

引用格式: FENG Leijie, DU Hubing, ZHANG Gaopeng, et al. Fringe Pattern Orthogonalization Method by Generative Adversarial Nets[J]. Acta Photonica Sinica, 2023, 52(1):0112003

冯雷洁, 杜虎兵, 张高鹏, 等. 基于 GANs 网络的条纹图正交化方法[J]. 光子学报, 2023, 52(1):0112003

基于 GANs 网络的条纹图正交化方法

冯雷洁¹, 杜虎兵¹, 张高鹏², 李燕杰¹, 韩金璐¹

(1 西安工业大学 机电工程学院, 西安 710021)

(2 中国科学院西安光学精密机械研究所, 西安 710119)

摘要:提出一种利用深度学习强大的隐式建模能力解决单帧条纹图正交化存在的欠采样问题, 结合条纹图降噪归一化技术, 利用对抗生成网络的特征先验, 构造了一种条纹图轮廓项数字方式的 $\pi/2$ 相移网络, 实现了单帧条纹图的正交化, 放松了应用解析模型法实现条纹图正交化时的严格要求。通过标签图像对训练后, 该网络成功地实现了归一化后的条纹图的正交化, 进而高精度地实现了单帧条纹图的相位解调。仿真和实验分析证明, 与基于 Riesz 变换的数字相移方法相比, 所提方法求解更可靠, 能有效地恢复测量相位。以现有的多帧高精度相移算法的解调结果作为参考值, 实验结果表明所提方法的相位误差分布在 0.05 rad 以内, 为瞬变场和物体三维轮廓测量提供了一种途径。

关键词:条纹图分析; 相位解调; 条纹图正交化; 深度学习; 三维轮廓测量

中图分类号: O439

文献标识码: A

doi: 10.3788/gzxb20235201.0112003

0 引言

光电三维轮廓测量技术在工业检测, 3D 成像, 生物医疗, 实验力学等领域具有广泛应用^[1]。按照条纹图分析方法的的不同, 现有的光电三维轮廓测量技术主要分为两类: 第一类是相移技术, 其需要在时域记录多帧相移条纹图^[2]; 第二类方法则通过一帧条纹图在频域搜索感兴趣的相位分布。尽管相移技术已成功地在很多精密测量场合得到了应用, 但其技术有一定的缺陷, 例如, 易受大气扰动的影响, 要求被测对象在测量时状态保持稳定, 难于实现快速瞬变现象或动态物理量的测量^[3]。相比, 单帧条纹图解调技术为研究动态问题提供了一种很好的途径。然而单帧条纹图相位解调是一个病态的反问题, 另外研究中很难对相位所有行为进行假定, 因此经典的基于物理模型的条纹图分析方法在设计可靠的单帧条纹图正交化方法时遇到了困难。传统上, 单帧条纹图正交化通常通过引入高频的空间载频将条纹图的轮廓项迁移至高频, 然后在频域利用傅里叶变换进行相位解调。然而该技术由于频率混叠、谱泄露等问题, 其测量精度和范围有限。更重要的是, 傅里叶变换的方法不能用于不含载频的条纹图的处理, 例如, 干涉条纹图。考虑到条纹图信号具有的非平稳特征, 研究者试图采用窗口傅里叶变换、小波变换、经验模态分解 (Empirical Mode Decomposition, EMD) 等方法克服傅立叶轮廓术的缺陷^[4-6]。但此时又产生了空间分辨率和频率分辨率间平衡的问题、模式混合问题等^[7-8]。解调单帧条纹图实质是建立条纹图轮廓项的正交变换, 即发展条纹图轮廓项正交变换算子。其最方便的方法是对条纹图进行 Hilbert 变换。然而 Hilbert 变换属于一维变换, 对于二维条纹图信号, 如果直接使用 Hilbert 变换, 会破坏条纹图数据的整体性, 而且对于一般条纹图, 由于其方法常常产生负的空间频率成分, 此时又产生了如何正确确定条纹图每一点空间频率符号的问题。最近, TOUNSI Y 等发展了一种基于 Riesz 变换的数字相移分析方法^[3], 该方法实质上是一种二维 Hilbert 变换, 为单帧条纹图相位恢复

基金项目: 国家自然科学基金 (No. 51975448), 陕西省重点研发计划 (No. 2021GY-274), 中国科学院青年创新促进会会员项目 (No. 2022410)

第一作者: 冯雷洁, 372078928@qq.com

通讯作者: 张高鹏, zhanggaopeng@opt.ac.cn

收稿日期: 2022-07-05; 录用日期: 2022-08-18

<http://www.photon.ac.cn>

提供了新思路。然而在实验中,我们发现该方法对条纹图光强的非正弦性敏感,变换效果较差。总之,尽管单帧测量技术测量速度快、装置简单,但是其方法还存在着对噪音和条纹形状变化敏感,测量时常常需要人工干预等问题,致使发展一种快速、有效的单帧相位解调方法充满了挑战和不确定性。

与传统的假定条纹图相位求解模型具有清晰的解析公式,进而通过一定的线性近似建立的基于模型的条纹图分析方法不同,深度学习的方法绕过建立解析模型的严格要求,通过输入、输出条纹图对训练给定的深度网络^[9],以非参数的方式学习可靠的先验知识,定义给定网络的功能,从而实现条纹图分析的欠采样问题的正则化。基于学习的条纹图分析方法在实现高效、高精的相位恢复方面潜力巨大。例如,使用深度学习网络已经实现了图片分割、信号降噪、解包裹等^[10-13]。FENG S等最早提出采用深度卷积神经网络辅助相位分析^[14],发现基于卷积神经网络(Convolutional Neural Networks, CNN)的辅助条纹图分析方法使用一帧条纹图计算相位时,比传统的傅里叶变换方法或窗口傅里叶变换方法,能更高精度的预测包裹相位图。NGUYEN H等^[15]制作并发表了训练网络的数据集,并以此评价了全连接卷积神经网络、自编码网络及U-Net网络的性能,发现U-Net网络由于具有结构对称和特征图叠合的特点,因而更适合条纹图分析。尽管深度学习在条纹分析中获得了成功,但其本质上是一种数据驱动的方法,需要大量的数据定义所使用的深度网络的条纹解调能力。然而条纹解调过程复杂,包括条纹图降噪、求解包裹相位、相位去包裹和相位高度映射等多个过程,且该过程不连续,与深度学习在对某一个过程拟合时在全局上连续的要求相违背,所以发展端-端的条纹分析网络不适应条纹图解调的特点。另外,已有的单帧条纹图处理方法常常要求采集的条纹图具有高的频率,例如,FENG S的方法^[14]应用时需要引入载频项获得高频率的条纹图。然而,低频率条纹图在实际中应用也很广泛,例如,干涉条纹图、莫尔条纹图等。因此,有必要发展一种用于低频率条纹图相位解调网络。

