

引文格式:

芮浩晖, 聂泽东, 曾光, 等. 面向无监督去噪模型的高效采样方法 [J]. 集成技术, 2025, 14(2): 46-57.

Rui HH, Nie ZD, Zeng G, et al. Efficient sampling method for unsupervised denoising model [J]. Journal of Integration Technology, 2025, 14(2): 46-57.

面向无监督去噪模型的高效采样方法

芮浩晖^{1,2} 聂泽东¹ 曾光¹ 秦文健^{1*}

¹(中国科学院深圳先进技术研究院 深圳 518055)

²(中国科学院大学 北京 100049)

摘要 基于深度学习的图像去噪方法有效解决了传统去噪方法的烦琐调参和复杂噪声建模的问题。然而, 有监督学习的模型训练严重依赖干净-噪声图像对, 这限制了此类模型的广泛使用。无监督学习去噪模型仅需单噪声图像进行训练, 但现有的无监督去噪方法仍存在网络训练效率与去噪性能难以兼顾的问题。本文提出一种高效的图像去噪方法, 提升了去噪模型训练的效率。具体来说, 本文方法提出了一种深度近邻下采样器, 用于从同一张噪声图像中获取训练噪声模型的相似图像对。基于该采样器的方法不仅满足了图像对像素相邻且外观相似的要求, 而且深度近邻下采样舍弃了部分冗余信息, 避免了对噪声分布假设的严重依赖。最后, 本文通过标准红绿蓝空间中具有不同噪声分布的合成实验和真实图像实验验证了本文方法的有效性, 实验结果表明: 本文提出的采样策略有效平衡了训练效率与去噪性能。

关键词 图像去噪; 无监督; 下采样

中图分类号 TP183; R319 文献标志码 A doi: 10.12146/j.issn.2095-3135.20241224001

CSTR: 32239.14.j.issn.2095-3135.20241224001

Efficient Sampling Method for Unsupervised Denoising Model

RUI Haohui^{1,2} NIE Zedong¹ ZENG Guang¹ QIN Wenjian^{1*}

¹(Shenzhen Institutes of Advanced Technology, Chinese Academy of Sciences, Shenzhen 518055, China)

²(University of Chinese Academy of Sciences, Beijing 100049, China)

*Corresponding Author: wj.qin@siat.ac.cn

Abstract Image denoising methods based on deep learning have effectively solved the problems of cumbersome parameter tuning and complex noise modeling in traditional denoising methods. However, the model training of supervised learning relies heavily on pairs of clean and noisy images, which limits the wide application of such models. Unsupervised learning denoising models only require single noisy images for training, but the existing unsupervised denoising methods still have the problem that it is difficult to balance

收稿日期: 2024-12-24 修回日期: 2025-02-11

基金项目: 国家重点研发计划青年科学家项目 (2023YFF0723400)

作者简介: 芮浩晖, 硕士研究生, 研究方向为医学图像处理; 聂泽东, 研究员, 研究方向为医学电子学; 曾光, 工程师, 研究方向为医学成像; 秦文健 (通讯作者), 研究员, 研究方向为医学成像, E-mail: wj.qin@siat.ac.cn.

network training efficiency and denoising performance. This paper proposes an efficient image denoising method, which improves the efficiency of denoising model training. Specifically, this method proposes a deep neighbor downsampler, which is used to obtain similar image pairs for training the noise model from the same noisy image. The research proposed sampler method not only meets the requirements that the pixels of the image pairs are adjacent and the appearances are similar, but also the deep neighbor downsampling discards some redundant information and avoids heavy dependence on assumptions about the noise distribution. Finally, the research verify the effectiveness of the research method through synthetic experiments with various noise distributions in the standard red green blue space and real image experiments. The experimental results confirm that the sampling strategy the research proposed effectively overcomes the balance problem between training efficiency and denoising performance.

Keywords image denoising; unsupervised; downsampling

Funding This work is supported by National Key Research and Development Program Young Scientist Project (2023YFF0723400)

1 引言

在当今数字化时代, 图像作为一种重要的信息载体, 在众多领域发挥关键作用。但在图像生成、采集、传输和存储等各环节, 噪声干扰导致图像质量下降。而图像去噪能提高信息获取时的质量, 因此既能助力医学诊断和工业检测, 又能助力材料和天文等科研领域研究, 还能提升视觉体验和传播效果, 并能推动图像处理技术发展, 意义重大。综上所述, 由于各领域对高质量图像的需求较大, 因此探索高效精准的去噪方法成为当下研究热点。

