

文章编号 1004-924X(2024)12-1812-12

## 相衬光学相干弹性成像的超分辨应变测量

张展华, 曹 鑫, 詹伟浩, 董 博, 谢胜利, 白玉磊<sup>\*</sup>  
(广东工业大学 自动化学院, 广东 广州 510006)

**摘要:** 相衬光学相干弹性成像的相位分辨率受限于系统的光源带宽, 导致层析应变成像质量低。这严重制约了相衬光学相干弹性成像的实际应用与发展。为此, 本文提出一种基于数据驱动的超分辨应变测量方法, 以解决相位分辨率受限下的应变重构困难问题。首先, 根据相衬光学相干弹性成像原理, 搭建了层析应变测量模型, 用于获取网络训练所需的数据集, 解决实际测量过程中超分辨应变标签难以获取的问题。其次, 构建深度卷积神经网络, 通过带有层析分辨率受限特点的数据驱动方式, 让网络学习低分辨率相位与高分辨应变之间的映射关系, 从而实现相衬光学相干弹性成像的超分辨应变测量。最后, 采用数值验证和压缩变形加载实验对本文方法的性能进行验证。实验结果表明本文方法在窄带宽输出下能重构出宽带宽的应变测量效果, 并且其信噪比相比于矢量方法和传统应变计算深度神经网络, 分别提高了 18.4 dB 和 1.45 dB。本文方法可以突破系统光源的带宽限制, 在低分辨率相位输入条件下实现超分辨应变测量, 从而加快相衬光学相干弹性成像在力学性能表征、内部早期损伤探测等方面的应用前景。

**关键词:** 光学弹性成像; 相衬技术; 应变测量; 深度神经网络; 超分辨重构

**中图分类号:** TP394.1; TH691.9 **文献标识码:** A **doi:** 10.37188/OPE.20243212.1812

## Super-resolution strain measurement in phase-contrast optical coherence elastography

ZHANG Zhanhua, CAO Xin, ZHAN Weihao, DONG Bo, XIE Shengli, BAI Yulei<sup>\*</sup>

(School of Automation, Guangdong University of Technology, Guangzhou 510006, China)

<sup>\*</sup> Corresponding author, E-mail: ylbai@gdut.edu.cn

**Abstract:** The resolution of phase-contrast optical coherence elastography (PC-OCE) is constrained by the bandwidth of the system's light source, leading to poor quality in tomographic strain imaging. This limitation significantly hinders the practical implementation and advancement of PC-OCE. This study introduced a data-driven super-resolution strain measurement approach to tackle the challenge of strain reconstruction under restricted phase resolution. Firstly, according to the principle of PC-OCE, a simulation measurement model was built to obtain the required data set, which solved the problem that was difficult to obtain the ground truth in the real measurement process. Secondly, a deep neural network was used to learn the mapping relationship between low-resolution phase and high-resolution strain through a data-driven manner, realizing the super-resolution measurement of strain. Finally, numerical validation and compression deformation loading experiments were employed to validate the efficacy of the method introduced in this study. The experimental results demonstrate that the approach presented in this study can recon-

收稿日期: 2024-01-05; 修订日期: 2024-03-07.

基金项目: 国家自然科学基金 (No. 61705047, No. 62171140)

struct the strain measurement outcomes across a wide bandwidth despite operating under a narrow bandwidth output. Furthermore, the signal-to-noise ratio is enhanced by 18.4 dB and 1.45 dB in comparison to the vector method and conventional deep neural network for strain calculation. The proposed method overcomes the bandwidth limitation of the system light source, enabling super-resolution strain measurement under low-resolution phase input conditions. This advancement enhances the potential applications of phase-contrast optical coherence elastography in characterizing mechanical performance, detecting early internal damage, and other related areas.

**Key words:** optical coherence elastography; phase contrast technology; strain measurement; deep neural network; super-resolution reconstruction

## 1 引 言

光学相干层析成像技术(Optical Coherence Tomography, OCT)是一种具有微米级分辨率和毫米级量程的层析成像方法<sup>[1]</sup>。由于OCT具有高分辨、非侵入和无辐射等特点,且能较好兼顾成像分辨率和穿透深度,因此其被广泛应用于生物组织内部结构成像<sup>[2]</sup>。例如,能够对毛细血管以及人类视网膜进行成像<sup>[3]</sup>。上述传统OCT技术只能获取样品内部结构,难以提供样品不同状态的参数信息。为此,人们在OCT技术基础上进一步提出了功能型OCT成像方法,其中光学弹性成像(Optical Coherence Elastography, OCE)能够测量得到样品在不同力学载荷环境下的体块应变场,进而实现样品内部的弹性模量功能成像<sup>[4-6]</sup>。由于疾病通常会引起组织生物弹性模量等力学性能的改变,因此OCE最早被用于生物医学领域的疾病早期诊断和致病机理的研究<sup>[7]</sup>。近些年来,OCE被逐渐推广应用于工业领域的复合材料力学性能表征<sup>[8]</sup>、高分子材料内部的亚微米级缺陷检测<sup>[9]</sup>、牙科树脂材料的固化监测<sup>[10]</sup>等。上述应用展示了OCE在力学功能成像方面的优秀性能。2017年,美国光学学会会士D. Sampson教授在《Nature Photonics》专题报道中总结指出“光学相干弹性成像是目前最具发展前景的内部力学性能表征方法”<sup>[11]</sup>。

光学相干弹性成像可采用散斑追踪<sup>[12]</sup>或相衬技术<sup>[13]</sup>实现样品内部的应变场测量,其中相衬技术的测量灵敏度为微应变级别且动态测量范围比散斑追踪方法高~20倍。因此,相衬光学相干弹性成像(Phase-contrast Optical Coherence Tomography, PC-OCE)成为目前OCE的研究热

