

基于 U-Net 网络的结构光三维测量术

张子超, 张宗华^{*}, 高楠, 孟召宗

河北工业大学机械工程学院, 天津 300130

摘要 结构光条纹投影是广泛应用的一种三维测量技术。虽然该技术经过几十年的研究和发展,但如何从单幅图像中快速获取物体三维形貌仍然是没有得到很好解决的难题之一。近几年,深度学习广泛应用于计算机视觉和图像处理领域。提出一种基于 U-Net 网络的结构光三维测量方法。该方法直接从单个变形条纹图中获取物体表面的深度信息,实现三维形貌的快速测量。仿真和实际实验数据证明了所提方法的有效性。由于仅从一幅变形条纹中计算得到三维数据,所提方法可应用于动态物体三维面形的测量。

关键词 图像处理; 条纹投影; 三维测量; 深度学习; 计算机视觉

中图分类号 TH741

文献标志码 A

doi: 10.3788/LOP202158.2010003

U-Net-based Structured Light Three-dimensional Measurement Technology

Zhang Zichao, Zhang Zonghua^{*}, Gao Nan, Meng Zhaozong

School of Mechanical Engineering, Hebei University of Technology, Tianjin 300130, China

Abstract Structured light fringe projection is widely used in three-dimensional (3D) shape measurement technologies. However, even after decades of related research and development, restoring the 3D shape of objects using a single fringe pattern remains a challenge. In recent years, deep learning methods have been used increasingly in computer vision and image processing tasks. Thus, this paper proposes a structured light 3D measurement method based on the U-Net network. The proposed method obtains the depth information of the target object's surface directly from a single deformed fringe pattern to realize high-speed 3D shape measurement. Simulated and experimental data prove the effectiveness of the proposed method. With the proposed method, 3D data can be calculated from a single deformed fringe pattern; thus, it can be applied to the 3D shape measurement of dynamic objects.

Key words image processing; fringe projection; 3D measurement; deep learning; computer vision

OCIS codes 100.3010; 110.6915; 150.1135

1 引言

随着光电子器件和计算机技术的发展,各种基于光学的三维数字成像技术在近年来得到了大量研究和快速发展,这些技术的精度、速度、可靠性和易用性不断提高^[1]。在众多光学三维测量方法中,结构光条纹投影技术由于具有非接触操作、全场、采集

速度快、精度高、数据处理自动化等优点,在学术界和工业领域得到了广泛研究和应用^[2]。

在过去的几十年里,学者们一直致力于研究各种条纹分析技术,它们大致分为两类。第一类是相移方法:需要在多个条纹图中提取相位信息,进而获得物体的三维形貌^[3]。第二类是基于变换的相位解调方法:可从一个条纹图中计算相位,如傅里叶变换

收稿日期: 2020-12-03; 修回日期: 2020-12-18; 录用日期: 2021-01-02

基金项目: 重大科学仪器设备开发重点专项(2017YFF0106404)、国家自然科学基金(51675160, 52075147)

通信作者: *zhzhang@hebut.edu.cn

(FT)、窗式傅里叶变换(WFT)和小波变换(WT)等^[4-6]。与基于变换的相位解调方法相比,相移方法具有较强的鲁棒性,可以实现像素级相位测量,具有较高的分辨率和精度,此外对非均匀背景光强和条纹调制不敏感。然而,由于需采集多幅条纹图,相移方法很难应用于动态测量,更容易受到外界干扰和振动的影响^[7]。因此,对于许多应用场合,需要从单个条纹图中提取相位进而恢复物体三维形貌^[8]。单幅条纹投影术主要步骤:首先产生一幅正弦条纹图样,利用投影装置(DLP)将其投射到被测物体表面,相机采集变形条纹图,应用基于变换的方法获得所采集的变形条纹图的折叠相位,进行相位展开和系统标定后,恢复物体的三维形貌^[9]。

传统的结构光三维测量方法步骤繁琐,不利于快速三维成像^[10]。深度学习方法在图像处理方面应用广泛,因此将深度学习用于条纹图分析,实现快速三维测量成为新的研究热点。国内外学者对基于深度学习的结构光三维测量进行了初步研究。Feng 等^[11]利用两个卷积神经网络从变形条纹图中获取相位信息。第一个神经网络通过输入单幅变形条纹图得到背景光强度图,第二个神经网络通过输入变形条纹图和背景光强度图输出折叠相位的分子和分母,根据函数关系获得折叠相位分布,进行相位展开后,恢复物体三维形貌。实验证明此方案可行,且在物体边缘处和梯度较大部分表现良好,性能优于传统的 FT 和 WFT 方法。Feng 等^[12]设计了三路并行神经网络,每路的网络结构均不相同,通过输入三幅频率不同的变形条纹图,获得三组对应折叠相位的分子和分母,根据简单的正切函数关系,获得折叠相位;利用折叠相位,通过差频的方法,获得展开相位,最终实现三维测量。实验证明,该网络训练的模型泛化能力比较好,能够应用于其他数据,但是精度有待提升。Spoorthi 等^[13]利用相位神经网络(PhaseNet)实现二维空间相位展开。该网络的输入为包裹相位,通过构建的深度卷积神经网络(DCNN),其输出为条纹级次。DCNN 由编码器、解码器和像素分类器组成。作者将相位解包裹重新定义为语义分割,并利用全卷积网络结构解决此问题。Wang 等^[14]也利用深度学习技术构建用于相位展开的神经网络。与 PhaseNet 不同,该网络不计算包裹相位的条纹级次,而是直接通过包裹相位获得展开相位,实现端到端的过程。