对此,本文提出一种模型和非模型结合的非载频条纹图分析方法。所提方法通过训练单一功能的深度学习网络解调单帧条纹图,首先对条纹图进行降噪归一化处理,然后设计网络对条纹图轮廓项进行正交化处理,最后利用模型的方法提取包裹相位。所提方法适应了深度学习在拟合过程的全局连续性要求,为单帧条纹图相位提取提供了一种有效途径。

1 问题描述

采集的非载频条纹图,如使用点衍射的方法,数学模型通常可表示为

$$I(x, y) = a(x, y) + b(x, y) \cos(\varphi(x, y)) + N(x, y) \quad (1)$$

式中, $a(x, y)$ 为背景项, $b(x, y)$ 为调制项, $\varphi(x, y)$ 为测量相位, $N(x, y)$ 为噪声。由于式(1)含有四个未知量,显然仅利用式(1)求解测量相位是欠定的。对此,本文首先对条纹图进行降噪和归一化处理,即去除背景项,噪声项,分离条纹轮廓项。

文献[16]提出了一种结合残差模块(Resnetblock)的U-Net深度卷积神经网络,有效地实现了条纹图降噪归一化处理。该网络模型由编码器(Encoder)与解码器(Decoder)两个模块组成,编码器通过压缩条纹图提取条纹图的主要特征,解码器用于还原条纹图的维度。构建该网络后,在均值为0,方差为2.5,振幅在0.4~1.25范围的高斯噪音下,使用模拟的条纹图作为训练数据对网络进行训练后,可得归一化的条纹图为

$$I'(x, y) = \cos(\varphi(x, y)) \quad (2)$$

考虑到若直接使用反余弦函数求解精度不高,且求解相位会将测量相位包裹于 $[0, \pi]$,不利于后续相位去包裹处理。因此,本文提出发展深度学习网络,对式(2)进行正交变换,并将变换后的条纹图表示为

$$I''(x, y) = \cos(\varphi(x, y) + \pi/2) = -\sin(\varphi(x, y)) \quad (3)$$

因此可得包裹相位 $\theta(x, y)$ 为

$$\theta(x, y) = \arctan \left[-\frac{I''(x, y)}{\tilde{I}'(x, y)} \right] \quad (4)$$

显然对包裹相位 $\theta(x, y)$ 进行相位去包裹,即可得相位分布 $\varphi(x, y)$ 。

2 条纹图正交变换网络

2.1 网络结构

式(2)表示的条纹图模型为偶函数,即 $\cos(\varphi(x,y)) = \cos(-\varphi(x,y))$ 。此时使用U-Net或其他网络时,网络不区分相位的符号。从而,造成拟合生成的条纹图可能是 $\cos(\varphi(x,y) + \pi/2)$ 也可能是 $\cos(-\varphi(x,y) + \pi/2)$,即出现了相位符号模糊的问题。考虑到生成对抗网络^[17]中含有一个判别器,能将生成条纹图与真值条纹图进行比较,通过反复迭代,促使二者相似,最终可解决上述正交条纹图生成过程中可能出现的符号不确定的问题,因此本文提出利用生成对抗网络实现条纹图的正交变换。

图1给出了设计的正交变换网络结构。其原理是:首先利用文献[16]的降噪归一化网络,对条纹图进行降噪归一化,然后将处理后的条纹图输入到生成对抗网络,利用网络已有的特征先验实现条纹图正交化。

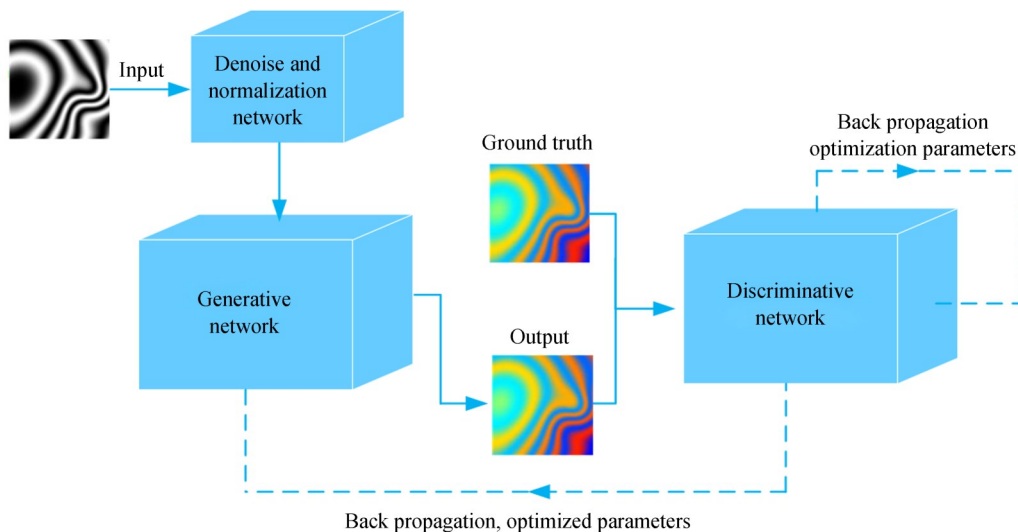


图1 正交变换网络的结构

Fig. 1 Orthogonal transformation network architecture

图2为生成网络实现条纹图正交化的训练过程。首先,生成网络对归一化的条纹图进行下采样,提取归一化条纹图的特征,然后通过上采样生成正交化条纹图。此时,判别网络将生成网络得到的正交化条纹图与真值条纹图进行真伪判别,经其输出层的sigmoid函数得到生成条纹图与真值条纹图的相似概率。接着由损失函数计算生成网络和判别网络的损失值(loss),并指导Adam优化器更新判别网络和生成网络的权重,进而由生成网络形成新的正交化条纹图。上述过程循环迭代,致使生成网络的正交条纹图生成能力不断加强,其结果更加接近真值条纹图,直至纳什平衡,判别网络无法判别生成条纹图与真值条纹图的真伪。




图2 生成网络组成

Fig. 2 Generative network architecture

数学上,本文的生成对抗网络是通过计算式(5)的交叉熵^[18]逼近真值条纹图并评价判别器的精度。

$$\min_G \max_D V(D, G) = E_{x \sim L(x)} [\log D(x)] + E_{y \sim I(y)} [\log(1 - D(G(y)))] \quad (5)$$

式中, D 为判别器的运算函数,用于判别生成图像 $G(y)$ 与标签图像的真伪, $I(y)$ 为输入数据的概率分布, $L(x)$ 为标签数据的概率分布。

为了对式(5)进行优化,本文使用 Tensorflow2.0 中的 Adaptive Moment Estimation 优化器,其学习率为 $lr=0.0002$,迭代次数 $epochs=80$ 。

