

基于 R2U-Net 的单帧投影条纹图深度估计

袁梦凯¹, 朱新军^{2*}, 侯林鹏¹¹天津工业大学控制科学与工程学院, 天津 300387;²天津工业大学人工智能学院, 天津 300387

摘要 从条纹图快速、准确获取被测物体准确深度信息是条纹投影三维测量技术关键环节之一。为解决单帧条纹图深度估计准确性问题, 基于 U-Net 的递归残差卷积神经网络 (R2U-Net), 提出了一种条纹图深度估计方法, 并在模拟数据和实验数据上进行了验证。对于模拟数据, 所提方法的预测结果误差为 1.71×10^{-6} , 小于 U-Net 方法对应的误差 7.98×10^{-6} ; 对于实验数据, 该方法预测的深度图误差比 U-Net 方法对应的误差降低了 13%。实验结果表明, 与已有的 U-Net 深度图预测方法相比, 所提方法所得深度图的高度分布曲线与标签拟合程度更高, 提高了单帧条纹图三维测量结果的准确性。

关键词 图像处理; 条纹投影; R2U-Net; 深度; 三维测量

中图分类号 TP391.4

文献标志码 A

DOI: 10.3788/LOP202259.1610001

Depth Estimation from Single-Frame Fringe Projection Patterns Based on R2U-Net

Yuan Mengkai¹, Zhu Xinjun^{2*}, Hou Linpeng¹¹School of Control Science and Engineering, Tiangong University, Tianjin 300387, China;²School of Artificial Intelligence, Tiangong University, Tianjin 300387, China

Abstract Fast and accurate depth estimation using fringe projection patterns plays an important role in the fringe projection three-dimensional measurement approach. Herein, a recurrent residual convolutional neural network based on U-Net (R2U-Net) is introduced to solve the problem of depth estimation with an improved accuracy than single-frame fringe projection patterns, and the corresponding depth estimation method for fringe projection patterns is proposed, which is verified using simulated and experimental data. Results reveal that, for the simulated data, the error in the predicted results of the proposed approach is 1.71×10^{-6} , which is less than the error of 7.98×10^{-6} corresponding to the U-Net method. For the experimental data, the error between the depth map predicted using the proposed method and the label decreases by 13% than that using the corresponding U-Net approach. Furthermore, compared with the existing U-Net depth map prediction method, the height distribution curve in the depth map obtained using the proposed approach exhibits a greater fitness with the label, which increases the accuracy of the three-dimensional measurement results from single-frame fringe patterns.

Key words image processing; fringe projection; R2U-Net; depth; three-dimensional measurement

1 引言

光学三维测量技术是光学测量中最重要的研究领域和研究方向之一^[1-4]。作为三维测量技术的一种重要方式, 条纹投影三维测量技术可快速准确获取被测物体表面的三维点云数据, 广泛应用于质量检测、文物保护、人机交互、生物医学等领域^[5-7]。在条纹投影三

维测量中直接获取的数据为条纹图, 而从条纹图到被测物体深度信息的获取需要经过条纹分析、相位提取和相位展开等过程^[4-5]。条纹分析、相位提取和相位展开方法对三维测量准确性有重要影响。如何从被测物体的条纹图像获取高精度的深度信息仍然是条纹投影三维测量技术的难点与重点内容^[8-10]。

从条纹图获取深度信息(或者展开相位)通常需要

收稿日期: 2021-05-10; 修回日期: 2021-05-31; 录用日期: 2021-06-27

基金项目: 国家自然科学基金(61905178)

通信作者: *xinjunzhu@tiangong.edu.cn

以相移法和傅里叶变换法等为代表的相位提取及空间相位展开和时间相位展开为代表的相位展开^[5,11-13]两大主要步骤。随着深度学习在图像分类和恢复等领域的成功应用,在条纹投影三维测量领域,基于深度卷积神经网络(CNN)开展的工作不断发展^[14-24]。Feng等^[19]提出了一种基于卷积神经网络实现包裹相位提取的方法,该方法分两步实现,第1步利用第1个卷积神经网络从单帧条纹图提取背景信息,第2步利用第2个卷积神经网络从单帧条纹图与其对应的背景信息生成包裹相位的正弦部分和余弦部分,然后通过计算获得相位信息。Spoorthi等^[20-21]在其提出的用于解包裹的PhaseNet的基础上再次提出了PhaseNet2.0,该网络的输入是包裹相位,输出是条纹级次,在编码-解码结构中使用密集块用作网络的构建块,达到了优于PhaseNet的测量结果,可靠地展开了复杂结构的相位。张钊等^[22]结合多阶段深度学习单帧条纹投影三维测量方法,通过分阶段学习方式依次获得物体的绝对相位与深度信息,通过传统的物理测量过程给予网络更多且更合理的约束,但分阶段学习容易引入误差。Nguyen等^[23]提出了一种利用卷积神经网络直接从条纹图预测深度信息的方法(U-Net),并在多种结构的卷积神经网络上进行了实验对比,结果表明,U-Net优于全卷积网络(FCN)和自动编码器网络(AEN),但预测精度仍然有待提升。Machineni等^[24]提出的框架通过多分辨率相似性评估卷积神经网络,从变形条纹本身直接重建对象的深度轮廓,在低边缘频率、高动态范围深度剖面 and 噪声边缘等具有挑战性和重要性的场景下的结果优于Nguyen等^[23]提出的U-Net方法,但该网络结构较为复杂,需要通过分阶段学习从投影条纹图依次获得参考条纹图和深度图。

总的来说,上述单帧条纹图深度预测算法可分为多阶段预测算法和单阶段预测算法。考虑到单阶段预测算法计算效率较高及数据准备较易等特点,本文提出了一种基于R2U-Net^[25]的条纹投影三维测量深度估计方法,该方法避免了包裹相位的计算及分步计算展开相位所带来的误差,只需要给定一帧条纹图即可获得对应的深度图。相比于利用U-Net进行深度估计的方法,所提方法预测的准确性更高。

2 所提方法

2.1 条纹投影轮廓术(FPP)

FPP一般利用投影仪向被测物体投射一系列条纹图,同时触发相机进行采集^[26]。 N 步相移算法对应的条纹图可表示为

$$I_n(x, y) = a(x, y) + b(x, y) \cos[\varphi(x, y) + 2\pi n/N], \quad (1)$$

式中: (x, y) 表示像素的空间坐标; $a(x, y)$ 是背景; $b(x, y)$ 和 $\varphi(x, y)$ 分别是调制强度和相位主值; $2\pi n/N$

为相移量, n 是相移指数, $0 \leq n < N$, N 为相移的步数。式(1)中包含 $a(x, y)$ 、 $b(x, y)$ 、 $\varphi(x, y)$ 3个未知量,在相移法中求解 $\varphi(x, y)$ 至少需要3帧条纹图,即 $N \geq 3$ 。 $\varphi(x, y)$ 的计算公式为

$$\varphi(x, y) = \arctan \left[\frac{\sum_0^{N-1} I_n(x, y) \sin\left(\frac{2n\pi}{N}\right)}{\sum_0^{N-1} I_n(x, y) \cos\left(\frac{2n\pi}{N}\right)} \right]. \quad (2)$$

和基于单帧条纹处理的变换域分析方法如傅里叶变换轮廓术、小波变换轮廓术和S变换轮廓术等一样,通过相移法所得的相位 $\varphi(x, y)$ 同样被截断在 $(-\pi, \pi]$,即包裹相位^[27],之后需要通过相位展开获取后续三维重建工作中所需的展开相位 $\phi(x, y)$ 。相位展开旨在从 $\varphi(x, y)$ 恢复连续的相位,其可通过增加或减去 2π 的适当倍数 $k(x, y)$ 来重建物理上连续的相位变化,从而消除相位跳变。因此,展开相位和包裹相位满足以下关系:

$$\phi(x, y) = \varphi(x, y) + 2\pi k(x, y). \quad (3)$$

最后,通过确定展开相位和高度之间映射表达式并标定出各项映射系数,实现被测物体的深度数据与相位数据转换,得到物体表面的三维形貌信息。

2.2 R2U-Net

本实验组采用U-Net以及基于U-Net改进的R2U-Net两种网络模型对单帧条纹图直接获取深度信息的方法进行研究。所选用的两种网络模型描述如下。

U-Net包括编码端和解码端两部分,每个编码层对应一个解码层,编码器逐步通过卷积层提取特征,通过池化层压缩特征图,提取主要特征,缩减输入数据的空间维度,而解码器逐步恢复目标的细节和相应的空间维度,且编码器到解码器之间添加了直接的信息连接,来帮助解码器更好地恢复目标细节。

