

DOI:10.19651/j.cnki.emt.2313313

# 基于改进 SwinIR 的条纹图去噪方法\*

张伟<sup>1,2</sup> 张俊杰<sup>1</sup> 宋杰<sup>1</sup> 吕圣<sup>1</sup> 王生怀<sup>1</sup>

(1. 湖北汽车工业学院机械工程学院 十堰 442002; 2. 中国工程科技十堰产业研究院 十堰 442003)

**摘要:** 条纹图的去噪处理可以恢复条纹图的边界信息,从而提高条纹图三维测量结果的准确性。为了进一步恢复条纹图的边界信息,提出了一种改进 SwinIR 神经网络的条纹图去噪方法。首先,引入 Inception 模块,对网络中的 RSTB 模块进行结构优化,以提高网络的局部特征提取能力。其次,引入多个残差块到网络整体结构中,缓解网络过深带来的梯度消失的问题。实验采用高密度区域条纹进行去噪性能测试,当噪声水平  $\sigma$  为 50 时,改进 SwinIR 算法的 PSNR 值可达 31.96、SSIM 值为 0.9955、去噪时间为 4.035 s。并且,本文改进 SwinIR 算法与其他 7 种代表性算法进行实验对比,结果显示本文方法在不同噪声水平下,去噪性能均为最优。

**关键词:** 条纹图去噪;深度学习;SwinIR;Inception;残差块

中图分类号: TP391.41 文献标识码: A 国家标准学科分类代码: 520.2060

## Fringe pattern denoising method based on improved SwinIR

Zhang Wei<sup>1,2</sup> Zhang Junjie<sup>1</sup> Song Jie<sup>1</sup> Lyu Sheng<sup>1</sup> Wang Shenghuai<sup>1</sup>

(1. School of Mechanical Engineering, Hubei University of Automotive Technology, Shiyan 442002, China;

2. China Engineering Science and Technology Shiyan Industrial Research Institute, Shiyan 442003, China)

**Abstract:** The denoising process of fringe pattern can recover the boundary information of fringe pattern and thus improve the accuracy of fringe pattern 3D measurement results. In order to recover the boundary information of the fringe pattern as much as possible, a fringe pattern denoising method is proposed to improve the SwinIR neural network. First, the Inception module is introduced and the structure of the RSTB module in the network is optimized to improve the local feature extraction capability of the network. Second, multiple residual blocks are introduced to the overall structure of the network to alleviate the problem of gradient disappearance caused by over-deepening of the network. The de-noising performance was tested by using high-density area stripes. When the noise level is 50, the PSNR value of the improved SwinIR algorithm is 31.96, the SSIM value is 0.9955, and the denoising time is 4.035 s. Moreover, the improved SwinIR algorithm is compared with seven other representative algorithms, and the results show that the denoising performance of this method is optimal at different noise levels.

**Keywords:** fringe pattern denoising; deep learning; SwinIR; Inception; residual blocks

## 0 引言

数字光栅投影三维测量技术是一种非接触式测量技术,其具有高精度、速度快、低成本等优点,所以被广泛应用于产品检测、逆向工程等领域<sup>[1-2]</sup>。数字投影仪将编制好的条纹图投影到被测物体上,经物体外形调制后生成变形条纹,工业相机采集变形条纹并发送给计算机,经参数标定和相位展开,得到物体轮廓信息<sup>[3-4]</sup>。然而,由于客观原因,相机采集到的条纹图存在噪声。为了减少噪声对后续相位提取的影响,在预处理阶段便需要对条纹图进行去噪<sup>[5]</sup>。

传统条纹图去噪方法有空间滤波和频率域滤波<sup>[6]</sup>。

Tounsi 等<sup>[7]</sup>提出了加权的非局部均值滤波 (non-local means, NLM) 算法,为每个领域滤波定义新的投影函数,实现图像块之间的均值方差最小化,从而最大程度保留条纹的边缘信息。Zhou 等<sup>[8]</sup>提出了一种自适应偏微分方程的条纹图去噪方法,利用方位相干性定义了一个新的控制速度函数,最终有选择地对连续和不连续区域进行去噪。Xin 等<sup>[9]</sup>提出一种改进三维块匹配(block-matching and 3D filtering, BM3D) 的条纹图去噪算法,结合卷积的局部特征提取能力,该算法取得非常好的去噪效果。张中华等<sup>[10]</sup>提出了一种条纹图盲去噪的方法,利用主成分分析法估计出

收稿日期:2023-04-09

\*基金项目:国家自然科学基金(51475150,51675167)、教育部人文社科项目(20YJCZH150)、湖北自然科学基金(2020CFB755)项目资助

