

文章编号 1004-924X(2026)17-2686-14

扩散式相位超分辨率条纹投影三维测量

曹义航, 何 贺, 盖绍彦, 达飞鹏^{*}
(东南大学 自动化学院, 江苏 南京 210096)

摘要: 针对条纹投影轮廓术(Fringe Projection Profilometry, FPP)中条纹/相位数据分辨率受成像硬件限制, 以及现有方法细节恢复不足等问题, 构建了一种扩散式包裹相位超分辨率方法(Phase Diffusion Super-Resolution, PhaseDiffSR)以提高三维重建精度。以残差迁移扩散模型 ResShift 为基础构建相位超分辨率框架, 通过低分辨率条件引导反向去噪过程恢复高分辨率相位分量。考虑到调制度图能够反映条纹对比度和局部相位可靠性, 将低分辨率调制度图作为额外条件输入, 与低分辨率相位分量共同引导反向去噪过程。实验结果表明, 所提方法在不同超分倍率的任务中均取得最优重建效果: 在 $\times 2$ 和 $\times 4$ 任务中, PhaseDiffSR 的包裹相位 MAE 分别为 0.030 9 rad, 0.042 9 rad, 三维点云欧氏距离 RMSE 分别为 0.189 mm, 0.296 mm, 均优于其他对比方法。上述结果表明, PhaseDiffSR 能够有效提高包裹相位超分辨率重建精度, 并将相位层面的精度提升传递至后续三维点云重建结果。

关键词: 条纹投影轮廓术; 包裹相位; 超分辨率; 扩散模型; 三维重建

中图分类号: O436; TP391.41 **文献标识码:** A

doi: 10.3724/OPE.20263417.2686 **CSTR:** 32169.14.OPE.20263417.2686

Fringe projection 3D measurement via diffusion-based phase super-resolution

CAO Yihang, HE He, GAI Shaoyan, DA Feipeng^{*}

(School of Automation, Southeast University, Nanjing 210096, China)

^{*} Corresponding author, E-mail: dafp@seu.edu.cn

Abstract: In fringe projection profilometry (FPP), the resolution of fringe and phase data is constrained by imaging hardware, while existing super-resolution methods remain limited in their ability to recover fine details. To improve three-dimensional reconstruction accuracy, a diffusion-based wrapped-phase super-resolution method, termed Phase Diffusion Super-Resolution (PhaseDiffSR), is proposed. A phase super-resolution framework is constructed on the basis of the residual-shifting diffusion model, ResShift, in which high-resolution phase components are recovered through a low-resolution-condition-guided reverse denoising process. Furthermore, because the modulation map reflects fringe contrast and local phase reliability, the low-resolution modulation map is introduced as an additional condition to jointly guide reverse denoising with the low-resolution phase components. Experimental results demonstrate that PhaseDiffSR achieves superior reconstruction performance across different super-resolution scales. For the $\times 2$ and $\times 4$

收稿日期: 2026-06-01; 修订日期: 2026-06-26.

基金项目: 国家自然科学基金面上项目(No. 62573119); 江苏省重大科技专项资助项目(No. BG2024003); 江苏省前沿引领技术基础研究专项资助项目(No. BK20192004C)

tasks, the mean absolute errors of the reconstructed wrapped phase are 0.0309 rad and 0.0429 rad, respectively, while the root-mean-square errors of the three-dimensional Euclidean distances of the point clouds are 0.189 mm and 0.296 mm, respectively. These results outperform those of the compared methods, demonstrating that PhaseDiffSR effectively enhances the accuracy of wrapped-phase super-resolution and transfers phase-level improvements to subsequent three-dimensional point-cloud reconstruction.

Key words: fringe projection profilometry; wrapped phase; super-resolution; diffusion model; 3D reconstruction

1 引言

条纹投影轮廓术(Fringe Projection Profilometry, FPP)是一种重要的结构光三维测量技术,其凭借非接触、高精度与高效率等特点在工业检测等诸多场景中得到了广泛应用^[1-3]。典型的FPP系统由投影仪与相机组成,投影仪向物体表面投射条纹,相机采集变形条纹图,再经过相位求解、相位展开、系统标定与三维重建,最终可获得物体的三维点云^[1-2]。

包裹相位是FPP三维测量中的关键中间量,其分辨率直接影响三维重建结果。一般而言,高分辨率包裹相位可为后续三维重建提供更丰富的细节信息,进而提升三维点云精度^[4-6]。然而,包裹相位分辨率受相机限制,直接提升相机分辨率会显著增加硬件成本^[1,7]。因此,在不增加硬件成本的前提下,通过算法手段提升FPP中条纹/相位数据的分辨率成为一种可行途径,其中基于深度学习的超分辨率方法逐渐成为该方向的重要研究路线^[8-10]。

围绕FPP中条纹/相位数据的超分辨率重建,现有的深度学习方法大致可分为两类:基于像素级回归损失的方法^[8-9,11-14]与基于生成对抗网络(Generative Adversarial Networks, GANs)的方法^[7]。Yao等^[8]提出了DdBSRN,利用双密集块与多路径结构融合多帧相移信息,输出高分辨率包裹相位,提升了三维重建的精度。Song等^[9]提出了SRPRNet,通过相位移模块和细化超分模块直接从单帧低分辨率条纹恢复高分辨率相位,在单帧结构光三维成像任务中取得较好效果。Wan等^[7]提出了HAFGAN,将GANs引入FPP超分辨率任务,通过生成器与判别器的协同训练增强高频细节,改善了后续的点云重建质量。然而,基于像素级回归损失

的方法容易生成过度平滑的结果,导致高频细节恢复不足^[15];基于生成对抗网络的方法虽能强化细节,但可能引入伪纹理,并伴随训练不稳定、模式崩塌等风险^[16]。

作为深度生成模型的重要分支,扩散模型(Diffusion Models, DMs)近些年来在图像生成与图像复原等领域得到了广泛应用^[17-20],并已经被引入到超分辨率等低层视觉任务中^[21-22]。Ho等^[17]提出了去噪扩散概率模型(Denoising Diffusion Probabilistic Models, DDPMs),将图像生成任务建模为前向逐步加噪与反向逐步去噪的随机过程,为后续扩散模型的研究奠定了基础。Saharia等^[23]提出了SR3,将DDPMs引入图像超分辨率任务,通过以低分辨率图像为条件的迭代去噪过程实现超分辨率重建。Yue等^[24]提出了ResShift,构建了一种沿着高分辨率—低分辨率残差方向逐步迁移的高效扩散模型,在保证重建性能的同时显著提高了推理效率。扩散模型相比于其他深度生成模型表现出更好的细节恢复效果,并在训练稳定性和复杂分布建模方面表现出更强优势^[18,23]。相比于基于像素级回归损失的方法,扩散模型通过逐步去噪过程恢复相位分量,能够在一定程度上缓解平均化预测造成的细节平滑问题,从而提高边缘和复杂区域的恢复效果;相较于基于GANs的方法,其训练不依赖对抗博弈,通常更稳定且伪纹理更可控^[25]。