目前, 传统方法通过设计滤波器或建立噪声模型实现图像去噪。经典的去噪方式基于滤波方法, 如中值滤波^[1]和 Wiener 滤波^[2]利用人工设计的滤波器去除图像噪声。若同一图像中具有很多相似图像块, 则非局部相似块堆叠的方式有助于去除特定类型噪声, 此类经典方法包括非局部均值算法^[3]和基于块匹配的 3D 滤波算法^[4]。但是, 此类块操作方法对参数选择十分敏感, 手动调整

较复杂, 且用于复杂混合噪声时效果有限。基于模型的方法试图对自然图像或噪声的分布进行建模, 然后将模型分布作为先验, 获得清晰的图像与优化算法。Gu 等^[5]提出一种基于低秩矩阵逼近的红外加权核范数最小化方法。Pang 等^[6]基于图的正则化器降低图像噪声。非局部自相似模型、稀疏模型、梯度模型和马尔可夫随机场模型等^[7]多种基于图像先验建模的方法的去噪性能虽较好, 但仍存在技术挑战。例如: 此类方法在测试阶段通常涉及复杂的优化问题, 导致去噪过程非常耗时, 因此在不牺牲计算效率的情况下, 基于先验图像的方法性能通常不高; 模型通常具有复杂的结构, 涉及几个手动选择的参数, 通过调节参数提高去噪性能十分困难。

与传统方法相比, 基于深度学习的方法在图像去噪领域也逐渐展现出优势, 无须复杂噪声建模和烦琐的手动调参, 近年来在图像去噪领域得到了广泛应用。Zhang 等^[8]通过叠加卷积、批归一化和校正线性单元层, 提出了一种简单有效的去噪卷积神经网络 (convolutional neural network,

CNN), 验证了 CNN 模型在图像去噪上的可行性。实验结果表明: DnCNN^[9]、U-Net^[10]、RED^[11]、MemNet^[12]和 SGN^[13]等基于 CNN 的图像去噪器的性能均优于传统去噪器。近年来, 基于 Transformer 的图像去噪网络日益流行, 如 CTNet^[14]、SUNet^[15]和 Dense residual Transformer for image denoising^[16], 与 CNN 相比, 去噪性能更优。然而, 有监督去噪模型训练严重依赖大量的噪声-干净图像对。但在真实场景中, 收集大量噪声-干净训练数据对极其具有挑战性和昂贵, 限制了有监督去噪方案的真实应用。

为缓解上述问题, 最新提出的无监督方法无须任何干净图像对即可完成模型训练, 获得了研究者青睐。Noise2Noise^[17]首次运用具有相同场景的多个噪声观测值训练降噪器。随后, Noise2Void^[18]和 Noise2Self^[19]用于训练每个场景只有一个噪声观测的网络。为获得更好的性能, Probabilistic Noise2Void^[20]、Laine 等^[21]的方法和 blind-spot network^[22]引入了显式噪声建模和概率推理。与基于盲点的自监督方法不同, Noisier2Noise^[23]将噪声模型生成的合成噪声添加到单个噪声图像, 以准备训练对。Neighbor2Neighbor^[24]从单张图像下采样生成图像, 以准备标签对。然而, 上述方法存在局限性。例如: 在真实场景中, 硬件设备的限制和算力资源的约束导致图像去噪的效率与性能难以兼顾。Zero-shot Noise2Noise^[25]虽然已经优化了下采样器, 但去噪效率与性能难以兼顾的限制并未得到改善。Noise2Info^[26]需给出噪声分布方差的理论上界, 并不断迭代更强大的模型, 以提升去噪性能, 对去噪性能与算力资源的平衡要求过高。SDAP^[27]同样优化了随机下采样过程, 但下采样器的采样效率并未获得很大提升。

同时, 在无监督去噪方法中, 扩散模型也广泛用于图像去噪, 如 DDPM^[28]等, 但由于扩散模型用于图像去噪时消耗的计算资源成本较高, 扩

散模型训练难度较大, 对初始条件较敏感, 因此难以利用先验信息。

与本文的去噪方案相比, Denoise Transformer^[29]等基于 Transformer 的去噪网络的自监督去噪方式十分复杂, 消耗的算力成本十分高昂。

针对上述挑战, 本文提出一种高效无监督学习的图像去噪方法, 改善了无监督去噪模型的训练效率与去噪性能不平衡的问题。具体而言, 该方法提出了一种更高效的深度下采样器, 通过对同一张噪声图像进行 4×4 窗口的深度近邻下采样, 将下采样后的图像输入去噪网络进行训练。深度近邻下采样指在尺寸为 4×4 的窗口中选取中心 2×2 区域中 4 个像素里任意两个相邻像素, 并作为单次下采样的结果, 不仅满足了无监督去噪模型对成对图像的像素相邻且外观非常相似的要求, 还舍弃了部分冗余信息, 提升了算法效率。该采样策略有望在高分辨率生物显微成像领域发挥更显著的作用。