R2U-Net是在U-Net的基础上进行改进的,与U-Net同样首先应用于医学图像分割领域,并取得了比U-Net理想的效果。R2U-Net将U-Net的编码和解码卷积单元用更为复杂的递归残差卷积单元(RRCU)代替,如图1所示。

RRCU中的递归卷积单元也称递归卷积层(RCL)是关键模块,它的使用增强了CNN捕获对象上下文中统计规律性的能力^[28]。图2为递归残差卷积单元,虚线框内的部分呈现了RCL的实现方法:RCL中除第1层卷积外,剩余每一层卷积的输入除了其上一层卷积的输出外都需要加上RCL的输入。对于RCL中位于第 k 张特征图处的 (i, j) 单元,它在时间步长 t 时的净输入 $\mathbf{z}_{ijk}(t)$ 为

$$\mathbf{z}_{ijk}(t) = (\mathbf{w}_k^t)^T \mathbf{u}^{(i,j)}(t) + (\mathbf{w}_k^r)^T \mathbf{x}^{(i,j)}(t-1) + \mathbf{b}_k, \quad (4)$$




图 1 基于 U-Net 的递归残差卷积神经网络

Fig. 1 Recurrent residual convolutional neural network based on U-Net

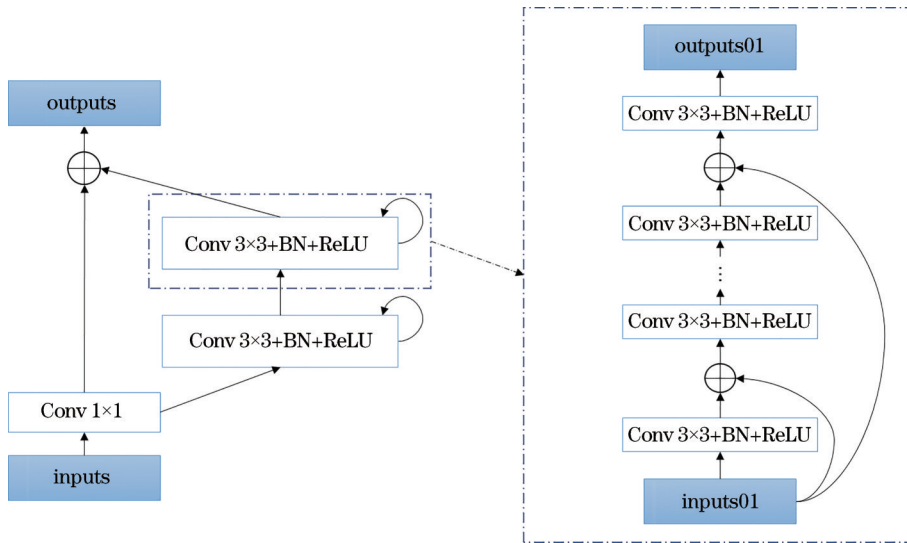


图 2 递归残差卷积单元和展开的递归卷积单元

Fig. 2 Recurrent residual convolutional units and unfolded recurrent convolutional units

式中： $u^{(i,j)}(t)$ 和 $x^{(i,j)}(t-1)$ 分别表示前馈输入和递归输入； $(w_k^f)^T$ 和 $(w_k^r)^T$ 分别为矢量化的前馈权值和递归权值； b_k 是偏差。

2.3 R2U-Net 深度图预测方法

本实验组通过 R2U-Net 深度学习算法从多帧相移条纹图中的第 1 帧直接获取所测量物体的深度信息。图 3 是所提算法的原理图，共包括训练和测试两个步骤。对于网络训练，在准备的模拟数据和实验数据^[23]上进行，训练 R2U-Net 学习输入数据（条纹图）和输出标记数据（深度图）之间的映射，预测的深度图通过与标签进行比较，使得网络输出的均方误差通过迭代反向传播最小化，以更新网络参数（权重和偏差）。在测试步骤中，经过训练的 R2U-Net 在输入单帧条纹图的情况下输出预测的深度图。




图 3 所提算法原理图

Fig. 3 Schematic diagram of proposed algorithm

3 实验与结果

为了验证所提算法的有效性，先后在模拟数据（模拟

数据中以展开相位代替深度)和实验数据上对所提算法进行了验证。网络架构基于 Python 3.8.3 的 Pytorch 框架版本 1.7.0+cu110 实现,在配置了 Nvidia GeForce RTX 3090 (24 GB)、英特尔 Core i7-10700K @3.80 GHz 八核和 64 GB RAM 的计算机上进行网络训练和测试。

3.1 仿真模拟

根据随机生成的形状用式(1)生成模拟条纹图以

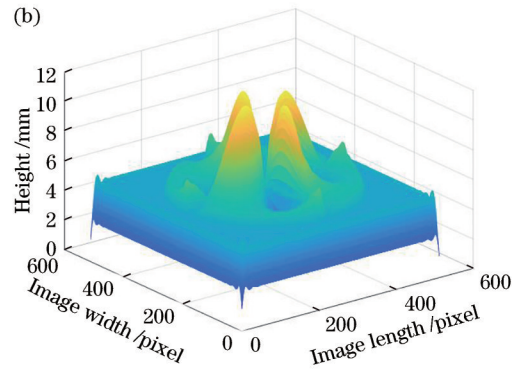



图4 模拟投影条纹图与模拟深度图。(a)模拟投影条纹图;(b)模拟深度图

Fig. 4 Simulated projection fringe pattern and simulated depth map. (a) Simulated projection fringe pattern; (b) simulated depth map

使用模拟数据在两种网络模型上分别进行训练,图5为进行仿真模拟时所采用的部分条纹图像和相对应的深度图。损失函数选择均方误差(MSE),优化器选用 Adam。通过分析训练集损失下降趋势,验证集的表现及测试集的测试效果,不断调整批大小、训练次数和

初始学习率网络超参数并选取合适的学习率动态调整策略,使得两种模型在设定的超参数下都能发挥到最佳。最终,批大小设定为 32,训练次数为 70,初始学习率设定为 1×10^{-4} 并在训练第 61 次衰减至 1×10^{-5} ,R2U-Net 和 U-Net 两种方法的训练时间分别约为 5 h 和 3 h。

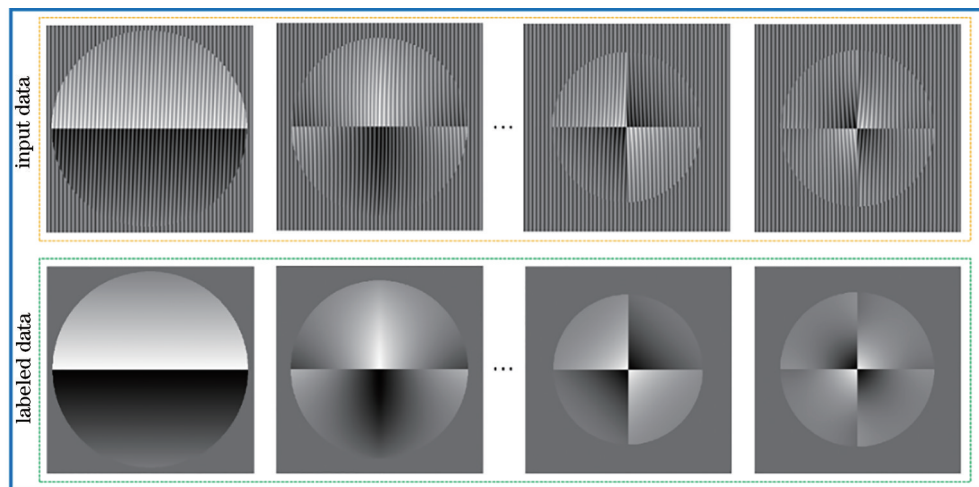


图5 模拟训练数据集

Fig. 5 Simulated training dataset

训练用的图片均为 512×512 的灰度图片,训练数据采用数据增强的方法以增加训练的数据量,提高模型的泛化能力,使得原有的 400 组训练样本增至 1200 组。同时,训练数据采取了小块训练策略,网络训练的输入数据维度为 $[32, 1, 80, 80]$,遍历 512×512 的图片区域,将其分解为多幅 80×80 的图片。训练完成后,利用 30 个测试样本对两种模型进行测试。区别于训