基于上述分析,本文提出了一种扩散式包裹相位超分辨率方法PhaseDiffSR。本文引入残差迁移扩散模型ResShift构建相位超分辨率框架,以低分辨率信息为条件输入,通过反向去噪过程预测高分辨率相位分量;进一步地,考虑到调制度图能够反映条纹对比度和局部相位可靠性,本文由低分辨率相移条纹图计算调制度图,并将其

作为额外条件输入,以增强模型的相位恢复能力。为验证所提方法的有效性,本文在 $\times 2$ 和 $\times 4$ 超分辨率任务下,从相位分量、包裹相位、绝对相位以及三维点云多个层面对所提方法与多种对比方法进行评估,并通过有无调制条件、有无自注意力模块的消融实验分析相应因素的作用。实验结果表明,所提方法能够有效提高相位超分辨率重建精度,并改善后续三维重建质量。

本文将残差迁移扩散模型 ResShift 引入 FPP 包裹相位超分辨率任务,构建了一种扩散式相位超分辨率框架;将低分辨率调制图作为额外条件输入,与低分辨率相位分量共同引导反向去噪过程,以增强模型的相位恢复能力;建立了从相位分量、包裹相位、绝对相位到三维点云的完整实验验证流程,与多种经典方法进行了对比,并通过消融实验验证了相应因素的有效性。

2 扩散式包裹相位超分辨率方法

2.1 任务定义

在 FPP 三维测量中,包裹相位是连接变形条纹图与三维点云的关键中间量。本文采用四步相移法计算包裹相位。设第 i 幅相移条纹图在像素 (u, v) 处的灰度值为 $I_i(u, v)$, 则其可表示为:

$$I_i(u, v) = A(u, v) + B(u, v) \cos \left[\varphi(u, v) + \frac{i\pi}{2} \right], \quad (1)$$

其中: $A(u, v)$ 为背景强度, $B(u, v)$ 为条纹调制度, $\varphi(u, v)$ 为待求解的包裹相位, $i=0, 1, 2, 3$ 。

由上述四幅相移条纹图可逐像素求得包裹相位:

$$\varphi(u, v) = \arctan 2 \left[\frac{I_3 - I_1}{I_0 - I_2} \right]. \quad (2)$$

同时,由四步相移条纹图还可计算得到调制度图,其表达式为:

$$B(u, v) = \frac{1}{2} \sqrt{(I_3 - I_1)^2 + (I_0 - I_2)^2}. \quad (3)$$

调制度图用于表征局部条纹对比度强弱,能够在一定程度上反映相位求解结果的可靠性。

由于包裹相位存在 2π 跳变,直接将其作为神经网络的回归对象容易增加模型训练难度并影响相位重建的稳定性。已有基于深度学习的相位解析研究^[26]表明,相比直接预测包裹相位,学

习包裹相位的正余弦分量有利于缓解该问题。因此,本文采用正余弦分量表示包裹相位 $\varphi(u, v)$, 将其转换为双通道形式 $[\sin \varphi(u, v), \cos \varphi(u, v)]$ 。由此,包裹相位超分辨率任务可转化为双通道相位分量的超分辨率任务。设高分辨率相位分量为 x_{HR} , 低分辨率相位分量为 x_{LR} , 将 x_{LR} 经过 Bicubic 上采样到高分辨率尺寸, 记为上采样低分辨率相位分量 y ; 将低分辨率调制度图 $B(u, v)$ 归一化至 $[0, 1]$ 后, 再经 Bicubic 上采样至高分辨率尺寸, 记为上采样低分辨率调制度图 m 。本文的目标是在给定 y 和 m 的条件下, 恢复高分辨率相位分量, 即

$$\hat{x}_{\text{HR}} = F_{\theta}(y, m), \quad (4)$$

其中: $F_{\theta}(\cdot)$ 表示本文所构建的相位超分辨率映射模型, θ 为模型的可学习参数。得到高分辨率相位分量后, 可通过反正切运算 $\arctan 2(\cdot)$ 计算得到高分辨率包裹相位。随后, 高分辨率包裹相位可用于后续相位展开和三维重建。

2.2 扩散过程建模

在相位超分辨率任务中, 低分辨率相位分量已经包含了目标高分辨率相位分量的主要结构信息, 因此无需像 DDPMs^[17] 那样从纯高斯噪声出发进行重建。本文采用残差迁移扩散模型 ResShift^[24], 使前向扩散过程中的带噪状态在残差迁移约束下由高分辨率相位分量逐步接近上采样后的低分辨率相位分量; 在反向去噪过程中, 去噪网络以低分辨率相位分量和低分辨率调制度图作为条件输入, 预测高分辨率相位分量。前向扩散过程与反向去噪过程如图 1 所示(为了方便观察, 在图 1 和图 2 中, 相位分量均显示为其相应的包裹相位)。

前向扩散过程从高分辨率相位分量 x_{HR} 出发, 将其作为扩散时间步 $t=0$ 时的初始状态 x_0 。定义高分辨率相位分量与上采样低分辨率相位




图 1 PhaseDiffSR 的前向扩散与反向去噪过程

Fig. 1 Forward diffusion and reverse denoising process of PhaseDiffSR

分量的残差为:

$$e = y - x_0. \quad (5)$$

引入残差迁移系数 $\eta_t, t=1, \dots, T$, 其中 $\eta_1 \rightarrow 0, \eta_T \rightarrow 1$, 并令:

$$\alpha_1 = \eta_1, \alpha_t = \eta_t - \eta_{t-1}, (t=2, \dots, T). \quad (6)$$

则前向扩散过程中不同时间步的带噪状态 x_t 的边缘分布可表示为:

$$q(x_t | x_0, y) = \mathcal{N}(x_t; x_0 + \eta_t e_0, \kappa^2 \eta_t I), \quad (7)$$

