

基于神经网络散斑干涉图像去噪方法研究与实现

李珂嘉¹, 赵自新¹, 马跃洋², 尹昱东³, 张璐¹

(1. 西安交通大学 仪器学院, 西安 710049; 2. 西安工业大学 光电工程学院, 西安 710021;
3. 西安交通大学 机械学院, 西安 710049)

摘要: 在科学研究和实际工程项目中, 需要对光学粗糙表面的位移、形变、振动及应变等物理量进行高精度测量; 散斑干涉测量是一种针对光学粗糙表面的高精度无损检测技术, 然而在测量过程中, 干涉条纹图像不可避免地包含大量的相干散斑噪声以及环境噪声, 严重影响后续的相位解调和解包裹精度和准确性; 因此设计了一种基于 DnCNN 神经网络模型的图像降噪实验模型, 设计搭建干涉测量硬件系统, 编写软件实现对图像的采集和增强; 利用计算机模拟的散斑干涉条纹图像生成数据集, 完成了神经网络的设计和训练; 实验结果表明, 设计方法能够有效去噪, 减少了白色噪点, 且网络的拟合效果达到最佳状态; 经过实验测试, 在去噪性能的评估测试中, 与传统的滤波方法相比, DnCNN 展现出了显著优势, 其中信噪比和散斑指数表现突出。

关键词: 神经网络; 散斑去噪; 自适应估计; 散斑干涉; DnCNN

Investigation and Implementation of Neural Network-based Speckle Interferometry Image Denoising Methods

LI Kejia¹, ZHAO Zixin¹, MA Yueyang², YIN Yudong³, ZHANG Lu¹

(1. School of Instruments Engineering, Xi'an Jiaotong University, Xi'an 710049, China;
2. School of Optoelectronics Xi'an Technological University, Xi'an 710021, China;
3. School of Mechanical Engineering, Xi'an Jiaotong University, Xi'an 710049, China)

Abstract: In scientific research and practical engineering projects, it is necessary to measure the displacement, deformation, vibration and strain of optical rough surfaces with high precision. Electronic speckle interferometry is a high-precision non-destructive testing technique for optical rough surfaces, but in the measurement process, the interference fringe image inevitably contains a large amount of coherent speckle noise and environmental noise, which seriously affects the subsequent phase demodulation and unwrapping accuracy and precision. Therefore, this paper designs an image denoising experimental model based on denoising convolutional neural network (DnCNN) model, builds a hardware system for interference measurement, develops software to realize the acquisition and enhancement of images, uses the computer simulated speckle interference fringe images to generate a dataset, and achieves the design and training of the neural network. Experimental results show that the designed method can effectively denoise, reduce white noise, and achieve the best fitting effect of the network. Through experimental tests, The DnCNN model has significant advantages over traditional filtering methods in the evaluation of denoising performance, among which the signal-to-noise ratio and speckle index are outstanding.

Keywords: neural network; speckle denoising; adaptive estimation; speckle interferometry; DnCNN

收稿日期:2024-05-27; 修回日期:2024-07-17。

基金项目:陕西省自然科学基金基础研究计划项目(2023-JC-QN-0649);陕西省教育厅项目(24JJP075);陕西省科技厅重点研发计划一般项目(2025SF-YBXM-287);西安交通大学 2024 年本科教学改革研究项目(常规项目)(2423Y)。

作者简介:李珂嘉(1987-),女,硕士,高级实验师。

通讯作者:张璐(1981-),女,博士,副教授。

引用格式:李珂嘉,赵自新,马跃洋,等. 基于神经网络散斑干涉图像去噪方法研究与实现[J]. 计算机测量与控制, 2025, 33(7): 203-209.