尽管国内外对基于深度学习的结构光三维测量开展了相关研究,但是关于直接通过变形条纹图恢

复物体三维形貌的研究还比较少,并且网络模型的泛化能力和鲁棒性普遍不高。本文提出一种基于 U-Net 网络的结构光条纹投影三维测量新方法。该方法构造卷积神经网络,并通过其直接从单个变形条纹图中获取深度信息,实现快速三维信息获取,提高测量效率。首先研究一种新型 U-Net 网络结构,运用经典神经网络架构和模型,设计卷积神经网络结构,然后对该网络模型进行训练学习,接着通过仿真和实验数据验证所提网络的有效性,实现对三维面形数据的快速测量,最后对所提网络结构模型进行分析和讨论。

2 基本原理

2.1 网络三维测量流程

应用传统结构光条纹投影技术仿真物体变形条纹图和深度数据集,研究一种新型的深度神经网络模型并对其进行训练,直接得到与输入变形条纹对应的深度图,实现三维测量,主要流程如图 1 所示。通过设计好的仿真系统,制作数据集,为神经网络提供充足的样本数据。设计网络并将数据参与训练,得到模型参数。最后,在测试阶段将变形条纹图处理后输入到已经训练好的模型中,得到物体的深度,进而恢复物体的三维面形。

2.2 网络模型和训练

受到 U-Net 网络在生物细胞分割领域成功应用的启发,将改进后的 U-Net 网络应用于三维测量^[15]。所采用的网络结构如图 2 所示,由图像输入层、下采样部分、上采样部分及图像输出层组成。下采样部分进行特征提取,主要由 4 块组成,每块包括 2 个 3×3 卷积(conv)、每个卷积后加入的批归一化(BN)、激活函数(ReLU),最后连接步长为 2、核大小为 2×2 的最大池化层(max pooling)。下采样部分可以降低图像分辨率,进而减少神经网络参数计算量,加快训练进程。下采样部分的每块依次将卷积核数量加倍,增加特征通道数量,尽可能多地提取图像特征。上采样部分同下采样部分相似,也是由 4 块组成。每块包括 1 个核大小为 2×2 的转置卷积(up-conv),每经过一个转置卷积后将卷积核数量减半,减少通道数量。与此同时,在与下采样部分相同特征数量的块级联(skip connection)之后,再经过 2 个 3×3 卷积,每个卷积后同样加入 BN 层和激活函数。由于卷积操作后会丢失边界像素点的值,下采样部分和上采样部分的级联可以增加边界信息,改善边缘效果。与此同时,级

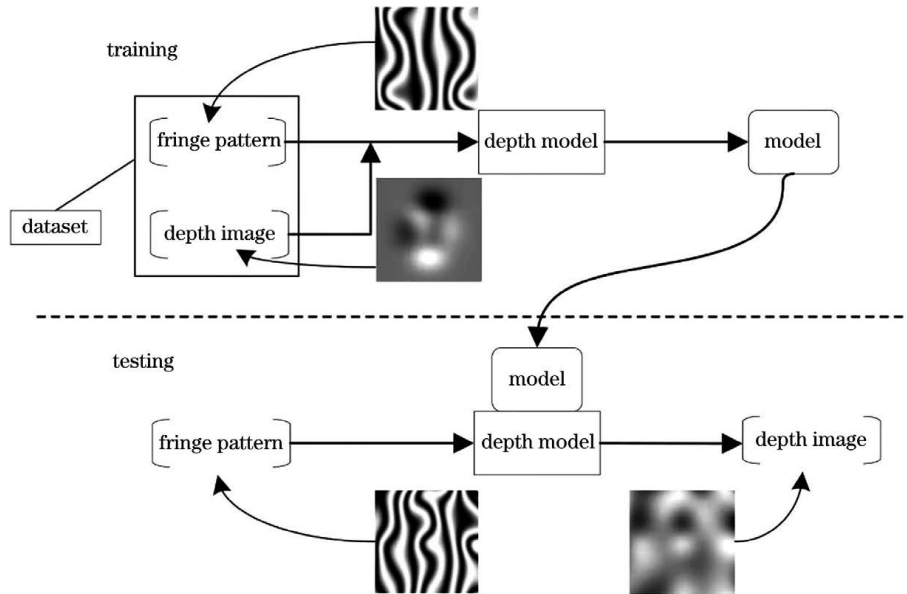


图 1 神经网络三维测量流程
Fig. 1 Procedure of neural network 3D measurement




图 2 卷积神经网络结构
Fig. 2 Convolutional neural network structure

联将神经网络的深层和浅层连接,将局部信息和全局信息结合,获得更精细的预测效果。在网络的最后一层,使用 1×1 卷积建立深度信息映射,输出物体深度。该网络一共包含 23 个卷积层,待学习参数大约为 3.104×10^7 个。该网络可实现物体面形的三维测量。为了增加模型的泛化能力,利用软件生成包含各种表面形貌的三维仿真物体,制作标准数据集。通过一定的训练方式将数据集参与到训练中,得到可以直接用于物体三维测量的网络模型。

3 实验和结果

3.1 仿真实验

3.1.1 数据集

为了训练所提网络,需要制作标准数据集。该数据集包括物体高度调制的变形条纹图及对应的深度图。由于需要大量数据,采取仿真方式获得具有不同高度分布的物体及其变形条纹图。为了自动实现数据集构建过程,设计了一个仿真物体生成器,通过该生成器,产生大小不同的矩阵,再将其插值到指