其中: κ 为控制噪声强度的超参数。由上式可知, 随着时间步 t 增大, x_t 的均值由高分辨率相位分量 x_0 逐渐向低分辨率相位分量 y 迁移, 并同时叠加一定程度的高斯噪声。最终状态 x_T 接近低分辨率相位分量 y 而非纯高斯噪声。

反向去噪过程的目的是在给定条件输入的前提下, 由 x_T 逐步恢复高分辨率相位分量 x_0 。条件输入为扩散模型的反向去噪过程提供先验约束, 其信息完备性直接影响模型对目标结果的恢复能力。现有基于扩散模型的图像超分辨率方法通常将低分辨率图像作为条件输入, 使反向去噪过程在其约束下逐步恢复高分辨率图像。然而, 与自然图像超分辨率任务不同, FPP 相位超分辨率任务中的低分辨率相移条纹不仅能够用于计算低分辨率相位分量, 还能够进一步计算得到低分辨率调制度图。调制度图表征了局部条纹对比度的空间分布, 能够为相位超分辨率任务提供与局部观测质量相关的先验信息。基于此, 本文将低分辨率调制度图作为额外条件输入, 使反向去噪过程不仅受到低分辨率相位结构信息的约束, 还能够感知局部条纹对比度差异, 从而为高分辨率相位分量恢复提供更充分的条件信息。具体而言, 本文将上采样低分辨率相位分量 y 与上采样低分辨率调制度图 m 在通道维度进行拼接, 共同构成三通道条件输入 $c = [y, m]$ 。其中, y 提供低分辨率相位结构约束, m 提供局部条纹对比度分布信息。基于该条件输入, 单步反向去噪过程可建模为:

$$p_\theta(x_{t-1} | x_t, c) = \mathcal{N}\left(x_{t-1}; \mu_\theta(x_t, c, t), \kappa^2 \frac{\eta_{t-1}}{\eta_t} \alpha_t I\right). \quad (8)$$

在本文中, 去噪网络 $f_\theta(\cdot)$ 用于预测高分辨率相位分量 x_0 , 其输出可表示为:

$$\hat{x}_0 = f_\theta(x_t, c, t), \quad (9)$$

其中: x_t 表示当前时间步的带噪状态, c 表示条件输入, t 表示扩散时间步。

基于该预测结果, 单步反向去噪过程的均值项可重参数化为:

$$\mu_\theta(x_t, c, t) = \frac{\eta_{t-1}}{\eta_t} x_t + \frac{\alpha_t}{\eta_t} f_\theta(x_t, c, t). \quad (10)$$

因此, 在推理阶段, 首先从接近低分辨率相位分量的分布中采样状态 x_T , 随后按照上述反向去噪过程逐步迭代更新, 最终得到高分辨率相位分量预测结果。综上所述, PhaseDiffSR 并非直接一步得到超分辨率结果, 而是在条件输入的约束下逐步恢复高分辨率相位分量, 再经过反正切运算得到包裹相位。

2.3 去噪网络架构

去噪网络是 PhaseDiffSR 反向去噪过程中的核心预测模块, 用于在条件输入约束下, 由当前带噪状态预测高分辨率相位分量, 进而实现单步反向去噪过程的状态转移。

去噪网络的输入包括当前时间步的带噪状态 x_t , 条件输入 c 以及当前时间步 t , 输出高分辨率相位分量预测结果。在去噪网络的开端, 将 x_t 与 c 在通道维度进行拼接, 并送入后续网络进行特征提取与重建。该方式能够在网络起始阶段引入低分辨率相位结构信息与局部条纹对比度分布信息, 使反向去噪过程始终受到低分辨率条件的约束。

去噪网络整体上属于 U-Net 式编码器—解码器结构^[27], 主要由输入卷积层、编码器路径、中间瓶颈层、解码器路径以及输出卷积层组成。输入端拼接后的特征 $[x_t, c]$ 首先经过输入卷积层映射到高维特征空间; 编码器路径通过多尺度残差块和下采样操作逐步降低特征图分辨率并扩大网络感受野, 以提取不同尺度下的相位结构特征; 中间瓶颈层在低分辨率特征空间中进一步进行深层特征建模; 在解码阶段, 网络通过上采样操作逐步恢复特征图分辨率, 并利用跳跃连接将编码阶段对应尺度的浅层特征与当前解码特征进行拼接, 从而融合低层细节信息与高层语义信息; 最后, 输出卷积层将解码后的特征映射为双通道高分辨率相位分量预测结果。通过这种多尺度编码器—解码器结构, 去噪网络能够在保持整体相位结构一致性的同时, 提高局部细节的重

建能力。其整体架构如图 2 所示。

去噪网络主要由时间步调制残差块 ResBlock 和移动窗口自注意力模块 SwinBlock 构成,

其中 ResBlock 用于提取不同时间步下的局部相位特征, SwinBlock 用于建模相位分量中的空间上下文关系。




图 2 PhaseDiffSR 的去噪网络架构

Fig. 2 Denoising network architecture of PhaseDiffSR

2.3.1 时间步调制残差块

为了在反向去噪过程中有效建模不同时间步下的特征表示,本文采用时间步调制残差块 ResBlock 作为去噪网络中的基础特征提取单元。该模块以残差学习结构为基础^[28],通过卷积操作进行局部特征建模,利用残差连接缓解深层网络训练过程中的梯度传播问题。与普通残差块不同,去噪网络中的 ResBlock 进一步引入扩散时间步信息,使网络能够根据不同时间步下的噪声水平自适应调整特征表示,提高高分辨率相位分量预测的稳定性。

具体而言,扩散时间步 t 首先经过正余弦位置编码,并通过多层感知机映射为时间步嵌入向量^[17]。在 ResBlock 内部,时间步嵌入向量被映射为缩放参数和偏移参数,用于对归一化后的中间特征进行仿射调制^[18]:

$$h' = \text{Norm}(h) \cdot (1 + s) + b, \quad (11)$$

其中: h 表示 ResBlock 的中间特征, s, b 分别表示由时间步嵌入生成的缩放参数和偏移参数, h' 表示经时间步嵌入仿射调制后的特征,用于在后续计算中注入当前扩散时间步的信息,使 ResBlock 能够根据不同噪声水平自适应调整特征响应。