2 材料与方法

2.1 数据来源

在标准红绿蓝空间的合成去噪实验中, 本文将 ImageNet^[30]验证数据集中的 5 万张图像作为干净图像的源, 具体如下: 仅选择大小在 256×256 像素和 512×512 像素间的干净图像, 然后随机裁剪 256×256 个补丁, 用于训练。本实验考虑了 4 种合成噪声分布:

- (1) 具有固定的高斯噪声, $\sigma = 25$;
- (2) 具有变化的高斯噪声, $\sigma \in [5, 50]$;
- (3) 具有固定的泊松噪声, $\lambda = 30$;
- (4) 具有变化的泊松噪声, $\lambda \in [5, 50]$ 。

其中, σ 值对应 $[0, 255]$ 中的图像颜色强度; λ 值对应 $[0, 1]$ 中的强度。本实验利用 Kodak^[31]、BSD300^[32]和 Set14^[33]图像集测试算法性能。此

外, 本实验利用 Fluorescence Microscopy Denoising (FMD)^[34]数据集中的公开荧光图像验证外部实验。

2.2 Neighbor2Neighbor 框架

Neighbor2Neighbor^[24]于 2021 年被提出, 仅需一张噪声图像即可对其进行去噪。Neighbor2Neighbor 算法的核心基于两个假设: 第一, Neighbor2Neighbor 使用参考标准相似的图片进行训练, 理论推理表明, 找到相似但不相同的含噪图像 y 和 z 时, 可用于降噪网络的训练; 第二, 从含噪图像 y 采样出来的图像被称为 neighbors。该算法框架构建了一个带约束的优化问题, 并构建了 Noise2Noise 的伪损失函数 L_{rec} 和其基于伪损失的正则项 L_{reg} 。最终的训练过程仅需优化损失函数 L , 表示如下:

$$L = L_{\text{rec}} + \gamma L_{\text{reg}} = \|f_{\theta}(g_1(y)) - g_2(y)\|_2^2 + \gamma \cdot \|f_{\theta}(g_1(y)) - g_2(y) - (g_1(f_{\theta}(y)) - g_2(f_{\theta}(y)))\|_2^2 \quad (1)$$

其中, f_{θ} 为一个具有任意网络设计的去噪网络; $g_1(y)$ 和 $g_2(y)$ 为随机近邻下采样器从单个噪声图像 y 生成的噪声图像对; $f_{\theta}(g_1(y))$ 为上述降噪网络处理后的下采样图像, $g_1(f_{\theta}(y))$ 和 $g_2(f_{\theta}(y))$ 为上述降噪网络处理后, 由同样的随机近邻下采样器生成的图像对; γ 为两个正则约束项的加权系数; L_{rec} 中 $f_{\theta}(g_1(y))$ 与 $g_2(y)$ 作差模方表示均方误差; L_{reg} 中 $f_{\theta}(g_1(y)) - g_2(y)$ 与 $g_1(f_{\theta}(y)) - g_2(f_{\theta}(y))$ 作差是对网络前后两个下采样图像差异的弥补, 是对原去噪损失的正则项补充。

因此, 该算法模型为了满足假设 1 中“使用参考标准相似的图片进行训练”, 下采样器选择十分关键。该论文中的随机近邻下采样把图像拆分为多个 2×2 的单元。在每个单元中随机选两个近邻的像素块, 分别赋给 $g_1(y)$ 和 $g_2(y)$, 最后构建了两个采样的子图。但是, 对于高分辨率成像场景中的超大尺寸图像而言, 该采样方式效率较低, 如生物医学显微图像。

2.3 主体框架及采样策略

针对现有的无监督学习去噪模型的采样效率问题, 本文设计了深度近邻下采样方法, 该策略使用 4×4 窗口的中心子采样器生成噪声图像对, 从噪声图像的单次观察中生成近似的子图像对, 具体如下:

(1) 假设尺度为 $[W, H]$ 的图像 y 被划分成 $[W/4, H/4]$, 即将图像划分成多个 4×4 单元, 在每个单元的 16 个像素中仅选取中心区域 2×2 单元中的任意近邻子块作为采样目标, 即随机选择两个像素组合拼接划分到两个子图中, 构造出两张“相似但不相同”的子图, 即 $D1(y)$ 和 $D2(y)$ 。该下采样器生成的图片也可近似为同一场景下的原始图片。

(2) 将生成的图像对用于训练, 并进一步使用正则化损失优化配对子采样噪声图像之间的非零地面真实差距。正则化损失由重建项和正则化项组成。网络训练采用 Neighbor2Neighbor, 其整体框架如图 1 所示。单张噪声图像 y 经过深度近邻下采样器生成两张相似的图片, 并作为网络训练的一组标签, 即 $D1(y)$ 和 $D2(y)$ 。损失项包括 Noise2Noise 的伪损失和其基于伪损失的正则项。

