neural Networks, PINN)的相位恢复方法,将采集效率提高了两个数量级。Zuo 等^[26]系统阐述了深度学习在光学计量中的理论框架与发展趋势。然而,现有深度学习研究多集中于单表面元件,尚无利用深度学习方法,从单帧混叠干涉图中同时实现多表面解耦与高精度移相重建的研究,以解决平行平板的混叠分离与相位提取的解耦测量问题。

针对上述问题,本文提出一种基于深度学习单帧干涉解耦的平行平板光学均匀性高精度测量方法。通过构建级联卷积神经网络(Convolutional Neural Network, CNN)架构,第一级网络(CNN1)学习混叠干涉图到单表面干涉图的非线性解耦映射,第二级网络(CNN2)按物理约束生成虚拟移相序列,实现单帧到多帧的端到端重构,无需机械或波长调谐移相即可获取相位信息及对应面形并实现最终光学均匀性的解算。实验结果表明,本文所提方法的光学均匀性测量结果与 ZYGO 干涉仪吻合良好,实现了 10^{-7} 量级的测量精度,为平行平板类光学元件的高精度检测提供了新的技术途径。

2 原 理

2.1 基于深度学习单帧干涉解耦的平行平板光学均匀性测量

针对平行平板光学均匀性测量中所遇到的前后表面干涉混叠难分离,受环境影响噪声难抑制等问题提出一种基于深度学习单帧干涉解耦的测量方法,将传统移相干涉术与深度学习结合起来,用神经网络替代混叠分离算法及物理移相过程,通过虚拟移相进而实现均匀性解算。

基于深度学习单帧干涉解耦的平行平板光学均匀性测量原理如图 1 所示。在干涉仪上采集平行平板前、后表面混叠及单面干涉图,通过训练好的混叠-单面映射网络(CNN1)分离出前、后表面单面干涉图,随后将 CNN1 输出的单面干涉图输入深度学习移相网络(CNN2),以单帧图像的形式直接预测等间隔移相的多帧干涉图,通过相位解包裹与泽尼克拟合得到相应面形,结合平行平板厚度、折射率等参数解算光学均匀性。该方法摆脱了传统方法对机械移相装置与环境稳定性的依赖,仅需单帧干涉图便能实现高精度相位提取与面形解算,显著提升了光学均匀性测量的效率与抗干扰能力,为平行平板光学均匀性的




图 1 基于深度学习单帧干涉解耦的平行平板光学均匀性测量原理

Fig. 1 Principle of deep learning-based single-frame interferometric decoupling for measuring optical homogeneity of parallel plates

在线、动态测量提供了新的技术途径。

2.2 基于深度学习多面解耦干涉移相的网络模型

为实现平行平板光学均匀性的高精度测量,构建了端到端神经网络架构。其中,CNN1用于从混叠干涉图中分离前后表面单面条纹,解决多表面信息混叠问题;CNN2用于由单帧干涉图生成等间隔虚拟移相序列,解决传统多帧机械移相采集效率低且抗扰动能力不足的问题。

利用深度学习强大的数据学习能力构建混叠干涉图与单面干涉图之间的映射关系,解决平行平板混叠干涉的问题。训练完成后,在实际测

量时只需采集前、后表面混叠干涉图,即可通过CNN1实时重构对应的单面干涉图,为后续相位提取与面形解算奠定基础。

CNN1采用编码-解码结构并引入跳跃连接(Skip Connections),以同时保留全局条纹形态与局部边缘细节,提升空间信息传递效率。网络输入为 256×256 单通道混叠干涉图,输出为同尺寸单面干涉图,其网络架构如图2所示。CNN1在方法中的核心价值在于提供一个具有明确物理含义的中间量,即前、后表面可分离的单面干涉图。这个中间量既与2.3节可构建的标签数据一致,也使后续CNN2和五步移相公式能够建立在更干净、更稳定的条纹输入基础上。