网络训练好后,将实际摄取的条纹图输入到图1网络结构中,经归一化后,便可由生成网络输出与输入条纹图对应的正交化条纹图。

研究发现,如果设计网络按照直接输入归一化条纹图,输出 $\pi/2$ 相移条纹图的方式工作,此时由于标签的特征较少,生成的相移条纹图易出现断裂及坏点。如图2所示为了避免该问题,本文提出一种 R、G、B 三通道输出方案,其中 R 通道输出相对输入有 $\pi/2$ 相移的条纹图, G 通道输出归一化的相位分布: $N \sim \varphi(x, y)$, B 通道输出相对输入有 $3\pi/2$ 相移的条纹图。由于本文在网络的输出中增加了 $\cos(\varphi(x, y) + \pi/2)$ 、归一化的相位分布 $N \sim \varphi(x, y)$ 、 $\cos(\varphi(x, y) + 3\pi/2)$ 三个标签,提供了丰富的信息量,从而避免了条纹断裂和坏点的情况。应当指出, R 通道或 B 通道的相移条纹图均可用于相位提取,二者没有精度差异,只是符号不同。本文采用了 R 通道的结果进行相位的提取。但是应注意, G 通道的输出是归一化相位,不能作为测量相位使用,其作用是用来丰富标签特征的。因为标签的特征越丰富,深度学习网络越容易学习到特征先验。

将网络的输入定义为

$$I_{input}(x, y) = \cos(\varphi(x, y)) \quad (6)$$

网络的输出(标签)定义为三通道 RGB 图像,其中 R 通道条纹图表示为

$$I_R(x, y) = \cos(\phi(x, y) + \pi/2) \quad (7)$$

G 通道的归一化相位分布为($N \sim$ 为归一化算子)

$$I_G(x, y) = N \sim \varphi(x, y) \quad (8)$$

B 通道条纹图为

$$I_B(x, y) = \cos(\varphi(x, y) + 3\pi/2) \quad (9)$$

图2生成网络结构中,网络的第一层到第三层均包含一个卷积层,一个 ReLU 函数,一个 BatchNormalization 层,具体的参数为 $3 \times 3 \times 64$, $3 \times 3 \times 128$, $3 \times 3 \times 256$; 为了避免梯度消失,在网络的中间加入了 20 个残差模块,每个残差模块含有两组 $3 \times 3 \times 256$ 的卷积核,且彼此之间跳跃连接;第四层和第五层为卷积层(具体参数为: $3 \times 3 \times 128$, $3 \times 3 \times 64$),最后一层为输出层,输出层包括一个卷积层和一个 tanh 函数。生成网络的具体参数见表1。

表1 生成网络参数
Table 1 Generative network parameters

Number	Parameter
1	Conv $3 \times 3 \times 64$, BN, ReLU
2	Conv $3 \times 3 \times 128$, BN, ReLU
3	Conv $3 \times 3 \times 256$, BN, ReLU
ResNets	Conv $3 \times 3 \times 256$, BN, ReLU } Block i , ($i = 1, 2, \dots, 20$) Conv $3 \times 3 \times 256$, BN, ReLU }
4	Conv $3 \times 3 \times 128$, BN, ReLU
5	Conv $3 \times 3 \times 64$, BN, ReLU
6	Conv $3 \times 3 \times 3$, BN, Tanh

判别网络采用了全卷积结构,共五层。第一层到第四层的结构均包含一个卷积层,一个 LeakyReLU 函数,一个 BatchNormalization 层,每层卷积核的数量分别为 64、125、256、512。输出层用于输出概率值,只有一个卷积核,并采用 Sigmoid 函数输出概率值。由于使用了 LeakyReLU 函数,本文的判别网络可以加速

网络训练并能实现参数的非线性的映射,具体结构如图3,参数设置见表2。




图3 判别网络组成

Fig. 3 Discriminative network architecture

表2 判别网络参数

Table 2 Discriminative network parameters

Number	Parameter
1	Conv3×3×64,BN,LeakyReLU
2	Conv3×3×128,BN,LeakyReLU
3	Conv3×3×256,BN,LeakyReLU
4	Conv3×3×512,BN,LeakyReLU
5	Conv3×3×1,Sigmoid

2.2 数据集制作

由于本文方法使用了归一化网络,去除了条纹图中背景项和振幅项的影响,因此训练的数据对可直接通过条纹图模型模拟产生。根据傅里叶级数理论,任意连续函数均可由一系列不同幅值,不同频率,不同相位,不同方向的三角谐波叠加而成,因此设计相位分布为

$$\varphi_i(x, y) = \sum_i^N a_i \sin(2\pi f_i(u_i x + v_i y) + \delta(x, y)) \quad i = 1, 2, 3, \dots, N \quad (10)$$

式中, a_i 为幅值, f_i 为频率, u_i 与 v_i 为正弦波 x 方向与 y 方向上的偏导,用以控制当前正弦波的方向, $\delta(x, y)$ 为相位。上述所有参数均为随机数,因此该方式制作的数据集在足够的规模下完备性较好。


训练中,本文生成了16 000对输入条纹图和真值条纹图,并按照6:2:2将数据集划分为训练集、验证集和测试集。为了避免过拟合,本文采用了交叉验证的方式,每迭代5次进行一次验证。

3 仿真分析

首先对训练好的正交变换网络进行仿真评测。为了使仿真条纹图具有典型性,仿真的相位函数定义为 $\varphi(x, y) = \text{peaks}(x, y) + \sum_1^4 a_i \sin(2\pi f_i(u_i x + v_i y) + \delta(x, y))$,保证了生成的条纹图具有闭型、开型以及疏密变化的特征,仿真生成的条纹图见图4(a)。

仿真时,将仿真的归一化条纹图输入到网络中后(见图4(a)),图4(b)为网络输出的RGB三通道条纹图,其中R通道为相对输入有 $\pi/2$ 相移的条纹图,G通道为归一化的相位分布: $N \sim \varphi(x, y)$,B通道为相对输入有 $3\pi/2$ 相移的条纹图。图4(c)为正交变换后的条纹图。参照图4(a)给出的归一化条纹图,可见,即使是peaks函数生成的复杂条纹图,本文正交网络也能很好地实现条纹图的正交变换。

为了进一步量化说明本文正交变换网络的精度,对仿真条纹图进行相位提取。图5(a)给出了真值条纹



(a) Input fringe pattern

(b) Output fringe pattern

(c) Quadrature fringe pattern

图4 条纹图正交变换仿真实验

Fig.4 Simulation for fringe pattern orthogonalization

图的相位,图5(b)为采用正交变换重建的相位,相位去包裹方法参见文献[19]。图5(c)给出的本文方法的相位重建误差,可见提出的正交变换网络相位提取误差不超过0.02 rad。