2.4 训练细节及评价方法

在标准红绿蓝空间的合成去噪实验中, 本文采用批量图像数为 4、初始学习率为 0.0003 的 Adam 优化器训练模型, 使用初始学习率为 0.0001 的 Adam 优化器进行 raw-RGB 空间中的真实图像去噪实验。训练周期设为 100, 学习率每 20 个周期衰减一半。对于用于控制正则化项强度的超参数 γ , 本文合成实验中设 $\gamma = 2$, 真实实验中设 $\gamma = 1$ 。所有实验均在一台装有 Python 3.6.4、PyTorch 1.3 和 GeForce_RTX_2080_Ti GPU 的服务器上进行。

针对高斯噪声和泊松噪声不同的噪声参数, 本文利用图像去噪前后的峰值信噪比

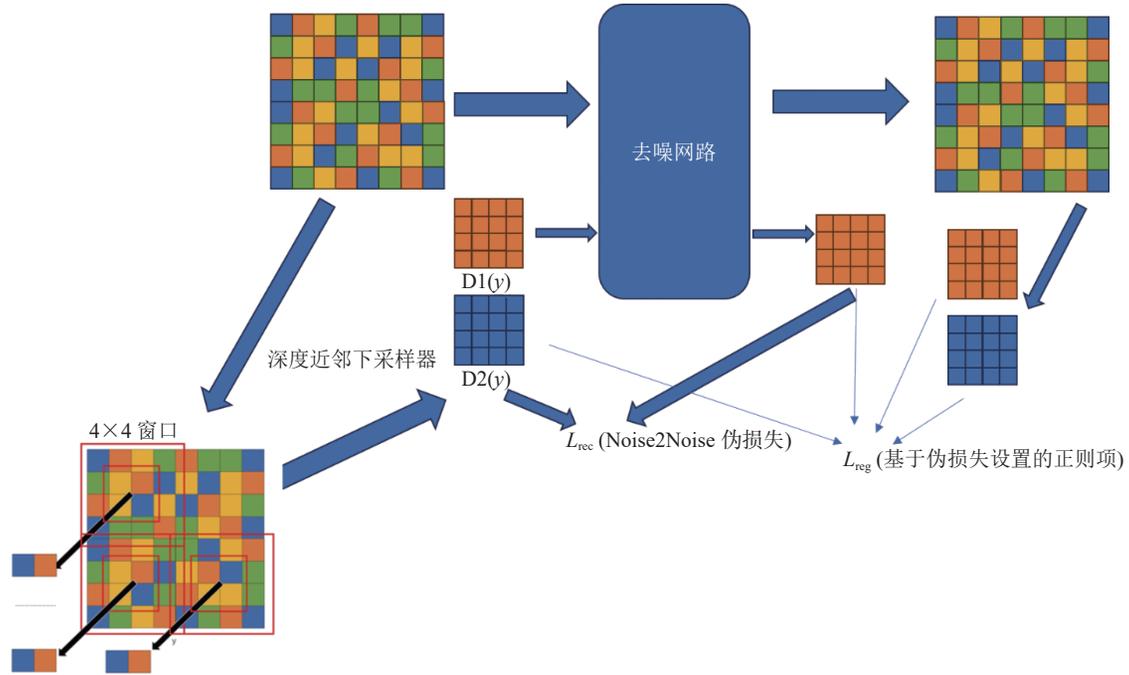


图 1 整体框架概述

Fig. 1 Overview of the overall framework

(peak signal-to-noise ratio, PSNR) 和结构相似性 (structure similarity index measure, SSIM) 评价去噪模型。

3 实验结果

3.1 不同采样器的实验结果与分析

本文通过实验对比分析 4 种下采样器在 KODAK、BSD300 和 SET14 等 3 个数据集上的去噪性能, 结果如表 1 所示。此外, 4 种下采样

器的效率和训练时间分别如表 2 和表 3 所示。

随机下采样器 2 和 4 的设计如图 2 所示, 深度近邻下采样器的设计如图 1 所示。由表 1、表 2 和表 3 可知, 在模型训练过程中, 与原下采样器相比, 随机下采样器 4、随机下采样器 2 和深度近邻下采样器的性能分别如下:

(1) 随机下采样器 4 在 3 组测试集上的性能均产生了较大衰减, PSNR 的平均衰减幅度约为 0.9%, SSIM 的平均衰减幅度约为 1.1%, 但其模型训练耗时最短。