0 引言

在科学研究和实际工程项目中^[1-3]，需要对光学粗糙表面的位移、形变、振动及应变等物理量进行高精度测量。电子散斑干涉测量（ESPI, electronic speckle pattern interferometry）是一种针对光学粗糙表面的高精度无损检测技术，具有非接触、高灵敏度、全场等优点。该技术可应用于文物修复、大坝检测、兵器工业、航天航空及医学检测等诸多领域。在测量过程中，其干涉条纹图像不可避免地包含大量的相干散斑噪声以及环境噪声，严重影响后续的相位解调和解包裹精度和准确性^[4]。因此，亟需找到一种有效彻底的方法对生成的干涉条纹^[5]图像进行降噪^[6]。目前基于空间域和变换域的滤波方法效果并不理想。

在过去几年里，见证了深度学习技术的快速发展，深度学习作为一种“数据驱动”的工具解决了许多难题，它也成功应用在光学计量的各个领域^[7]，例如超分辨率成像^[8-9]、全息成像^[10]、波前重建^[11]、去噪^[12]、自动聚焦^[13-14]及计算成像^[15]等，并展现出了其在噪声鲁棒性上的独特优势，研究如何将其有效应用于散斑干涉条纹图像的滤波中，彻底消除散斑噪声，对提高散斑干涉测量技术的精度具有重要意义。

基于深度学习的去噪方法相比于传统的去噪方法（BM3D、小波变换等）有着去噪速度快、去噪精度高的特点，所以许多研究学者也将深度学习用在相位图的去噪处理上，提高后续相位恢复的精度，其中文献 [16-18] 做了许多研究工作。辅助去噪方法通过搭建对条纹图或包裹相位图的去噪网络模型，然后在相位恢复前，先对条纹图或包裹相位图进行快速去噪处理，得到高质量的包裹相位图，进而结合传统算法进行相位解包裹。2020 年，文献 [17] 提出了一种基于卷积神经网络（CNN）的包裹相位去噪方法，此方法的原理与正余弦滤波相似，首先得到待处理包裹相位的正弦条纹图和余弦条纹图，然后通过 CNN 对正余弦条纹图进行去噪处理，获得干净的正余弦条纹，最后通过反正切函数得到干净的包裹相位图，该方法结合正余弦滤波的思路将包裹相位去噪的问题转化为条纹图去噪问题，提供了一种传统方法数学模型与深度学习相结合的思路。2021 年，文献 [18] 提出了一种名为 DBDNet 的包裹相位去噪网络，该方法提出了一种多尺度连接的膨胀卷积模块，增加了网络对多尺度特征信息的获取能力，提供一种网络改进的思路，而且该方法可以对包裹相位直接进行去噪处理。基于深度学习辅助去噪的方法有着实时性好、精度高、易实现、易移植的特点，作为一种预处理方法，应用的场景较为广泛，可以与多种技术相结合，而且相对于其它图像处理任务，去噪的网络结果模型更

为容易搭建训练，如 DnCNN^[19]、U-Net^[20] 等经典网络框架均能实现不错的去噪性能。此类方法研究发展的方向主要是在对网络模型的结构进行改进，如引入注意力机制解决空间或特征通道信息的不一致性、改进多层连接模块增加模型的稳定性及改进卷积模块减少参数等。作为预处理方法，虽然辅助去噪在整体上会提高包裹相位的质量，但也有着丢失信息的风险，当噪声复杂，尤其是噪声密度空间分布不均匀时，去噪处理可能会破坏局部噪声密集区域的信息，影响后续相位恢复过程。近年来，随着深度学习神经网络技术的快速发展，研究如何将其有效应用于散斑干涉条纹图像的滤波中，彻底消除散斑噪声，对提高散斑干涉测量技术的精度具有重要意义。

鉴于此，设计了一种基于 DnCNN 神经网络模型^[21] 的图像降噪实验模型，经验证后，在散斑降噪实验中取得显著效果。

1 方法原理

1.1 散斑干涉测量原理

散斑的形成是由于激光照射在粗糙物体表面，产生漫反射。因此，散斑包含了物体表面粗糙度的信息。当物体表面发生微小的变化时，散斑也相应地发生变化。利用这一现象，研究物体表面的形态、受力状态和变化。散斑干涉测量法在测量不同物体或满足不同测量需求时，采用不同的光路设计，通常分为 3 种类型：双光束型光路、剪切型光路和参考光束型光路。双光束型光路常用于测量面内位移，剪切型光路用于测量离面应变，参考光束型光路主要用于离面位移测量。通过采用参考光束型光路来测量微小离面位移。