图2 CNN1网络架构

Fig. 2 Architecture of CNN1 network

编码器通过下采样处理将特征通道数提升至512,空间维度压缩至 16×16 ,实现高层级特征的聚焦。解码器负责特征恢复与细节融合,由4个上采样模块构成,逐步恢复特征图尺寸。同时,拼接操作能够实现通道维度上的特征融合,使解码器同时获得高层级语义特征与低层级细节特征。最后再用输出层的 1×1 卷积核映射至1通道,并配合Sigmoid激活函数得到最终输出。

CNN1在保证特征恢复平滑性的同时极大地简化了网络参数结构,又结合编码-解码架构及跳跃连接,最终实现混叠条纹到单面条纹的高效映射。

获得单面干涉图后,需进行相位提取与面形

解算。传统五步移相法的相位解算公式为:

$$\varphi(x, y) = \arctan \left[\frac{2(I_4 - I_2)}{2I_3 - I_1 - I_5} \right], \quad (1)$$

其中: φ 代表提取出的相位, $I_1 \sim I_5$ 分别代表五张移相干涉图。

为抑制环境振动与空气扰动对移相精度的影响,提出一种基于深度学习的单帧到多帧移相预测方法。具体流程为:首先,采集大量传统五步移相法获取的干涉图序列(每组5帧);随后,以第一帧为输入,后四帧为标签,建立单帧到四帧的时空映射,实际应用时仅需输入单帧干涉图,CNN2便可直接输出固定移相间隔的四

帧干涉图,结合输入帧共五帧,代入式(1)完成相位提取,再经相位解包裹与泽尼克拟合得到面形;最后,依据样品翻转法原理解算光学均匀性。

CNN2采用编码-解码主干并引入注意力机

制,实现单帧到四帧移相序列的端到端映射,其结构如图3所示。该模型以单通道灰度图像为输入,张量维度表示为 $X \in \mathbf{R}^{B \times 1 \times H \times W}$ (其中 B 为批次大小, $H \times W$ 为图像分辨率,均为 256×256 大小),最终输出四通道特征图 $Y \in \mathbf{R}^{B \times 4 \times H \times W}$ 。




图3 CNN2网络架构

Fig. 3 Architecture of CNN2 network

编码阶段主要提取不同尺度的条纹特征,重点捕获条纹周期、方向和边缘过渡等与相位恢复密切相关的信息,通过三级下采样将特征图空间维度压缩为 32×32 ,通道数提升至512。特征融合阶段用于综合全局结构与局部细节,抑制噪声、对比度波动和局部扰动对移相预测的影响。解码阶段则逐步恢复空间分辨率,最后输出与输入帧对应的四帧虚拟移相干涉图。

CNN2实质上承担了“单帧输入、多帧输出”的时空映射功能,替代传统多帧采集过程,为单帧、快速、抗扰动的光学均匀性测量提供了关键支撑。

相较于传统测量方法,本文提出的级联网络架构仅需单帧混叠干涉图即可完成从混叠解耦到虚拟移相重建的全流程,提升了光学均匀性解算效率,且整个过程为数据驱动计算,无需任何移相执行机构,对环境扰动不敏感。

相较于常见网络模型,本文的网络设计亦有针对性改进。其中,CNN1采用编码-解码结构并引入跳跃连接,相比普通U-Net在保持全局条纹形态的同时保留了更多边缘细节,重建精度更

高。CNN2则引入注意力机制,相比无注意力机制的卷积网络能更有效地捕获条纹特征,提升虚拟移相序列的相位连续性和空间一致性。此外,两阶段级联设计相比端到端单网络方案,中间输出的单面干涉图具有明确物理含义,增强了模型的可解释性。

2.3 基于深度学习移相的训练集

采用在被测平行平板样品表面涂覆凡士林并结合翻转测量的方法,获取样品前后表面的面形信息,并将测量得到的大量数据作为深度学习模型的训练数据集。该涂覆方法为光学均匀性绝对测量的标准操作,凡士林的折射率接近1.5,与多数光学玻璃的折射率相近,能起到抑制后表面反射并避免引入额外干涉条纹的作用。在实际操作中,凡士林涂抹均匀且厚度适中,其引入的附加光程差对测量结果可忽略不计。该方法能够有效分离样品前、后表面的面形误差与测量系统误差,从而实现光学均匀性的绝对测量,其原理如图4所示。干涉仪系统的平面标准镜参考表面面形误差为 $W_T(x, y)$,样品前表面面形误差为 $W_A(x, y)$,样品后表面面形误差为 $W_B(x, y)$,