定尺寸来生成形状各异的物体。在预定义高度范围内,该生成器随机改变矩阵大小和插值方法,自动生成尺寸相同、形状各异的仿真物体。其中仿真物体的高度限制在 0~30 mm,插值方法包括三次样条插值、线性插值和三次 Hermite 插值等。

为了获取模拟物体的变形条纹图,需要一套相

机、投影仪和物体的组合仿真系统^[16]。为了建立和实际系统相同的仿真系统,需要预先标定搭建的实际系统,获得相机和投影仪的内部参数、外部参数矩阵及系统参数。根据以上参数,仿真虚拟相机、虚拟投影仪和虚拟物体之间的关系,使仿真系统参数和实际系统参数相同,最后利用软件实现该仿真系统。

$$z = \frac{L_0}{\frac{2\pi L_0^2 L \cos \theta}{P_0 \Delta \varphi(x, y) (L_0 + x \cos \theta \sin \theta)^2} - \frac{L \cos \theta \sin \theta}{L_0 + x \cos \theta \sin \theta} + 1}, \quad (1)$$

式中: L_0 表示相机出瞳到参考面的距离; L 表示相机出瞳到投影仪出瞳的距离; P_0 表示条纹周期; θ 表示投影仪光轴和相机光轴的夹角; $\Delta \varphi(x, y)$ 表示经过物体表面高度调制后的相位变化; z 表示物体 (x, y) 处的高度。根据(1)式中 $\Delta \varphi$ 和 z 的函数关

系,确定正弦条纹图经物体调制后的变形条纹图。由于真实环境中存在随机噪声,所以部分条纹图生成时,向其添加 0~2.5% 随机噪声。将条纹图和物体深度图一一对应生成数据集,部分数据如图 3 所示。




图 3 数据集的部分数据

Fig. 3 Part data in the dataset

3.1.2 三维测量结果

生成 10500 对图片制作数据集,分为训练集、验证集和测试集,三者比例为 8:1:1。使用 pytorch 框架实现网络,训练中共执行 1600 轮,一次训练选取的样本数为 128,共进行 105000 次迭代。训练初始阶段,卷积核权重使用 Xavier 均匀分布初始化,优化器设置为 Adam,初始学习率为 10^{-4} 。为了获

得更好的测量效果,采取分阶段训练方式,并加入 L2 正则化惩罚项,初始大小为 10^{-3} ^[17-18]。训练过程中,每经过 320 轮,学习率减半,L2 正则化惩罚项缩减 1/10,使用均方误差(MSE)作为损失函数训练网络^[19]。每 100 轮保存一次模型,同时保存训练效果最好的模型。该网络使用 NVIDIA 2080Ti 显卡训练 15 h 后完成训练。训练过程中的训练集和验

证集损失函数变化如图 4 所示。

网络训练完成后,选取验证集和测试集样本对训练后的网络进行实验。重构后的计算结果表明,测试集的整体均方根误差(RMSE)为 0.72%。为

了和文献[20]中的方法作比较,利用相同的数据集进行测试。实验结果表明,文献[20]中测试集的整体 RMSE 为 0.83%。可见所提方法优于文献[20]中的方法。




图 4 训练集和验证集的损失函数曲线。(a)训练集损失曲线;(b)验证集损失曲线

Fig. 4 Loss curves of the training set and validation set. (a) Loss curve of the training set; (b) loss curve of the validation set

在验证集和测试集中选择编号为 9920、10020 和 10120 的三个变形条纹图,经过网络正向传播,获得物体深度,结果如图 5 所示。所提网络预测的深度图和真实深度图用肉眼几乎无法区分。通过误差图可以看出,文献[20]中方法的误差明显大于所提

方法的误差,进一步验证了所提方法的有效性。物体的三维形貌如图 6 所示。三个样本的 RMSE 和结构相似度(SSIM)如表 1 所示,归一化后的 RMSE 均小于 0.9%且 SSIM 均大于 0.98,证明所提方法具有恢复物体三维形貌的能力。




图 5 仿真实验结果。(a)(f)(k)深度图;(b)(g)(l)所提方法预测的深度图;(c)(h)(m)所提方法的误差图;(d)(i)(n)文献[20]中方法预测的深度图;(e)(j)(o)文献[20]中方法的误差图

Fig. 5 Experiment results of simulation. (a)(f)(k) Depth images; (b)(g)(l) depth images predicted by proposed method; (c)(h)(m) error images of proposed method; (d)(i)(n) depth images predicted by method in Ref. [20]; (e)(j)(o) error images of method in Ref. [20]