图像的噪声水平值,再通过高斯滤波进行条纹图去噪。尽管这些基于噪声水平先验模型能获得较好的去噪效果,但是当噪声水平较高时,这些方法的去噪性能大幅度下降。

近些年,深度学习理论逐渐应用于图像去噪领域中<sup>[11-12]</sup>。Yan 等<sup>[13]</sup>通过相关公式仿真获得训练样本数据,解决全息图和散斑去噪问题的同时减少了应用成本且性能稳定。Omar<sup>[14]</sup>利用深度学习对噪声的分类进行学习从而进行去噪。林薇等<sup>[15]</sup>提出了一种基于无监督图像风格转换模型(CycleGAN)的相位条纹图滤波方法,通过网络训练将的原始噪声图像转换为理想无噪声图像“风格”,实现对相位条纹图中噪声的滤除,使得在较短时间内可以完成对噪声的高效滤除。Hao 等<sup>[16]</sup>提出了一种基于 FFDNet(fast and flexible denoising convolutional neural network)神经网络的 ESPI(electronic speckle pattern interferometry)条纹图去噪方法,利用一个可调整的噪声水平图和图像数据集训练网络的权重参数,保证了模型能够处理不同噪声水平的高斯噪声。彭广泽等<sup>[17]</sup>提出了一种条纹图高光区域修复算法,利用 DnCNN(denoising convolutional neural network)网络估计出条纹图的噪声,从而修复高光区域的边界信息。Yan 等<sup>[18]</sup>提出一种由 7 个残差网络组成的条纹图神经网络去噪方法,解决了梯度在反向传播过程中消失的问题。Gurrola 等<sup>[19]</sup>和张伟等<sup>[20]</sup>利用并行卷积网络作为编码层和解码层的基本结构,在编码和解码部分用一个  $3 \times 3$  卷积层连接,获取更多局部细节的同时减少网络的权重参数和网络训练时间。熊巍等<sup>[21]</sup>提出将通道注意力自适应地嵌入 Transformer 变换特征及卷积运算特征,有效

改进网络的学习能力及超分辨率性能。王坤等<sup>[22]</sup>对 U-Net 网络进行改进,通过 Haar 离散小波变换将条纹图像分解为不同分量作为神经网络的输入,使得网络学习噪声图像与条纹噪声之间的映射,最后使用逆 Haar 离散小波变换进行图像重构。

对于现有的条纹图去噪方法不能很好恢复条纹的边界信息,提出了一种改进 SwinIR 的条纹图去噪方法。SwinIR<sup>[23]</sup>网络的局部特征提取能力不足,并且网络结构过深,容易出现梯度消失问题。通过 Inception<sup>[24-26]</sup>模块和残差块<sup>[27-28]</sup>对 SwinIR 网络结构进行优化,以提高网络的去噪能力,从而减少条纹的边界信息丢失。

## 1 改进 SwinIR 的条纹图去噪模型

### 1.1 SwinIR 网络结构

SwinIR 网络结构如图 1 所示,包括 3 部分:第 1 部分,浅层特征提取,由 1 个 Conv 层组成;第 2 部分,深层特征提取,由多个 RSTB(residual swin transformer blocks)模块和 Conv 层组成;第 3 部分,高质量图像重建,由 1 个 Conv 层组成。其中,RSTB 模块的结构如图 2 所示,包含多个 Swin Transformer<sup>[29-30]</sup>层(STL)和 1 个 Conv 层的残差结构。与基于卷积神经网络的条纹图去噪模型相比,基于 Transformer 的 SwinIR 具有以下优势:1)通过 Swin Transformer 层可以对远程依赖进行建模,具有卷积处理大尺寸图像的优势;2)图像信息与注意力权重之间可以实现交互,可以被作为空间变化的卷积。因此,在 SwinIR 网络的基础上,提出一种改进 SwinIR 的条纹图去噪模型。

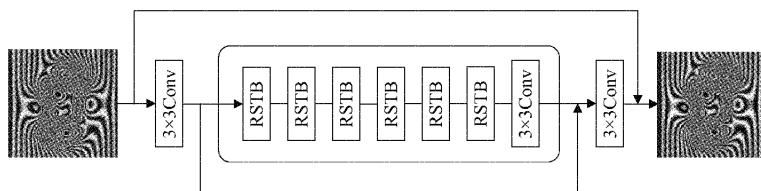


图 1 SwinIR 网络结构

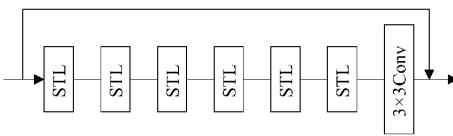


图 2 RSTB 模块

### 1.2 改进的 SwinIR 网络

#### 1) Inception 模块

SwinIR 网络可以对远程依赖进行建模,并且实现图像信息之间交互。然而,网络中的 RSTB 模块利用一个 Conv 层提取图像中的细节信息,导致网络的局部特征提取能力不足。将 RSTB 模块中的 Conv 层替换为 Inception 模块,构建局部增强的 LE-RSTB(locally enhanced RSTB, LE-RSTB)模块,可以获得不同尺度的图像局部信息,从而提