参考光与物光的合成复振幅为：

$$E(x, y) = a_r(x, y)e^{i\phi_r(x, y)} + a_o(x, y)e^{i\phi_o(x, y)} \quad (1)$$

相应的光强为：

$$I_1(x, y) = E(x, y) \cdot E^*(x, y) = I_r + I_o + 2\sqrt{I_r I_o} \cos\theta \quad (2)$$

当物体发生微小离面位移之后，物光从激光器经过透镜到被测物粗糙表面，再到 CCD 成像平面的光程发生了改变，设物体在像平面发现方向发生的离面位移为 d_z ，与物体发生微小离面位移之前相比较，参考光和物光之间的光程差发生变化，并且光程差的变化量为 $2d_z$ ，与之对应的相位差 $\Delta\varphi$ 为：

$$\Delta\varphi = \frac{2\pi}{\lambda} 2d_z \quad (3)$$

CCD 像平面记录的光强为：

$$I_2(x, y) = I_r + I_o + 2\sqrt{I_r I_o} \cos(\theta + \Delta\varphi) \quad (4)$$

式中， I_r 为参考光光强； I_o 为物光光强； θ 为随机散斑相位。

光路如图 1 所示。一部分光束经过透镜发散, 直接照射在物体表面上产生漫反射, 然后通过棱镜汇聚, 传输到 CCD, 形成“物光”。另一部分光束在反射之后, 通过分光棱镜传输到 CCD, 称作“参考光”。物光的散斑场与参考光在像平面上相互干涉, 形成散斑干涉场。




图 1 参考光束型光路图

1.2 散斑干涉条纹图原理

在深度学习领域, 光强相减模式是一种广泛使用的方法, 用于生成散斑干涉条纹图, 以测试网络性能。通过直接相减物体微小位移前后记录的两个混合散斑场来生成散斑干涉条纹图。条纹图因受到高频散斑的双边调制, 具有较低的对比度和不明显的条纹包络线。为了解析形变相位 $\Delta\varphi$, 需增强条纹对比度。通过对相减后的散斑干涉场 ΔI 进行绝对值或平方值运算来实现, 从而提高条纹的对比度。选取绝对值运算方法。

将式 (4) 和式 (2) 相减取绝对值, 可以得到:

$$I_{\text{sub}} = |I_2 - I_1| = 4 \sqrt{I_0 I_r} \left| \sin\left(\theta + \frac{\Delta\varphi}{2}\right) \right| \quad (5)$$


式中, $\theta + \frac{\Delta\varphi}{2}$ 为随机散斑相位, $4 \sqrt{I_0 I_r}$ 是背景光强调制项。

在通过相减模式生成的散斑干涉条纹图中如图 2 所示, 条纹结构通常较为清晰, 但伴随着显著的乘性噪声。为了有效进行相位解调和解包裹, 需要实施滤波处理。此外, 散斑条纹的亮度还会受到背景光强 $4 \sqrt{I_0 I_r}$ 的影响。如果背景光强在物体表面分布不均, 则通过生成的散斑干涉条纹图在亮度分布上也将表现出不均匀性。

2 系统设计

2.1 系统硬件设计

基于马赫曾德干涉仪的光路系统。使用波长为 632 nm 的氦氖激光器和分辨率为 $4\,248 \times 2\,832$ 的黑白 Baumer 工业相机。激光器发出的光被分光镜分为参考光和被测光。被测光在两次反射后通过透镜照射到被测



(a) 散斑场条纹 (b) 绝对值散斑场条纹图

图 2 相减模式生成的干涉条纹图

物体表面, 并将离面位移的反射光传回 CCD 成像。参考光则通过衰减器和 4 f 扩束准直系统, 经分光镜反射至 CCD。两束光在 CCD 的成像靶面上相遇并产生干涉。