为了说明提出方法的效果,以斜面为样品,将Riesz变换的结果与提出方法的结果进行了比较。图6(b)为本文方法重建的结果,图6(c)为Riesz变换方法重建的相位分布。参照真值相图(图6(a))可知,通过Riesz变换方法的结果存在着符号模糊的问题,容易受背景影响,在进行二维正交变换时发生了明显的畸变,而本文的方法具有好的效果。图7(a)和图7(b)给出了Riesz变换方法的误差分布和本文方法结果的误差分布。仿真实验证明,本文方法的精度比Riesz变换方法的精度提高了两个数量级。

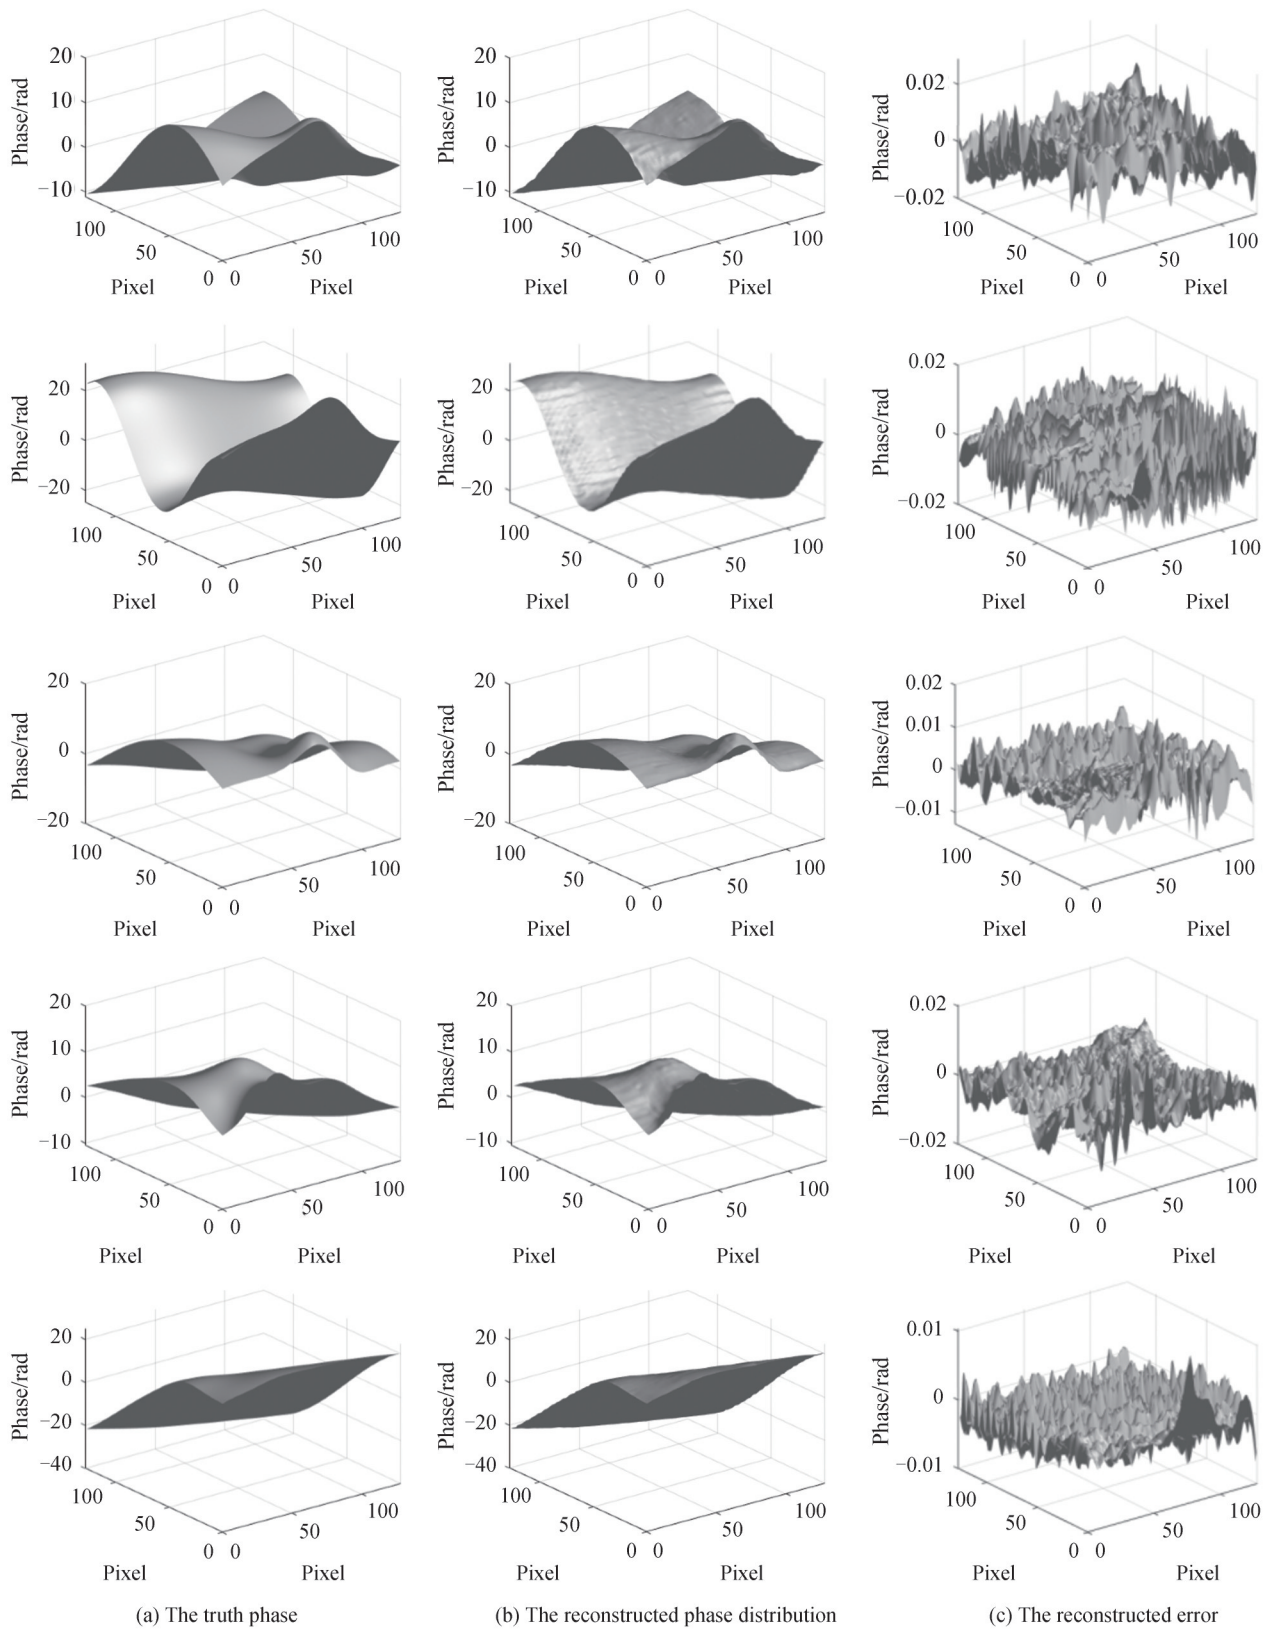


图5 相位重建仿真实验
Fig. 5 Simulation for phase reconstruction




图 6 所提方法与 Riesz 变换方法的重建性能比较
Fig. 6 Comparisons between the proposed method and the Riesz transform method