2.3.2 移动窗口自注意力模块

为了增强去噪网络对空间依赖关系和局部结构信息的建模能力,去噪网络在部分低分辨率特征层中嵌入了基于 Swin Transformer^[29] 的移动窗口自注意力模块 SwinBlock。该模块首先将特征图划分为多个局部窗口,并在窗口内部计算多头自注意力;随后通过移动窗口机制实现相邻窗口之间的信息交互,从而在控制计算复杂度的同时扩大特征建模范围。相比全局自注意力,移动窗口自注意力有助于网络捕获相位数据中的局部周期结构与空间上下文信息,进而提高高分辨率相位分量的预测能力^[30]。

3 实验系统与评价方法

3.1 实验系统与数据集构建

本文基于实际 FPP 系统采集数据构建包裹相位超分辨率数据集。实验系统由数字投影仪、工业相机组成,其中投影仪型号为 DLP Light-Crafter 4500,分辨率为 912×1140 像素;工业相机型号为 Basler acA1600-20um,分辨率为 1626×1236 像素。实验过程中,投影仪向被测物体表面投射四步相移条纹图,相机同步采集经

物体表面调制后的变形条纹图。

为构建不同超分倍率下的低分辨率—高分辨率数据对,首先将相机采集到的原始变形条纹图裁剪为 800×800 像素,并将其作为高分辨率数据。随后,采用Bicubic下采样分别将其降采样为 400×400 像素和 200×200 像素,对应构建 $\times 2$ 和 $\times 4$ 超分辨率任务下的低分辨率数据。对于各分辨率下的四步相移条纹图,均采用四步相移法计算包裹相位正余弦分量,并将其组织为双通道相位分量数据。低分辨率调制度图也由相应分辨率的四步相移条纹图计算得到。考虑到无效区域可能对网络训练和指标统计产生干扰,本文根据调制度图构建有效区域掩码,并对无效区域的相位分量进行置零处理。最终得到的相位分量数据范围为 $[-1, 1]$ 。本文选取诸多典型石膏雕像作为实验对象,包括大卫头像、拉奥孔头像、凯撒头像等,不同雕像在表面形貌上具有明显差异。本文通过对已有诸多石膏雕像的不同视角进行拍摄,共构建100组有效样本,其中90组用于模型训练,剩余10组作为评估数据,用于训练过程中的性能监控以及最终实验结果统计。为直观展示数据集的典型实验场景,并便于后续误差可视化结果分析,本文选取三组具有代表性的石膏雕像作为主要可视化对象,其平均强度图如图3所示。



图3 实验数据集中三种代表性场景的平均强度

Fig. 3 Mean intensity of three representative scenes in the experimental dataset

3.2 实现细节

本文所提出的PhaseDiffSR基于PyTorch深度学习框架实现,并在单张NVIDIA GeForce RTX 4090 GPU上完成训练与测试。训练过程中采用AdamW优化器,初始学习率为 3×10^{-5} ,最小学习率为 1×10^{-6} ,权重衰减系数为0。模型总训练迭代次数为25 000,前600次迭代采用线性

warmup,随后使用余弦退火策略调整学习率。训练阶段batch size设置为3,评估阶段batch size设置为1。为降低显存占用并提高训练效率,训练过程中启用自动混合精度。扩散模型采用ResShift残差迁移扩散过程,扩散步数设置为25,残差迁移序列采用指数形式, $\kappa=1.0$, $\eta_T=0.99^2$,指数调节参数 $p=0.3$ 。训练损失采用带有效区域掩码的MSE损失,仅在有效相位区域内约束网络输出与高分辨率相位分量参考值之间的差异。本文采用互补格雷码法^[31]进行相位展开,并结合系统标定参数通过三角测量^[32]完成三维重建。本文统计了模型参数量、完整扩散推理过程的FLOPs以及单张图像推理时间。FLOPs按完整采样过程统计,即单步去噪网络前向传播的FLOPs乘以扩散采样步数。本文方法的参数量为9.052 M,在 $\times 2$ 和 $\times 4$ 超分任务下完整推理FLOPs均约为17.896 TFLOPs,平均推理时间分别为1.632 s/image和1.638 s/image。

3.3 对比方法与评价指标

为验证所提方法的有效性,本文选取Bicubic、SRPRNet^[9]、SRCNN^[33]、HAFGAN^[7]、EDSR^[34]作为其余对比方法。本文在相同训练数据、相同评估数据以及相同超分倍率下对各方法进行训练和测试。

本文从相位分量、包裹相位、绝对相位和三维点云四个层面对不同方法进行评估。对于相位分量和包裹相位,采用平均绝对误差MAE、均方误差MSE、均方根误差RMSE和峰值信噪比PSNR作为定量评价指标。为避免无效区域对评价结果产生干扰,所有指标均在有效区域内统计。PSNR的计算公式为:

$$PSNR = 10 \log_{10} \left(\frac{L^2}{MSE} \right), \quad (12)$$

其中: L 表示数据动态范围。对于正余弦相位分量,其取值范围为 $[-1, 1]$,因此 $L=2$;对于包裹相位,其取值范围为 $(-\pi, \pi]$,因此 $L=2\pi$ 。MAE、MSE和RMSE越小,PSNR越大,表示重建结果与高分辨率参考值越接近。对于三维点云,本文计算重建点云与参考点云之间的三维欧氏距离误差和Z方向误差,并分别采用MAE和RMSE进行统计,以评价不同方法对最终三维重建精度的影响。其中,参考点云由高分辨率采集

数据经相同相位展开和三维重建流程得到,用于评价不同超分辨率方法相对于高分辨率测量结果的偏差。除上述定量指标外,本文进一步通过绝对相位误差图和三维点云深度误差图对不同方法进行可视化比较,以验证超分辨率结果对后续相位展开和三维重建的影响。此外,为进一步验证不同方法在实际几何尺寸测量中的表现,本文选取标准阶梯块作为测试对象,并以阶梯块已知台阶间距作为真实尺寸参考,计算不同方法重建点云的测量距离、绝对误差和相对误差。

4 实验结果分析

4.1 对比实验

4.1.1 误差指标分析

为定量评估不同方法在不同超分倍率下的重建性能,本文分别从相位分量、包裹相位以及三维点云三个层面将各方法的误差指标结果进行比较,结果如表 1~表 3 所示。本文中所有表格的最优结果均已加粗。

表 1 为各方法在相位分量上的误差指标。从表 1 可以看出,在相位分量重建层面,PhaseDiffSR 在 $\times 2$ 和 $\times 4$ 超分辨率任务中均取得最优结果。对于 $\times 2$ 任务,所提方法的 MAE、MSE 和 RMSE 分别为 2.17×10^{-2} 、 1.28×10^{-3} 和 $3.43 \times$