图4 样品翻转法测量原理

Fig. 4 Principle of window-flipping method

干涉仪系统反射镜表面面形误差为 $W_R(x, y)$ 。 n 为材料折射率, t 为材料厚度, T 为透射波前测量结果, S_1 为样品前表面测量结果, S_2 为样品后表面测量结果, C 为空腔测量结果。

第1步:前表面反射测量,在样品后表面涂抹折射率匹配液(凡士林),消除后表面反射,干涉仪参考表面与样品前表面干涉,测得波像差:

$$S1 = 2W_T(x, y) - 2W_A(x, y). \quad (2)$$

第2步,后表面反射测量,在样品前表面涂抹折射率匹配液,以 y 轴为对称轴翻转样品,干涉仪参考表面与样品后表面干涉。由于翻转前后样品后表面面形误差仅发生镜像对称变换,设翻转后的后表面面形为:

$$S2 = 2W_T(x, y) + 2W_B(-x, y). \quad (3)$$

翻转后样品后表面面形误差与翻转前的后表面面形误差不变,只是以 y 轴对称,则可通过坐标变换得到:

$$W_B(x, y) = W_B(-x, y). \quad (4)$$

第3步,透射测量光路透过样品,经系统反射镜反射后再次透过样品,参考表面与反射镜表面干涉,测得波像差:

$$T = 2W_T(x, y) - 2(1-n)W_A(x, y) + 2(1-n)W_B(x, y) + 2t\Delta n(x, y) - 2W_R(x, y). \quad (5)$$

第4步,空腔测量,通过移除样品使得参考表面与反射镜表面直接干涉,测得系统固有波

像差:

$$C = 2W_T(x, y) - 2W_R(x, y). \quad (6)$$

联立式(2)~式(6),得到材料光学均匀性:

$$\Delta n = [(n-1)(S1 + S2) + (T - C)] / 2t. \quad (7)$$

样品翻转法通过涂覆折射率匹配液选择性抑制某一表面反射,从根本上避免了干涉混叠问题,同时可获取单面干涉图作为深度学习标签数据,构建配对数据集。为保证样本数据的多样性,选取不同口径、不同材质的平行平板样品,分别在不同条纹密度、不同条纹倾斜方向条件下进行干涉图采集。并对采集图像随机施加旋转、平移及高斯噪声等操作,扩充数据集规模,提升模型泛化能力。

在训练数据准备过程中,首先对原始干涉图数据进行预处理:采用平场校正算法消除光源不均匀性与暗电流,通过双边滤波抑制散斑噪声并保留条纹边缘,利用基于尺度不变特征转换特征点的仿射变换实现亚像素级图像配准,最后将灰度值线性归一化至 $[0, 1]$ 。在训练数据集构建过程中,针对不同厚度(10 mm、15 mm 等)和不同材料(K9玻璃、熔融石英等)的平行平板样品,分别在不同条纹密度、不同条纹倾斜方向、不同离焦量及不同调制度条件下进行干涉图采集,共获取用于CNN1和CNN2两个网络模型的有效配对数据集各2 000组。

本文方法的平行平板厚度适用范围受电荷耦合器件(Charge-Coupled Device, CCD)采样分辨率以及条纹稀疏度共同约束。测量仪器使用的OK_AM1160型号的黑白面阵CCD相机,像元尺寸为 $8.3 \mu\text{m}$,其极限分辨率约为60线/mm。在干涉测量中,干涉条纹的空间频率为:

$$f = \frac{2nt}{\lambda}, \quad (8)$$

其中: n 为材料折射率,设为1.5; t 为材料厚度, λ 为激光光源波长,这里为632.8 nm。当干涉条纹空间频率大于CCD极限分辨率时,CCD将无法有效分辨。因此,结合式(8)可得理论厚度下限约为 $12.7 \mu\text{m}$ 。考虑到实际成像中的衰减效应,有效厚度下限约为理论值的2倍。所以在本文实验条件下,厚度下限约为 $25 \mu\text{m}$ 。对于厚平板,当厚度超过50 mm时,干涉腔长显著增大,环境振动引起的光程差波动将导致干涉图信噪比下降。因此,本文方法适用平行平板的厚度为