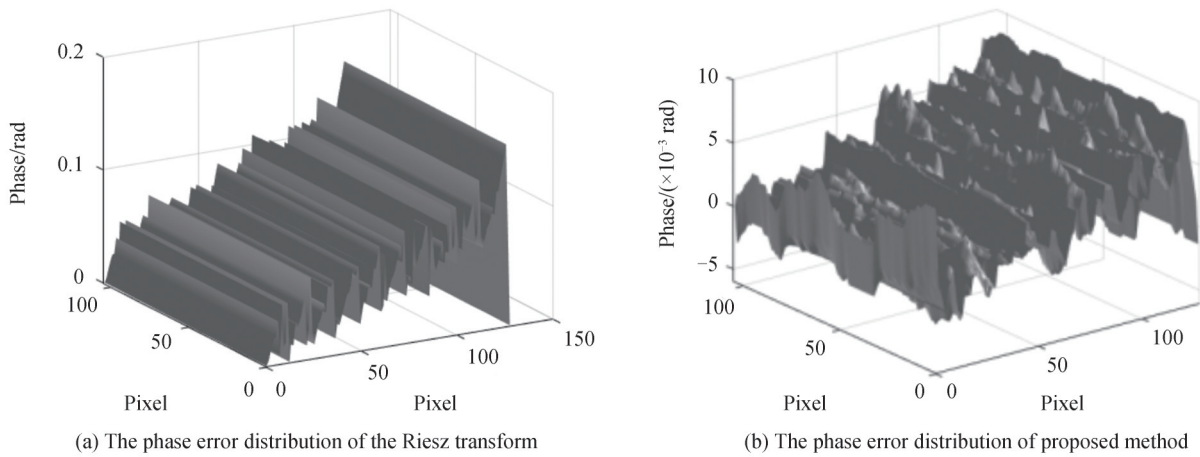


图 7 相位误差
Fig. 7 Phase error distribution

4 实验分析

为了说明本文提出的在网络输出中增加 G 通道归一化相位的作用,图 8 比较了没有增加归一化相位通道的网络与增加了归一化相位通道的网络对条纹图正交化的结果。可以看出没有归一化通道的网络的输出(图 8(b))发生了明显条纹断裂,而增加归一化通道的网络的输出(图 8(a)),由于提供了丰富条纹图的标签特征,容易学习到特征先验,得到了一个好的正交化结果。

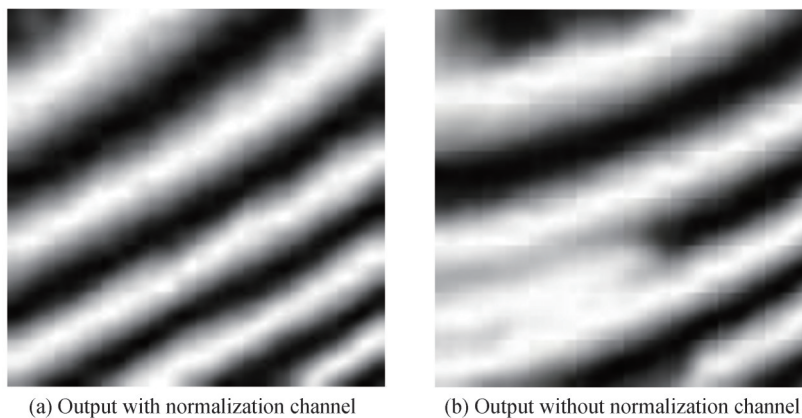


图 8 不同网络输出结果比较
Fig. 8 Comparisons of the different networks

为了进一步说明所提方法的性能,对实际条纹图进行了正交变换和相位提取。图9给出了采用点衍射^[20]方法,以非球面为测量样品,得到的五帧相移条纹图,其在局部具有闭型、开型以及疏密变化的特征,很好地代表了非载频条纹图的特点,因此保证了实验验证的典型性。




图9 点衍射方法采集的五帧条纹图

Fig. 9 Five experimental phase-shifting fringe patterns collected by point diffraction interferometer

由于网络设计时输入的图片大小为 128×128 ,实验处理时,首先在图9(a)中随机截取一块大小为 128×128 的子图,然后使用降噪归一化网络对子图进行降噪归一化处理^[16],再将其输入正交变换网络,得到RGB条纹图,进而分离出 $\pi/2$ 相移条纹,最后使用归一化条纹图和 $\pi/2$ 相移条纹图提取相位分布。为了说明本文方法的重复性,上述操作重复了三次,截取的子图及处理结果见图10。图11是重建结果。图12给出了重复上述实验10次,由误差分布得到的均方根误差曲线,可见本文方法重复性较好。