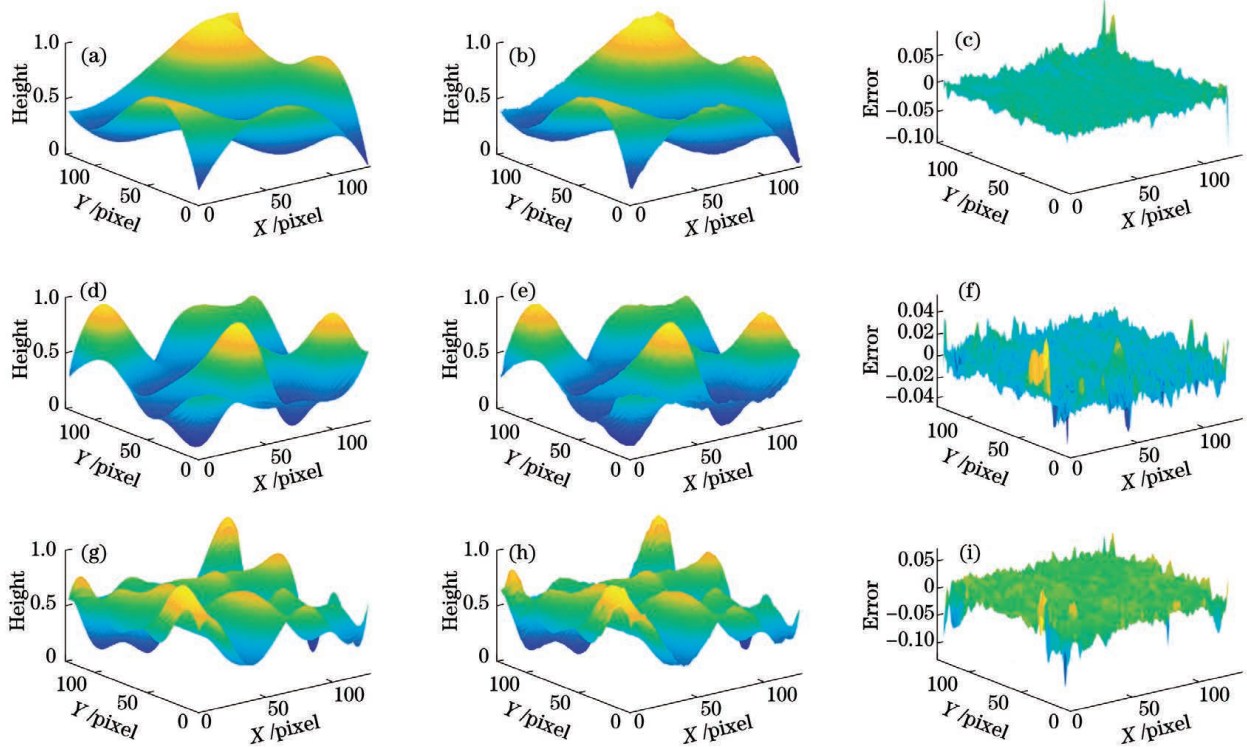


图 6 三维展示。(a)(d)(g)三维形貌图；(b)(e)(h)预测三维形貌图；(c)(f)(i)误差图

Fig. 6 3D effect. (a)(d)(g) 3D shape images; (b)(e)(h) predicted 3D shape images; (c)(f)(i) error images

表 1 仿真实验误差分析

Table 1 Error analysis of simulation experiment

Sample No.	RMSE / %	SSIM
9920	0.65	0.9916
10020	0.64	0.9921
10120	0.88	0.9886

3.2 实际实验

3.2.1 实验系统

为验证所提基于 U-Net 网络的结构光三维测量技术的有效性,搭建了实验系统,如图 7 所示。该系统主要由计算机、数字投影仪和 CCD 相机组成。投影仪 (LightCrafter4500, Texas Instruments, 美国) 的物理分辨率为 $912 \text{ pixel} \times 1140 \text{ pixel}$ 。相机 (ECO655CVGE, SVS-VISTEK, 德国) 的物理分辨率为 $2448 \text{ pixel} \times 2050 \text{ pixel}$ 。镜头型号为 Computar-M321228C-MP, 具有 $12 \sim 36 \text{ mm}$ 的可变焦距, 用于采集经物体调制后的变形条纹图。

3.2.2 实际测量结果

利用所搭建的实验系统,采集了投影在面具和移动人手的变形条纹图。对采集的变形条纹图进一步处理后输入网络,得到物体三维形貌,如图 8、9 所示。其中图 9(a) 和图 9(b) 是三维重构结果视频中一帧




图 7 三维测量系统实物图

Fig. 7 Photograph of 3D measurement system




图 8 相机采集到的变形条纹图。(a)面具的变形条纹图；(b)人手的变形条纹图

Fig. 8 Deformed fringe patterns obtained by camera. (a) Deformed fringe pattern of mask; (b) deformed fringe pattern of human hand