25~50 mm。

本文模型在 NVIDIA GeForce RTX 4090 (24 GB) GPU 上训练且系统安装了 CUDA 12.8,在 Pytorch2.8.0 框架下使用 Python 3.12 编写。两个网络模型的数据集均按 8:2 比例随机划分为训练集与验证集,训练图像的尺寸均为 256×256 。CNN1 选用带权重衰减的 AdamW 优化器,初始学习率设为 10^{-4} ;采用 ReduceLROnPlateau 学习率调度器,以验证集总损失为监测指标;训练批次为 8,训练轮数为 800 轮,实施早停策略,参数量达 1 700 万,训练耗时约为 14 h,推理耗时约为 0.27 s。CNN2 设计了 L1 损失与 SSIM 损失(权重比 3:7)的加权组合损失函数以平衡像素级细节误差与结构相似性,同样采用 AdamW 优化器(权重衰减为 10^{-4}),初始学习率为 10^{-3} ;学习率调度器使用 CosineAnnealingWarmRestarts 避免模型陷入局部最优,训练批次为 4,训练轮数为 500 轮,参数量达到 2 200 万,训练耗时约为 33 h,推理耗时约为 2.1 s。

3 实验验证与结果分析

为了验证本文提出的基于深度学习单帧干涉解耦的平行平板光学均匀性测量方法的可行性,研制了基于深度学习单帧干涉解耦的平行平板光学均匀性测量仪器,如图 5 所示。首先,利用该仪器采集若干组平行平板前、后表面的混叠干涉图及相应的前、后表面单面干涉图。随后,构建两个映射数据集:前表面混叠-单面图映射对、




图 5 激光差动共焦干涉元件参数测量仪器总体架构

Fig. 5 Overall architecture of laser differential confocal interference measuring instrument

后表面混叠-单面图映射对。接着,采集若干组透射和空腔条件下的干涉图以获取其波像差。最后,根据四步分别获取的波像差依据式(7)得到平行平板的光学均匀性。

选取 $\Phi 75$ mm 和 $\Phi 50$ mm 两块圆形熔融石英平行平板作为被测样品,系统验证本文所提方法的测量能力。验证方案为设计 3 组对比实验,本方法的处理流程为单帧混叠干涉图经 CNN1 分离得到单面干涉图,再经 CNN2 预测生成四帧移相序列,通过五步移相算法解算面形,最终依据样品翻转法求解光学均匀性;传统五步移相法直接测量结果作为真值(Ground Truth, GT);ZYGO GPI XP/D 干涉仪(标称精度 $\lambda/100$, RMS 重复性 0.5 nm)测量结果作为参考基准(Reference)。所有测量均在相同环境条件下进行,测量前恒温时间大于 2 h。采用峰谷值(Peak to valley, PV)、均方根值(Root Mean Square, RMS)作为评价指标,分别使用本文方法和传统五步移相法进行面形解算,并将结果与 ZYGO 干涉仪测量结果进行定量比较。

CNN1 与 CNN2 的训练损失曲线分别如图 6 和图 7 所示。可以看到,两个模型随着不断训练均趋于收敛。




图 6 CNN1 训练损失曲线

Fig. 6 CNN1 training loss curves

为验证 CNN1 的混叠分离能力和 CNN2 的虚拟移相重构能力,构建了如图 8 所示的模型验证流程。首先,从测试集中随机选取一组混叠干涉图输入 CNN1,评估混叠-单面映射精度。定量评价结果表明,CNN1 实际输出的单面干涉图与




图7 CNN2训练损失曲线

Fig. 7 CNN2 training loss curves




图8 本文所提深度学习神经网络模型验证流程

Fig. 8 Verification process of proposed deep learning neural network model

理想真值之间的结构相似性指数 (Structural Similarity Index, SSIM) 达 0.98, 峰值信噪比 (Peak Signal-to-Noise Ratio, PSNR) 为 34.9 dB, 证实网络实现了高保真的混叠条纹分离, 为后续移相预测奠定了可靠基础。