图10(b)为降噪和归一化处理后的条纹图。可见深度学习的方法很好地抑制了采集条纹图的背景项和

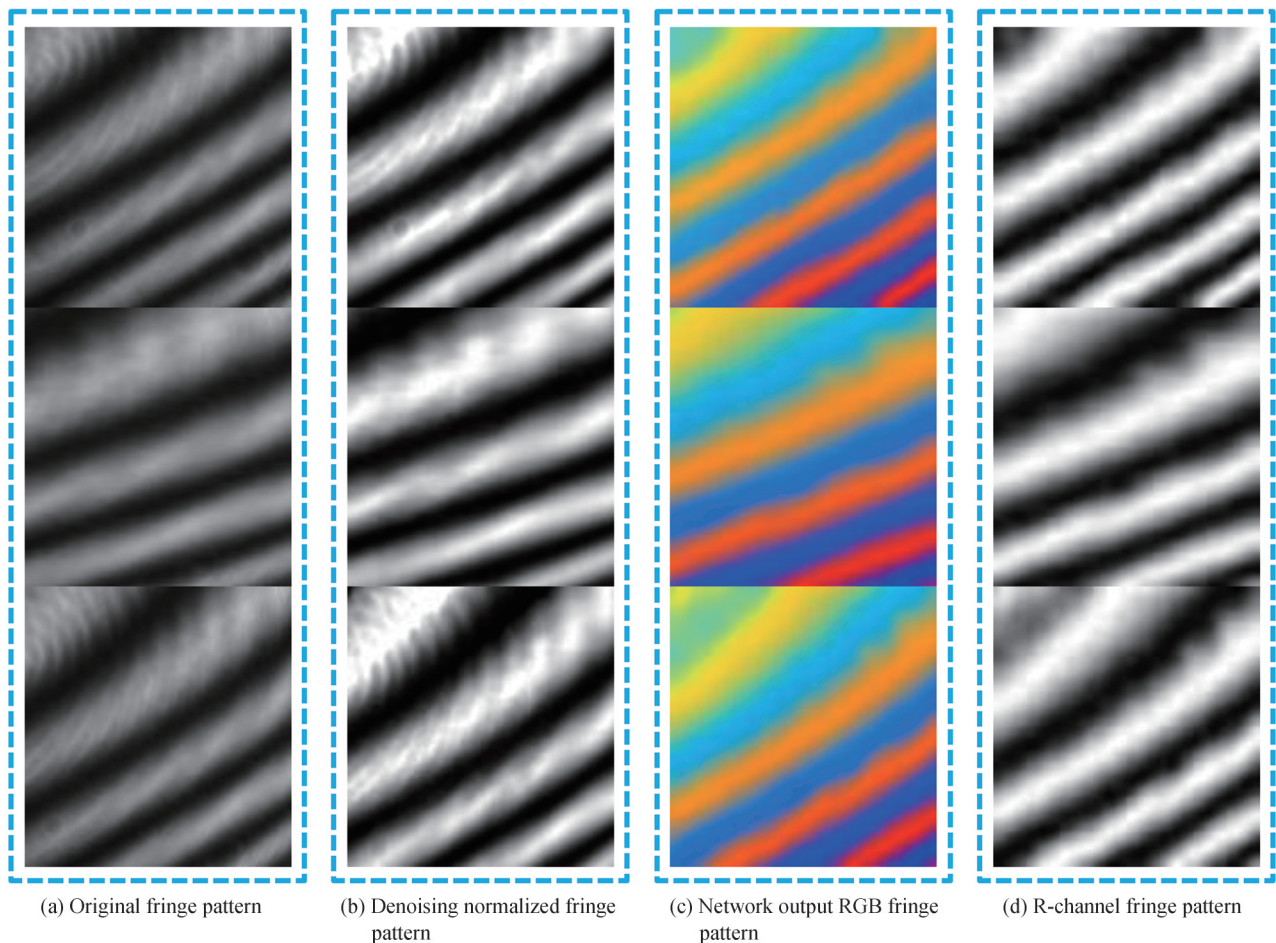


图10 条纹图正交变换实验

Fig. 10 Experiment for fringe pattern orthogonalization

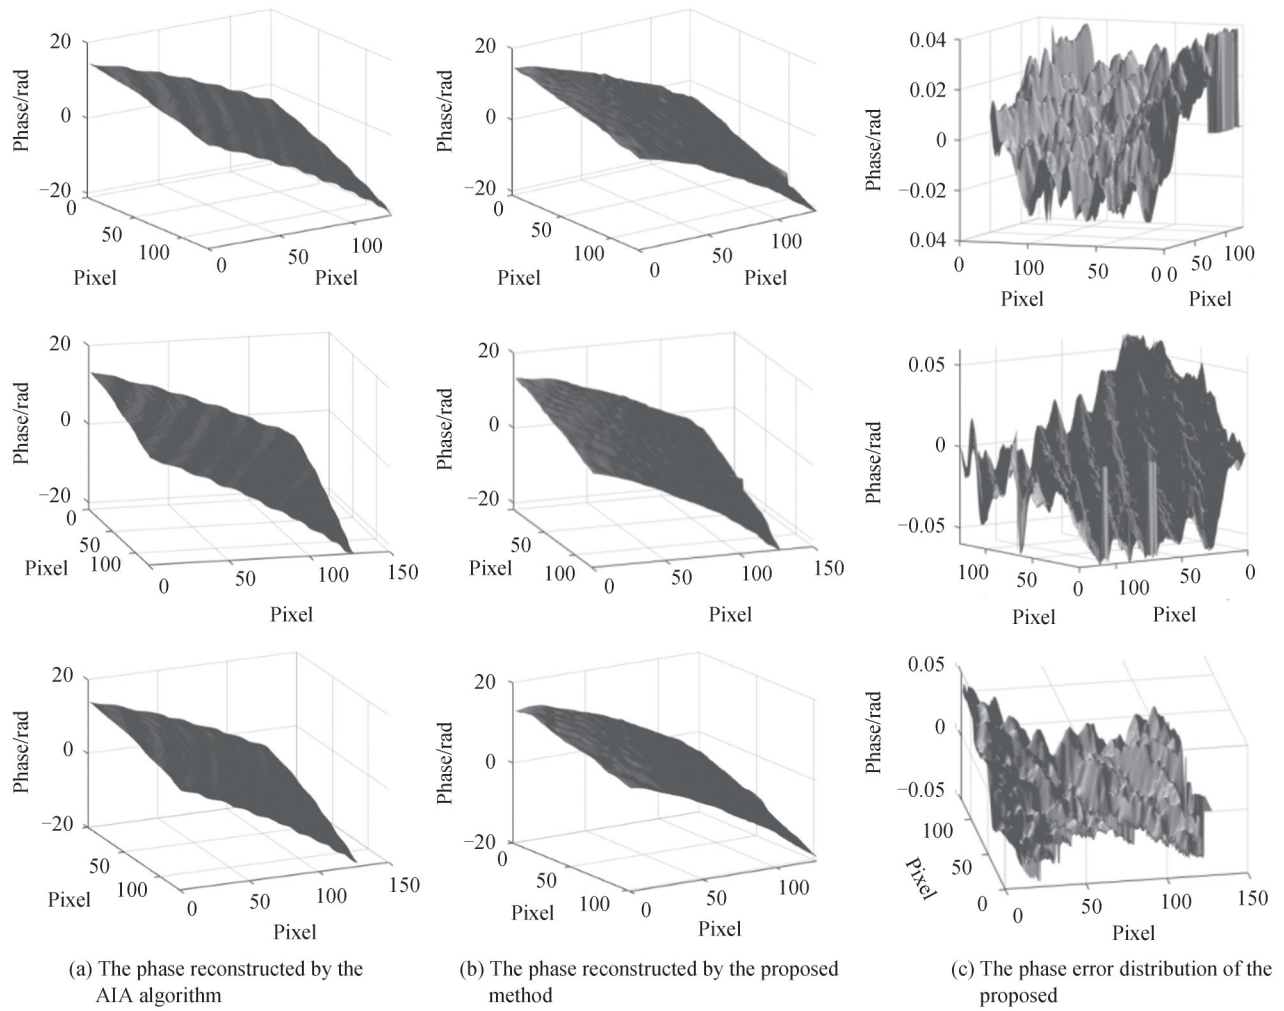


图 11 相位重建实验

Fig. 11 Experiment for phase reconstruction




图 12 均方根误差分布

Fig. 12 Root mean square of error

噪音项。图 10(c)和(d)为应用本文方法得到的结果。比较图 10(b)和图 10(d)可知,所提方法成功地实现了数字相移。

由于实际的原因,参考相位往往难以获取。考虑到 AIA 算法^[21]是一种高精度的广泛应用的多帧相移求解算法,本文首先应用 AIA 算法,使用图 9 给出的点衍射条纹图进行了相位解调。然后以其去包裹^[19]后的结