系统中, 被测物是一块粗糙的铝板, 使用材质为纯铝的应变铝板当做制造微小离面位移的生成装置, 如图 3 所示, 应变铝板的套筒由 45 钢加工制造而成, 套筒与千分尺通过螺钉固定, 旋转旋钮可以使测杆前后移动从而使铝板与测杆的接触点发生形变, 以接触点为圆心的部分圆形区域受力产生形变, 使应变铝板外表面上的任意一个点相较于未受力之前的状态发生不同程度的微小位移。

实验主要目的是获取散斑干涉条纹图, 所以通过旋钮旋转移动适当距离, 即可获得微小的离面位移。




图 3 应变铝板

激光器采用的是相干光激发装置, 选取美国 REO 精密光学仪器公司生产的标准氦氖激光器, 型号是 30992, 红外光的波长为 633 nm, 最大功率可以达到 20 mW, 最小的功率为 12 mW, 该型号激光器具有很好的热补偿机制, 通过热补偿机制可以在高功率输出的同时维持低温敏感性, 能在光强模式和频率模式之间自由切换, 并且光强具有很好的稳定性, 维持同一光强一小时的误差可控制在 0.2% 以内。该激光器的频率能够保持同一频率 8 个小时误差在 2 MHz 以内, 具有优良的稳定性。

散斑干涉测量系统需要获取散斑灰度图像, 所以选用瑞士黑白 Baumer 工业相机, 型号 PXU-120M. Q 分辨率最高为 $4\,248 \times 2\,832$, 该相机全尺寸下的帧率为 13 帧, 数据接口为 USB3.0 的接口, 传输数率最高可达

625 MB/s。该相机具有非常好的灵敏度、线性度和动态范围,即使在黑暗的光线条件下也依然能够获得高品质的图像质量,契合实验的需求。

光学镜头在散斑图像采集的过程中是不可缺少的配件之一,在硬件系统的设计中,需要考虑所选择的 CCD 相机传感器尺寸以及被测对象的尺寸,从而确定出光学镜头的光学参数,通过比较这些镜头的类型,同时计算并测试了 CCD 工业相机的实际工作距离,选定了焦距为 50 mm 的 NAVITAR 镜头。

根据马赫曾德干涉仪理论光路设计离面位移测量光路系统,由于实验平台的限制,设计 3 个反射镜以改变光路,分别使用衰减器对物光和参考光的光强进行调节,避免 CCD 工业相机出现过曝光而不能得到散斑干涉图,同时也能通过调节物光和参考光的光强,保证照射在 CCD 像平面上的物光和参考光的光强接近,获得对比度清晰的散斑干涉图。

通过计算机收集铝板表面发生微小离面位移时的干涉场,并对收集到的两幅图像进行处理,通过相减模式,计算原理通过上节原理已给出。从而获得散斑干涉条纹图,其系统光路图如图 4 所示。




图 4 系统光路图

2.2 系统软件设计

为实现散斑干涉条纹图简单方便地获取,需要设计相应的测试软件,该软件系统主要包括有:图像采集、图像处理以及用户交互界面。软件功能由 MFC、OpenCV 和 Baumer 相机 API 联合编程完成。选用版本为 OpenCV2.4.11,该版本已经包含了 Mat 基本图形容器,很大程度上能够实现自动内存的管理,极大地提高了程序的编写效率和便捷性。Baumer 相机自带的 API 函数库就包含了大量能用来进行图像采集的有关函数。

软件系统的主要功能是实现动态散斑图像的采集、散斑干涉条纹图的生成等目的。程序运行界面如图 5 所示,“相机动态图像”能够实时动态地展示散斑干涉场,“形变前散斑场捕捉”采集物体状态改变前的散斑场图像,通过旋转千分尺旋钮,使测杆前进或后移微小的距离,就能使被测物的粗糙表面发生微小离面位移,“形

变后散斑场捕捉”采集物体状态改变后的散斑场图像,利用相减模式就能生成相应的散斑干涉条纹图。




图 5 程序运行界面

2.3 DnCNN 神经网络结构模型设计

前馈降噪卷积神经网络 (DnCNN) 是神经网络的一个重要的分支,在图像降噪方面效果显著,使用 DnCNN 网络来进行散斑干涉图像噪声的去除。DnCNN 的网络结构如图 6 所示。