表 1 4 种下采样器的性能

Table 1 Performance of 4 downsamplers

采样器类型	PSNR/SSIM		
	KODAK	BSD300	SET14
随机下采样器 2	32.05/0.878	30.87/0.876	31.06/0.863
深度近邻下采样器	31.95/0.873	30.79/0.871	31.00/0.859
随机下采样器 4	31.53/0.866	30.41/0.866	30.56/0.853
原下采样器	32.08/0.878	30.91/0.876	31.11/0.863

注: 实验噪声类型为 Gaussian_25

表 2 4 种下采样器的效率

Table 2 Efficiencies of 4 downsamplers

采样器类型	采样器尺寸	采样前后效率比	同尺寸归一化的性能参数
			PSNR/SSIM
随机下采样器 2	2×2	1:2	32.05/0.878
深度近邻下采样器	4×4	1:4	31.95/0.873
随机下采样器 4	4×4	1:4	31.53/0.866
原下采样器	2×2	1:2	32.08/0.878

注: 同尺寸归一化的性能参数噪声类型为 Gaussian_25, 测试集为 KODAK

表 3 4 种下采样器的训练时间

Table 3 Training time of 4 downsamplers

采样器类型	采样器尺寸	模型训练时间/h
随机下采样器 2	2×2	37.62
深度近邻下采样器	4×4	24.88
随机下采样器 4	4×4	23.24
原下采样器	2×2	36.32

注: 同尺寸归一化的性能参数噪声类型为 Gaussian5_50, 数据集为 ImageNet, 训练轮次为 100 epoch

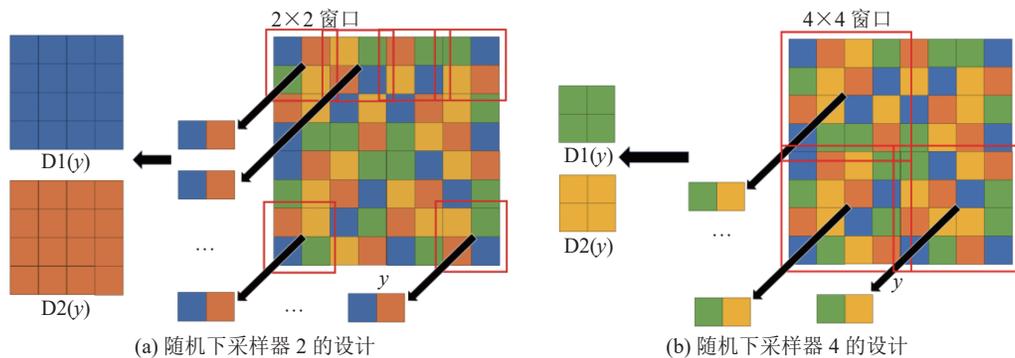


图 2 下采样器实验示意图

Fig. 2 Schematic diagram of downsampler experiment

(2) 随机下采样器 2 在 3 组测试集上的性能无较大变化, 表明像素块的增加并未提升模型的训练效果, 还增加了获取图像标签时的冗余信息。

(3) 深度近邻下采样器在 3 组测试集上的性能仅微弱衰减, PSNR 的平均衰减幅度约为 0.3%, SSIM 的平均衰减幅度约为 0.2%, 但在获取图像标签时采样效率提升了 1 倍, 模型训练时

间也相对较短。可见深度近邻下采样器在处理大尺寸图像的实际场景中十分有用。

3.2 不同噪声下深度近邻下采样器的实验结果

为进一步验证深度近邻下采样器对不同噪声模型的影响, 本文分别在 Gaussian 和 Poisson 两种常见噪声模型上进行了实验分析, 并验证了深度近邻下采样器对不同噪声分布参数的影响, 实验结果如表 4 所示。当 $\sigma = 25$ 时, 本文方法与其他方法

表4 深度近邻下采样器实验结果

Table 4 Experimental results of deep nearest neighbor downsampler

噪声类型	PSNR/SSIM		
	KODAK	BSD300	SET14
Gaussian_25	31.95/0.873	30.79/0.871	31.00/0.859
Gaussian5_50	31.09/0.842	29.96/0.838	30.12/0.835
Poisson_30	31.23/0.861	30.04/0.857	30.16/0.847
Poisson5_50	30.55/0.844	29.61/0.844	29.74/0.836

的视觉比较如图3所示。测试数据集分别来自BSD300和Kodak, PSNR(dB)和SSIM的定量结果列在图像下方。

由表4和表5可知,在4种噪声类型的实验中,深度近邻下采样器在3组测试集上的性能仅产生微弱衰减,PSNR的衰减幅度为0.3%~0.5%,SSIM的衰减幅度为0.2%~0.5%,表明本文采样方法未对去噪性能产生影响,即对不同噪声的鲁棒性较好。