随后, 将 CNN1 输出的单帧单面干涉图作为 CNN2 的输入, 预测生成四帧移相干涉图, 再结

合输入帧共五帧, 采用五步移相算法解算面形。真值面形通过传统五步移相法在相同实验条件下实测获取, 以消除系统误差对比的影响。定性分析显示, 本文方法解算的面形轮廓与真值高度一致, 没有出现明显的波纹或畸变。

定量对比结果如表 1 所示。本文方法得到的面形 PV 为 0.072λ , RMS 为 0.025λ ; 真值面形的 PV 为 0.084λ , RMS 为 0.016λ 。与真值相比, PV 偏差为 7.6 nm, RMS 偏差为 5.7 nm, 进一步验证了 CNN2 移相预测的高精度与相位连续性保持能力。

表 1 本文提出的方法与真值面形数值结果对比

Tab. 1 Comparison of surface profile results between proposed method and GT value

Error	Proposed method	GT value	Deviation
PV	0.072λ	0.084λ	$<7.6\text{ nm}$
RMS	0.025λ	0.016λ	$<5.7\text{ nm}$

上述结果表明, 本文提出的深度学习神经网络模型能够有效实现混叠条纹分离与单帧移相预测, 满足高精度光学均匀性测量的需求。

为系统评估本文方法的测量精度与可靠性, 分别采用本文方法、传统五步移相法及 ZYGO 商用干涉仪对 $\Phi 75\text{ mm}$ 圆形熔融石英平行平板进行光学均匀性测量, 结果如图 9 所示。3 种方法得到的均匀性分布均呈现中心高、边缘略低的典型分布特征。




图9 $\Phi 75\text{ mm}$ 口径圆形平行平板光学均匀性测量结果

Fig. 9 Optical homogeneity measurement results of $\Phi 75\text{ mm}$ circular parallel plate

对比结果如表 2 所示。本文方法测得的光学均匀性为 2.93×10^{-6} , 光学均匀性 RMS 为 4.41×10^{-7} ; 传统五步移相法测得光学均匀性为 3.59×10^{-6} , 光学均匀性 RMS 为 4.39×10^{-7} ; ZYGO 干涉仪测得光学均匀性为 3.17×10^{-6} , 光学均匀性 RMS 为 4.32×10^{-7} 。以 ZYGO 测量结果为参考基准, 本文方法的光学均匀性偏差为 2.4×10^{-7} , 光学均匀性 RMS 偏差为 9×10^{-9} , 优于传统五步移相法的光学均匀性偏差 4.2×10^{-7} 及光学均匀性 RMS 偏差 7×10^{-9} 。

表 2 $\Phi 75\text{ mm}$ 口径圆形平行平板的三种方法光学均匀性结果
Tab. 2 Optical homogeneity results of three methods for $\Phi 75\text{ mm}$ circular parallel plate

	Proposed method	Traditional five-step PSI	ZYGO	Deviation with ZYGO
Homogeneity	2.93×10^{-6}	3.59×10^{-6}	3.17×10^{-6}	2.4×10^{-7}
Homogeneity RMS	4.41×10^{-7}	4.39×10^{-7}	4.32×10^{-7}	9×10^{-9}

为进一步验证本文方法对不同口径样品的适应性及测量一致性, 选取 $\Phi 50\text{ mm}$ 圆形熔融石英平行平板进行补充实验。该样品与 $\Phi 75\text{ mm}$ 样品材料相同但口径减小, 可评估本文方法在更小通光孔径下的测量性能。3 种方法的测量结果如图 10 所示。本文方法测得的光学均匀性分布呈现对称的环状结构, 与 ZYGO 测量结果高度吻合; 传统五步移相法因对环境振动较为敏感, 局部出现轻微波纹噪声。