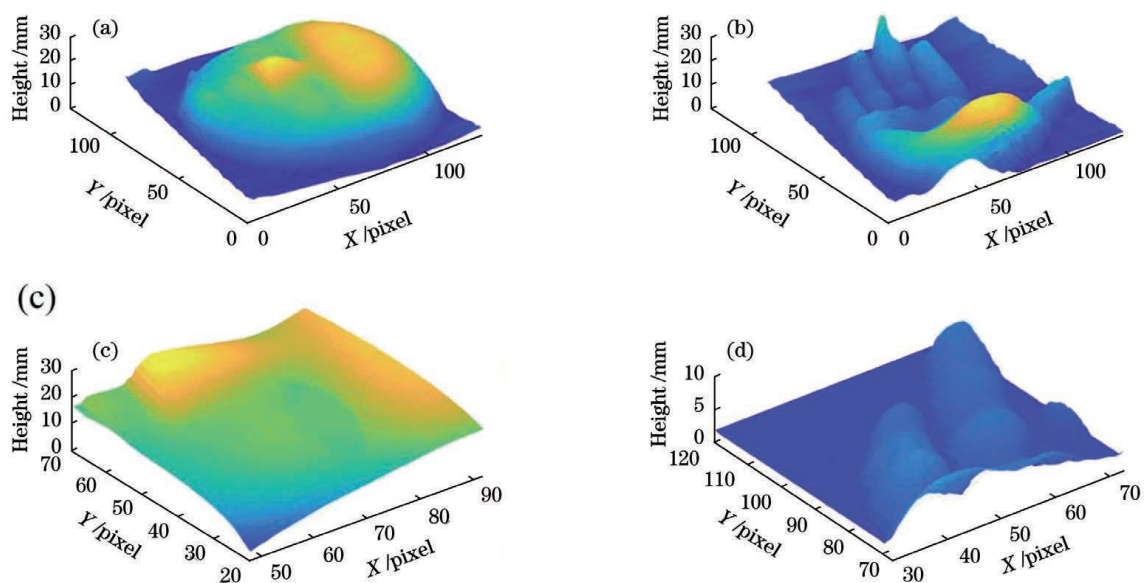


图 9 实际物体的三维形貌图。(a)面具的三维形貌图;(b)人手的三维形貌图;(c)面具眼睛细节展示;(d)人手手指细节展示
Fig. 9 3D shape data of real objects. (a) 3D shape data of mask; (b) 3D shape data of human hand; (c) detail display of mask eye; (d) detail display of human hand finger

的三维面形展示,图 9(c)和图 9(d)分别为面具眼睛和人手手指等细节的三维形貌图。由于采集的条纹图包含没有条纹的区域和阴影部分,网络预测该区域时无法完成预测。利用软件,将网络输出的深度图中缺失数据部分替换为物体高度的最小值来完成预测。

在面具测量中,由于所提方法无法很好地测量不连续的物体,所以在实际实验过程中,面具的眼睛空洞部分用 A4 纸遮挡,以形成连续表面。经过网络预测,可以很好地恢复面具整体三维形貌。在移动人手测量中,于不同时刻采集移动人手的变形条纹图,将采集到的变形条纹图经过数据预处理后导入到网络模型中,获得深度图进而恢复三维形貌。从图 9(b)中可以看出,中指指尖位置恢复效果较差,整体三维形貌效果良好。从图 9(c)、(d)可以看出,所提方法预测实际物体的三维面形时在细节方面仍表现良好。将所提方法同传统相移方法相比较,其中在比较移动人手时,使用人手一个姿态位置的三维数据进行比较;使人手尽量保持不动,并利用 8 步相移的方法计算三维形貌,将计算结果作为真值。两个实际物体的误差结果如表 2 所示。RMSE

表 2 实际物体误差分析

Table 2 Error analysis of real objects

Object	RMSE / %	SSIM
Mask	1.42	0.9755
Human hand	2.25	0.9353

均小于 2.5% 且 SSIM 均大于 0.93。实验结果说明,所提方法既可有效恢复物体的三维形貌,也可用于测量动态物体的三维面形。

4 分析与讨论

4.1 网络泛化能力分析

为了评估所提网络模型测量其他物体的能力,测试网络的泛化能力。通过构建 3D 物体样本并调整网络输入大小,将样本的变形条纹图作为神经网络输入,结果如图 10、11 所示。第一个实验,利用软件生成一个具有复杂表面的物体。实验结果表明,除了物体四周边缘处误差较大,其余部分恢复效果良好。物体样本的误差如表 3 所示, RMSE 小于 0.95%, SSIM 大于 0.97, 同验证集和测试集误差接近。第二个实验,生成 128×128 大小的仿真物体。该物体具有较大梯度变化和更复杂的表面分布。经网络获得深度图恢复的三维形貌同真实值基本吻合, RMSE 小于 0.9% 且 SSIM 大于 0.98, 误差极小。与此同时由误差图可以看出,文献[20]中方法的恢复误差较大,所提方法优于它。

表 3 3D 物体样本误差分析

Table 3 Error analysis of 3D object sample

Object	RMSE / %	SSIM
Sample 1	0.94	0.9782
Sample 2	0.89	0.9813

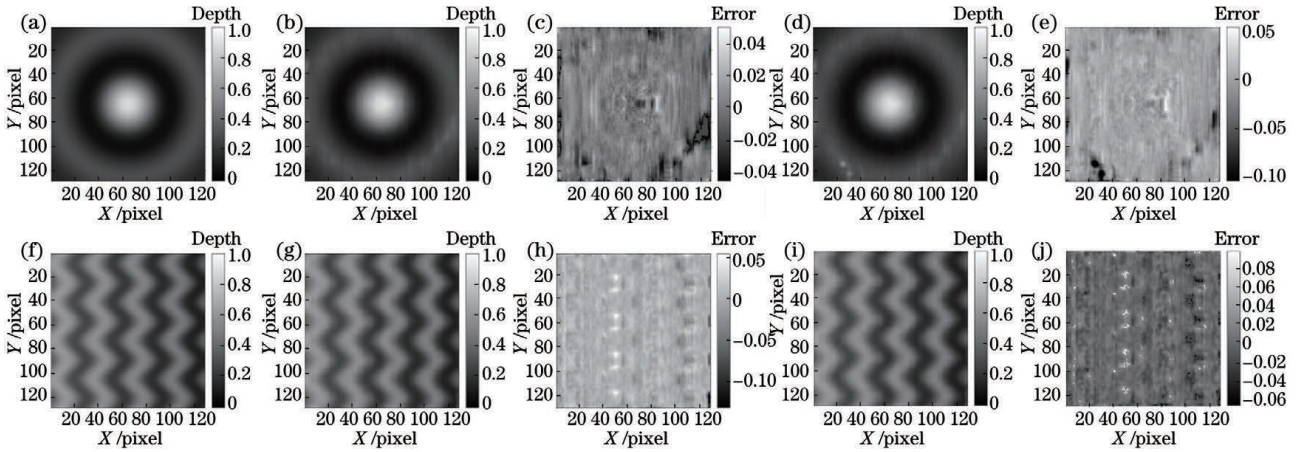


图 10 泛化能力分析结果。(a)(f)深度图;(b)(g)所提方法预测的深度图;(c)(h)所提方法的误差图;(d)(i)文献[20]中方法预测的深度图;(e)(j)文献[20]中方法的误差图