图 6 DnCNN 网络结构图

深度卷积网络结构分为 3 个主要部分。首先,网络的入口层(第一部分)由卷积层 Conv ($3 \times 3 \times c \times 64$) 与激活函数 ReLU 组成,其中 ‘c’ 代表输入图像的通道数;单通道灰度图像对应 “ $c=1$ ”,而三通道彩色图像对应 “ $c=3$ ”。该层利用 64 个 “ 3×3 ” 的卷积核来提取特征,生成 64 个特征图。

继而,网络的第二部分涉及从第 2 层至第 (D-1) 层,每一层均包含 Conv ($3 \times 3 \times 64 \times 64$) 卷积层,随后接批量标准化 (BN) 层,以及 ReLU 激活层。批量标准化层置于卷积层与激活层之间,其目的是为了加速网络训练过程中的收敛,并提升训练效率。

最后,在网络结构的终端层(第三部分),使用 c 个 $3 \times 3 \times 64$ 的卷积核来重建输出图像。网络的每一层均采用零填充策略,以保持输入与输出尺寸的一致性并

避免在图像边界产生人工效应。通过此种结构设计, 确保了信息在各层之间的无损传递, 为网络训练提供了稳定的基础。

2.4 DnCNN 神经网络去噪流程设计

在正向传播中, 采用了残差学习训练残留映射为:

R(y_i; \theta) \approx y_i - x_i \tag{6}

式中, R(y_i; \theta) 表示网络预测的噪声; x_i 和 y_i 表示噪声训练图像对, 即表示可训练的网络参数, 训练网络实际上就是寻求最优参数 \theta 的过程。

去噪后的图像 \hat{x}_i 可以算法来获得预测噪声的输入图像, 这可以表示为:

\hat{x}_i = y_i - R(y_i; \theta) \tag{7}

然后利用损失函数对正向传播得到的去噪图像和无噪图像之间的差异进行量化, 其定义如下:

\ell(\theta) = \frac{1}{2N} \sum_{i=1}^N R(y_i; \theta) - (y_i - x_i)^2 \tag{8}

其中: N 表示训练数据集的样本数量。在神经网络的训练过程中, 采用了自适应矩估计 (Adam) 优化算法来最小化损失函数, 从而学习网络中的可训练参数。通过反复执行反向传播算法, 不断地对网络参数进行更新, 以逐渐减少网络的损失函数值。训练完成后, 待处理的散斑干涉图被输入到训练完毕的网络中, 网络对图像中的噪声进行预测。最终, 从输入图像中减去预测出的噪声, 得到去噪后的图像。

2.5 数据集的创建

为有效训练深度卷积网络, 建了一组包含有噪声和无噪声图像对的训练数据集。理论上, 较大的数据集能够更加有效地训练神经网络模型。这些数据集可以通过计算机模拟产生, 也可以通过物理实验获得。然而, 实验数据往往难以获得理想的无噪声条纹图样, 会对神经网络的训练带来不便。因此, 为了便于操作, 选择使用计算机模拟生成的散斑干涉条纹图及其对应的无噪声条纹图作为训练数据集。模拟产生的散斑干涉条纹图是基于一下方程生成的:

I_{sub} = \left| 4 \sqrt{I_o I_r} \sin(\Phi_r - \Phi_o) + \frac{\varphi}{2} \right| + NN \times \text{rands} \tag{9}


其中: \Phi_r - \Phi_o, I_o, I_r, \text{rands} 分别取值于区间 [-\pi, \pi], [0, I_m], [0, \rho I_m], [-1, 1] 上的随机变量。其中 I_m 为 90, \Phi_r - \Phi_o 为 \pi, I_o 为 I_m, I_r 为 \rho I_m, \text{rands} 为 1, 此时得到相应的无噪声条纹图, 通过设置不同的噪声强度 (NN) 和不同的能见度 (\rho) 获得不同的训练图。