升网络的局部特征提取能力。Inception 模块的结构如图 3 所示,包含 4 条并行卷积线路,前 3 条线路分别使用卷积核大小为  $1 \times 1$ 、 $3 \times 3$  和  $5 \times 5$  的卷积层,第 4 条线路使用平均池化。中间的两条线路首先对输入数据作卷积核为  $1 \times 1$  的卷积运算,减少数据的输入通道数,从而降低模型的复杂度。第 4 条线路平均池化后,接一个卷积核为  $1 \times 1$  的卷积层来改变通道数。为了数据的输出在高(H)和宽(W)维度上保持一致,4 条线路中的卷积都使用合适的填充。最后,将 4 条线路的输出数据在通道维度上拼接起来。

#### 2) 残差块

SwinIR 网络的结构较深,容易出现网络梯度消失问题,从而导致网络的性能下降。为了保证网络的训练精度不会随着网络深度增加降低,在网络整体框架中插入多个

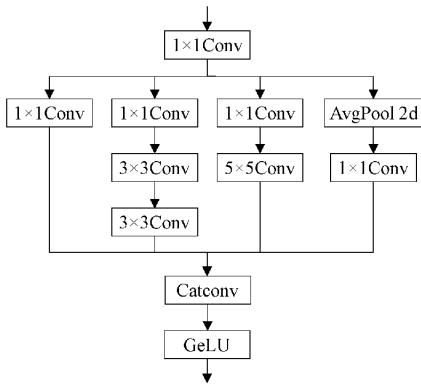


图 3 Inception 模块结构

残差块。残差块将浅层网络的图像特征恒等映射到深层的网络中,保证深层的网络比浅层的网络包含更加丰富的特征信息,同时能捕捉到网络的细微变化。因此,残差块可以加快网络权重的更新,从而缓解网络的梯度消失问题。残差块的结构如图 4 所示,使用跳跃连接将残差值  $x$  和输入值  $F(x)$  相加并求和。

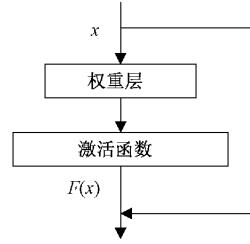


图 4 残差块结构

改进 SwinIR 的条纹图去噪网络如图 5 所示,主要由 LE-RSTB 模块、Conv 层和残差块组成。网络的第 1 层是 1 个卷积核为  $3 \times 3$  的 Conv 层。对图像进行浅层的特征提取,并将输入图像映射到更高维度的特征空间。第 2~8 层为网络的核心部分,包含 6 个 LE-RSTB 模块、1 个卷积核为  $3 \times 3$  的 Conv 层和 4 个残差块,对图像进行深度特征提取。通过 4 个残差块,将网络第 1、2、3 和 4 层的残差分别映射到网络的第 5、6、7 和 8 层,帮助网络的权重参数更新及缓解网络出现梯度消失现象。网络的第 9 层为 1 个卷积核为  $3 \times 3$  的 Conv 层,并且通过残差块学习图像中的噪声。

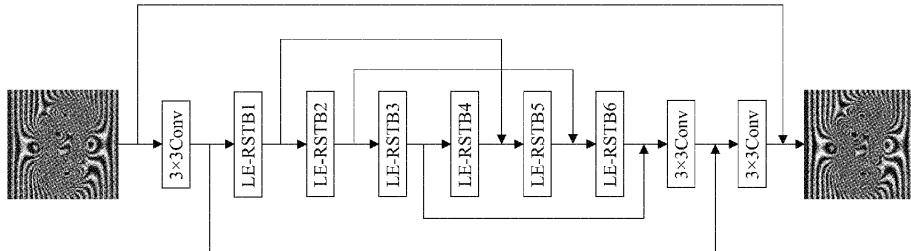


图 5 改进 SwinIR 网络结构

### 1.3 损失函数

基于改进 SwinIR 神经网络的条纹图去噪算法是根据设定好的噪声水平  $\sigma$  建立的,其表达式为:

$$\hat{I}_{RHQ} = F(y, \sigma, \Theta) \quad (1)$$

式中:  $\hat{I}_{RHQ}$  表示经模型去噪的条纹图,  $F$  表示改进 SwinIR 神经网络模型。

对于条纹图去噪,使用 Charbonnier 损失定义网络的损失函数,增加一个正则项  $\epsilon$ ,使得接近零值得梯度不会太小,避免梯度消失。同时,采用 ADAM 优化器来优化网络结构参数,通过损失函数的反向传播,不断更新网络的权重,使得网络达到收敛的状态。模型的损失函数表达式为:

$$\Gamma_{loss} = \frac{1}{2N} \sum_{i=1}^N \sqrt{\|\hat{I}_{RHQ} - I_i\|^2 + \epsilon^2} \quad (2)$$

式中:  $\hat{I}_{RHQ}$  为经模型去噪后的条纹图,  $I_i$  为无噪声条纹图,  $\epsilon$  为正则项,一般设置为  $1 \times 10^{-3}$ 。