点之一。PC-OCE的应变测量步骤包括3步:(1)采集样品的干涉光谱信号;(2)通过傅里叶变换相频图获取样品形变前后的差分包裹相位;(3)计算相位沿轴向方向的梯度变化从而得到样品应变分布测量结果。然而在实际测量过程中,有限的光源光谱带宽会引入频谱窗函数卷积运算,进而导致层析分辨率降低<sup>[14]</sup>。此时,由步骤(2)计算的差分包裹相位难以分辨出形变较大区域时的相位分布,使得后续的相位梯度计算难以开展,最终影响到PC-OCE的应变测量分辨率。因此,PC-OCE亟待解决的问题是如何在差分包裹相位的现有分辨率基础上突破光源带宽限制,从而实现超分辨应变成像。

针对光源光谱带宽有限带来的层析分辨率问题,国内外研究者给出了两类解决思路:(1)采用现代谱估计方法实现层析干涉谱的高分辨重构,减轻窗函数卷积引起的频谱混叠<sup>[15]</sup>。(2)构建出关于层析干涉相位谱的非线性优化模型,最大限度逼近周期信号的离散谱<sup>[16]</sup>。但是,现代谱估计方法因涉及干涉信号的自相关运算,导致仅能改善层析结构分辨率,而无法扩展应用于PC-OCE的差分包裹相位测量结果。层析干涉相位谱的非线性优化模型须提供样品测量的先验信息从而得到优化迭代计算的初始值,导致其难以应用到样品变形测量的实际应用场景。综上所述,现有方法均聚焦到OCT层析结构分辨率的提升,但鲜有文献报道关于PC-OCE超分辨应变成像方面的研究。

近些年来,深度学习技术在自动聚焦<sup>[17]</sup>、景深扩展<sup>[18]</sup>、图像去噪<sup>[19]</sup>等图像增强和图像恢复方面取得了显著成效。受深度学习在图像领域应用的启发,研究者们开始尝试将其引入到光学测

量中,并提出了相位解包裹深度神经网络<sup>[20]</sup>、基于 U-Net 卷积神经网络的条纹投影相位恢复<sup>[21]</sup>、基于生成对抗网络的 OCT 散斑噪声去噪<sup>[22]</sup>等。由于深度学习能直接建立输入与输出两者间的映射关系,因此其可减少测量信号解调过程中存在的算法模型误差。基于该特点,深度学习技术能从根本上避免差分包裹相位解调的频谱窗函数卷积运算,有望用于克服 PC-OCE 的层析分辨率问题。

本文提出基于深度卷积神经网络的 PC-OCE 超分辨应变重构方法。为解决因样品形变先验信息未知导致的训练集难以获取问题,本文首先采用数值计算方法模拟 PC-OCE 的成像机理,以此得到低分辨差分包裹相位自变量和超分辨相位梯度标签;通过搭建 UNet++ 的深度卷积神经网络架构,学习从低分辨包裹相位到高分辨相位梯度之间的映射关系,实现 PC-OCE 的超分辨应变成像。数值实验和压缩加载实验对比验证了本文方法效果。实验结果表明本文方法在窄带宽输出下能重构出宽带宽的应变测量效果,并且其信噪比相比于矢量方法和传统应变计算深度神经网络,分别提高了 18.4 dB 和 1.45 dB。本文方法可以突破系统光源的带宽限制,在低分辨相位输入条件下实现超分辨应变测量,从而加快相衬光学相干弹性成像在力学性能表征、内部早期损伤探测等方面的应用前景。

## 2 方 法

### 2.1 相衬光学相干弹性成像的应变测量原理

如图 1 所示,近红外宽带光源发射出近红外光经过透镜 L3、柱面镜 CL、分光棱镜 CBS 分别照射到参考面和样品上。来自样品内部和参考面的反射光相互叠加于衍射光栅 G 上,随后被分光成像于相机 CCD 的像平面上,从而产生 OCT 光谱信号:

$$I(k, z) = 2\sqrt{L_r L_s} \sum_{n=1}^N r(z_n) \Gamma(z_n) \cos(2k \cdot z_n + \phi(z_n)), \quad (1)$$

其中:  $k=2\pi/\lambda$  为光源波数,  $z$  表示样品内部每一层与参考镜的光程差,假设样品有  $n=1, 2, 3, \dots, N$  一共  $N$  层。  $L_r$  表示由反射面反射回来的光强,




图 1 相衬光学相干弹性成像的应变测量原理图

Fig. 1 Schematic diagram of strain measurement in phase-contrast optical coherence elastography

$L_s$  表示由样品反射回来的光强,  $r(z_n)$  为样品不同层的反射率,  $\Gamma(z_n)$  为光源相干函数,  $\phi(z_n)$  表示各层反射系数的相位。对采集到的 OCT 光谱信号进行傅里叶变换以获取幅度和相位信息:

$$\tilde{I}[f_s, z] = \sum_{m=1}^M I[k, z] \cdot \exp[-j \cdot 2\pi \cdot f_s \cdot k], \quad (2)$$

其中:  $\tilde{I}[f_s, z]$  表示傅里叶变换后的干涉光谱,  $m=1, 2, 3, \dots, M$  表示采样点数的索引值,  $f_s$  表示频域采样点间距,  $j$  表示虚数单位。在施加外力后,样品发生形变,其表面及内部会产生不同程度的形变位移,使用数码相机对该形变过程进行连续拍摄,以获取不同形变量下的 B 扫描图像,也即干涉光谱。通过选择任意两帧干涉光谱  $I_A(k, z)$  和  $I_B(k, z)$ , 进行傅里叶变换得到差分包裹相位,如公式(3)所示。其中,  $\tilde{I}_A$  与  $\tilde{I}_B$  表示干涉光谱傅里叶变换的结果;  $Re$  与  $Im$  分别表示复数的实部与虚部。

$$\Delta\varphi_{AB}^{\text{wrap}} = \tan^{-1} \left[ \frac{Re(\tilde{I}_A)Im(\tilde{I}_B) - Im(\tilde{I}_A)Re(\tilde{I}_B)}{Im(\tilde{I}_A)Im(\tilde{I}_B) + Re(\tilde{I}_A)Re(\tilde{I}_B)} \right]. \quad (3)$$