3 实验结果与分析

3.1 干涉图生成

图 7 (a) 与图 7 (b) 展示了被测物位移前后的散斑场图像。图像大小为 4 248 * 2 832, 图 7 (c) 展示了

利用程序生成的散斑干涉图, 其尺寸调整为 256 * 256。鉴于原始图像较暗, 影响视觉效果, 采用直方图均衡化技术对图像进行处理, 以改善图像的亮度和对比度, 处理后的图像如图 7 (d) 所示。



(a) 位移前散斑场 (b) 位移后散斑场 (c) 干涉条纹图 (d) 直方图均衡化后的干涉条纹图

图 7 干涉图生成

3.2 神经网络测试和训练

为了训练深度卷积网络, 从数据集中选取了 1 000 对图像, 并将它们按照一一对应的顺序置于训练集中, 每张图像的分辨率均为 256 \times 256 像素。实验采用的网络总共包含 17 层, 批次大小 (batch size) 设置为 2, 整体数据集被训练了 15 个周期 (epochs)。该训练过程共耗时 7 小时。训练结果展示于图 8 (a), 从左至右分别为干净的散斑干涉图、加噪声的散斑干涉图, 以及去噪后的散斑干涉图。从图中可以观察到去噪效果有所体现, 但仍存在白色斑点, 表明所选 epoch 值并非最优, 且损失函数未能良好收敛。

为了优化训练结果, epoch 值提升至 30, 其他参数保持不变。该条件下的网络训练耗时增至 27 小时。其训练结果如图 8 (b) 所示, 此时网络在噪声移除方面的性能有显著提升, 依然可以观察到白色斑点。

随后, 将 epoch 值增加至 40, 保持其他参数不变, 训练时间延长至 34 小时。训练结果如图 8 (c) 所示, 去噪效果显著, 白色斑点几乎消失或可忽略。

最终, 当 epoch 值设置为 50 时, 训练时间为 42 小时, 结果如图 8 (d) 所示, 去噪效果仍然可观, 但白色斑点的再次出现, 暗示过拟合的问题。

经过深度卷积神经网络的训练, 进一步对数据集中未曾训练过的带噪声散斑干涉条纹图进行了测试。测试结果如图 9 (a), 9 (b) 所示, 图中从左至右分别为带噪声图像及其去噪后的散斑干涉条纹图。结果显示, 噪声被有效去除, 尽管仍可观察到极少量的白点, 但其数量少到可以被忽略。此外, 研究发现, 当噪声水平过高时, 图像在恢复过程中会丢失更多细节, 这使得图像变得难以去噪, 如图 9 (c), 9 (d) 所示。

在训练的深度卷积神经网络基础上, 进一步使用参考光束型光路获得的散斑干涉条纹图进行了去噪效果测试。测试结果展示在图 10 (b) 中, 显示了去噪后的图像质量较高。然而, 由于原始图像的较低对比度, 为了增强图像的可视性, 采用了直方图均衡化技术以提高对比度。图 10 (c), 10 (d) 展示了应用均值滤波和中值




图 8 训练结果




图 9 测试结果

滤波后，经过直方图均衡化处理的去噪图像。比较结果表明，DnCNN 在去噪效果上超越了传统滤波方法。

此外，对不同条纹形式的散斑干涉条纹图进行测试，以进一步评估 DnCNN 的去噪能力。相关测试结果如图 10 所示。




图 10 测试去噪结果

3.3 对滤波结果的评价指标

均方根信噪比和散斑指数是两种经常用来对滤波结果好坏进行评价的有效指标。均方根信噪比（SNR，signal-to-noise ratio）能够说明噪声的滤除程度，公式为：

$$NR = \sqrt{\frac{\sum_{x=0}^{M-1} \sum_{y=0}^{N-1} I_{fil}^2(x,y)}{\sum_{x=0}^{M-1} \sum_{y=0}^{N-1} (I_{fil}(x,y) - I_0(x,y))^2}} \quad (10)$$