### 1.4 条纹图数据集

条纹图一般为正(余)弦条纹,条纹图的灰度值表达式为:

$$g(x, y) = a(x, y) + b(x, y) \cos[2\pi f_0 x + \varphi(x, y)] \quad (3)$$

式中: $a(x, y)$  为背景光强度值,  $b(x, y)$  为调制强度值,  $\varphi(x, y)$  为被测物体高度的调制相位,  $f_0$  为载波频率。调制强度的值一般设置为 1,  $\varphi(x, y)$  使用 MATLAB 中的 peaks 函数, 函数图像如图 6 所示, 其数学表达式为:

$$z = 3(1-x^2)e^{-x^2-(y+1)^2} - 10\left(\frac{x}{5}-x^3-y^5\right)e^{-x^2-y^2} - \frac{1}{3}e^{-(x+1)^2-y^2} \quad (4)$$

$f_0$  的值越大,条纹图的相位移越小,即条纹之间的间隔越小;  $\varphi(x, y)$  的数值越大,即被测物体高度差变化越大,物体对条纹的相对相位变化越大。图 7(a)是未被调制的条纹图,当  $f_0$  和  $\varphi(x, y)$  的系数设置不同的值时,可以生成不同的条纹图。挑选出高密度的条纹图,并对它们进行尺寸调整和灰度化处理,得到像素为  $256 \times 256$  的条纹图,如图 7(b)所示。

### 1.5 数据的预处理

为了加快模型的训练速度和训练数据的多样性,首先,使用滑动的窗口从条纹图中裁取尺寸大小为  $128 \times 128$

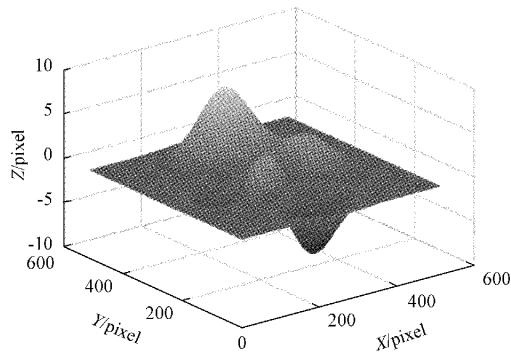


图 6 peak 函数图

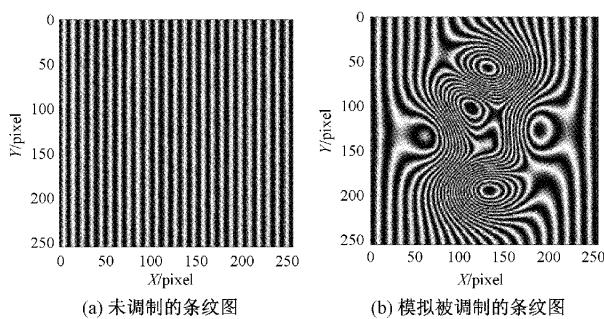


图 7 模型的数据集

pixels 的图像块；然后，将图像块进行一次随机的几何变换，从而达到数据增强的效果，变换方式为旋转 90°、180°、270°，翻转原图像与旋转的图像；最后，根据模型设定的噪声水平  $\sigma=15, 25, 50$ ，选定模型训练的噪声水平，将噪声水平  $\sigma$  生成高斯白噪声，并将高斯白噪声添加到图像块中。

## 2 实验结果

### 2.1 实验参数设定

实验的数据集共 3 050 张条纹图，其中的 3 000 张作为模型的训练集，50 张作为测试集。 $epoch$  为 50，W-MSA 的窗口尺寸大小为  $8 \times 8$ ，训练期间的学习率为 0.000 2。计算机的操作系统为 Windows 10，CPU 配置为 Intel(R) Xeon(R) Gold 6248R CPU @ 3.00 GHz，GPU 为 Nvida GTX3090，运行内存为 16 GB。训练网络模型是基于 Pytorch 框架完成的，使用 GPU 加速模型的训练速度，并用 Pycharm，Python 3.8 对模型进行训练。

### 2.2 评价指标

为了客观评价模型的去噪能力，使用峰值信噪比（peak signal to noise ratio, PSNR）和结构相似性（structural similarity index, SSIM）作为去噪结果的评价指标。

PSNR：表示信号的最大可能功率与信号中存在的噪声功率的比值，单位为 dB，数值越大表示去噪后的图像失真越小，图像去噪的效果越好。表达公式为式(5)所示。

$$PSNR = 10 \lg \left( \frac{(2^n - 1)^2}{MSE} \right) \quad (5)$$

式中： $MSE$  为去噪后的图像与原始图像之间的均方误差，其表达式为式(6)。

$$MSE = \frac{1}{H \times W} \sum_{i=1}^H \sum_{j=1}^W (x(i, j) - y(i, j))^2 \quad (6)$$