定量对比结果如表 3 所示。本文方法测得的光学均匀性为 4.07×10^{-6} , 光学均匀性 RMS 为 6.63×10^{-7} ; 传统五步移相法测量结果为 4.30×10^{-6} , 光学均匀性 RMS 为 5.49×10^{-7} ; ZYGO 干涉仪测量结果为 4.40×10^{-6} , 光学均匀性 RMS 为 6.08×10^{-7} 。以 ZYGO 结果为基准, 本文方法的光学均匀性偏差为 3.3×10^{-7} , 光学均匀性 RMS 偏差为 5.5×10^{-8} , 两种方法差别极小。




图 10 $\Phi 50\text{ mm}$ 口径圆形平行平板光学均匀性测量结果
Fig. 10 Optical homogeneity measurement results of $\Phi 50\text{ mm}$ circular parallel plate

表 3 $\Phi 50\text{ mm}$ 口径圆形平行平板的三种方法光学均匀性结果
Tab. 3 Optical homogeneity results of three methods for a $\Phi 50\text{ mm}$ circular parallel plate

Homogeneity	Proposed method	Traditional five-step PSI	ZYGO	Deviation with ZYGO
Value	4.07×10^{-6}	4.30×10^{-6}	4.40×10^{-6}	3.3×10^{-7}
RMS	6.63×10^{-7}	5.49×10^{-7}	6.08×10^{-7}	5.5×10^{-8}

为进一步验证本文方法的测量重复性, 对 $\Phi 75\text{ mm}$ 熔融石英平行平板进行了简单重复性测试。在相同环境条件下, 每隔 2 min 采集一次单帧混叠干涉图, 共采集 10 组独立样本, 分别通过

本文方法解算光学均匀性。测试结果如表 4 所示。光学均匀性的简单重复性为 2×10^{-8} ; 光学均匀性 RMS 的简单重复性为 2.6×10^{-9} 。上述结果表明, 本文方法在单帧输入条件下具有良好的测量重复性, 验证了本文所提方法在多次独立测量中的稳定性与一致性。

表 4 $\Phi 75$ mm 口径圆形平行平板的本文方法光学均匀性重复性测试结果

Tab. 4 Repeatability test results of optical homogeneity of proposed method for $\Phi 75$ mm circular parallel plate

Test	Homogeneity	Homogeneity RMS
1	2.91×10^{-6}	4.38×10^{-7}
2	2.95×10^{-6}	4.45×10^{-7}
3	2.89×10^{-6}	4.40×10^{-7}
4	2.93×10^{-6}	4.36×10^{-7}
5	2.90×10^{-6}	4.42×10^{-7}
6	2.93×10^{-6}	4.41×10^{-7}
7	2.89×10^{-6}	4.37×10^{-7}
8	2.92×10^{-6}	4.41×10^{-7}
9	2.93×10^{-6}	4.38×10^{-7}
10	2.91×10^{-6}	4.40×10^{-7}
Repeatability	2×10^{-8}	2.6×10^{-9}

综合 $\Phi 75$ mm 与 $\Phi 50$ mm 两块平行平板的测量结果, 本文方法展现出优异的测量精度。与 ZYGO 商用干涉仪相比, 绝对偏差达 10^{-7} 量级; 与传统五步移相法相比, 测量结果基本一致, 均匀性分布更加平滑, 有效抑制了环境振动与空气扰动引入的测量误差。此外, 本文方法仅需单帧干涉图便能实现相位提取与面形解算, 显著提升了测量效率。实验结果表明, 本文提出的基于深度学习单帧干涉解耦的平行平板光学均匀性测量方法具有准确、可靠、抗干扰能力强的特点, 且

现有深度学习光学测量方法的网络主要解决相位解调、三维重建等任务, 展现出优异的性能, 但其输入条纹图必须来源于单一光学表面, 局限于非混叠的干涉条纹分析。本文工作的先进性正是在于首次实现基于深度学习的平行平板混叠干涉图解耦, 建立了从混叠干涉图到单面干涉图的非线性映射, 为光学均匀性的高精度、高效率检测提供了有效的技术途径。