练时将数据分块送入网络,测试时以 512×512 的整幅图片送入网络测试,送入网络测试的数据维度为 $[30, 1, 512, 512]$,一次性输出所有测试样本的测试结果。以测试样本的测试输出与标签的 MSE 作为衡量模型性能的标准,U-Net 和 R2U-Net 两种模型得到的深度图误差分别为 7.98×10^{-6} 和 1.71×10^{-6} 。图6为 R2U-Net 和 U-Net 对应的 30 个无噪声测试样本误差。

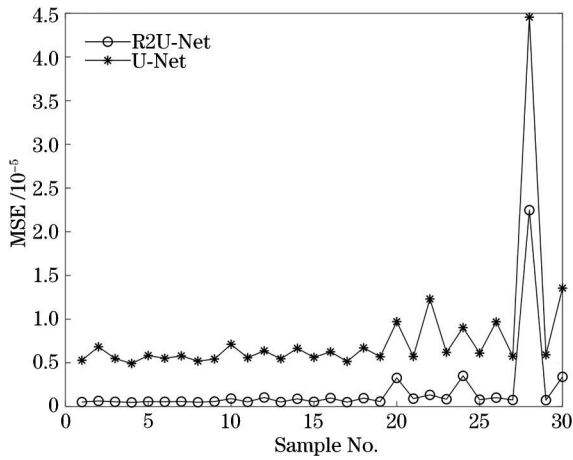


图 6 R2U-Net 和 U-Net 在无噪声测试样本下的误差
Fig. 6 Error of R2U-Net and U-Net under free noise testing samples

图 7 为某一模拟样本的测试结果,其中[图 7(a)]为测试输入的模拟条纹图,[图 7(b)]为该条纹图对应的深度图,[图 7(c)]和[图 7(d)]分别为 U-Net 与 R2U-Net 从该条纹图到深度图的预测结果,[图 7(e)]为这两种方法第 270 行数据的结果。与 U-Net 方法相比, R2U-Net 方法的曲线与标签数据的拟合程度更好,这得益于 R2U-Net 中递归残差卷积单元的使用。

此外,图 8 为所提方法与传统单帧条纹投影 Fourier 变换 (FTM) 相位提取方法及质量导向相位展开方法的对比。对比实验采用的模拟条纹图为[图 7(a)],R2U-Net 与 FTM (以 FTM 代指 Fourier 变换相位提取方法及质量导向相位展开方法)方法所得的结果误差 MSE 分别为 9.29×10^{-5} 和 4.71×10^{-2} ,其中[图 8(a)]为条纹图对应的深度图,[图 8(b)]和[图 8(c)]分别为 R2U-Net 与 FTM 对应的深度图,[图 8(d)]为这两种

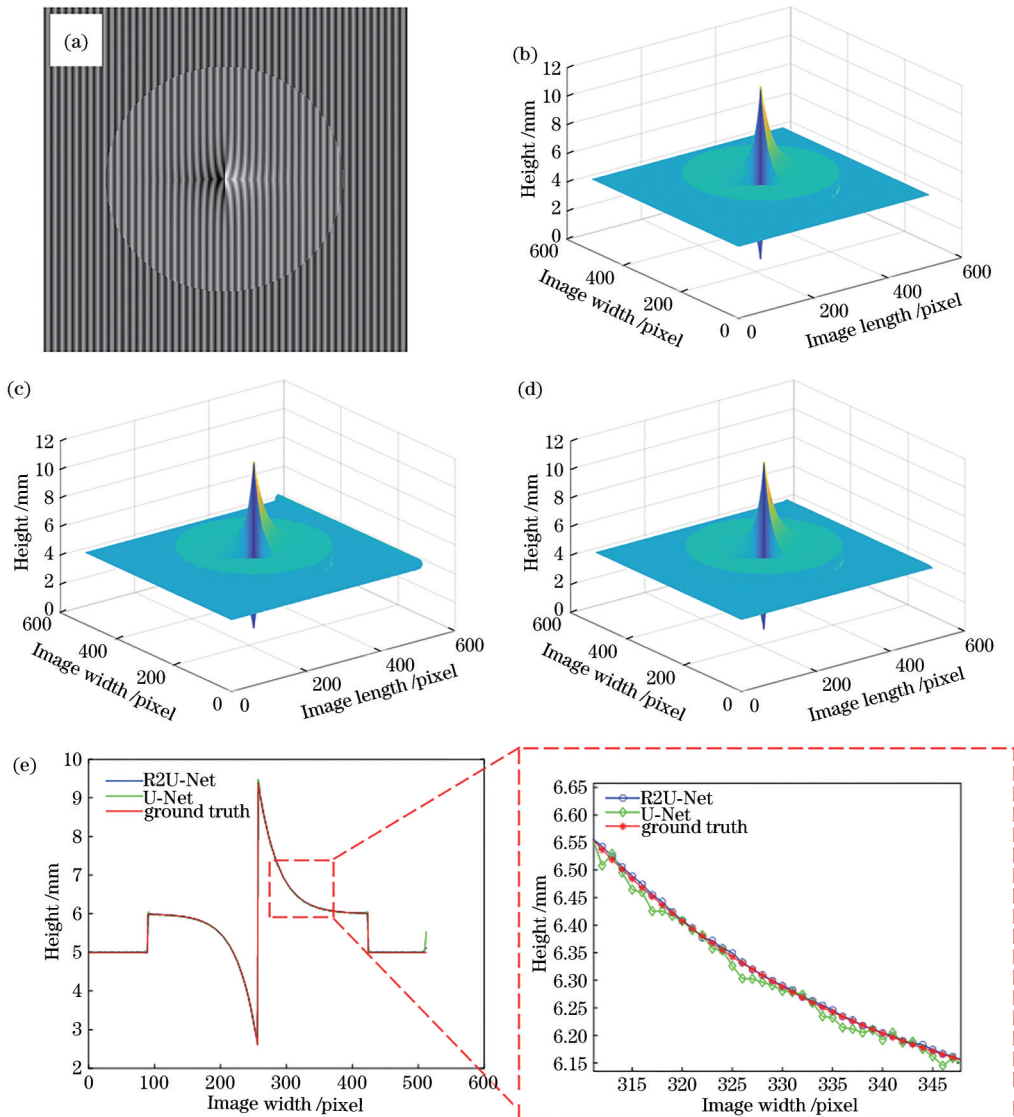


图 7 仿真数据的深度图预测结果。(a) 测试输入的模拟条纹图;(b) 条纹图对应的深度图;(c) U-Net 的预测结果;(d) R2U-Net 的预测结果;(e) 预测结果第 270 行数据的对比

Fig. 7 Depth map prediction result of simulated data. (a) Simulated fringe pattern of test input; (b) depth map corresponding to fringe pattern; (c) prediction result of U-Net; (d) prediction result of R2U-Net; (e) comparison of 270th row of prediction result