Fig. 10 Generalization capability analysis results. (a)(f) Depth images; (b)(g) depth images predicted by proposed method; (c)(h) error images of proposed method; (d)(i) depth images predicted by method in Ref. [20]; (e)(j) error images of method in Ref. [20]

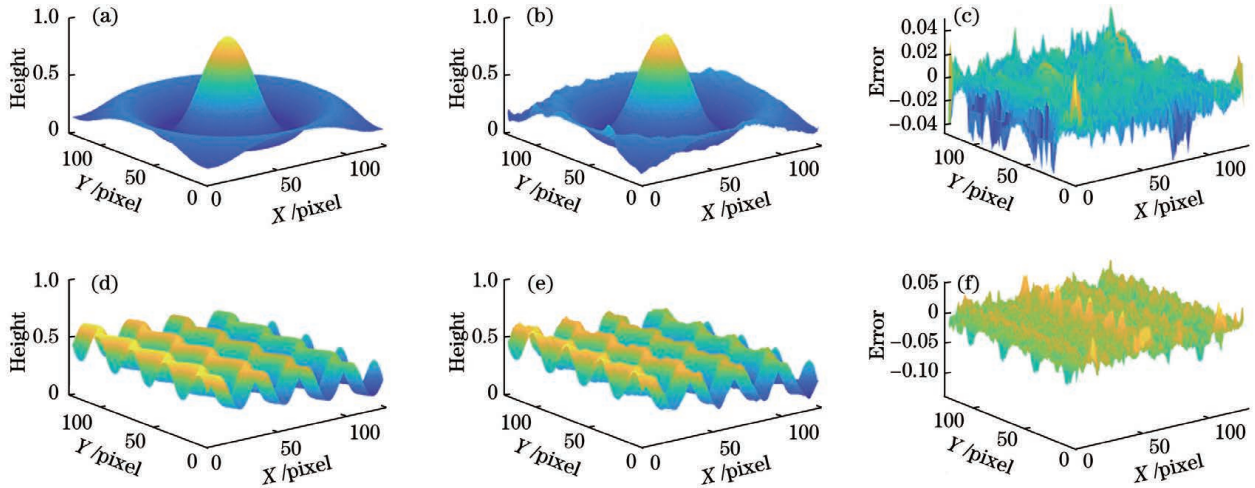


图 11 三维展示。(a)~(c)3D 物体样本 1 的三维形貌图、预测三维形貌图和误差图;(d)~(f)3D 物体样本 2 的三维形貌图、预测三维形貌图和误差图

Fig. 11 3D effect. (a)–(c) 3D shape data, predicted 3D shape data, and error image of sample 1; (d)–(f) 3D shape data, predicted 3D shape data, and error image of sample 2

综上所述,所提网络的泛化能力较好,具有恢复其他较复杂物体三维形貌的能力。

4.2 网络抗噪声能力分析

由于实际实验中采集到的变形条纹图会受到随机噪声的影响,研究所提网络的抗噪声能力。前期的实验表明:多数相机的随机噪声在 2.5% 左右。为进一步验证所提方法在较大噪声水平时的抗噪能力,重新分析了验证集和测试集中的 10 个样本,并加入 4.5% 水平内的随机噪声,最后给出定量分析的平均值,结果如表 4 所示。结果表明, RMSE 均小于 0.9%, SSIM 均大于 0.98。网络预测结果受随机噪声的影响较小。在编号 10020 样本中分别加

表 4 验证集、测试集噪声分析

Table 4 Noise analysis of validation set and test set

Noise level	RMSE / %	SSIM
0.5%	0.61	0.9937
1.5%	0.63	0.9923
2.5%	0.70	0.9886
3.5%	0.78	0.9862
4.5%	0.87	0.9824

入 0.5%、2.5%、4.5% 水平的随机噪声,结果如图 12、13 所示。可以看出,4.5% 以内的噪声水平对




图 12 抗噪声能力分析结果。(a)(e)(i)(m)变形条纹图；(b)(f)(j)(n)深度图；(c)(g)(k)(o)预测深度图；
(d)(h)(l)(p)误差图

Fig. 12 Anti-noise capability analysis results. (a)(e)(i)(m) Deformed fringe images; (b)(f)(j)(n) depth images;
(c)(g)(k)(o) predicted depth images; (d)(h)(l)(p) error images

物体的精度影响极小,仅对物体边缘有一定影响。综上所述,在正常的噪声范围内,所提网络并没有因为噪声的存在而影响性能,证明所提网络具有较好的抗噪能力,鲁棒性较好。

4.3 网络测量效率

所提网络结构比较复杂,包含大量矩阵运算和卷积运算。由于神经网络可以在并行硬件-图形处理器(GPU)上高速实现,即使网络参数量巨大,也能以较快速度完成运算^[21]。尽管训练网络需要几小时甚至几天的时间,但是网络一旦训练完成,测量将十分快捷。对于本文测量,在 NVIDIA 2080Ti 显卡上仅需要不到 2 ms 的时间。