10^{-2} ,相比各项指标中的次优结果分别降低了 6.47%、29.28% 和 16.55%。相比于传统插值方法 Bicubic,深度学习方法整体上能够降低相位分量重建误差,其中 HAFGAN 和 EDSR 已表现出较好的恢复能力,但 PhaseDiffSR 进一步取得更低误差和更高 PSNR,说明扩散式恢复过程能够更有效地重建高分辨率相位分量。

在 $\times 4$ 任务中,由于低分辨率输入退化程度进一步加大,各方法的误差均有所上升,重建难度明显增加。尽管如此,所提方法仍在所有评价指标上保持最优,其 MAE、MSE 和 RMSE 分别为 2.86×10^{-2} 、 2.97×10^{-3} 和 5.21×10^{-2} ,相比各项指标中的次优结果分别降低了 22.28%、42.88% 和 25.04%。与 $\times 2$ 任务相比, $\times 4$ 任务中 PhaseDiffSR 相对于次优误差指标的降低幅度更加明显,说明在低分辨率输入退化更严重的情况下,所提方法对高分辨率相位分量的恢复更具优势。

表 2 为各方法在包裹相位上的误差指标。可以看出,PhaseDiffSR 在 $\times 2$ 和 $\times 4$ 任务中仍保持最低误差和最高 PSNR,说明其在相位分量层面的重建优势能够有效传递至包裹相位恢复结果。相比之下传统方法 Bicubic 仅依赖插值重建,难以充分恢复高频相位细节;EDSR 等深度学习方法虽然能够在一定程度上降低包裹相位误差,但其综合表现仍弱于所提方法。在 $\times 4$ 任务中,PhaseDiffSR 的包裹相位 MAE、MSE 和 RMSE 分别为 4.29×10^{-2} rad、 6.70×10^{-3} rad 和 7.80×10^{-2} rad,相比各项指标中的次优结果分别降低了 15.72%、37.38% 和 21.45%,表明在高倍率超分任务下,所提方法能够获得更准确的包裹相位恢复结果。

表 3 为各方法在三维点云上的误差指标,用于进一步评价相位超分辨率结果对最终三维重建精度的影响。可以看出,PhaseDiffSR 在 $\times 2$ 和 $\times 4$ 任务下的三维欧氏距离误差和 Z 方向误差均取得最优结果,这说明所提方法在相位恢复阶段获得的精度提升能够进一步通过相位展开和三维重建流程传递至三维点云结果,从而降低最终三维测量误差。

表 1 不同方法在相位分量上的误差指标

Tab. 1 Error metrics of different methods on phase component

方法	倍率	MAE/ ($\times 10^{-2}$)	MSE/ ($\times 10^{-3}$)	RMSE ($\times 10^{-2}$)	PSNR /dB
Bicubic		3.23	3.65	5.98	30.56
SRPRNet		3.18	3.20	5.50	31.53
SRCNN	$\times 2$	2.79	2.92	5.29	31.77
HAFGAN		2.35	1.89	4.20	33.89
EDSR		2.32	1.81	4.11	34.08
PhaseDiffSR		2.17	1.28	3.43	35.69
Bicubic		5.05	10.22	9.97	26.18
SRPRNet		4.28	6.45	7.76	28.62
SRCNN	$\times 4$	3.94	6.46	7.86	28.35
HAFGAN		3.68	5.28	6.99	29.59
EDSR		3.70	5.20	6.95	29.62
PhaseDiffSR		2.86	2.97	5.21	32.15

表 2 不同方法在包裹相位上的误差指标
Tab. 2 Error metrics of different methods on wrapped phase

方 法	倍率	MAE/($\times 10^{-2}$)	MSE/($\times 10^{-3}$)	RMSE/($\times 10^{-2}$)	PSNR/dB
Bicubic	$\times 2$	3.93	4.70	6.75	39.55
SRPRNet		4.11	5.05	6.88	39.57
SRCNN		3.65	4.26	6.32	40.28
HAFGAN		3.33	3.37	5.60	41.40
EDSR		3.24	3.12	5.38	41.73
PhaseDiffSR		3.09	2.45	4.72	42.90
Bicubic	$\times 4$	6.37	21.24	14.31	33.03
SRPRNet		5.66	12.91	10.91	35.72
SRCNN		5.50	13.59	11.31	35.22
HAFGAN		5.16	11.31	10.19	36.34
EDSR		5.09	10.70	9.93	36.53
PhaseDiffSR		4.29	6.70	7.80	38.61

表 3 不同方法在三维点云上的误差指标
Tab. 3 Error metrics of different methods on 3D point clouds

方 法	倍率	三维欧氏距离误差/mm		Z方向误差/mm	
		MAE/($\times 10^{-1}$)	RMSE/($\times 10^{-1}$)	MAE/($\times 10^{-1}$)	RMSE/($\times 10^{-1}$)
Bicubic	$\times 2$	1.23	2.65	1.17	2.51
SRPRNet		1.28	2.63	1.22	2.49
SRCNN		1.13	2.43	1.08	2.31
HAFGAN		1.03	2.13	0.98	2.03
EDSR		1.00	2.06	0.96	1.96
PhaseDiffSR		0.95	1.89	0.91	1.80
Bicubic	$\times 4$	2.02	5.43	1.93	5.13
SRPRNet		1.78	4.16	1.69	3.94
SRCNN		1.73	4.20	1.64	3.98
HAFGAN		1.62	3.87	1.54	3.66
EDSR		1.59	3.74	1.52	3.54
PhaseDiffSR		1.33	2.96	1.27	2.80

具体而言,在 $\times 2$ 任务中,PhaseDiffSR 的三维欧氏距离 MAE 和 RMSE 分别为 0.095 mm 和 0.189 mm,Z 方向 MAE 和 RMSE 分别为 0.091 mm 和 0.18 mm,均低于其他方法。在 $\times 4$ 任务中,各方法点云误差均明显增大,但所提方法仍保持最低误差,其三维欧氏距离 RMSE 和 Z 方向 RMSE 分别为 0.296 mm 和 0.28 mm。上述结果表明,在较高超分倍率下,所提方法仍能够获得更稳定的三维重建结果。