式中： $x$  表示原始图像， $y$  表示去噪后的图像， $H$  与  $W$  分别表示图像的高度和宽度。

SSIM：一种用图像的亮度、对比度和结构的组合来衡量两幅图像相似程度的评价指标，符合人类视觉的直观效果，取值区间为 [0, 1]，其表达式为式(7)。

$$SSIM(x, y) = \frac{(2\mu_x\mu_y + c_1)(2\sigma_{xy} + c_2)}{(\mu_x^2 + \mu_y^2 + c_1)(\sigma_x^2 + \sigma_y^2 + c_2)} \quad (7)$$

式中： $\mu_x$  是原图像  $x$  的平均值， $\mu_y$  是去噪后的图像  $y$  的平均值， $\sigma_x^2$  是  $x$  的方差， $\sigma_y^2$  是  $y$  的方差， $\sigma_{xy}$  是  $x$  和  $y$  的协方差。 $c_1=(k_1L)^2$ ,  $c_2=(k_2L)^2$  是用来维持稳定的常数， $L$  是像素值的动态范围， $k_1=0.01$ ,  $k_2=0.01$ 。

### 2.3 实验结果与分析

将从如下 3 个方面进行消融实验：网络的通道数，LE-RSTB 模块中的 Swin Transformer 层 (STL) 数，多头自注意力机制 (MSA) 的 Head 数。并且用测试集检验模型的训练效果，噪声水平  $\sigma$  设置为 50。

当 LE-RSTB 中的  $STL=3$  时，MSA 的  $Head=3$  时，调整网络的通道数。如表 1 所示，网络的去噪能力随着网络的通道数增加而提升；当网络的通道数增至 120 时，网络的去噪能力逐渐趋近于饱和。因此，网络的通道数设置为 120。

表 1 网络的通道数对去噪模型的影响

网络的通道数	PSNR/dB	SSIM
30	28.54	0.985 6
60	29.65	0.987 8
90	30.58	0.989 0
120	31.07	0.989 7
150	31.20	0.989 9
180	31.21	0.990 1

当网络的通道数为 60 时，MSA 的  $Head=3$  时，调整 LE-RSTB 中的 STL 数量。由表 2 可知，网络的去噪能力随着 STL 的数量增加而提升；当  $STL=6$  时，网络的去噪能力逐渐趋近于饱和。因此，将 STL 的数量设置为 6。

当网络的通道数为 60，LE-RSTB 中的  $STL=3$  时，调整 MSA 的 Head 数量。由表 3 可知，网络的去噪能力随着 MSA 的 Head 数量增加而提升；当 MSA 的  $Head=6$  时，网络的去噪能力提升幅度不大。因此，STL 的数量设置为 6。

表 2 LE-RSTB 中的 *STL* 数对去噪模型的影响

LE-RSTB 中的 <i>STL</i> 数	PSNR/dB	SSIM
1	28.5	0.9854
2	29.6	0.9874
4	30.14	0.9883
6	30.66	0.9892
8	30.82	0.9894
10	30.9	0.9895

表 3 MSA 的 *Head* 数对去噪模型的影响

MSA 的 <i>Head</i> 数	PSNR/dB	SSIM
1	29.21	0.9866
2	29.69	0.9875
4	29.95	0.9879
6	30.16	0.9883
8	30.19	0.9884
10	30.22	0.9887

综上可得,通道数、LE-RSTB 中的 *STL* 数量和 MSA 的 *Head* 数量对模型的去噪性能都有一定的影响。为了使模型得到最佳的训练效果,网络的通道数设置为 120,LE-RSTB 中的 *STL* 数量设为 6,MSA 的 *Head* 数量设置为 6。

当噪声水平分别为  $\sigma=15, 25, 50$  时,用测试集检验模型去噪的能力。由图 8(a)、(b)可知,当 epoch 增加至 50 左右时,PSNR 的均值和 SSIM 的均值逐渐趋于稳定值,从而模型的去噪能力也趋于饱和;当噪声水平为  $\sigma=15$  时,模型的 PSNR 均值接近 39 dB;当噪声水平为  $\sigma=50$  时,模型的 PSNR 均值高于 31 dB。由此得出,在不同的噪声水平测试下,训练的网络模型都能取得较好的去噪效果。

本文选取 NLM、BM3D、DnCNN、FFDNet、U-Net、Transformer 和 SWinIR 算法进行横向对比实验。实验选取 1 张条纹图进行去噪性能测试,将改进 SwinIR 算法与上述算法作对比。

如表 4 所示,当  $\sigma=15$  时,改进 SwinIR 算法的 PSNR 提高了 2.90~5.82 dB,SSIM 提高了 0.0014~0.0045;如表 5 所示,当  $\sigma=25$  时,改进 SwinIR 算法的 PSNR 提高了 2.55~6.04 dB,SSIM 提高了 0.0024~0.0092;如表 6 所示,当  $\sigma=50$  时,改进 SwinIR 算法的 PSNR 提高了 2.66~7.35 dB,SSIM 提高了 0.0065~0.0278。