5 结 论

提出一种基于 U-Net 网络的结构光三维测量方法。该方法通过单幅条纹图即可获得物体表面的三维形貌,克服了传统光学方法需要多幅条纹图像造成测量速度慢的缺点,简化了测量步骤,提高测量效率。所提网络在泛化能力和抗噪声能力方面均表现良好。对于传统光学方法来说,简化了三维测量步骤,拓宽了三维测量领域的实现方法。不同的网络结构有可能进一步提高精度,未来的进一步工作将是试验其他领域网络能否有更好的测量性能,诸如残差网络(Res-Net)、金字塔网络(PSP-Net)、生成对抗网络(GAN)等^[22-23]。

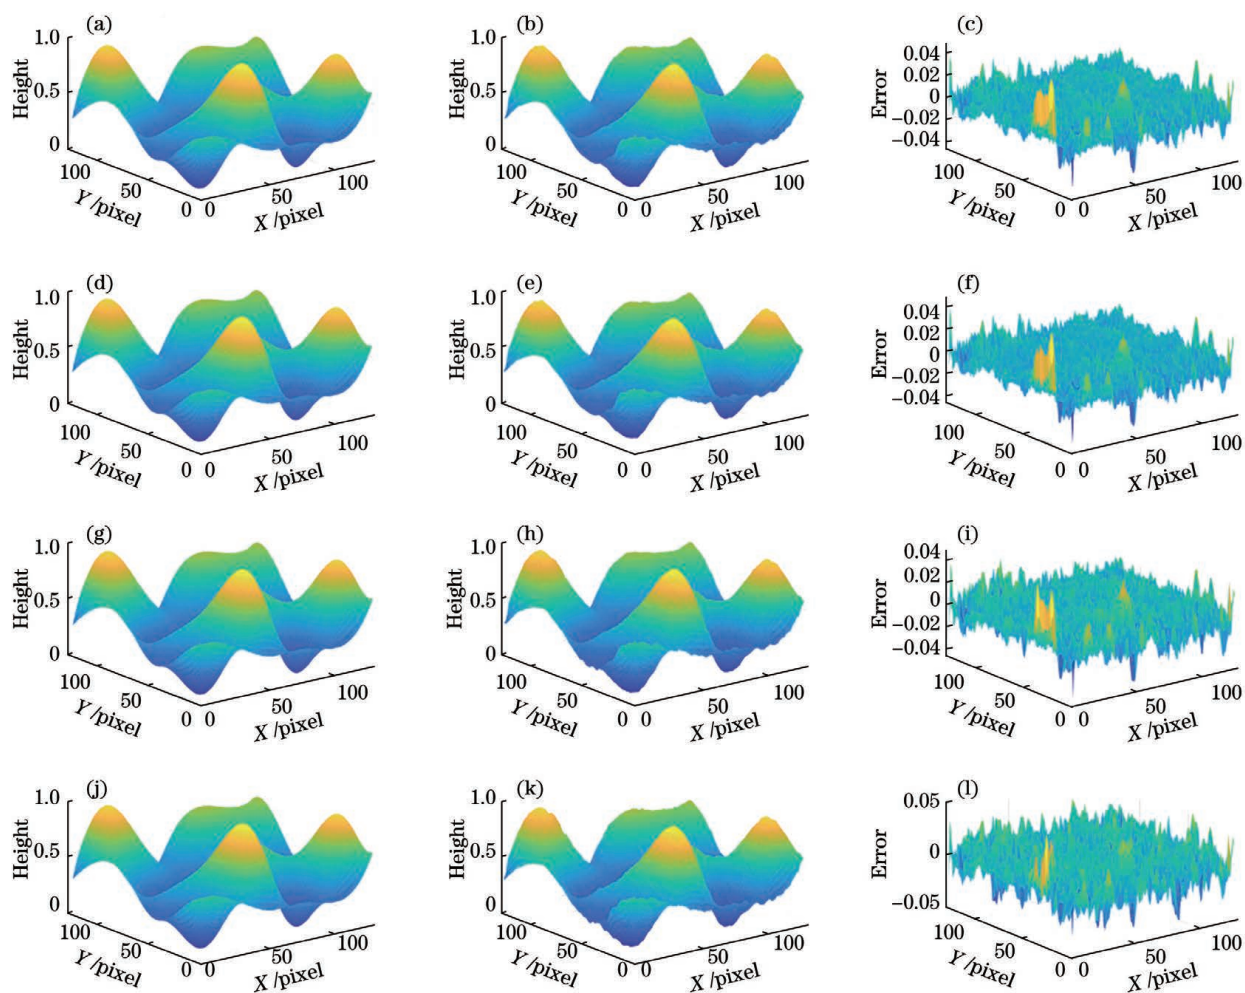


图 13 三维展示。(a)(d)(g)(j)三维形貌;(b)(e)(h)(k)预测三维形貌;(c)(f)(i)(l)误差图

Fig. 13 3D effect. (a)(d)(g)(i) 3D shape data; (b)(e)(h)(k) predicted 3D shape data; (c)(f)(i)(l) error images