计算得到的相位  $\Delta\varphi_{AB}^{\text{wrap}}$  被包裹在  $[-\pi, \pi]$ , 用解包裹算法进行相位展开得到  $\Delta\varphi_{AB}^{\text{unwrap}}$ 。此时,该相位可用以描述样品内部的形变位移量,其计算式如式(4)所示:

$$W_{AB} = \frac{\Delta\varphi_{AB}^{\text{unwrap}}}{2 \cdot k_{\min}}, \quad (4)$$

其中,  $k_{\min}$  为起始波数。进一步,通过沿竖直方向  $z$  计算  $\Delta\varphi_{AB}^{\text{unwrap}}$  的梯度,即可得到层析应变变量:

$$\epsilon_{AB} = \frac{\lambda_c}{4\pi} \cdot \frac{\partial \Delta\varphi_{AB}^{\text{unwrap}}}{\partial z}, \quad (5)$$



其中,  $\lambda_c$  表示系统光源的中心波长。

神经网络作为一种直接实现端到端映射的方法,有望可以学习分辨率较低的差分包裹相位到高分辨率应变之间的映射关系,从而实现应变的超分辨。本文提出使用深度卷积神经网络(Deep Convolutional Neural Network, DCNN)学习低分辨率差分包裹相位与高分辨率应变的映射关系。但是在实际测量中,样品形变复杂,难以借助先验信息获取应变标签。此外,相衬光学相干弹性成像的光源设备昂贵、系统集成复杂度高,更难以借助不同光源设备获取不同带宽下的相位测量数据集,因此本文采用仿真模型以获取网络训练所需数据。

## 2.2 卷积神经网络的超分辨应变预测

### 2.2.1 网络结构

如图 2 所示,我们使用基于 UNet++<sup>[23]</sup> 的神经网络,网络分别使用最大池化层和反卷积层完成下采样和上采样,总共包括 5 次下采样,15 次上采样。深层网络能够提取出更多包含图像间映射关系的特征,但也会面临浅层信息丢失的问题,而在结构中加入许多嵌套的残差连接能够弥补该问题,提高了网络的稳定性。具体来说,该结构的嵌套关系为:卷积  $X^{i,j}$  上采样的结果与卷积  $X^{a,b}$  的结果进行拼接,其中  $a$  表示层级( $a = i - 1, i \in [1, 5]$ );  $b$  表示该层级中卷积的位置序号( $b \in [0, j], j \in [0, 5 - i]$ );例如,  $X^{1,4}$  上采样后的结果与  $X^{0,0}, X^{0,1}, X^{0,2}, X^{0,3}, X^{0,4}$  同时拼接。网络从输入维度为  $H \times W$  的图像中提取  $C$  个通道的特征,通过 5 次下采样将  $H \times W \times C$  的低阶特征编码为  $H/64 \times W/64 \times C/32$  的高阶特征,此后




图 2 本文方法采用的网络结构

Fig. 2 Network structure employed in our approach

通过上采样对高阶特征解码,最终得到维度为  $H \times W$  的应变分布。

在上述网络结构中,卷积的计算过程为,输入先依次通过卷积核维度  $3 \times 3$  的卷积层、组归一化层(Group Normalization)<sup>[24]</sup>、ReLU 激活函数各三次,其结果与输入进行残差连接,再进行一次组归一化层处理,得到卷积的输出。结构中添加的组归一化层的目的是在网络训练时提升收敛速度,并减少批量大小对预测误差的影响。该结构通过将图像通道分组,并分别计算均值与方差,从而简化优化过程。

### 2.2.2 训练集获取

图 2 中的神经网络需求大量的数据作为训练支撑,包括低分辨率包裹相位与对应的应变标签。由于相衬光学弹性成像在实际测量中难以获取应变标签,因此本文通过模拟层析成像原理,并参照真实实验的测量流程,设置了相关的测量模块与物理量,从而构建出仿真模型。最后使用仿真图像作为神经网络的训练数据。生成训练数据的过程如图 3 所示。

步骤(1):获取高分辨率网络标签。首先,随机生成高斯分布的伪随机数矩阵,再通过拉格朗日插值方法将其扩展到高维度的光滑曲面,从而模拟轴向方向上的形变。通过计算形变量,得到解包裹相位,再根据公式(5)计算理想应变,并将其作为标签值。过程如图 3(a)~图 3(b)。

步骤(2):获取形变前后的 B 扫描。根据公式(1)对形变量进行计算,得到位移前和位移后的干涉光谱,并添加均值为 0,方差区间为  $[0.11, 0.18]$  的高斯噪声以模拟不同等级的散斑噪声。如图 3(c)所示。

步骤(3):获取不同分辨率的 B 扫描。更改光源的带宽参数,实现不同数值带宽下的 B 扫描,最终得到不同分辨率的干涉光谱。如图 3(d)所示。

步骤(4):获取分辨率受限的相位输入。在不同光源带宽下,依据公式(2)和公式(3)计算分辨率受限的差分包裹相位。如图 3(e)所示。

经过上述步骤后,获取到网络的训练集。训练集中包含了不同分辨率的相位,且其对应的理想应变是由模拟形变计算而来,与模拟光源的参数设置无关,该方法解决了实验数据缺少真值的