4 结 论

本文提出了一种基于深度学习单帧干涉解耦的平行平板光学均匀性高精度测量方法, 通过 CNN1 与 CNN2 两级级联网络分别实现混叠干涉图到单面干涉图的高保真分离以及单帧到四帧移相序列的端到端预测, 将传统机械移相转化为数据驱动计算, 显著提升了测量效率与环境抗干扰能力。实验结果表明, 该方法在 $\Phi 75$ mm 与 $\Phi 50$ mm 熔融石英平行平板上的光学均匀性测量结果与 ZYGO 商用干涉仪相比具有高度一致性, 绝对偏差达 10^{-7} 量级, 测量精度满足 $\lambda/80$ 要求。未来工作可进一步拓展至复杂面形和更多材料类型, 并结合轻量化网络结构与物理先验约束提升模型的泛化能力和实时性, 推动光学均匀性检测向智能化、高精度、高效率方向发展。

作者贡献声明:

周顺业: 模型建立, 实验设计与分析, 初稿撰写;

汤 亮: 方法论, 获取资助, 论文审核与编辑;

崔 晗: 项目管理, 论文审核与编辑;

邱丽荣: 提供资源, 实验指导;

赵维谦: 提供资源, 论文审核。

参考文献:

- [1] 李强, 刘昂, 高波, 等. 光学材料光学不均匀性绝对测量误差分析[J]. 应用光学, 2013, 34(3): 463-468.
LI Q, LIU A, GAO B, *et al.* Error analysis of absolute test method of inhomogeneity of optical mate-

rials[J]. *Journal of Applied Optics*, 2013, 34(3): 463-468. (in Chinese)

- [2] 郭培基, 余景池, 丁泽钊, 等. 光学玻璃光学均匀性的绝对测量技术[J]. 激光杂志, 2003, 24(3): 26-27.
GUO P J, YU J CH, DING Z ZH, *et al.* Absolute testing method of the homogeneity of optical glass[J].