本文方法与原下采样器方法的视觉比较如图4所示,从上到下,依次为 $\lambda \in [5, 50]$, $\lambda = 30$,

$\sigma \in [5, 50]$,定量PSNR(dB)/SSIM结果列在图像下方。

3.3 与领域内新技术的比较

深度近邻下采样方法与基线方法Neighbor2Neighbor^[24]、N2C^[35]、N2N^[14]、N2V^[15]和DBSN^[22]的定量分析比较如表6所示,表明本文方法性能与该领域新技术不相上下。

3.4 真实图像数据集实验结果

为验证本文提出的采样策略在真实荧光图像上的有效性,本文在真实荧光图像上进行了实验对比分析。不同噪声参数下,本文方法的实验结



图3 实验结果

Fig. 3 Experimental results

表 5 原下采样器实验结果

Table 5 Experimental results of Neighbor2Neighbor downsampler

噪声类型	PSNR/SSIM		
	KODAK	BSD300	SET14
Gaussian_25	32.08/0.878	30.91/0.876	31.11/0.863
Gaussian5_50	31.96/0.866	30.69/0.858	30.98/0.855
Poisson_30	31.44/0.871	30.22/0.866	30.30/0.852
Poisson5_50	30.70/0.846	29.75/0.849	29.90/0.841

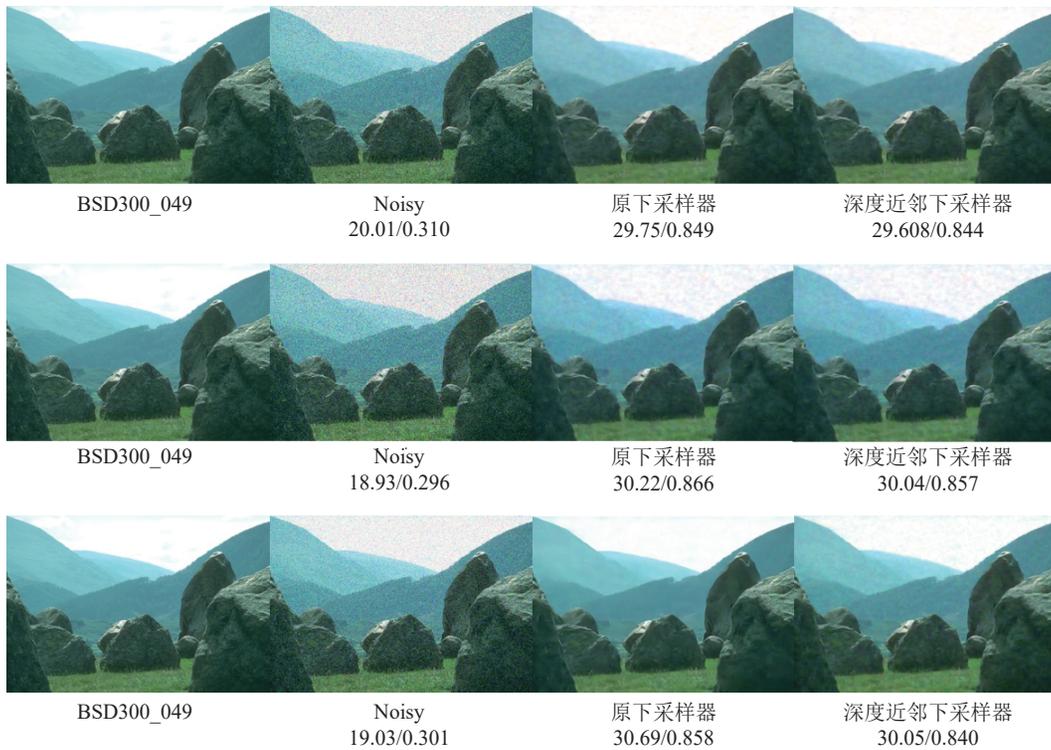


图 4 实验结果比较

Fig. 4 Experimental results comparison

果如图 5 所示。噪声参数为 Poisson5_50 时, FMD 公开数据集中 Confocal_BPAE_G 作为 test 集的效果如图 5(a) 所示。当噪声参数为 Poisson_30 时, FMD 公开数据集中 Confocal_BPAE_B 作为 test 集的效果如图 5(b) 所示。其中高质量的参考标准图像均为同一场景下拍摄的 50 张图像平均后的干净图像。实验结果表明: 本文方法推广至荧光显微镜图像仍然有效, 泛化性很强。图 5(a) 是 FMD 数据集中 Confocal_BPAE_G 在 Poisson5_50 噪声

分布下的干净、有噪和去噪实验结果。图 5(b) 是 FMD 数据集中 Confocal_BPAE_B 在 Poisson_30 噪声分布下的干净、有噪和去噪实验结果。