4.1.2 误差可视化分析

为进一步观察不同方法在相位展开结果上

的误差分布,本文对 $\times 2$ 和 $\times 4$ 任务下不同方法的绝对相位误差进行可视化比较,结果如图 4 和图 5 所示。可以看出,不同方法的绝对相位误差主要集中在物体边缘以及局部细节区域,这些区域对相位分量重建精度更加敏感,更容易在相位展开后形成较明显的误差响应。

在 $\times 4$ 任务中,由于低分辨率输入退化程度更高,各方法的高误差区域相比 $\times 2$ 任务更加明显。相比之下,PhaseDiffSR 在两个超分倍率下均表现出更低的整体误差分布,局部放大区域中的高误差范围相对更小,说明所提方法能够更稳




图4 $\times 2$ 任务中不同方法在不同场景下的绝对相位误差

Fig. 4 Absolute phase errors of different methods in different scenes for the $\times 2$ task




图5 $\times 4$ 任务中不同方法在不同场景下的绝对相位误差



Fig. 5 Absolute phase errors of different methods in different scenes for the $\times 4$ task

定地恢复复杂区域的相位细节。该结果进一步表明 PhaseDiffSR 能够有效提高相位恢复精度。

为进一步验证不同方法对最终三维重建结果的影响,本文对 $\times 2$ 和 $\times 4$ 任务下不同方法的深度误差进行可视化比较,结果如图 6 和图 7 所示。与绝对相位误差分布类似,深度误差主要集中在

物体边缘、轮廓突变以及局部细节区域。

从图 6 和图 7 可以看出,Bicubic 由于仅依赖插值恢复低分辨率相位信息,在局部放大区域中存在较明显的高误差响应,说明简单插值难以充分恢复与三维形貌相关的高频相位细节;EDSR 等深度学习方法能够在一定程度上降低深度误

图 6 $\times 2$ 任务中不同方法在不同场景下的深度误差Fig. 6 Depth errors of different methods in different scenes for the $\times 2$ task图 7 $\times 4$ 任务中不同方法在不同场景下的深度误差Fig. 7 Depth errors of different methods in different scenes for the $\times 4$ task

差,但在物体边缘和复杂结构区域仍存在显著的误差扩散现象,可观察到较明显的高误差区域。

相比之下,PhaseDiffSR在 $\times 2$ 和 $\times 4$ 任务下均表现出更低的深度误差分布,局部放大区域中的高误差范围相对更小。尤其在 $\times 4$ 任务中,低分辨率输入退化程度更高,各方法的深度误差整

体增加,但PhaseDiffSR仍能够有效抑制高误差区域向周围平滑区域扩散,说明所提方法在较强退化条件下仍能保持较好的三维重建稳定性。该结果表明PhaseDiffSR不仅能够提高相位层面的恢复精度,还能够将相位超分辨率带来的精度提升进一步传递至最终三维点云重建结果。

4.2 消融实验

4.2.1 调制度条件的消融实验

为验证低分辨率调制度图作为额外条件输入的有效性,本文在保持网络结构、训练数据和训练参数一致的情况下,通过改变是否引入调制度条件进行消融实验,并在 $\times 2$ 和 $\times 4$ 任务下分别统计了两种情况所对应的相位分量、包裹相位的误差指标,其结果如表 4 和表 5 所示。

表 4 有无调制度条件对相位分量误差指标的影响
Tab. 4 Effect of modulation condition on error metrics of phase components

方法	倍率	MAE/ ($\times 10^{-2}$)	MSE/ ($\times 10^{-3}$)	RMSE/ ($\times 10^{-2}$)	PSNR/ dB
无调制度	$\times 2$	2.38	1.44	3.64	35.15
有调制度		2.17	1.28	3.43	35.69
无调制度	$\times 4$	3.87	4.82	6.71	29.86
有调制度		2.86	2.97	5.21	32.15

表 5 有无调制度条件对包裹相位误差指标的影响
Tab. 5 Effect of modulation condition on error metrics of wrapped phase

方法	倍率	MAE/ ($\times 10^{-2}$)	MSE/ ($\times 10^{-3}$)	RMSE/ ($\times 10^{-2}$)	PSNR/ dB
无调制度	$\times 2$	3.33	2.78	5.07	42.23
有调制度		3.09	2.45	4.72	42.90
无调制度	$\times 4$	5.14	10.47	9.80	36.66
有调制度		4.29	6.70	7.80	38.61

由表 4 可以看出,引入调制度条件后,相位分量重建指标在 $\times 2$ 和 $\times 4$ 任务中均得到改善。对于 $\times 2$ 任务,加入调制度后 MAE, MSE 和 RMSE 分别降低至 2.17×10^{-2} , 1.28×10^{-3} 和 3.43×10^{-2} , 相比于不加调制度的情况分别提升了 8.82%, 11.11% 和 5.77%。对于 $\times 4$ 任务,调制度条件带来的改善更加明显, MAE, MSE 和 RMSE 分别降低了 26.10%, 38.38% 和 22.35%。

表 5 进一步给出了包裹相位的误差指标。可以看出,在由相位分量恢复包裹相位后,调制度条件仍然能够带来稳定的误差降低。尤其

在 $\times 4$ 任务中,加入调制度后包裹相位的 MAE, MSE 和 RMSE 分别降低至 4.29×10^{-2} rad, 6.70×10^{-3} rad 和 7.80×10^{-2} rad。上述结果表明,低分辨率调制度图能够为相位超分辨率任务提供有效的局部条纹对比度信息,使模型在低分辨率相位结构条件之外进一步感知局部退化差异,从而提升高分辨率相位分量及包裹相位的恢复精度。

4.2.2 SwinBlock 的消融实验

为分析 SwinBlock 对相位恢复结果的影响,本文进一步开展了有无 SwinBlock 的消融实验。在无 SwinBlock 设置中,将去噪网络中的 SwinBlock 替换为 ResBlock,其余网络结构、训练数据和训练参数保持一致,实验结果如表 6 和表 7 所示。

表 6 有无 SwinBlock 对相位分量误差指标的影响
Tab. 6 Effect of SwinBlock on error metrics of phase components

方法	倍率	MAE/ ($\times 10^{-2}$)	MSE/ ($\times 10^{-3}$)	RMSE/ ($\times 10^{-2}$)	PSNR /dB
无 SwinBlock	$\times 2$	2.61	1.56	3.84	34.57
有 SwinBlock		2.17	1.28	3.43	35.69
无 SwinBlock	$\times 4$	3.03	3.46	5.62	31.52
有 SwinBlock		2.86	2.97	5.21	32.15