果作为本文的参考值,计算了本文方法的误差分布。图11处理的结果表明,本文方法的相图与参考相图非常接近,相位误差不超过0.05 rad。

由以上重建相位结果可知,相比参考相位,所提方法解调出的相位图在边缘处出现了较小的畸变,但在其他部位,重建的相图与参考相图很好的相吻合。考虑到应用多帧条纹图时,因为均化作用可消除求解结果中大多数不确定性因素的影响,而采用单帧条纹图解调相位时,由于条纹信息较少,尽管进行了归一化处理,但由于处理的残差、条纹图光强非正弦分布等因素的影响,单帧解调的结果容易受到条纹图中不确定性因素影响。因此发生较小畸变在所难免。

应当说明,网络的处理过程是各向同性的,所以B通道和R通道结果的精度是一样的。为了说明这一点,采用图10第一行第一个条纹图作为输入数据,再使用B通道的输出提取相位,然后再比较B通道和R通道的输出结果。图13(a)、(b)给出了取反后的相位分布及误差分布,其与R通道得到相位分布及误差分布(见图11第一行第二个和第三个图)比较可知,两个方法的结果除了符号相反外,得到的相位分布和误差分布完全相同。因此提出的网络R通道和B通道均可用于相位提取。




图13 不同通道输出结果比较
Fig. 13 Comparisons of output results of different channel

增加B通道的作用主要是为了丰富标签特征,促使网络容易收敛。图13(c)给出了G通道的输出的结果,可见该通道的结果不能作为测量相位使用。

图14给出了图10(a)的第一个图使用Riesz变换方法的处理结果。由图14(a)可知,Riesz变换的结果发生了明显的畸变,其方法与参考相位的误差较大,见图14(b)。该实验结果与仿真实验结果类似,证明本文正交化方法具有很好的效果。总之,本文提出的算法具有优良性能,可以很好的实现条纹图正交化,为发展单帧条纹图分析提供了一种有效途径。

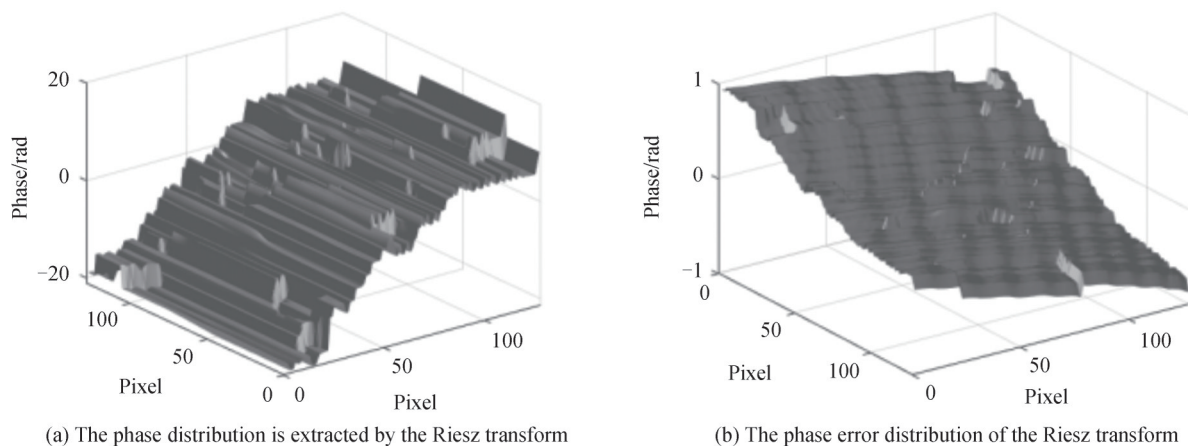


图14 Riesz变换方法结果
Fig. 14 Result of the Riesz transform method

5 结论

发展条纹图正交化方法对于非载频条纹图相位解调非常重要,为了解决单帧条纹图正交化欠采样问题,本文发展了一种基于GANs网络的条纹图正交方法。所提方法实现了归一化条纹图的正交变换,并根据获得的正交信号实现了单帧条纹图相位解调。提出的正交化方法基于GANs网络,采用制作的数据集对设计的深度学习网络训练后,最终高精度地实现了单帧条纹图相位解调。与典型方法相比,实验以及仿真证明本文方法性能优良。另外,本文方法仅需一帧条纹图可以恢复测量相位,大大节约测量时间,因此结合不断提高了硬件水平为快速测量场合提供了一种实用的途径。后续的研究将集中对所提方法的优化,包括数据集的完备性、网络的集成性等方面,以提高解调精度。