- Laser Journal*, 2003, 24(3): 26-27. (in Chinese)
- [3] 廖之山. 基于非均匀傅里叶变换的平行平板光学均匀性的干涉测量技术研究[D]. 南京: 南京理工大学, 2019.
LIAO ZH SH. *Research on Optical Homogeneity Interferometry of Parallel Plates Based on Nonuniform Fast Fourier Transform* [D]. Nanjing: Nanjing University of Science and Technology, 2019. (in Chinese)
- [4] 郭仁慧. 近红外大口径波长移相干涉仪关键技术及应用研究[D]. 南京: 南京理工大学, 2013.
GUO R H. *Research on Key Techniques and Applications of the Near-Infrared Large Aperture Wavelength-Tuning Interferometer* [D]. Nanjing: Nanjing University of Science and Technology, 2013. (in Chinese)
- [5] 周永昊, 常林, 何婷婷, 等. 超精密平面光学元件检测技术[J]. 自然杂志, 2023, 45(3): 157-176.
ZHOU Y H, CHANG L, HE T T, *et al.* Research on measurement technology of ultra-precision planar optics[J]. *Chinese Journal of Nature*, 2023, 45(3): 157-176. (in Chinese)
- [6] 钱宇, 郭仁慧, 蒋金威, 等. 平行平板光学参数的快速高精度测量方法[J]. 光学学报, 2024, 44(3): 0312002.
QIAN Y, GUO R H, JIANG J W, *et al.* Fast and high-precision measurement method of optical parameters of parallel flat plates[J]. *Acta Optica Sinica*, 2024, 44(3): 0312002. (in Chinese)
- [7] 刘旭, 任寰, 于德强, 等. 干涉法测量光学材料光学非均匀性[J]. 激光技术, 2011, 35(2): 189-192.
LIU X, REN H, YU D Q, *et al.* Measurement method for inhomogeneity of optical material by means of interferometry [J]. *Laser Technology*, 2011, 35(2): 189-192. (in Chinese)
- [8] AI C, WYANT J C. Measurement of the inhomogeneity of a window [J]. *Optical Engineering*, 1991, 30(9): 1399-1404.
- [9] 李建欣, 郭仁慧, 朱日宏, 等. 光学材料光学均匀性的波长调谐两步绝对测量法[J]. 光学学报, 2012, 32(11): 1112007.
LI J X, GUO R H, ZHU R H, *et al.* Two-step wavelength tuning absolute testing method of the optical homogeneity of optical material[J]. *Acta Optica Sinica*, 2012, 32(11): 1112007. (in Chinese)
- [10] 张瑞, 陈磊, 朱文华, 等. 点源异位同步移相法检测平行平晶的光学均匀性[J]. 光子学报, 2018, 47(1): 0112002.
ZHANG R, CHEN L, ZHU W H, *et al.* Measuring optical homogeneity of parallel plates based on simultaneous phase-shifting by lateral displacement of point sources[J]. *Acta Photonica Sinica*, 2018, 47(1): 0112002. (in Chinese)
- [11] LIU H Y, YAN N, SHAO B F, *et al.* Deep learning in fringe projection: a review[J]. *Neurocomputing*, 2024, 581: 127493.
- [12] FENG S J, CHEN Q, GU G H, *et al.* Fringe pattern analysis using deep learning [J]. *Advanced Photonics*, 2019, 1(2): 025001.
- [13] YIN W, CHE Y X, LI X S, *et al.* Physics-informed deep learning for fringe pattern analysis[J]. *Opto-Electronic Advances*, 2024, 7(1): 230034.
- [14] FENG S J, ZUO C, ZHANG L, *et al.* Generalized framework for non-sinusoidal fringe analysis using deep learning [J]. *Photonics Research*, 2021, 9(6): 1084.
- [15] GURROLA-RAMOS J, DALMAU O, ALARCÓN T. U-Net based neural network for fringe pattern denoising [J]. *Optics and Lasers in Engineering*, 2022, 149: 106829.
- [16] GURROLA-RAMOS J, DALMAU O, ALARCÓN T E. A residual dense U-Net neural network for image denoising [J]. *IEEE Access*, 2021, 9: 31742-31754.
- [17] QIAO G, HUANG Y Y, SONG Y P, *et al.* A single-shot phase retrieval method for phase measuring deflectometry based on deep learning [J]. *Optics Communications*, 2020, 476: 126303.
- [18] WANG K Q, LI Y, QIAN K M, *et al.* One-step robust deep learning phase unwrapping [J]. *Optics Express*, 2019, 27(10): 15100.
- [19] WANG K Q, SONG L, WANG C T, *et al.* On the use of deep learning for phase recovery [J]. *Light: Science & Applications*, 2024, 13: 4.
- [20] TANG L, HAN M Z, YANG S, *et al.* High-precision large-aperture single-frame interferometric surface profile measurement method based on deep learning [J]. *International Journal of Extreme Manufacturing*, 2025, 7(5): 055601.
- [21] WANG F Z, WANG C X, GUAN Q Z. Single-shot fringe projection profilometry based on deep learning and computer graphics [J]. *Optics Express*, 2021, 29(6): 8024.
- [22] NGUYEN H, WANG Y Z, WANG Z Y. Single-

- shot 3D shape reconstruction using structured light and deep convolutional neural networks[J]. *Sensors*, 2020, 20(13): 3718.
- [23] YU H T, ZHENG D L, FU J A, *et al.* Deep learning-based fringe modulation-enhancing method for accurate fringe projection profilometry[J]. *Optics Express*, 2020, 28(15): 21692.
- [24] FU Y J, HUANG Y L, XIAO W, *et al.* Deep learning-based binocular composite color fringe projection profilometry for fast 3D measurements[J]. *Optics and Lasers in Engineering*, 2024, 172: 107866.
- [25] WANG F, BIAN Y M, WANG H C, *et al.* Phase imaging with an untrained neural network[J]. *Light: Science & Applications*, 2020, 9: 77.
- [26] ZUO C, QIAN J M, FENG S J, *et al.* Deep learning in optical metrology: a review[J]. *Light: Science & Applications*, 2022, 11: 39.

作者简介:



周顺业(2001—),男,山西新绛人,硕士研究生,2023年于北京工业大学获得学士学位,主要从事光电测试技术及仪器的研究。E-mail: zsy_030824@163.com

通讯作者:



汤亮(1996—),女,吉林长春人,博士,助理研究员,2020年于北京工业大学获得硕士学位,2024年于北京理工大学获得博士学位,主要从事光学精密检测技术的研究。E-mail: 7520240174@bit.edu.cn