4 结 论

本文通过采样算法的设计和实验分析, 提出一种深度近邻采样的高效无监督学习去噪方法, 解决了无监督去噪模型训练效率与去噪性能不平

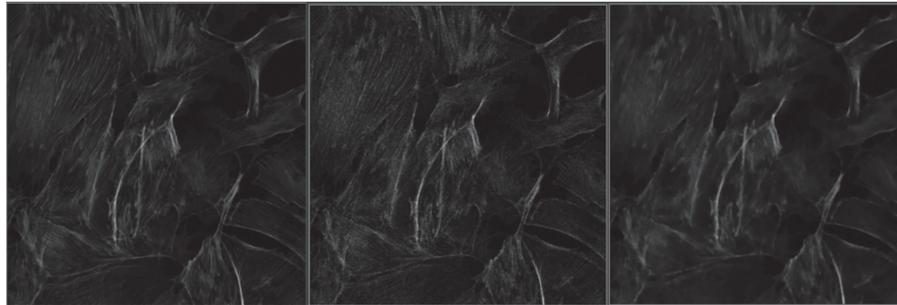
表 6 不同高斯噪声和泊松噪声参数下不同方法的定量比较

Table 6 Quantitative comparison of different methods for Gaussian noise and Poisson noise under various parameters

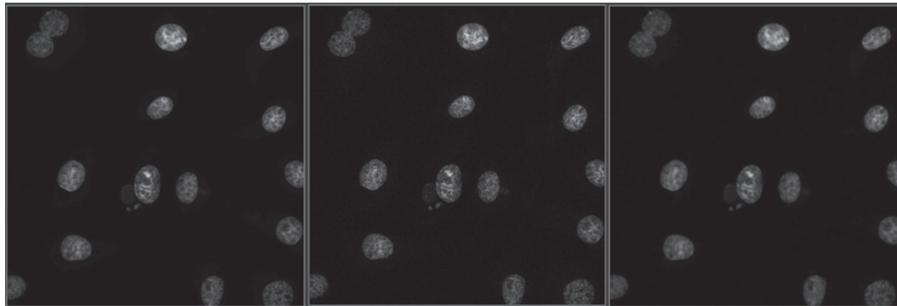
噪声类型	方法	PSNR/SSIM		
		KODAK	BSD300	SET14
Gaussian_25	N2C ^[35]	32.43/0.884	31.05/0.879	31.40/0.869
	N2N ^[14]	32.41/0.884	31.04/0.878	31.37/0.868
	N2V ^[15]	30.32/0.821	29.34/0.824	28.84/0.802
	DBSN ^[22]	31.64/0.856	29.80/0.839	30.63/0.846
	Neighbor2Neighbor ^[24]	32.08/0.878	30.91/0.876	31.11/0.863
	本文研究方法	31.95/0.873	30.79/0.871	31.00/0.859
Gaussian5_50	N2C ^[35]	32.51/0.875	31.07/0.866	31.41/0.863
	N2N ^[14]	32.50/0.875	31.07/0.866	31.39/0.863
	N2V ^[15]	30.44/0.806	29.31/0.801	29.01/0.792
	DBSN ^[22]	30.38/0.826	28.34/0.788	29.49/0.814
	Neighbor2Neighbor ^[24]	31.96/0.866	30.69/0.858	30.98/0.855
	本文研究方法	31.09/0.842	29.96/0.838	30.12/0.835
Poisson_30	N2C ^[35]	31.78/0.876	30.36/0.868	30.57/0.858
	N2N ^[14]	31.77/0.876	30.35/0.868	30.56/0.857
	N2V ^[15]	28.90/0.788	28.46/0.798	27.73/0.774
	DBSN ^[22]	30.07/0.827	28.19/0.790	29.16/0.814
	Neighbor2Neighbor ^[24]	31.44/0.871	30.22/0.866	30.30/0.852
	本文研究方法	31.23/0.861	30.04/0.857	30.16/0.847
Poisson5_50	N2C ^[35]	31.19/0.861	29.79/0.848	30.02/0.842
	N2N ^[14]	31.18/0.861	29.78/0.848	30.02/0.842
	N2V ^[15]	28.78/0.758	27.92/0.766	27.43/0.745
	DBSN ^[22]	29.60/0.811	27.81/0.771	28.72/0.800
	Neighbor2Neighbor ^[24]	30.70/0.846	29.75/0.849	29.90/0.841
	本文研究方法	30.55/0.844	29.61/0.844	29.74/0.836

衡的问题。此外，本文通过合成图像实验数据和真实荧光噪声图像进行了实验验证分析。实验结果表明：本文提出的深度近邻下采样策略对无监督去噪方法的训练效率有一定提升。然而，受计算资源和噪声数据采集条件的限制，目前本文工作仅在小尺寸的公开图像数据集上进行了实验分