参考文献

- [1] GORTHI S, RASTOGI P. Fringe projection techniques: whither we are?[J]. *Optics & Lasers in Engineering*, 2010, 48(2):133-140.
- [2] DU Hubing, ZHANG Shaofeng, YU Jianhong, et al. Research on random phase shifting shadow moiré technique[J]. *Acta Optica Sinica*, 2018, 38(8): 0815010.
杜虎兵, 张少锋, 宇建红, 等. 随机相移阴影莫尔法研究[J]. *光学学报*, 2018, 38(8):0815010.
- [3] TOUNSI Y, KUMAR M, SIARI A, et al. Digital four-step phase-shifting technique from a single fringe pattern using Riesz transform[J]. *Optics Letters*, 2019, 44(14):3434-3437.
- [4] QIAN K. Two-dimensional windowed Fourier transform for fringe pattern analysis: principles, applications and implementations[J]. *Optics & Lasers in Engineering*, 2007, 45(2):304-317.
- [5] ZHONG J, WENG J. Spatial carrier-fringe pattern analysis by means of wavelet transform: wavelet transform profilometry [J]. *Applied Optics*, 2004, 43(26):4993-4998.
- [6] ZHENG S, CAO Y. Fringe-projection profilometry based on two-dimensional empirical mode decomposition[J]. *Applied Optics*, 2013, 52(31):7648-7653.
- [7] LAGUBEAU G, COBELLI P, BOBINSKI T, et al. Empirical mode decomposition profilometry: small-scale capabilities and comparison to Fourier transform profilometry[J]. *Applied Optics*, 2015, 54(32):9409-9414.
- [8] TRUSIAK M, WIELGUS M, PATORSKI K. Advanced processing of optical fringe patterns by automated selective reconstruction and enhanced fast empirical mode decomposition[J]. *Optics & Lasers in Engineering*, 2014, 52:230-240.
- [9] HUANG Hong, WANG Tao, LI Yuan, et al. Cancer pathological segmentation network based on depth feature fusion[J]. *Acta Photonica Sinica*, 2022, 51(3):0310001.
黄鸿, 王涛, 李远, 等. 基于深度特征融合的癌症病理图像分割网络[J]. *光子学报*, 2022, 51(3):0310001.
- [10] BADRINARAYANAN V, KENDALL A, CIPOLLA R. SegNet: a deep convolutional encoder-decoder architecture for image segmentation[J]. *IEEE Transactions on Pattern Analysis & Machine Intelligence*, 2017, 39(12):2481-2495.
- [11] YAN K, YU Y, SUN T, et al. Wrapped phase denoising using convolutional neural networks[J]. *Optics and Lasers in Engineering*, 2020, 128:0143-8166.
- [12] ZHANG J, TIAN X, SHAO J, et al. Phase unwrapping in optical metrology via denoised and convolutional segmentation networks[J]. *Optics Express*, 2019, 27(10):14903.
- [13] JEUGHT S, DIRCKX J. Deep neural networks for single shot structured light profilometry[J]. *Optics Express*, 2019, 27(12):17091.
- [14] FENG S, CHEN Q, GU G, et al. Fringe pattern analysis using deep learning[J]. *Advanced Photonics*, 2019, 1(2): 025001.
- [15] NGUYEN H, WANG Y, WANG Z. Single-shot 3d shape reconstruction using structured light and deep convolutional neural networks[J]. *Sensors*, 2020, 20(13):1-13.
- [16] REYES-FIGUEROA A, FLORES V, RIVERA M. Deep neural network for fringe pattern filtering and normalization [J]. *Applied Optics*, 2021, 60(7):2022-2036.
- [17] LI Bing, XIAN Yong, ZHANG Daqiao. Infrared image generation algorithm based on conditional generation adversarial networks[J]. *Acta Photonica Sinica*, 2021, 50(11):1110004.
李冰, 鲜勇, 张大巧. 基于条件生成对抗网络的红外图像生成算法[J]. *光子学报*, 2021, 50(11):1110004.
- [18] HUANG Rui, ZHANG Shu, LI Tianyu, et al. Beyond face rotation: global and local perception GAN for photorealistic and identity preserving frontal view synthesis[C]. *Computer Vision and Pattern Recognition*, 2017, 4086:1704-1715.
- [19] ZHAO Z, ZHAO H, ZHANG L, et al. 2d phase unwrapping algorithm for interferometric applications based on derivative zernike polynomial fitting technique[J]. *Measurement Science and Technology*, 2015, 26(1):017001.
- [20] JIANG Zhangde, GAO Fen, LI Bing. Research on system error calibration algorithm of point diffraction interferometer [J]. *Journal of Mechanical Engineering*, 2013, 49(16):48-56.
- [21] WANG Z, HAN B. Advanced iterative algorithm for phase extraction of randomly phase-shifted interferograms[J]. *Optics Letters*, 2004, 29(14):1671-1673.

Fringe Pattern Orthogonalization Method by Generative Adversarial Nets

FENG Leijie¹, DU Hubing¹, ZHANG Gaopeng², LI Yanjie¹, HAN Jinlu¹

(1 School of Mechatronic Engineering, Xi'an Technological University, Xi'an 710021)

(2 Xi'an Institute of Optics and Precision Mechanics, Chinese Academy of Sciences, Xi'an 710119)

Abstract: Optical measurement techniques, such as interferometry, moiré techniques, and digital holography, are the most popular noncontact approaches for measuring three-dimensional (3D) object surfaces in terms of non-invasive, fast, and accurate evaluation. Usually, the property of the measured quantity is encoded in the phase of the intensity distribution of the fringe pattern, which can be decoded by phase retrieval, in other words, the recovery of a complex-valued signal from the sampled intensity patterns. In this way, phase demodulation of the fringe pattern plays a crucial role in the ubiquitous optical measurements. Among various single frame phase demodulation techniques, the high-frequency fringe pattern demodulation technique, such as Fourier transform profilometry, sampling moiré method and spatial carrier phase-shifting have been intensively studied and are mainly based on known analytical models of measurement systems, such as harmonic representation of the intensity of fringe patterns. But for low-frequency fringe pattern, phase reconstruction from only a single interferogram is difficult, especially for those including closed fringes. Sign ambiguity during the single-frame demodulation is one of the main problems that impede the development of single-frame interferometry. In this case, fringe pattern orthogonalization plays a very important role in low-frequency fringe pattern phase extraction. However, due to the ill-posed problem of orthogonalization of a single frame fringe pattern, the development of an analytical method for fringe pattern orthogonalizing is full of challenges. In recent years, researchers have demonstrated that deep learning is a powerful machine learning technique that uses artificial neural networks with deep layers to fit complex mathematical functions, thereby, deep learning provides a promising improvement over classical methods derived from explicit analytical formulations of the forward models. More specifically, deep learning approaches handle problems by searching and establishing sophisticated mapping between the input and the target data owing to the powerful computation capability, and therefore may provide a new solution for the phase demodulation of low-frequency fringe pattern. Inspired by recent successful artificial intelligence-based optical imaging applications, in this paper, we propose to utilize the deep learning to solve this problem of under sampling. This paper shows the new phase retrieval method based on deep learning can effectively improve performance and enable new functionalities for fringe profilometry. In the proposed network, the Generative Adversarial Nets are used to generate digitally the phase shifting of original image by combining the prior knowledge of network and fringe pattern denoising normalization. After training on labeled image pairs, the proposed method successfully implements the desired phase-shifting fringes pattern, which can be viewed as the orthogonal transformation of a fringe pattern. With this Orthogonal transformation network, the wrapped phase can be extracted easily if the sampled fringes pattern is normalized using a trained deep neural network. The validity of the proposed Orthogonal transformation network is demonstrated on both the simulated and experimentally obtained fringe patterns. We also perform a comparative analysis of the proposed and existing approaches. Herein, we conducted fringe pattern denoising-normalization by using a deep-learning-based method developed because of its high-quality reconstruction ability. Thereafter, we input the normalized FP into the proposed Hilbert transformation network to perform Hilbert transform. We demonstrated our approach on both an open and a closed fringe pattern. Indeed, owing to local phase-sign ambiguity, the processed results show that the unwrapped phase map cannot be reconstructed adequately from the existing D4-PS wrapped map, even for a plane. Further, the reference phase from the proposed method is compared with the phase obtained by the multiple-frame high precision phase shift algorithm. Experimental results show that the proposed Orthogonal transformation network can provide a simple and robust solution for optical phase extraction from a single fringe pattern with phase error distribution within 0.05 rad and, therefore, make it allow for paving a new way to measure object 3D profilometry in a transient situation.

Key words: Fringe pattern analysis; Phase demodulation; Orthogonalization of fringe pattern; Deep learning; 3D profile measurement

OCIS Codes: 120.2650; 120.6650; 120.4820