由此可得,在不同的噪声水平下,改进 SwinIR 都取得了较好的去噪效果;并且,当处理含有高噪声水平的噪声条纹图时,改进 SwinIR 算法依旧表现优异。相比于目前较为先进的 U-net 和 Transformer 神经网络,改进 SwinIR 算法虽然在去噪时间上略有增加,但在去噪性能上都取得了明显的提升。

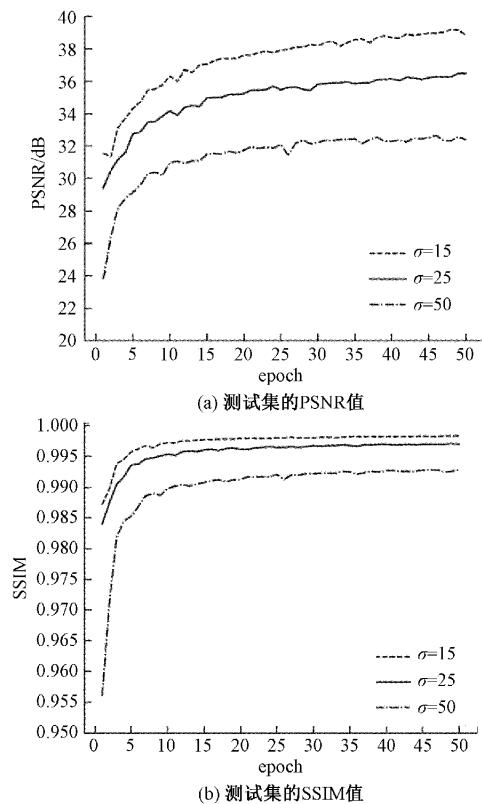


图 8 改进 SwinIR 的测试集结果

表 4  $\sigma=15$  时,不同算法去噪结果对比

算法	PSNR/dB	SSIM	去噪时间/s
NLM	31.09	0.9921	46.129
BM3D	30.55	0.9925	78.750
DnCNN	31.90	0.9944	0.879
FFDNet	32.28	0.9956	0.855
U-Net	32.89	0.9960	2.360
Transformer	33.46	0.9967	3.358
SwinIR	34.82	0.9975	4.787
改进 SwinIR	37.72	0.9989	4.028

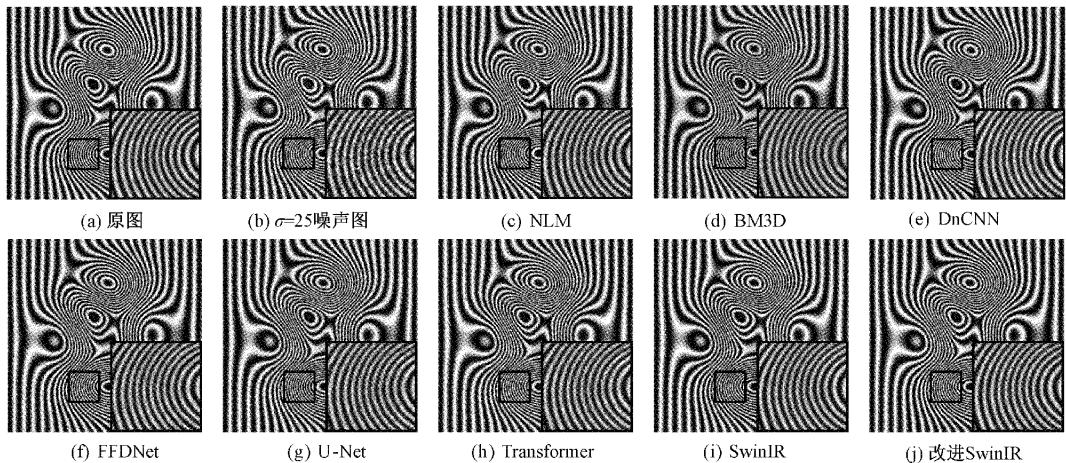
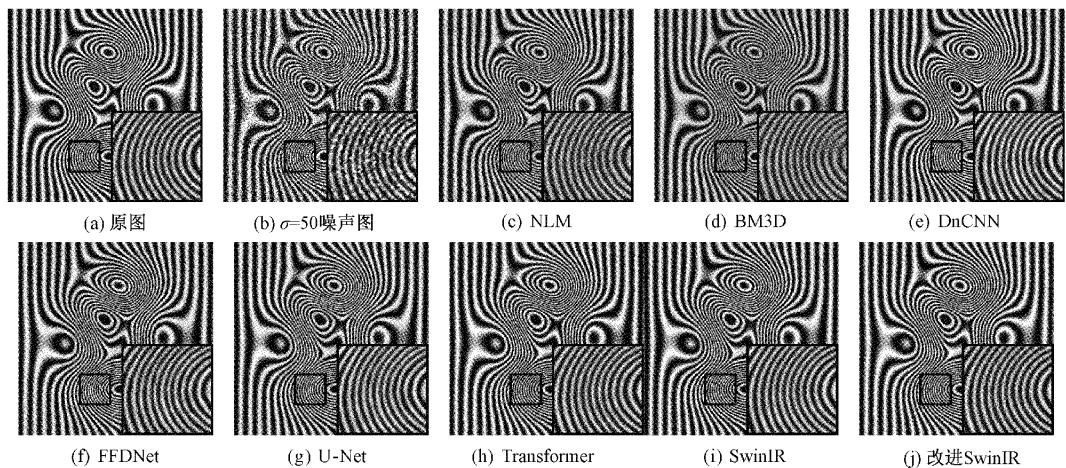
表 5  $\sigma=25$  时,不同算法去噪结果对比