图3 训练集生成过程

Fig. 3 Training data generation

问题,使得网络能够对不同分辨率的相位输入学习对应的高分辨率应变结果。

### 2.2.3 网络训练

通过 2.2.2 节所述步骤获取 30 000 组尺寸为  $512 \times 512$  的数据以训练网络。网络的卷积从  $X^{0,j}$  到  $X^{5,j}$  分别将输出的通道数(本文中  $C=16$ )分别设置为  $C, 2C, 4C, 8C, 16C, 32C$ ; 经过一次卷积处理后通过最大池化层进行一次下采样,每次下采样会使图像宽高减半且特征通道翻倍。反卷积层则是将图像宽高翻倍且特征通道减半实现上采样。上采样的结果与对应卷积结果进行残差连接后再经过卷积处理。网络训练中的损失函数与评判指标分别使用 MAE 与 MSE, 对于一个维度为  $H \times W$  的数据, 两者定义如下:

$$MAE = \frac{1}{H} \cdot \frac{1}{W} \sum_{i=1}^H \sum_{j=1}^W |y_{ij} - f(x_{ij})|, \quad (6)$$

$$MSE = \frac{1}{H} \cdot \frac{1}{W} \sum_{i=1}^H \sum_{j=1}^W (y_{ij} - f(x_{ij}))^2, \quad (7)$$

其中:  $y_{ij}$  表示真值,  $f(x_{ij})$  表示网络的预测结果。

## 3 实验

本节方法以仿真模型随机生成的窄带宽包裹相位及其理想应变作为训练集。在网络训练完成后,我们先使用仿真测试集验证网络的性能;随后,我们将使用光源中心波长为 840 nm, 带宽为 75 nm 的谱域光学相干层析测量系统获取实际的相位测量结果,从而测试网络的实际表现能力。

### 3.1 数值实验

本文首先通过计算机模拟生成不同分辨率的包裹相位测试集,以定量分析本文方法的应变预测效果。为此,我们选取不同带宽的相位作为输入,分析本文方法的应变预测效果。带宽的选取遵循以下原则:由于 75 nm 带宽是相衬光学相干层析测量系统使用的主流光源带宽,其代表着当前最好的层析分辨率,因此我们以 75 nm 带宽作为起始点;随后,通过不断减少带宽,测试本文方法在低分辨率相位输入下的应变预测效果,结果表明带宽 7.5 nm 是本文方法收敛的临界值,因此以该带宽体现本文方法的极限性能;为了进一步探究本文方法在分辨率减少情况下的应变预测变化趋势,我们在 75 nm 和 7.5 nm 之间加入带宽 20 nm 和 10 nm 的对照组。

如图 4(a) 所示,随着相位分辨率的逐步降低,条纹密集区域的模糊程度不断增加,沿纵向产生的拖拽现象使其条纹不可见。图 4(b-1)至(b-4)为应变的真值,通过公式(5)计算所得。图 4(c-1)至(c-4)为主流的矢量方法应变计算结果;此外,我们也对比了另外一种基于深度学习的应变计算方法<sup>[25]</sup>。该方法的训练过程仅考虑从相位图像到应变图像的“端到端”映射关系,而未有考虑层析分辨率受限的整个物理过程;为方便讨论,下文将该网络称为传统应变计算网络。图 4(d-1)至(d-4)为传统应变计算网络预测的应变结果。本文将矢量方法与传统应变计算网络作为对比标准,以低分辨率包裹相位作为输入,展示本文方法的应变预测效果。为量化各方法与真

实值的误差,本文给出了矢量方法、传统应变计算网络与本文方法的误差分布图,如图 4(f)~图 4(h)所示。

当带宽为 75 nm 和 20 nm 时,矢量方法计算结果如图 4(c-1)和(c-2)所示,此时能看出整张图像的应变分布,但由于噪声的影响出现了部分不平整的计算结果;当带宽降低至 10 nm 时,矢量方法的计算结果开始发散,在 A 区域虽然可以根据边缘判断应变的大致分布,但区域的内部出现了较大误差;当带宽降至 7.5 nm 时 A 区域的应变几乎完全发散,但在相位条纹较稀疏处的应变仍然相对清晰。传统应变计算网络的预测结果如图 4(d-1)至(d-4)所示。当带宽为 75 nm 与 20 nm 时,该方法预测结果较好,应变分布完整;当带宽降低至 10 nm 时,与矢量方法类似,A 区域开始出现较大误差;当带宽到达 7.5 nm 时,A 区域应变分布发散。结合图 4(f)和图 4(g)可以看出,当采用低带宽光源进行成像时,由于相位中的复杂信息被模糊化,尤其在条纹密集处图像细节的尺度小于测量系统的分辨率,导致矢量方法与传统应变计算网络的计算结果的计算效果不佳,因此当

处理低分辨率相位时,迫切需要新方法提高应变预测结果的分辨率。图 4(e-1)至(e-4)为使用本文方法的预测结果,当带宽处于 75 nm 与 20 nm 时预测结果与理论真值接近,整体的应变分布清晰,整体上好于矢量方法与传统应变计算网络的计算结果。带宽为 10 nm 时,图 4(e-3)中 A 区域开始出现些误差,而图 4(c-3)与图 4(d-3)中该区域的应变已发散。即使带宽减少到最初的 1/10,预测误差增大,图 4(e-4)中 A 区域仍然未完全发散,网络预测的应变分布仍然可见,整体上各个区域的边缘相对清晰。如图 4(f)、图 4(g)和图 4(h)所示,随着相位分辨率降低,矢量方法的误差始终较大,可见矢量方法在处理分辨率较低的相位时可靠性不足;传统应变计算网络虽然在带宽 75 nm 与 20 nm 情况下误差较小,但分辨率继续降低该方法的误差将与矢量方法的误差大小接近。另一方面,根据图 4(h-1)至(h-4)所示,本文方法的预测结果的误差随着分辨率的降低逐渐增大,但仍有较高的可靠性。在 75 nm 带宽条件下的预测误差较低与视觉观察上相近;当带宽降低到 10 nm 以及 7.5 nm 时,大部分区域的误差基本维持