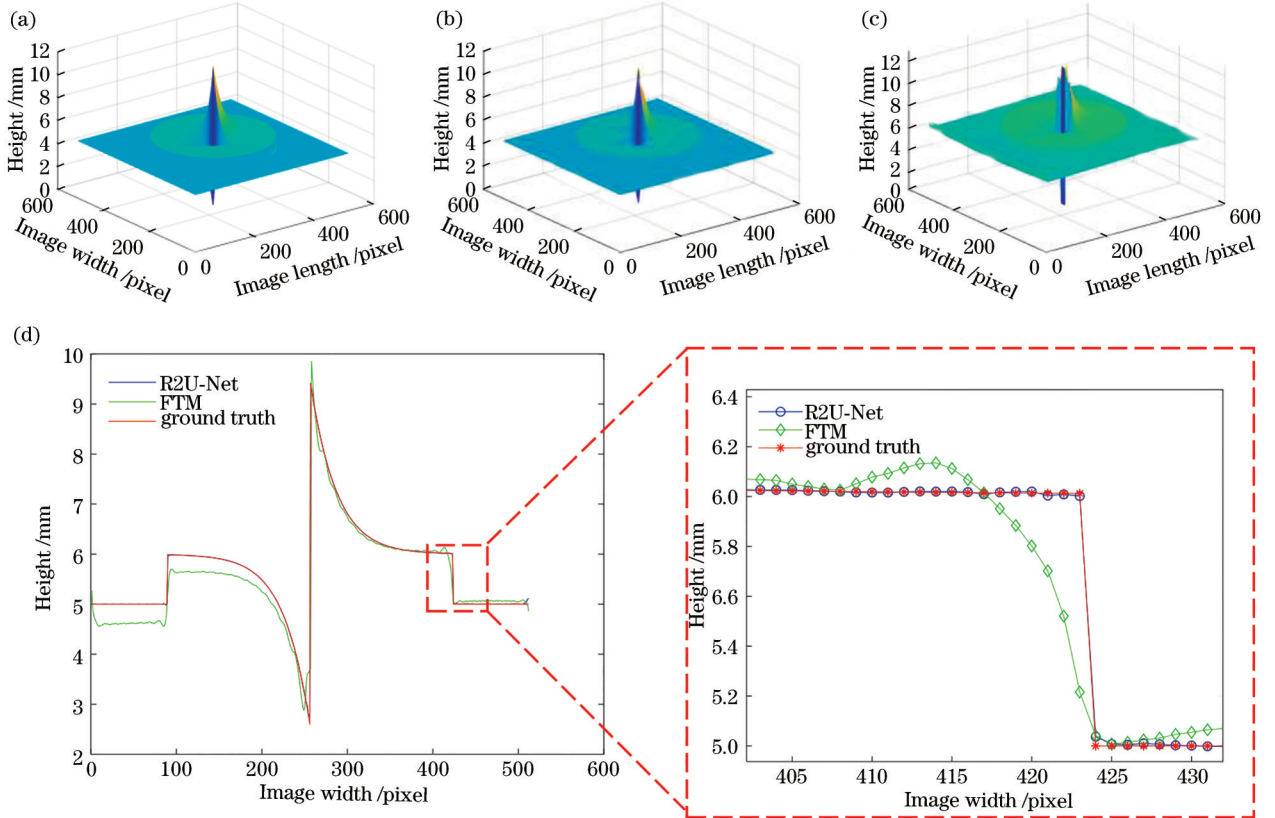


图 8 R2U-Net方法与FTM方法的对比。(a)条纹图对应的深度图;(b) R2U-Net的预测结果;(c) FTM的结果;(d)预测结果第270行数据的对比

Fig. 8 Comparison of R2U-Net method and FTM method. (a) Depth map corresponding to fringe pattern; (b) prediction result of R2U-Net; (c) result of FTM; (d) comparison of the 270th row of the prediction result

方法第 270 行数据的对比。从 [图 8(d)] 可以看出,所提方法优于 FTM 方法。

考虑到网络训练中损失函数对方法性能的影响,所提方法使用的结构相似性(SSIM)构造的损失函数及结合 SSIM 和平均绝对误差(MAE)构造的损失函数^[29]的表达式为

$$l(I, I') = \frac{\alpha}{2} [1 - \text{SSIM}(I, I')] + (1 - \alpha) \|I - I'\|_1, \quad (5)$$

式中: α 为 0.85; I 和 I' 分别是标签和网络的输出。表 1 为不同损失函数结果对比,从表中可以看出,预测的结果误差并没有降低。因此,在接下来的研究中均使用 MSE 作为损失函数。

表 1 损失函数对比

Table 1 Comparison of three loss functions

Loss function	MSE
MSE	1.71×10^{-6}
SSIM	2.22×10^{-6}
SSIM-MAE	2.17×10^{-6}

在实际环境下通过相机采集条纹数据时,由于被测物体的材质、测量环境的不确定性以及采集设备本身的工艺缺陷等,所采集的条纹数据存在噪声。因此在训练策略保持不变的情况下,将生成的模拟条纹图加入噪声,即在式(1)的基础上加上噪声项 noise,使用

的是高斯白噪声,噪声水平 δ 设定为 0.2,可表示为

$$I_n(x, y) = a(x, y) + b(x, y) \times \cos[\varphi(x, y) + 2\pi n/N] + \delta_{\text{noise}} \quad (6)$$

然后对两种网络模型的性能进一步进行测试对比(模拟数据加噪声时,两种网络模型的训练时间分别约为 5 h 和 3 h)。对于加噪声的测试样本, U-Net 和 R2U-Net 两种模型得到的深度图误差分别为 3.19×10^{-5} 和 1.52×10^{-5} 。图 9 为 R2U-Net 和 U-Net 对应的 30 个有噪声测试样本误差。




图 9 R2U-Net和U-Net在噪声测试样本下的误差
Fig. 9 Error of R2U-Net and U-Net under noisy testing samples

图 10 为某一加噪声模拟样本的测试结果,其中 [图 10(a)] 是测试输入的模拟条纹图, [图 10(b)] 是该条纹图对应的深度图, [图 10(c)] 和 [图 10(d)] 分别为 U-Net 与 R2U-Net 从该条纹图到深度图的预测结果,

[图 10(e)] 是这两种方法第 270 行数据的结果。从图中可以看出,在模拟数据的条纹图中加上噪声的情况下,与 U-Net 方法相比, R2U-Net 方法的曲线与标签数据的拟合程度更高。