参 考 文 献

- [1] Yang P B, Deng L J, Chen Y, et al. Three-dimensional shape measurement of highly reflective objects based on structured light[J]. Chinese Journal of Lasers, 2019, 46(2): 0204004.
杨鹏斌, 邓林嘉, 陈元, 等. 基于结构光的高反物体三维形貌测量方法[J]. 中国激光, 2019, 46(2): 0204004.
- [2] Feng W, Tang S J, Zhao X D, et al. Three-dimensional shape measurement method of high-reflective surfaces based on adaptive fringe-pattern [J]. Acta Optica Sinica, 2020, 40(5): 0512003.
冯维, 汤少靖, 赵晓冬, 等. 基于自适应条纹的高反光表面三维面形测量方法[J]. 光学学报, 2020, 40(5): 0512003.
- [3] Feng J Y, Chen H Y, Shi C, et al. Three-dimensional measurement of highly-reflective surface using structured light technique[J]. Laser & Optoelectronics Progress, 2019, 56(22): 221202.
- [4] Wu S Q, Zhang Y, Zhang S Y, et al. Analysis of three-dimensional measurement system and the coordinates calibration in Fourier transform profilometry[J]. Acta Optica Sinica, 2009, 29(10): 2780-2785.
吴双卿, 张引, 张三元, 等. 傅里叶变换轮廓术物体三维形貌测量的系统分析及其坐标校准方法[J]. 光学学报, 2009, 29(10): 2780-2785.
- [5] Qian K M. Two-dimensional windowed Fourier transform for fringe pattern analysis: principles, applications and implementations [J]. Optics and Lasers in Engineering, 2007, 45(2): 304-317.
- [6] Sun J, Chen W J, Su X Y, et al. Study the measurement range of wavelet transform profilometry [J]. Acta Optica Sinica, 2007, 27(4): 647-653.
孙娟, 陈文静, 苏显渝, 等. 小波变换轮廓术的测量范围研究[J]. 光学学报, 2007, 27(4): 647-653.

- [7] van der Jeught S, Dirckx J J J. Real-time structured light profilometry: a review[J]. *Optics and Lasers in Engineering*, 2016, 87: 18-31.
- [8] Zhang Z H. Review of single-shot 3D shape measurement by phase calculation-based fringe projection techniques[J]. *Optics and Lasers in Engineering*, 2012, 50(8): 1097-1106.
- [9] Chen C, Yu J, Gao N, et al. High accuracy 3D calibration method of phase calculation-based fringe projection system by using LCD screen considering refraction error[J]. *Optics and Lasers in Engineering*, 2020, 126: 105870.
- [10] Bai X F, Zhang Z H. 3D shape measurement based on colour fringe projection techniques [J]. *Chinese Journal of Scientific Instrument*, 2017, 38(8): 1912-1925.
白雪飞, 张宗华. 基于彩色条纹投影术的三维形貌测量[J]. *仪器仪表学报*, 2017, 38(8): 1912-1925.
- [11] Feng S J, Chen Q, Gu G H, et al. Fringe pattern analysis using deep learning[J]. *Advanced Photonics*, 2019, 1(2): 025001.
- [12] Feng S J, Zuo C, Yin W, et al. Micro deep learning profilometry for high-speed 3D surface imaging [J]. *Optics and Lasers in Engineering*, 2019, 121: 416-427.
- [13] Spoorthi G E, Gorthi S, Gorthi R K S S. PhaseNet: a deep convolutional neural network for two-dimensional phase unwrapping [J]. *IEEE Signal Processing Letters*, 2019, 26(1): 54-58.
- [14] Wang K Q, Li Y, Qian K M, et al. One-step robust deep learning phase unwrapping[J]. *Optics Express*, 2019, 27(10): 15100-15115.
- [15] Ronneberger O, Fischer P, Brox T. U-net: convolutional networks for biomedical image segmentation[M]//Navab N, Hornegger J, Wells W M, et al. *Medical image computing and computer-assisted intervention-MICCAI 2015. Lecture notes in computer science*. Cham: Springer, 2015, 9351: 234-241.
- [16] Zhang Z, Zhang D, Peng X. Performance analysis of a 3D full-field sensor based on fringe projection[J]. *Optics and Lasers in Engineering*, 2004, 42(3): 341-353.
- [17] Kingma D P, Ba J. Adam: a method for stochastic optimization[EB/OL]. (2017-01-30) [2020-07-07]. <https://arxiv.org/abs/1412.6980>.
- [18] Loshchilov I, Hutter F. Decoupled weight decay regularization[EB/OL]. (2019-01-04) [2020-07-07]. <https://arxiv.org/abs/1711.05101>.
- [19] Botchkarev A. Performance metrics (error measures) in machine learning regression, forecasting and prognostics: Properties and typology [EB/OL]. (2018-09-09) [2020-07-07]. <https://arxiv.org/abs/1809.03006>.
- [20] van der Jeught S, Dirckx J J J. Deep neural networks for single shot structured light profilometry [J]. *Optics Express*, 2019, 27(12): 17091-17101.
- [21] Coelho I M, Coelho V N, Luz E J D S, et al. A GPU deep learning metaheuristic based model for time series forecasting [J]. *Applied Energy*, 2017, 201: 412-418.
- [22] He K M, Zhang X Y, Ren S Q, et al. Deep residual learning for image recognition [C] // 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), June 27-30, 2016, Las Vegas, NV, USA. New York: IEEE Press, 2016: 770-778.
- [23] Radford A, Metz L, Chintala S. Unsupervised representation learning with deep convolutional generative adversarial networks[EB/OL]. (2016-01-07) [2020-07-07]. <https://arxiv.org/abs/1511.06434>.