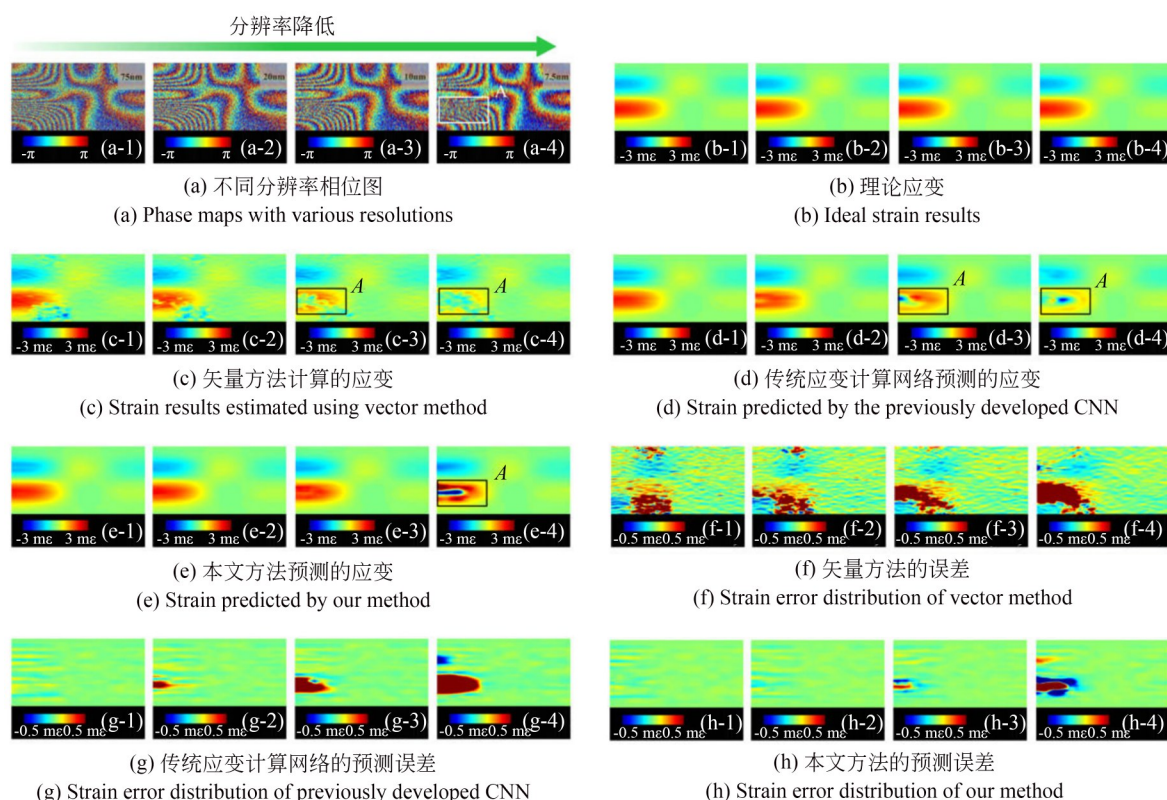


图 4 不同方法应变结果

Fig. 4 Strain results estimated using different approaches



不变,而 A 区域的误差更加明显,从图 4(a-3)和图 4(a-4)的相位中也能观察到 A 区域密集的条纹因分辨率降低而混乱。整体上,相比矢量方法与传统应变计算网络,本文采用的方法在计算低分辨率相位时有更高的可靠性。

### 3.2 加载实验

考虑到使用不同带宽光源测试的成本较高,且为了减少系统集成时增加的额外干扰。为模拟不同带宽条件下的分辨率,本文采用单一光源的数据,并通过截断带宽的方式达到获取不同分辨率的效果。样本选择上,由于均匀形变数据的先验信息可知,其应变分布可推断,因此下文采用真实环境中获取的压缩加载数据,使用本文方法对该数据进行预测,验证网络性能。为此,我

们搭建了一套线扫描谱域光学相干层析测量系统,如图 5(b)所示;并使用如图 5(a)的硅胶薄膜材料作为压缩加载实验的样本,样本包括上下两层厚度 2 mm 的亚克力板与中间单层 0.6 mm 的硅胶薄膜。加载实验过程中,先由加载装置对样本预紧,再对图 5(a)所示样本进行  $3\ \mu\text{m}$ ,  $5\ \mu\text{m}$ ,  $7\ \mu\text{m}$ ,  $9\ \mu\text{m}$  的均匀压缩加载,加载过程中层析测量系统将采集干涉光谱并测量层析形变。测量过程中,由光源发射的近红外宽带光经过双凸透镜后被准直为平行光,再经过柱面透镜后,通过 50:50 分光棱镜分别照射到样本和参考面,样本内部各层的散射光与参考面反射光叠加后形成干涉光谱信号,干涉光谱信号通过衍射光栅后展开,最终在相机平面上成像。




图 5 光学相干层析系统与测量材料

Fig. 5 Optical coherence tomography system and measurement materials

测量系统采集硅胶薄膜样本的干涉光谱,并通过公式(3)计算得到图 6(a-1)至(a-4)的差分包裹相位,其分别对应  $3\ \mu\text{m}$ ,  $5\ \mu\text{m}$ ,  $7\ \mu\text{m}$ ,  $9\ \mu\text{m}$  的力学加载量;同时差分包裹相位的低分辨版本如图 7(a-1)至(a-4)所示。并在表 1 中列出图 6-7 各个结果的信噪比,以便量化比较。随着压缩加载,被测件的形变量增加,导致相位条纹逐渐密集。其中,图 6(a-4)方框区域 A 的相位对比同张图像的中间区域更为模糊;并且随着分辨率的降低,从模糊的相位中获取有效信息并计算应变的难度增大。