表 7 有无 SwinBlock 对包裹相位误差指标的影响
Tab. 7 Effect of SwinBlock on error metrics of wrapped phase

方法	倍率	MAE/ ($\times 10^{-2}$)	MSE/ ($\times 10^{-3}$)	RMSE/ ($\times 10^{-2}$)	PSNR /dB
无 SwinBlock	$\times 2$	3.33	2.75	5.04	42.27
有 SwinBlock		3.09	2.45	4.72	42.90
无 SwinBlock	$\times 4$	4.56	7.85	8.45	37.96
有 SwinBlock		4.29	6.70	7.80	38.61

可以看出,引入 SwinBlock 后,模型在相位分量和包裹相位两个层面的误差指标均得到改善。在 $\times 2$ 和 $\times 4$ 任务中,含 SwinBlock 的模型均取得更低的 MAE, MSE, RMSE 和更高的 PSNR,说明 SwinBlock 有助于提高高分辨率相位分量的恢

复精度。相比无 SwinBlock 的纯 ResBlock 结构,加入 SwinBlock 后的模型在较高倍率超分辨率任务中仍保持更稳定的重建效果,表明空间上下文建模对复杂相位结构恢复具有一定作用。

4.3 阶梯块真实尺寸测量实验

为进一步验证不同方法在实际几何尺寸测量中的表现,本文在×4 超分辨率任务下选取阶梯块进行尺寸测量实验。具体而言,本文测量阶梯块第一级台阶与第三级台阶之间的距离,并以其标准距离 10 mm 作为参考,计算不同方法重建点云的测量距离、绝对误差和相对误差,结果如表 8 所示。

由表 8 可以看出,PhaseDiffSR 的测量距离为 9.645 mm,最接近 10 mm 标准距离,其绝对误差和相对误差分别为 0.355 mm 和 3.55%,均为各方法中最低。该结果表明,在高倍率超分任务下,所提方法能够获得更接近标准尺寸的三维点云重建结果,进一步验证了 PhaseDiffSR 对实际三维尺寸测量精度的改善作用。

表 8 ×4 任务下不同方法对阶梯块的尺寸测量结果
Tab.8 Dimension measurement results of step block by different methods under the ×4 task

方法	标准距 离/mm	测量距 离/mm	绝对误 差/mm	相对误 差/%
Bicubic	10	9.633	0.367	3.67
SRPRNet		9.630	0.370	3.70
SRCNN		9.638	0.362	3.62
HAFGAN		9.629	0.371	3.71
EDSR		9.636	0.364	3.64
PhaseDiffSR		9.645	0.355	3.55

参考文献:

[1] ZHANG S. High-speed 3D shape measurement with structured light methods: a review[J]. *Optics and Lasers in Engineering*, 2018, 106: 119-131.

[2] FENG S J, ZUO C, ZHANG L, *et al.* Calibration of fringe projection profilometry: a comparative review[J]. *Optics and Lasers in Engineering*, 2021, 143: 106622.

[3] 韩氏,张琛萍,张宗华,等. MEMS 振镜式结构光

5 结 论

本文围绕 FPP 中包裹相位分辨率受限对三维重建精度的影响,构建了基于残差迁移扩散模型 ResShift 的相位超分辨率方法 PhaseDiffSR。该方法以低分辨率相位分量为主要条件输入,并进一步引入低分辨率调制度图作为额外条件输入,通过反向去噪过程恢复高分辨率相位分量。本文从相位分量、包裹相位、绝对相位和三维点云四个层面对重建结果进行了验证。实验结果表明,相比其他对比方法,PhaseDiffSR 在×2 和×4 任务中均取得更低的相位误差和点云误差。在×2 任务中,所提方法的包裹相位 MAE 为 0.030 9 rad,PSNR 为 42.90 dB,三维点云欧氏距离 RMSE 为 0.189 mm;在×4 任务中,包裹相位 MAE 为 0.042 9 rad,PSNR 为 38.61 dB,三维点云欧氏距离 RMSE 为 0.296 mm。消融实验表明,调制度条件和 SwinBlock 均有助于提升相位恢复精度;阶梯块真实尺寸测量实验进一步表明,PhaseDiffSR 在对比方法中取得最低尺寸测量误差。上述结果说明,所提方法能够提升包裹相位超分辨率重建精度,并将相位层面的精度提升有效传递至后续三维点云重建过程。

作者贡献声明:

曹义航:论文构思,方法设计,模型实现,实验设计,实验结果分析,论文初稿写作;
何 贺:实验数据采集,数据集构建与整理;
盖绍彦:论文审核与编辑写作,实验结果讨论;
达飞鹏:研究指导,论文审核与编辑写作,项目管理。

三维重建综述[J]. *光学精密工程*, 2025, 33(7): 1065-1090.


HAN M, ZHANG CH P, ZHANG Z H, *et al.* Review of MEMS vibration-mirror-based 3D reconstruction of structured light[J]. *Optics and Precision Engineering*, 2025, 33(7): 1065-1090. (in Chinese)

[4] ZUO C, HUANG L, ZHANG M L, *et al.* Temporal phase unwrapping algorithms for fringe projection profilometry: a comparative review[J]. *Optics and Lasers in Engineering*, 2016, 85: 84-103.