算法	PSNR	SSIM	去噪时间/s
NLM	28.44	0.9837	47.221
BM3D	27.96	0.9850	78.866
DnCNN	28.88	0.9886	0.859
FFDNet	29.92	0.9922	0.867
U-Net	30.58	0.9934	2.423
Transformer	31.15	0.9942	3.367
SwinIR	32.37	0.9954	4.729
改进 SwinIR	34.92	0.9978	4.254

表 6  $\sigma=50$  时, 不同算法去噪结果对比

算法	PSNR	SSIM	去噪时间/s
NLM	22.92	0.9406	46.018
BM3D	22.75	0.9511	78.152
DnCNN	24.34	0.9677	0.857
FFDNet	26.07	0.9803	0.856
U-Net	27.15	0.9819	2.386
Transformer	28.26	0.9845	3.688
SwinIR	29.03	0.9890	4.530
改进 SwinIR	31.69	0.9955	4.035

图 9 和 10 显示了 8 种条纹图去噪算法的视觉效果对比, 图中小矩形表示选取的局部放大区域, 大矩形框则对应为小矩形框放大 3 倍的内容。当噪声水平  $\sigma=25$  时, 由图 9 可以看出, 经 8 种算法去噪后的条纹图边界比较清晰; 其中,

图 9  $\sigma=25$  时, 8 种算法的视觉效果对比图 10  $\sigma=50$  时, 8 种算法的视觉效果对比

### 3 结 论

本文提出了一种改进 SwinIR 网络的条纹图去噪方

图 9(a)、(b) 为原始条纹和  $\sigma=25$  的噪声条纹, 图 9(c)、(d)、(e) 出现轻微的局部模糊, 即 NLM 算法、BM3D 算法和 DnCNN 算法使得条纹图出现轻微局部信息丢失。图 9(f) 使用 FFDNet 算法取得了较好的去噪效果; 图 9(g)、(h) 使用 U-Net 和 Transformer 算法去噪后还有部分噪点残留; 图 9(i)、(j) 使用 SwinIR 和改进 SwinIR 算法均取得了较好的去噪效果。当噪声水平  $\sigma=50$  时, 图 10(a)、(b) 为原始条纹和  $\sigma=50$  的噪声条纹。如图 10(c) 所示, 使用 NLM 算法进行去噪的效果较差; 图 10(d) 的局部模糊严重, 即 BM3D 算法使得条纹图出现严重局部信息丢失; 图 10(e)、(f) 的边界模糊, 即 DnCNN 和 FFDNet 算法使得条纹图出现边界信息丢失; 图 10(g)、(h) 的局部区域依然有模糊存在, 即 U-Net 和 Transformer 算法使得局部放大区域依然有信息丢失; 图 10(i)、(j) 的边界比较清晰, 同时经 SwinIR 和改进 SwinIR 算法处理后的局部条纹都取得很好的去噪效果。

度。最后,使用不同的噪声水平的高斯白噪声创建训练集,利用 PSNR 和 SSIM 进行网络性能评价。由实验可知,当网络的通道数为 120、LE-RSTB 中的 *STL* 数为 6 及 MSA 的 *Head* 数为 6 时,模型的训练效果最佳;改进 SwinIR 算法获得的去噪效果明显优于 NLM、BM3D、DnCNN、FFDNet、U-Net、Transformer 和 SWinIR 等算法;当噪声水平  $\sigma$  为 50 时,相较于原网络,改进 SwinIR 算法的 PSNR 值提高了 2.66 dB,SSIM 值提高了 0.0065。