图 6(b)~6(d)分别为 75 nm 带宽时矢量方法、传统应变计算网络与本文方法计算的应变分

布,图 7(b)~7(d)则分别为 10 nm 带宽下矢量方法、传统应变计算网络与本文方法计算的应变分布。可见在带宽较高且形变量较低的情况下,矢量方法、传统应变计算网络与本文方法的结果目视结果差距较小;从表 1 中也可看出,带宽 75 nm、加载量  $3\ \mu\text{m}$  时三种方法的信噪比差距小于 1 dB。随着形变量增大,不断接近矢量方法的分辨率极限,导致矢量方法的计算结果开始出现较大误差,如图 6(b-4)方框区域 A, B 所示,加载量  $9\ \mu\text{m}$  时的应变信噪比降低至加载量  $3\ \mu\text{m}$  时的 58%;而此时传统应变计算网络与本文方法的预测结果依然符合均匀压缩形变分布平整均匀的特征,且仍保持较高的信噪比。当带宽降低到




图 6 压缩加载实验(高分辨率)

Fig. 6 Compression loading experiment (high resolution)

10 nm 时,与图 6(b-2)中的预测相比,矢量方法在图 7(b-2)中出现了较为明显的计算误差;随着形变量增加,该误差逐渐增加,图 7(b-3)中近三分之一区域计算错误,此时的信噪比也降低为 3  $\mu\text{m}$  时的 36%;图 7(b-4)的应变结果则是完全被噪声淹没。10 nm 时传统应变计算网络在图 7(c-1)图 7(c-2)情况下,相比 75 nm 时,目视结果差别较小,信噪比相差小于 2.5 dB;形变量继续增大时,图 7(c-3)的 A 区域出现了两处明显的预测错误,而在图 7(c-4)中出错区域超过 50%;相比之下本文方法在带宽 10 nm 时,其预测结果图 7(d-3)与图 6(d-3)目视相近,信噪比相差仅 3.23 dB,且只在 A 区域的上侧出现小部分预测错误,总体上应变结果仍然平滑连续;当加载的形变量最大时,图 7(d-4)中 A 区域出现较大误差,其余部分虽然应变预测效果下降,但整体分布维持大致不变。结合表 1 可知,在带宽

10 nm 时随着加载量增加,本文方法相比矢量方法与传统应变计算网络,信噪比变化幅度最小;且在加载量 9  $\mu\text{m}$  时信噪比远高于矢量方法与传统应变计算网络。




图 7 压缩加载实验(低分辨率)

Fig. 7 Compression loading experiment (low resolution)

以上实验结果可以得出以下三点结论:(1) 形变量的增加与相位分辨率的降低皆会导致应变的分辨率下降。在形变量较小(3  $\mu\text{m}$ , 5  $\mu\text{m}$ )时,分辨率的降低对矢量方法与传统应变计算网络的计算结果影响不大;而当形变量较大(7  $\mu\text{m}$ , 9  $\mu\text{m}$ )时,分辨率的降低会明显放大矢量方法的计算误差,传统应变计算网络也出现多处预测错误;(2) 无论是高加载量还是低分辨率的情况,本文方法的预测结果都优于矢量方法,并且在矢量方法完全无法计算出正确应变的情况下,本文方法依然能给出较为可信的预测结果。(3) 虽然传



统应变计算网络在 75 nm 带宽时,其结果的信噪比高于本文方法,但当带宽减少时,传统应变计

算网络的信噪比大幅降低,表明其在分辨率受限下的鲁棒性不如本文方法。

表 1 压缩加载实验

Tab. 1 Compression loading experiment (dB)

| 带宽/nm | 方法       | 加载量/ $\mu\text{m}$ |       |       |       |
|-------|----------|--------------------|-------|-------|-------|
|       |          | 3                  | 5     | 7     | 9     |
| 75    | 矢量方法     | 32.33              | 31.73 | 25.15 | 18.71 |
|       | 传统应变计算网络 | 33.22              | 41.17 | 40.31 | 42.42 |
|       | 本文方法     | 32.87              | 39.56 | 39.28 | 35.82 |
| 10    | 矢量方法     | 34.22              | 24.39 | 12.33 | -4.51 |
|       | 传统应变计算网络 | 35.66              | 39.74 | 28.01 | 7.95  |
|       | 本文方法     | 35.33              | 40.77 | 36.05 | 16.62 |

为了进一步定量分析在不同分辨率时,矢量方法、传统应变计算网络与本文方法预测结果的差距,我们以五个不同分辨率的相位作为输入,分别计算三者预测结果的均值与标准差,并以公式(8)计算三者的信噪比:

$$\text{SNR} = 10 \cdot \log\left(\frac{\mu_{ps}^2}{\sigma_{ps}^2}\right). \quad (8)$$

由图 8 与表 2 可知,当分辨率较高时,本文方法与矢量方法的应变信噪比差距较小,与传统应变计算网络的信噪比非常接近,随着分辨率降低,应变的误差不断增大,与前文数值模拟与压缩加载实验结果相符;其中矢量方法与传统应变计算网络的变化趋势相近,而本文方法的变化趋势较缓;在带宽不断减少的过程中,本文方法预测的应变信噪比始终高于矢量方法;在 20 nm 之

前,传统应变计算网络的信噪比一度高于本文方法,但在此后其信噪比开始低于本文方法并更快地降低。其中,矢量方法与传统应变计算网络的均值与信噪比下降较快;本文方法的均值在 13 nm 前变化较为平缓,此后快速降低,可推断此时已逐渐接近本文方法的计算极限。此外,由于矢量方法计算的均值不断降低,如图 7(b-4)所示此时的应变已经几乎被噪声淹没,其信噪比极低导致负值出现。根据实验结果对比,相比矢量方法,本文提出的方法信噪比平均上提高了 18.4 dB,是矢量方法的 3 倍。由此可以得出,在不同相位分辨率下,本文方法的应变结果均优于矢量方法;在相位高分辨率较高时,本文方法与传统应变计算网络信噪比差距小,但在相位分辨率降低后,本文方法计算的应变信噪比更高。