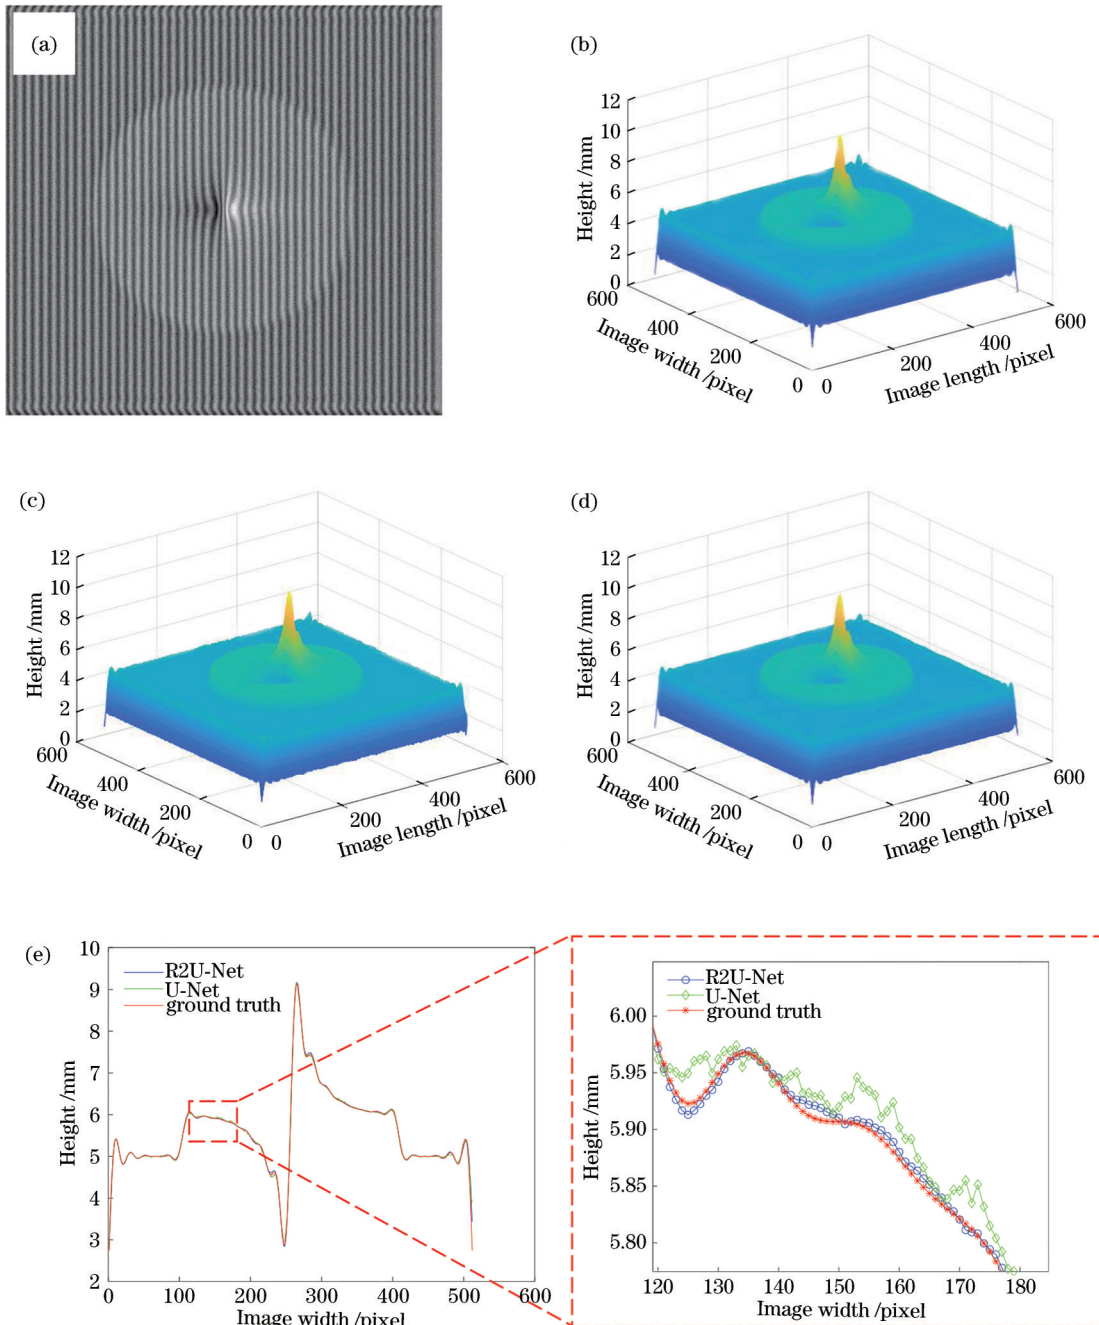


图 10 噪声模拟数据的深度图预测结果。(a) 测试输入的模拟条纹图; (b) 条纹图对应的深度图; (c) U-Net 的预测结果; (d) R2U-Net 的预测结果; (e) 预测结果第 270 行数据的对比

Fig. 10 Depth map prediction result of noise simulated data. (a) Simulated fringe pattern of test input; (b) depth map corresponding to fringe pattern; (c) prediction result of U-Net; (d) prediction result of R2U-Net; (e) comparison of 270th row of prediction result

图 11 为所提方法与 FTM 方法在噪声模拟数据上的对比。对比实验采用的模拟条纹图为 [图 10(a)], R2U-Net 与 FTM 方法所得的结果误差 MSE 分别为 2.64×10^{-3} 和 9.40×10^{-2} , 其中 [图 11(a)] 为条纹图对应的深度图, [图 11(b)] 和 [图 11(c)] 分别为 R2U-Net 与

FTM 对应的深度图, [图 11(d)] 为这两种方法第 270 行数据的结果。从图中可以看出,对于噪声数据 FTM 方法得到结果噪声较大,所提方法得到的深度图误差更小,结果更准确。

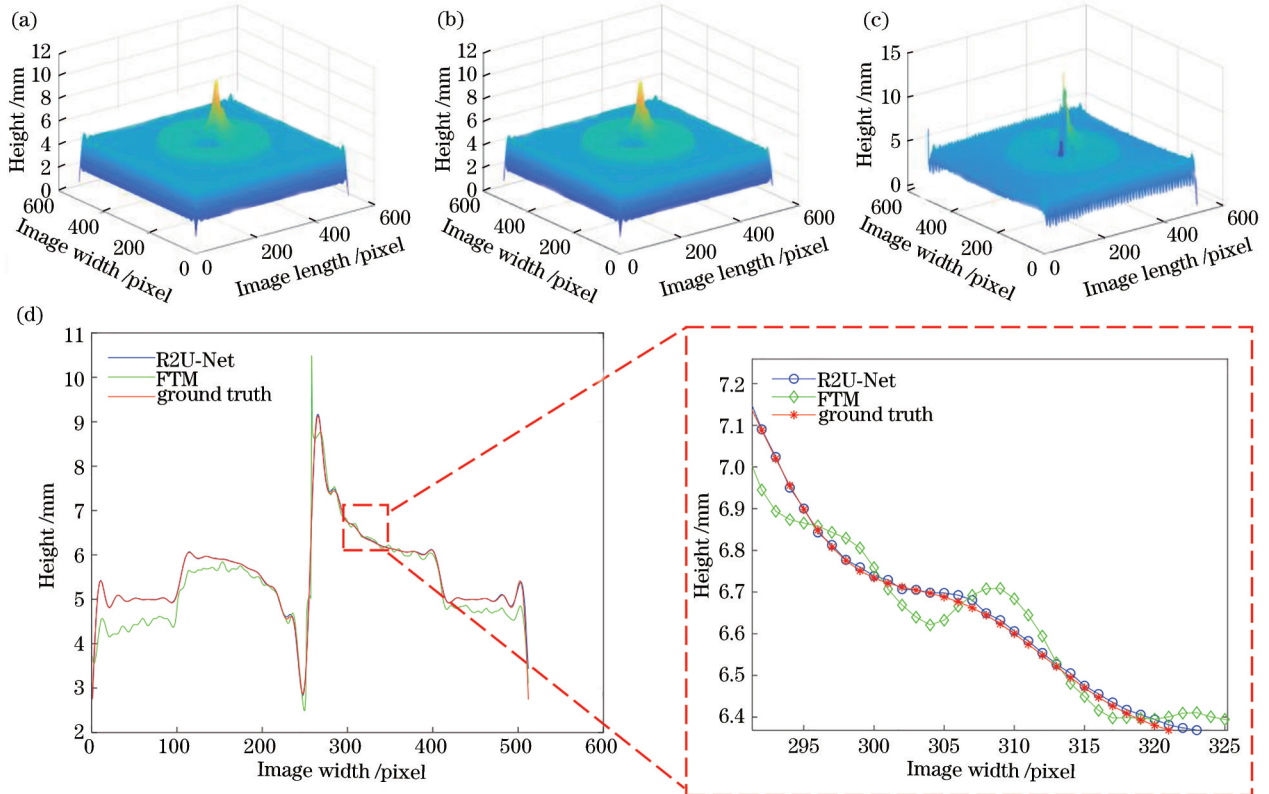


图 11 R2U-Net 方法与 FTM 方法的对比 (噪声数据)。(a) 条纹图对应的深度图; (b) R2U-Net 的预测结果; (c) FTM 的结果; (d) 预测结果第 270 行数据的对比