## 参考文献

- [1] 王建华.光栅投影三维测量关键技术研究[D].西安:西安理工大学,2019.
- [2] 吕深圳.基于数字光栅投影技术的三维面型测量研究[D].长春:中国科学院大学(中国科学院长春光学精密机械与物理研究所),2021.
- [3] 牛小兵,林玉池,赵芙蓉,等.光栅投影三维测量的原理及关键技术分析[J].仪器仪表学报,2001(S2):203-205.
- [4] 王建华,周玉国,杨延西.基于相位误差自校正的高速三维测量技术[J].电子测量与仪器学报,2019,33(12):116-125.
- [5] KULKARNI R, RASTOGI P. Fringe denoising algorithms: A review [J]. Optics and Lasers in Engineering, 2020, 135: 106190.
- [6] KUMAR M, TOUNSI Y, KAUR K, et al. Speckle denoising techniques in imaging systems[J]. Journal of Optics, 2020, 22(6): 063001.
- [7] TOUNSI Y, KUMAR M, NASSIM A, et al. Speckle denoising by variant nonlocal means methods [J]. Applied optics, 2019, 58(26): 7110-7120.
- [8] ZHOU Q, TANG C, LI B, et al. Adaptive oriented PDEs filtering methods based on new controlling speed function for discontinuous optical fringe patterns[J]. Optics and Lasers in Engineering, 2018, 100: 111-117.
- [9] XIN H M, SUN Z Z, XING Y, et al. BM3D adaptive TV filtering-based convolutional neural network for ESPI image denoising [J]. Applied Optics, 2021, 60(35): 10920-10927.
- [10] 张申华,杨延西,秦桥孟.针对光栅图像的快速盲去噪方法[J].中国光学,2021,14(3):596-604.
- [11] 杨昆,杜瑀,钱武侠,等.基于多尺度上下文信息融合的条件生成对抗神经网络用于低剂量 PET 图像去噪[J].电子测量技术,2021,44(7):74-81.
- [12] 王婕,罗静蕊,岳广德.一种改进的多尺度融合并行稠密残差去噪网络[J].小型微型计算机系统,2021,42(4):798-804.
- [13] YAN K, YU Y, HUANG C, et al. Fringe pattern denoising based on deep learning [J]. Optics Communications, 2019, 437: 148-152.
- [14] OMAR E Z. A refined denoising method for noisy phase-shifting interference fringe patterns[J]. Optical and Quantum Electronics, 2021, 53(8): 464.
- [15] 林薇,崔海华,郑炜,等.基于深度学习的剪切散斑干涉条纹图滤波方法[J].激光与光电子学进展,2022,59(22): 210000.
- [16] HAO F, TANG C, XU M, et al. Batch denoising of ESPI fringe patterns based on convolutional neural network[J]. Applied Optics, 2019, 58(13): 3338-3346.
- [17] 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):89-98.
- [18] YAN K, YU Y, SUN T, et al. Wrapped phase denoising using convolutional neural networks [J]. Optics and Lasers in Engineering, 2020, 128: 105999.
- [19] GURROLA-RAMOS J, DALMAU O, ALARCÓN T. U-Net based neural network for fringe pattern denoising [J]. Optics and Lasers in Engineering, 2022, 149: 106829.
- [20] 张伟,龚渠,张俊杰,等.基于改进 U-net 的条纹图去噪分析[J].光学技术,2022,48(3):334-340.
- [21] 熊巍,熊承义,高志荣,等.通道注意力嵌入的 Transformer 图像超分辨率重构[J].中国图象图形学报,2023,DOI:10.11834/jig.221033.
- [22] 王坤,叶招君.基于小波空洞残差 U-Net 的红外图像去条纹噪声方法[J].光学技术,2022,48(5):616-626.
- [23] LIANG J, CAO J, SUN G, et al. Swinir: Image restoration using swin transformer[C]. Proceedings of the IEEE/CVF International Conference on Computer Vision, 2021: 1833-1844.
- [24] 李冬辉,刘功尚,高龙.基于 Inception-LSTM-Attention 的冷水机组传感器偏差故障诊断方法[J].中南大学学报(自然科学版),2023,54(1):102-112.
- [25] 许瑶瑶,单剑锋.基于密集连接和 Inception 模块的前列腺图像分割[J].电子测量技术,2022,45(15):151-157.
- [26] 许萌,王丹,李致远,等. IncepA-EEGNet:融合 Inception 网络和注意力机制的 P300 信号检测方法[J].浙江大学学报(工学版),2022,56(4):745-753,782.
- [27] 陈立,张帆,郭威,等.基于级联式逆残差网络的遥感图像轻量目标检测算法[J].电子学报,2023,51(9):2588-2597.
- [28] 邓宇平,王桂棠.基于 GoogleNet 网络与残差网络的织物纹理分析[J].电子测量技术,2021,44(7):31-38.
- [29] LIU Z, LIN Y, CAO Y, et al. Swin transformer: Hierarchical vision transformer using shifted windows[C]. Proceedings of the IEEE/CVF International Conference on Computer Vision, 2021: 10012-10022.
- [30] 慕长平,耿丽清,董建,等.基于多层级 Swin-Transformer 的低剂量 CT 重建[J].国外电子测量技术,2022,41(12):156-163.

## 作者简介

张伟,副教授,硕士生导师,主要研究方向为精密测量、精密机械。

E-mail:zhangwei7766@163.com

张俊杰(通信作者),硕士研究生,主要研究方向为深度学习、图像处理。

E-mail:zhangjunjie7373@163.com