图 8 应变结果对比

Fig. 8 Comparison of Strain

表 2 应变结果对比(a)均值(b)信噪比

Tab. 2 Comparison of Strain (a) Mean value; (b) SNR

| 带宽/nm | 矢量方法  |        | 传统应变计算网络 |        | 本文方法  |        |
|-------|-------|--------|----------|--------|-------|--------|
|       | 均值/mε | 信噪比/dB | 均值/mε    | 信噪比/dB | 均值/mε | 信噪比/dB |
| 75    | 1.96  | 18.71  | 2.32     | 42.42  | 2.30  | 35.82  |
| 20    | 1.84  | 14.78  | 2.21     | 29.90  | 2.24  | 29.08  |
| 15    | 1.59  | 9.51   | 2.10     | 23.35  | 2.22  | 27.75  |
| 13    | 1.26  | 3.64   | 1.85     | 15.81  | 2.16  | 24.63  |
| 10    | 0.82  | -4.51  | 1.37     | 7.95   | 1.93  | 16.62  |

如表 2 所示,本文在不同带宽(75 nm, 20 nm, 15 nm, 13 nm, 10 nm)下的应变均值分别为 2.30 mε, 2.24 mε, 2.22 mε, 2.16 mε 和 1.93 mε。从该结果可知,在带宽减少到 10 nm 时,样品的应变值发生了较明显的变化这表明该带宽下的网络应变预测结果出现了偏差。由于相衬光学相干弹性成像的层析分辨率取决于光源带宽(光源带宽越宽,层析分辨率越高),因此我们可以从应变均值曲线中推测出本文方法能提高层析分辨率 75/13≈5.7 倍(即 13 nm 带宽的层析分辨率能达到 75 nm 的效果)。

此外使用深度神经网络的方法计算低分辨率相位应变还有以下几点优势。(1)不需要额外的参数设置。矢量方法需要提供相应的幅值图像,并根据不同的相位差调整不同的窗口大小;而深度神经网络的方法只需要输入相位图就能得到对应的应变。(2)更快的运算效率。训练好的低分辨率相位应变计算网络只需要一步就能从相位得到应变结果。

3.3 敏感性测试

为了验证本文方法在不同输入情况下,其预测结果间是否存在较大的差距,因此下文中将采用数值模拟实验进行敏感性测试。测试使用目前测量系统主流的 75 nm 带宽数据,向数据中加入不同概率密度分布的散斑噪声,并逐渐提高噪声强度等级,以测试其结果的稳定性。在实验中,我们选择了 3 种常见的光学散斑相位的概率密度分布,分别为均匀分布、高斯分布和莱斯

分布。

如图 9 所示,相位与理论值间的均方根误差图在下方相应给出。逐步提高相位噪声的强度,相位目视逐渐模糊,为了能够量化结果间的差距,我们将均方根误差的具体数值列出,如表 3 所示。随着噪声逐渐增大,三种噪声下的应变误差也略微增加。可以从表 3 中看出,同一强度等级下三种分布的误差值差别较小。这一结果证明了本文方法在不同类型相位噪声的干扰下测量值无太大偏差,具有很好的鲁棒性。




图 9 不同分布的数值实验

Fig. 9 Numerical experiments with different distributions

表 3 数值实验均方根误差  
Tab. 3 Mean square error of numerical experiments

| 噪声<br>分布类型 | 噪声强度等级   |          |          |          | 均值       |
|------------|----------|----------|----------|----------|----------|
|            | 等级 1     | 等级 2     | 等级 3     | 等级 4     |          |
| 均匀分布       | 0.000 76 | 0.000 93 | 0.001 15 | 0.001 23 | 0.001 02 |
| 高斯分布       | 0.000 73 | 0.000 85 | 0.000 97 | 0.001 18 | 0.000 93 |
| 莱斯分布       | 0.000 72 | 0.000 87 | 0.001 04 | 0.001 15 | 0.000 95 |

4 结 论

本文提出了一种基于神经网络的方法,对光学相干层析获取到的低分辨率相位进行超分辨计算,预测的应变相较于传统方法具有更高的分辨率,能更好地表征样品内部的力学特性。该方法无需人为根据不同被测物单独调整参数,只需单张相位图像即可计算出应变结果。本文方法的训练数据来自模拟 OCT 信号原理的仿真模型,减少了处理与收集实验数据集所需的大量时间;通过模拟系统窄带宽光源的成像过程,获取低分辨率特点的差分包裹相位,并依据相位梯度定义计算其对应的理想应变值。这解决了光学测量领域中先验信息未知,实验数据集真值难获取的问题。仿真实验以及压缩加载实验证明,

本文方法获取的应变分辨率高于矢量方法,且相比传统应变计算网络有更强的鲁棒性。与此同时,通过不同类型的噪声对本文方法进行测试,证明了本文方法有较高的可靠性。本文方法在 10 nm 带宽时的应变信噪比,约为传统应变计算网络的 2 倍,同时接近 75 nm 带宽时的矢量方法;并且在带宽较低时,本文方法在条纹密集处计算的应变分布更为清晰。上述结果表明了本文方法适用于低分辨率相位的应变超分辨计算。最后,我们指出本文方法存在的一些不足以及未来改进的空间:当面向各向异性特点的材料时,网络的泛化能力仍需进一步提高;在未来的工作中可进一步强化数据生成模型与真实实验情况的关联性,并研究具有更强泛化能力与稳定性的应变计算网络架构。

参考文献:

[1] WANG J F, XU Y, BOPPART S A. Review of optical coherence tomography in oncology[J]. *Journal of Biomedical Optics*, 2017, 22(12): 1-23.

[2] YI J, RADOSEVICH A J, ROGERS J D, et al. Can OCT be sensitive to nanoscale structural alterations in biological tissue? [J]. *Optics Express*, 2013, 21(7): 9043-9059.