Fig. 11 Comparison of R2U-Net method and FTM method (Noise simulation data). (a) Depth map corresponding to fringe pattern; (b) prediction result of R2U-Net; (c) result of FTM; (d) comparison of 270th row of prediction result

3.2 实验验证

为了测试所提算法在真实数据下的性能,进一步在实验数据^[23]上进行验证,所有深度图在深度方向统一放大 4.4 倍。图 12 显示了验证时所采用的部分条纹图像和相对应的深度图。训练集共 540 组数据,进行

数据增强操作后至 1620 组,训练次数为 250 次,初始学习率设定为 1×10^{-4} 并分别在训练第 201 次和 241 次衰减至 1×10^{-5} 和 1×10^{-6} 。R2U-Net 和 U-Net 两种方法的训练时间分别约为 20 h 和 12 h。

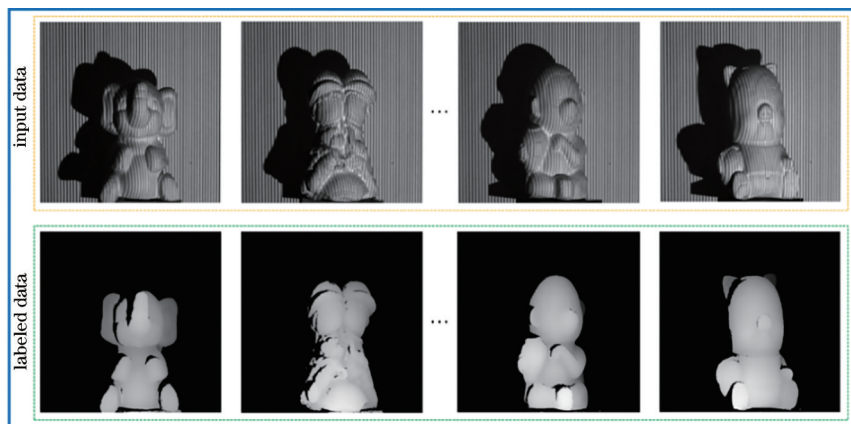


图 12 实验训练数据集

Fig. 12 Experimental training dataset

完成训练后,采用 72 个测试样本对两种网络的学习能力进行测试,将两种模型的测试结果与标签数据做误差分析。测试的结果误差如图 13 所示,R2U-Net

方法的误差低于 U-Net 方法,U-Net 和 R2U-Net 两种模型得到的深度图误差分别为 1.24×10^{-3} 和 1.08×10^{-3} 。

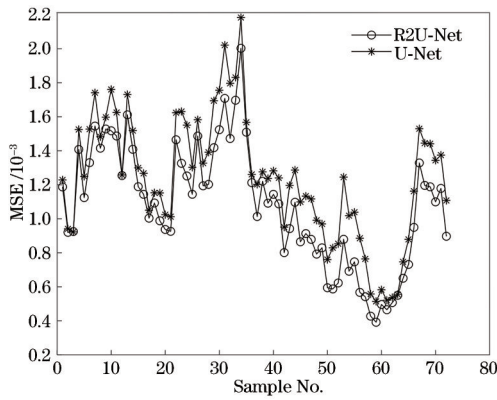


图 13 R2U-Net 和 U-Net 在实验测试样本下的误差

Fig. 13 Error of R2U-Net and U-Net under experimental testing samples

为了进一步评价两种模型对于实验数据计算重建的三维形状误差,在分析中增加使用了两种评价方法,即 MAE 和 SSIM,分析结果如表 2 所示,其中 SSIM 越高代表预测的深度图与标签越相似。从使用的三种评价方法可以看出,R2U-Net 方法的预测精度高于 U-Net 方法。

图 14 为某一实验样本的测试结果,其中[图 14(a)]是测试输入的实验条纹图,[图 14(b)]是该条纹图对应的深度图,[图 14(c)]和[图 14(d)]分别为 U-Net 与

表 2 模型的性能评估

Table 2 Performance evaluation of the two models

Model	MAE	SSIM	MSE
U-Net	8.62×10^{-3}	0.98495	1.24×10^{-3}
R2U-Net	7.12×10^{-3}	0.98775	1.08×10^{-3}

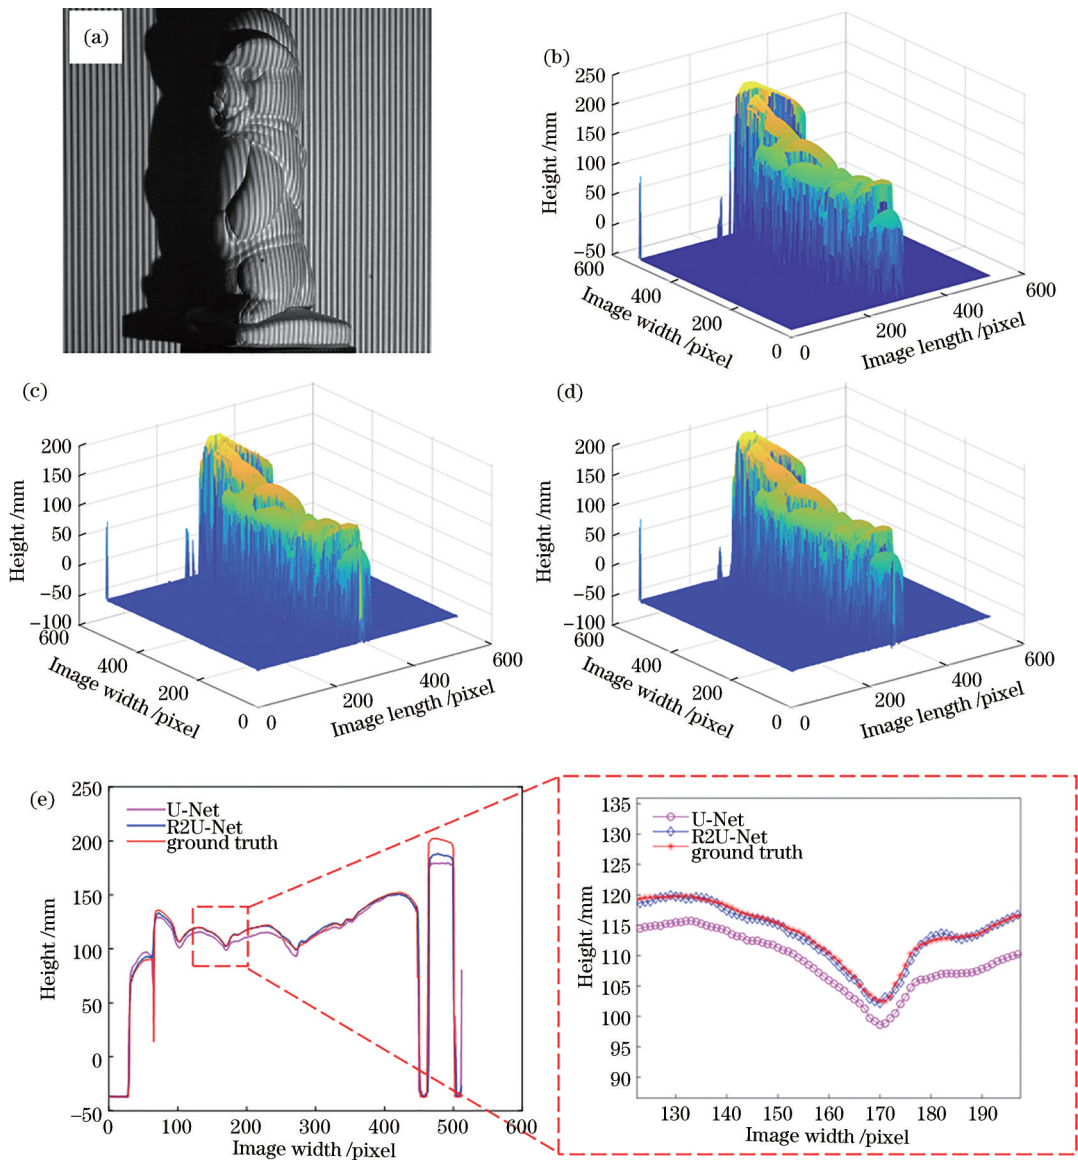


图 14 实验样本的深度图预测结果。(a)测试输入的模拟条纹图;(b)条纹图对应的深度图;(c) U-Net 的预测结果;(d) R2U-Net 的预测结果;(e)预测结果第 310 行数据的对比