式中， M 为水平方向图像像素尺寸； N 为竖直方向图像像素尺寸； I_{fil} 为图像滤波后效果； I_0 为原始噪声图像。均方根信噪比越大，说明噪声去除更加地彻底，滤波效果更好。

散斑指数（SI，speckled index）被用来衡量图像的局部平滑程度：

$$SI = \frac{1}{M \times N} \sum_{x=0}^{M-1} \sum_{y=0}^{N-1} \frac{\sigma_{x,y}}{[I_{x,y}]} \quad (11)$$

$$\sigma_{x,y} = \sqrt{\frac{1}{(2m+1) \times (2n+1) - 1} \sum_{i=-m}^m \sum_{j=-n}^n [I_{x+i,y+j} - (I_{x,y})]^2} \quad (12)$$

式中， $[I_{x,y}]$ 为点 $P(x, y)$ 所在邻域 $(2m+1) \times (2n+1)$ 的灰度平均值； $\sigma_{x,y}$ 为该邻域灰度局部标准偏差。散斑指数越小，说明该图像的局部平滑性越好，滤波效果更好。

表 1 提供了图 10 所采用不同滤波方法得到的去噪图像的滤波效果的定量比较。从表中可以观察到，通过 DnCNN 网络处理得到的去噪图像的均方根信噪比（SNR）显著高于应用均值滤波和中值滤波等传统滤波技术所得到的结果，表明其在噪声移除方面的性能更为出色。此外，经 DnCNN 去噪后的图像显示出较低的散斑指数，这意味着图像在局部区域的平滑性得到了改善。

表 1 去噪结果

滤波类型	均方根信噪比	散斑指数
DnCNN 图 8(b)	0.807 4	0.849 3
均值滤波图 8(c)	0.429 7	5.583 6
中值滤波图 8(d)	0.499 3	6.383 2
DnCNN(图 8(b))	0.784 5	0.972 8
均值滤波图 8(c)	0.502 4	5.773 0
中值滤波图 8(d)	0.492 7	5.984 9

根据实验结果分析，当批次大小（batch size）设定为 2，数据集训练次数（epochs）设定为 40 时，常数 $\epsilon = 10^{-10}$ 时图片的训练效果最好，神经网络的训练效果最为理想。在这一参数配置下，噪声去除效果显著，且模型拟合达到最优状态，图片中白色斑点的数量微乎其微，可在后续分析中忽略。网络在测试阶段表现良好，能有效处理待去噪图像。然而，值得注意的是，若原始图像中的噪声水平过高，则去噪效果会受到负面影响，去噪性能会明显下降。

从计算机仿真和实验获得的散斑干涉条纹图的上述

结果可以看出, 所设计方法在大多数情况下都能获得良好的去噪效果。该方法的优点如下。

批量去噪: 对网络进行训练时, 可以批量化处理, 现有的硬件条件下, 可以同时处理 2 张图像。

去噪的性能优越: 通过使用数据集训练网络的方法可以获得很好的图像去噪效果。

降噪的速率快: 使用经过训练的网络对 2 张图像进行降噪仅需几秒。

利用 DnCNN 网络去噪后的图片, 相较于均值滤波和传统滤波等方法, 用深度学习的方法去噪获得的图像条纹结构损害少, 细节保留完善, 去噪效果好。

所以无论是计算机仿真还是实验获得的散斑干涉条纹图, 所采用的方法均能实现良好的去噪效果。

4 结束语

综上所述, 应用了深度卷积神经网络 (DnCNN) 对散斑干涉图像进行去噪处理, 并通过计算机仿真与实验验证了该方法的有效性。在适当的训练周期和批次大小设置下, DnCNN 展现出了优于传统滤波技术的去噪能力, 尤其在保持图像细节和减少白色噪点方面表现卓越。DnCNN 证明了其在图像处理领域的潜力和应用价值。未来的研究可以探索更高效的网络结构和优化算法, 以进一步提高去噪性能。

参考文献:

- [1] 李珂嘉, 陈选文, 王保健, 等. 基于智能制造场景的物流机器人小车系统优化 [J]. 信息记录材料, 2021, 22 (1): 170-172.
- [2] 李珂嘉, 张璐, 赵宏, 等. 新工科下智能制造人才培养及实验室建设研究 [J]. 教育教学论坛, 2020 (53): 385-387.
- [3] 李珂嘉, 张璐薇, 马跃洋, 等. ChatGPT 在实验教学中的应用与探索 [J]. 中国现代教育装备, 2024 (7): 33-35.
- [4] ZHANG K, ZUO W, CHEN Y, et al. Beyond a gaussian denoiser: residual learning of deep CNN for image denoising [J] - IEEE Transactions on Image Processing, 2017, 26 (7): 3142.
- [5] 高 晔, 薛 瑞, 高 考. 一种基于条纹密度和方向的干涉条纹图滤波方法 [J]. 科学技术与工程, 2014, 14 (7): 227-232.
- [6] 姚芦鹂, 余桂英, 张宝武. 几种 OCT 图像散斑降噪算法的研究与比较 [J]. 中国计量学院学报, 2015, 26 (3): 336-340.
- [7] ZUO C, QIAN J, FENG S, et al. Deep learning in optical metrology: a review [J]. Light: Science & Applications, 2022, 11: 39.
- [8] HU H, YANG S, LI X, et al. Polarized image super-reso-

- lution via a deep convolutional neural network [J]. Optics Express, 2023, 31 (5): 8535-47.
- [9] HE Y, YAO Y, HE Y, et al. Surpassing the resolution limitation of structured illumination microscopy by an untrained neural network [J]. Biomed Opt Express, 2023, 14 (1): 106-17.
- [10] GANGADHAR A, SARI-SARRAF H, VANAPALLI S. Staining-free, in-flow enumeration of tumor cells in blood using digital holographic microscopy and deep learning [J]. BioRxiv Preprint BioRxiv; 2022. 05. 01. 490222, 2022.
- [11] LIUX, LIUZ, YANG Z, et al. Reconstruction and analysis of wavefront with irregular-shaped aperture based on deep learning [J]. OSA Continuum, 2020, 3: 835-843.
- [12] GURROLA-RAMOS J, DALMAU-CEDENO O, ALARCÓN T. U-Net based neural network for fringe pattern denoising [J]. Optics and Lasers in Engineering, 2021, 149: 106829.
- [13] PITKÄÄHO T, MANNINEN A, NAUGHTON T. Focus prediction in digital holographic microscopy using deep convolutional neural networks [J]. Appl Opt, 2019, 58: A202.
- [14] DING H, LI F, MENG Z, et al. Auto-focusing and quantitative phase imaging using deep learning for the incoherent illumination microscopy system [J]. Optics Express, 2021, 29 (17): 26385-403.
- [15] BARBASTATHIS G, OZCAN A, SITU G. On the use of deep learning for computational imaging [J]. Optica, 2019, 6: 921-43.
- [16] HAO F, TANG C, XU M, et al. Batch denoising of ESPI fringe patterns based on convolutional neural network [J]. Appl Opt, 2019, 58: 3338.
- [17] YAN K, YU Y J, SUN T, et al. Wrapped phase denoising using convolutional neural networks [J]. Optics and Lasers in Engineering, 2020, 128: 105999.
- [18] LI J, TANG C, XU M, et al. DBDNet for denoising in ESPI wrapped phase patterns with high density and high speckle noise [J]. Appl Opt, 2021, 60: 10070-10079.
- [19] MURALLI V, SUDEEP P V. Image denoising using DnCNN: An exploration study [C] //Advances in Communication Systems and Networks: Select Proceedings of ComNet 2019. Springer Singapore, 2020: 847-859.
- [20] MURALI V, SUDEEP P V. Image denoising using DnCNN: An exploration study [C] //Advances in Communication Systems and Networks: Select Proceedings of ComNet 2019. Springer Singapore, 2020: 847-859.
- [21] 李珂嘉, 张璐薇, 马跃洋, 等. 基于机器视觉的钢轨表面面型缺陷分类实验设计 [J]. 实验室研究与探索, 2024, 43 (3): 122-127.