[3] ABDOLAH F, ZHOU X, ASHIMATEY B S, et al. Optical coherence tomography angiography-derived flux as a measure of physiological changes in retinal capillary blood flow [J]. *Translational Vision Science & Technology*, 2021, 10(9): 5.

[4] ZAITSEV V Y, MATVEYEV A L, MATVEEV L A, et al. Strain and elasticity imaging in compression optical coherence elastography: the two-decade perspective and recent advances[J]. *Journal of Biophotonics*, 2021, 14(2): e202000257.

[5] WANG S, LARIN K V. Optical coherence elastography for tissue characterization: a review[J]. *Journal of Biophotonics*, 2015, 8(4): 279-302.

[6] KENNEDY K M, CHIN L, MCLAUGHLIN R A, et al. Quantitative micro-elastography: imaging of tissue elasticity using compression optical coherence elastography[J]. *Scientific Reports*, 2015, 5: 15538.

[7] GUBARKOVA E V, SOVETSKY A A, MATVEEV L A, et al. Nonlinear elasticity assessment with optical coherence elastography for high-selectivity differentiation of breast cancer tissues[J]. *Materials*, 2022, 15(9): 3308.

[8] HUANG P B, LIN Y K, YOU R F, et al. Simultaneously measurement of strain field and Poisson's ratio by using an off-axis phase-sensitive optical coherence elastography [J]. *Measurement Science and Technology*, 2022, 33(9): 095406.

[9] ALEXANDROVSKAYA Y M, KASIANENKO E M, SOVETSKY A A, et al. Spatio-temporal dynamics of diffusion-associated deformations of biological tissues and polyacrylamide gels observed



- with optical coherence elastography [J]. *Materials*, 2023, 16(5): 2036.
- [10] GORNIG D C, MALETZ R, OTTL P, *et al.* Influence of artificial aging: mechanical and physico-chemical properties of dental composites under static and dynamic compression[J]. *Clinical Oral Investigations*, 2022, 26(2): 1491-1504.
- [11] LARIN K V, SAMPSON D D. Optical coherence elastography - OCT at work in tissue biomechanics [J]. *Biomedical Optics Express*, 2017, 8(2): 1172-1202.
- [12] ZAITSEV V Y, MATVEYEV A L, MATVEEV L A, *et al.* Deformation-induced speckle-pattern evolution and feasibility of correlational speckle tracking in optical coherence elastography [J]. *Journal of Biomedical Optics*, 2015, 20(7): 75006.
- [13] MOTAGHIANNEZAM S M, KOOS D, FRASER S E. Differential phase-contrast, swept-source optical coherence tomography at 1060 nm for *in vivo* human retinal and choroidal vasculature visualization [J]. *Journal of Biomedical Optics*, 2012, 17(2): 026011.
- [14] DREXLER W. Ultrahigh-resolution optical coherence tomography [J]. *Journal of Biomedical Optics*, 2004, 9(1): 47-74.
- [15] DE WIT J, ANGELOPOULOS K, KALKMAN J, *et al.* Fast and accurate spectral-estimation axial super-resolution optical coherence tomography [J]. *Optics Express*, 2021, 29(24): 39946-39966.
- [16] RATHEESH K M, SEAH L K, MURUKESHAN V M. Spectral phase-based automatic calibration scheme for swept source-based optical coherence tomography systems [J]. *Physics in Medicine and Biology*, 2016, 61(21): 7652-7663.
- [17] PU W. SAE-net: a deep neural network for SAR autofocus [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2022, 60: 5220714.
- [18] WU Y C, RIVENSON Y, ZHANG Y B, *et al.* Extended depth-of-field in holographic imaging using deep-learning-based autofocusing and phase recovery [J]. *Optica*, 2018, 5(6): 704.
- [19] CHAUDHARY S, MOON S, LU H. Fast, efficient, and accurate neuro-imaging denoising via supervised deep learning [J]. *Nature Communications*, 2022, 13: 5165.
- [20] ZHAO J X, LIU L, WANG T H, *et al.* VDE-Net: a two-stage deep learning method for phase unwrapping [J]. *Optics Express*, 2022, 30(22): 39794-39815.
- [21] SUN G W, LI B Y, LI Z, *et al.* Phase unwrapping based on channel transformer U-Net for single-shot fringe projection profilometry [J]. *Journal of Optics*, 2023: 1.
- [22] ZHOU Y, YU K, WANG M, *et al.* Speckle noise reduction for OCT images based on image style transfer and conditional GAN [J]. *IEEE Journal of Biomedical and Health Informatics*, 2022, 26(1): 139-150.
- [23] ZHOU Z, SIDDIQUEE M M R, TAJBAKHSN N, *et al.* UNet++: a nested U-net architecture for medical image segmentation [J]. *Deep Learn Med Image Anal Multimodal Learn Clin Decis Support* (2018), 2018, 11045: 3-11.
- [24] WU Y X, HE K M. Group normalization [C]. *European Conference on Computer Vision*. Cham: Springer, 2018: 3-19.
- [25] DONG B, HUANG N X, BAI Y L, *et al.* Deep-learning-based approach for strain estimation in phase-sensitive optical coherence elastography [J]. *Optics Letters*, 2021, 46(23): 5914-5917.

## 作者简介:



张展华(1999—),男,广东惠州人,硕士研究生,2021年于广东工业大学获得学士学位,主要研究方向为应变计算成像。E-Mail: 1052743082@qq.com

## 通讯作者:



白玉磊(1988—),男,陕西榆林人,博士,副教授,硕士生导师,2011年于广东工业大学获得学士学位,2016年于广东工业大学获得博士学位,2017年于香港大学担任助理研究员,主要从事层析干涉测量、光测力学、计算成像等方面的研究。E-mail: ylbai@gdut.edu.cn