Fig. 14 Depth map prediction result of experimental sample. (a) Experimental fringe pattern of test input; (b) depth map corresponding to fringe pattern; (c) prediction result of U-Net; (d) prediction result of R2U-Net; (e) comparison of 310th row of prediction result

R2U-Net从该条纹图到深度图的预测结果,[图 14(e)]为此两种方法第 310 行数据的结果。R2U-Net方法的曲线较 U-Net方法与标签数据的拟合程度更高,与在模拟数据上的表现一致。

图 15 为测试集中另一实验样本的测试结果,其中[图 15(a)]是测试输入的实验条纹图,[图 15(b)]是该

条纹图对应的深度图,[图 15(c)]和[图 15(d)]分别为 U-Net 与 R2U-Net 从该条纹图到深度图的预测结果,[图 15(e)]为此两种方法第 320 行数据的结果。从结果可以看出,与 U-Net 方法相比,R2U-Net 方法的曲线与标签数据的拟合程度更好,验证了所提方法的有效性。

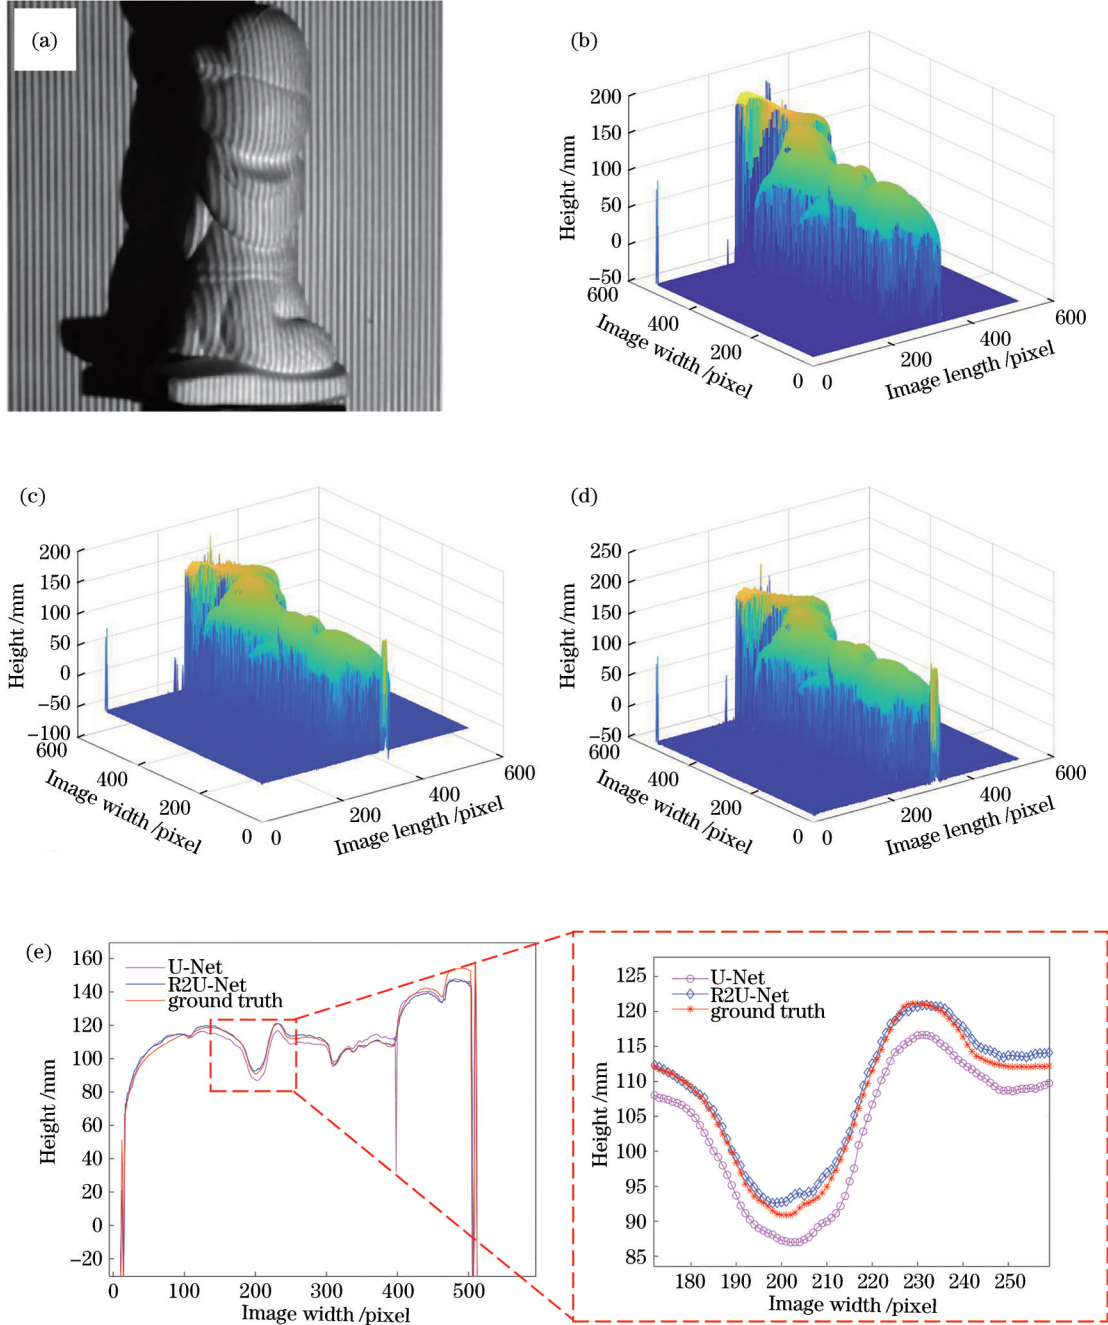


图 15 第二个实验样本的深度图预测结果。(a)测试输入的模拟条纹图;(b)条纹图对应的深度图;(c) U-Net 的预测结果;(d) R2U-Net 的预测结果;(e)预测结果第 320 行数据的对比

Fig. 15 Depth map prediction result of the second experimental sample. (a) Simulated fringe pattern of the test input; (b) depth map corresponding to fringe pattern; (c) prediction result of U-Net; (d) prediction result of R2U-Net; (e) comparison of 320th row of prediction result

4 结 论

提出了一种基于深度学习实现物体深度图获取的

方法,该方法通过 R2U-Net 学习输入的单帧条纹图案和输出期望深度信息之间的映射。在训练过程中训练数据进行了数据增强操作,首先在模拟数据上进行实

验然后在实验数据上进行验证。所提方法在模拟数据上得到的深度图误差为 1.71×10^{-6} , 小于 U-Net 方法对应的误差 7.98×10^{-6} , 在实验数据上预测的深度图与标签的误差比 U-Net 方法对应的误差降低了 13%。实验结果表明, 与已有的利用 U-Net 解决该方法的方法相比, 所提方法预测的深度信息具备更高的精度, 提高了单帧条纹图三维测量结果的准确性。所提方法只需单帧条纹图即可实现更高精度深度估计, 因此可有效用于动态条纹投影三维测量领域, 更好地满足科学研究和实际应用中的动态物体 3D 形状测量需求。下一步将继续研究所提方法在其他更多实验场景下的有效性, 比如彩色物体、高光物体以及投影失焦等情况下条纹图深度估计的有效性及精度。另一方面, 模型的泛化能力是深度学习普遍存在的难题, 也是接下来工作中对所提方法进行改进需要关注的重点问题。