- [5] 张昂, 孙亚琴, 高楠, 等. 三灰度编码相位展开方法条纹投影轮廓术[J]. *光学 精密工程*, 2022, 30(5): 518-526.
- ZHANG A, SUN Y Q, GAO N, *et al.* Fringe projection profilometry by ternary-gray encoded phase unwrapping method[J]. *Optics and Precision Engineering*, 2022, 30(5): 518-526. (in Chinese)
- [6] WANG B W, CHEN W W, QIAN J M, *et al.* Single-shot super-resolved fringe projection profilometry (SSSR-FPP): 100, 000 frames-per-second 3D imaging with deep learning [J]. *Light: Science & Applications*, 2025, 14: 70.
- [7] WAN C Y, GAI S Y, DA F P. Generative adversarial network for 3D super-resolution in fringe projection profilometry [J]. *Optics & Laser Technology*, 2025, 183: 112324.
- [8] YAO P C, GAI S Y, DA F P. Super-resolution technique for dense 3D reconstruction in fringe projection profilometry [J]. *Optics Letters*, 2021, 46(18): 4442-4445.
- [9] SONG J W, LIU K, SOWMYA A, *et al.* Super-resolution phase retrieval network for single-pattern structured light 3D imaging[J]. *IEEE Transactions on Image Processing*, 2023, 32: 537-549.
- [10] LIU H Y, YAN N, SHAO B F, *et al.* Deep learning in fringe projection: a review [J]. *Neurocomputing*, 2024, 581: 127493.
- [11] YAO P C, GAI S Y, DA F P. Toward real-world super-resolution technique for fringe projection profilometry[J]. *IEEE Transactions on Instrumentation and Measurement*, 2022, 71: 5011908.
- [12] ZHAO Y, ZHU R B, ZHANG K, *et al.* Accurate dynamic 3-D shape measurement based on the fringe pattern super-reconstruction technique [J]. *Measurement*, 2022, 200: 111575.
- [13] XUE Y L, ZHAO Y, HAN J, *et al.* Adaptive-resolution-based high-resolution indoor 3D perceiving in fringe projection profilometry [C]. *International Conference on Optical and Photonic Engineering (icOPEN 2023)*. November 27-December 1, 2023, Singapore. SPIE, 2024: 35.
- [14] YANG Y F, TAI Y C, HUANG Z Z, *et al.* Structured light residual channel attention network for super-resolution enhancement of 3D measurement images[J]. *Applied Optics*, 2025, 64(10): 2570.
- [15] LEDIG C, THEIS L, HUSZÁR F, *et al.* Photo-realistic single image super-resolution using a generative adversarial network [C]. *2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. July 21-26, 2017, Honolulu, HI, USA. IEEE, 2017: 105-114.
- [16] SALIMANS T, GOODFELLOW I, ZAREMBA W, *et al.* Improved techniques for training GANs [EB/OL]. 2016; *arXiv*: 1606.03498. <https://arxiv.org/abs/1606.03498>.
- [17] HO J, JAIN A, ABBEEL P. Denoising diffusion probabilistic models [EB/OL]. 2020; *arXiv*: 2006.11239. <https://arxiv.org/abs/2006.11239>.
- [18] DHARIWAL P, NICHOL A. Diffusion models beat GANs on image synthesis [EB/OL]. 2021; *arXiv*: 2105.05233. <https://arxiv.org/abs/2105.05233>.
- [19] LUGMAYR A, DANELLJAN M, ROMERO A, *et al.* RePaint: inpainting using denoising diffusion probabilistic models [C]. *2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*. June 18-24, 2022, New Orleans, LA, USA. IEEE, 2022: 11451-11461.
- [20] KAWAR B, ELAD M, ERMON S, *et al.* Denoising diffusion restoration models [C]. *Advances in Neural Information Processing Systems 35*. November 28-December 9, 2022. New Orleans, Louisiana, USA. Neural Information Processing Systems Foundation, Inc. (NeurIPS), 2022: 23593-23606.
- [21] HE C M, SHEN Y Q, FANG C Y, *et al.* Diffusion models in low-level vision: a survey [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2025, 47(6): 4630-4651.
- [22] GENDY G, HE G H, SABOR N. Diffusion models for image super-resolution: State-of-the-art and future directions [J]. *Neurocomputing*, 2025, 617: 128911.
- [23] SAHARIA C, HO J, CHAN W, *et al.* Image super-resolution via iterative refinement [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2023, 45(4): 4713-4726.
- [24] YUE Z S, WANG J Y, LOY C C. ResShift: efficient diffusion model for image super-resolution by residual shifting [C]. *Advances in Neural Information Processing Systems 36*. December 10-16, 2023. New Orleans, Louisiana, USA. Neural Information Processing Systems Foundation, Inc. (NeurIPS), 2023: 13294-13307.

- [25] LI H Y, YANG Y F, CHANG M, *et al.* SR-Diff: Single image super-resolution with diffusion probabilistic models [J]. *Neurocomputing*, 2022, 479: 47-59.
- [26] FENG S J, CHEN Q, GU G H, *et al.* Fringe pattern analysis using deep learning [J]. *Advanced Photonics*, 2019, 1(2): 1.
- [27] RONNEBERGER O, FISCHER P, BROX T. U-Net: convolutional networks for biomedical image segmentation [C]. *Medical Image Computing and Computer-Assisted Intervention-MICCAI 2015*. Cham: Springer, 2015: 234-241.
- [28] 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. IEEE, 2016: 770-778.
- [29] LIU Z, LIN Y T, CAO Y, *et al.* Swin transformer: hierarchical vision transformer using shifted windows [C]. 2021 *IEEE/CVF International Conference on Computer Vision (ICCV)*. October 10-17, 2021, Montreal, QC, Canada. IEEE, 2022: 9992-10002.
- [30] LIANG J Y, CAO J Z, SUN G L, *et al.* Swin-IR: image restoration using swin transformer [C]. 2021 *IEEE/CVF International Conference on Computer Vision Workshops (ICCVW)*. October 11-17, 2021, Montreal, BC, Canada. IEEE, 2021: 1833-1844.
- [31] ZHANG Q C, SU X Y, XIANG L Q, *et al.* 3-D shape measurement based on complementary Gray-code light [J]. *Optics and Lasers in Engineering*, 2012, 50(4): 574-579.
- [32] 姬小峰, 李建军, 牛健, 等. 基于双投射结构光系统的多尺度点云融合 [J]. *光学精密工程*, 2025, 33(1): 37-49.
- JI X F, LI J J, NIU J, *et al.* Multi-scale point cloud fusion based on dual-projection structured light system [J]. *Optics and Precision Engineering*, 2025, 33(1): 37-49. (in Chinese)
- [33] DONG C, LOY C C, HE K M, *et al.* Image super-resolution using deep convolutional networks [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2016, 38(2): 295-307.
- [34] LIM B, SON S, KIM H, *et al.* Enhanced deep residual networks for single image super-resolution [C]. 2017 *IEEE Conference on Computer Vision and Pattern Recognition Workshops (CVPRW)*. July 21-26, 2017, Honolulu, HI, USA. IEEE, 2017: 1132-1140.

作者简介:



曹义航(2002—),男,辽宁锦州人,硕士研究生,2024年于南京理工大学获得学士学位,主要从事结构光三维测量及深度学习方面的研究。E-mail: 2451753546@qq.com

通讯作者:



达飞鹏(1968—),博士,教授,博士生导师,1998年于东南大学获得博士学位,主要从事三维测量、三维识别与智能控制等方面的研究。E-mail: dafp@seu.edu.cn