参 考 文 献

- [1] 卢荣胜, 史艳琼, 胡海兵. 机器人视觉三维成像技术综述[J]. 激光与光电子学进展, 2020, 57(4): 040001.
Lu R S, Shi Y Q, Hu H B. Review of three-dimensional imaging techniques for robotic vision[J]. Laser & Optoelectronics Progress, 2020, 57(4): 040001.
- [2] 张启灿, 苏显渝. 动态三维面形测量的研究进展[J]. 激光与光电子学进展, 2013, 50(1): 010001.
Zhang Q C, Su X Y. Research progress of dynamic three-dimensional shape measurement[J]. Laser & Optoelectronics Progress, 2013, 50(1): 010001.
- [3] 杨帆, 丁晓剑, 曹杰. 基于彩色结构光的自由曲面三维重建方法[J]. 光学学报, 2021, 41(2): 0212001.
Yang F, Ding X J, Cao J. 3D reconstruction of free-form surface based on color structured light[J]. Acta Optica Sinica, 2021, 41(2): 0212001.
- [4] 左超, 张晓磊, 胡岩, 等. 3D 真的来了吗?: 三维结构光传感器漫谈[J]. 红外与激光工程, 2020, 49(3): 0303001.
Zuo C, Zhang X L, Hu Y, et al. Has 3D finally come of age?: an introduction to 3D structured-light sensor[J]. Infrared and Laser Engineering, 2020, 49(3): 0303001.
- [5] 郭文博, 张启灿, 吴周杰. 基于相移条纹分析的实时三维成像技术发展综述[J]. 激光与光电子学进展, 2021, 58(8): 0800001.
Guo W B, Zhang Q C, Wu Z J. Real-time three-dimensional imaging technique based on phase-shift fringe analysis: a review[J]. Laser & Optoelectronics Progress, 2021, 58(8): 0800001.
- [6] 苏显渝, 张启灿, 陈文静. 结构光三维成像技术[J]. 中国激光, 2014, 41(2): 0209001.
Su X Y, Zhang Q C, Chen W J. Three-dimensional imaging based on structured illumination[J]. Chinese Journal of Lasers, 2014, 41(2): 0209001.
- [7] 冯建洋, 谌海云, 石础, 等. 基于结构光技术的高反射表面三维测量[J]. 激光与光电子学进展, 2019, 56(22): 221202.
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.
- [8] 冯世杰, 左超, 尹维, 等. 深度学习技术在条纹投影三维成像中的应用[J]. 红外与激光工程, 2020, 49(3): 0303018.
Feng S J, Zuo C, Yin W, et al. Application of deep learning technology to fringe projection 3D imaging[J]. Infrared and Laser Engineering, 2020, 49(3): 0303018.
- [9] 朱新军, 邓耀辉, 唐晨, 等. 条纹投影三维形貌测量的变分模态分解相位提取[J]. 光学精密工程, 2016, 24(9): 2318-2324.
Zhu X J, Deng Y H, Tang C, et al. Variational mode decomposition for phase retrieval in fringe projection 3D shape measurement[J]. Optics and Precision Engineering, 2016, 24(9): 2318-2324.
- [10] 王霖, 韩旭, 伏燕军, 等. 用于三维测量的快速相位解包裹算法[J]. 应用光学, 2019, 40(2): 271-277.
Wang L, Han X, Fu Y J, et al. Fast phase unwrapping algorithm for 3D measurement[J]. Journal of Applied Optics, 2019, 40(2): 271-277.
- [11] 刘达, 雷振坤, 姜昊, 等. 条纹投影法中抗噪声干扰的相移编码去包裹方法[J]. 光学学报, 2020, 40(23): 2312002.
Liu D, Lei Z K, Jiang H, et al. Anti-noise phase-shift coding unwrapping method in fringe projection profilometry[J]. Acta Optica Sinica, 2020, 40(23): 2312002.
- [12] Zuo C, Feng S J, Huang L, et al. Phase shifting algorithms for fringe projection profilometry: a review[J]. Optics and Lasers in Engineering, 2018, 109: 23-59.
- [13] Zhang S. Absolute phase retrieval methods for digital fringe projection profilometry: a review[J]. Optics and Lasers in Engineering, 2018, 107: 28-37.
- [14] 彭广泽, 陈文静. 基于卷积神经网络去噪正则化的条纹图修复[J]. 光学学报, 2020, 40(18): 1810002.
Peng G Z, Chen W J. Fringe pattern inpainting based on convolutional neural network denoising regularization[J]. Acta Optica Sinica, 2020, 40(18): 1810002.
- [15] Zheng Y, Wang S D, Li Q, et al. Fringe projection profilometry by conducting deep learning from its digital twin[J]. Optics Express, 2020, 28(24): 36568-36583.
- [16] Shi J S, Zhu X J, Wang H Y, et al. Label enhanced and patch based deep learning for phase retrieval from single frame fringe pattern in fringe projection 3D measurement[J]. Optics Express, 2019, 27(20): 28929-28943.
- [17] Qian J M, Feng S J, Tao T Y, et al. Deep-learning-enabled geometric constraints and phase unwrapping for single-shot absolute 3D shape measurement[J]. APL Photonics, 2020, 5(4): 046105.
- [18] Zhang J C, Tian X B, Shao J B, et al. Phase unwrapping in optical metrology via denoised and convolutional segmentation networks[J]. Optics Express, 2019, 27(10): 14903-14912.
- [19] Feng S J, Chen Q, Gu G H, et al. Fringe pattern analysis using deep learning[J]. Advanced Photonics, 2019, 1(2): 025001.
- [20] Spoorthi G E, Gorthi R K S S, Gorthi S. PhaseNet 2.0:

- phase unwrapping of noisy data based on deep learning approach[J]. IEEE Transactions on Image Processing, 2020, 29: 4862-4872.
- [21] 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.
- [22] 张钊, 韩博文, 于浩天, 等. 多阶段深度学习单帧条纹投影三维测量方法[J]. 红外与激光工程, 2020, 49(6): 20200023.
Zhang Z, Han B W, Yu H T, et al. Multi-stage deep learning based single-frame fringe projection 3D measurement method[J]. Infrared and Laser Engineering, 2020, 49(6): 20200023.
- [23] 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.
- [24] Machineni R C, Spoorthi G E, Vengala K S, et al. End-to-end deep learning-based fringe projection framework for 3D profiling of objects[J]. Computer Vision and Image Understanding, 2020, 199: 103023.
- [25] Alom M Z, Yakopcic C, Taha T M, et al. Nuclei segmentation with recurrent residual convolutional neural networks based U-net (R2U-net)[C]//NAECON 2018 - IEEE National Aerospace and Electronics Conference, July 23-26, 2018, Dayton, OH, USA. New York: IEEE Press, 2018: 228-233.
- [26] 殷永凯, 张宗华, 刘晓利, 等. 条纹投影轮廓术系统模型与标定综述[J]. 红外与激光工程, 2020, 49(3): 0303008.
Yin Y K, Zhang Z H, Liu X L, et al. Review of the system model and calibration for fringe projection profilometry[J]. Infrared and Laser Engineering, 2020, 49(3): 0303008.
- [27] 赵文静, 陈文静, 苏显渝. 几种时间相位展开方法的比较[J]. 四川大学学报(自然科学版), 2016, 53(1): 110-117.
Zhao W J, Chen W J, Su X Y. The comparison of several time phase unwrapping methods[J]. Journal of Sichuan University (Natural Science Edition), 2016, 53(1): 110-117.
- [28] Liang M, Hu X L. Recurrent convolutional neural network for object recognition[C]//2015 IEEE Conference on Computer Vision and Pattern Recognition, June 7-12, 2015, Boston, MA. New York: IEEE Press, 2015: 3367-3375.
- [29] Song X B, Li W, Zhou D F, et al. MLDA-net: multi-level dual attention-based network for self-supervised monocular depth estimation[J]. IEEE Transactions on Image Processing, 2021, 30: 4691-4705.