析，还需进一步验证采样策略在真实采集的更大尺寸图像数据或在视频去噪等扩展任务中的潜力。同时，本文去噪模型框架仅采用了 U-Net 主干网络，后续工作考虑将本文方法带入更多更新的低算力成本无监督网络框架进行验证，可能对整体的去噪性能有更多提升。



(a) FMD 数据集中 Confocal_BPAE_G 在 Poisson5_50 噪声分布下的干净、有噪和去噪实验结果



(b) FMD 数据集中 Confocal_BPAE_B 在 Poisson30 噪声分布下的干净、有噪和去噪实验结果

图 5 FMD 数据集的实验结果

Fig. 5 Experimental results from FMD

参 考 文 献

- [1] Chen T, Ma KK, Chen LH. Tri-state median filter for image denoising [J]. IEEE Transactions on Image Processing, 1999, 8(12): 1834-1838.
- [2] Chen JD, Benesty J, Huang YT, et al. New insights into the noise reduction Wiener filter [J]. IEEE Transactions on Audio, Speech, and Language Processing, 2006, 14(4): 1218-1234.
- [3] Buades A, Coll B, Morel JM. A non-local algorithm for image denoising [C] // Proceedings of the 2005 IEEE Computer Society Conference on Computer Vision and Pattern Recognition, 2005: 60-65.
- [4] Dabov K, Foi A, Katkovnik V, et al. Image denoising by sparse 3-D Transform-domain collaborative filtering [J]. IEEE Transactions on Image Processing, 2007, 16(8): 2080-2095.
- [5] Gu SH, Zhang L, Zuo WM, et al. Weighted nuclear norm minimization with application to image denoising [C] // Proceedings of the 2014 IEEE Conference on Computer Vision and Pattern Recognition, 2014: 2862-2869.
- [6] Pang JH, Cheung G. Graph Laplacian regularization for image denoising: analysis in the continuous domain [J]. IEEE Transactions on Image Processing, 2017, 26(4): 1770-1785.
- [7] Goyal B, Dogra A, Agrawal S, et al. Image denoising review: from classical to state-of-the-art approaches [J]. Information Fusion, 2020, 55: 220-244.
- [8] Zhang KB, Gao XB, Tao DC, et al. Single image super-resolution with non-local means and steering kernel regression [J]. IEEE Transactions on Image Processing, 2012, 21(11): 4544-4556.
- [9] Zhang K, Zuo WM, Chen YJ, et al. Beyond a Gaussian denoiser: residual learning of deep CNN for image denoising [J]. IEEE Transactions on Image Processing, 2017, 26(7): 3142-3155.
- [10] Ronneberger O, Fischer P, Brox T. U-Net: convolutional networks for biomedical image segmentation [C] // Proceedings of the Medical Image Computing and Computer-Assisted Intervention, 2015: 234-241.

- [11] Mao XJ, Shen CH, Yang YB. Image restoration using very deep convolutional encoder-decoder networks with symmetric skip connections [Z/OL]. arXiv Preprint, arXiv: 1603.09056, 2016.
- [12] Tai Y, Yang J, Liu XM, et al. MemNet: a persistent memory network for image restoration [C] // Proceedings of the 2017 IEEE International Conference on Computer Vision, 2017: 4549-4557.
- [13] Gu SH, Li YW, Gool LV, et al. Self-guided network for fast image denoising [C] // Proceedings of the 2019 IEEE/CVF International Conference on Computer Vision, 2019: 2511-2520.
- [14] Tian CW, Zheng MH, Zuo WM, et al. A cross Transformer for image denoising [J]. Information Fusion, 2024, 102: 102043.
- [15] Fan CM, Liu TJ, Liu KH. SUNet: Swin Transformer UNet for image denoising [C] // Proceedings of the 2022 IEEE International Symposium on Circuits and Systems, 2022: 2333-2337.
- [16] Yao C, Jin S, Liu MQ, et al. Dense residual Transformer for image denoising [J]. Electronics, 2022, 11(3): 418.
- [17] Lehtinen J, Munkberg J, Hasselgren J, et al. Noise2Noise: learning image restoration without clean data [C] // Proceedings of the International Conference on Machine Learning, 2018: 2965-2974.
- [18] Krull A, Buchholz TO, Jug F. Noise2Void-learning denoising from single noisy images [C] // Proceedings of the 2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2019: 2124-2132.
- [19] Batson J, Royer L. Noise2Self: blind denoising by self-supervision [C] // Proceedings of the 36th International Conference on Machine Learning, 2019: 524-533.
- [20] Krull A, Vicar T, Jug F. Probabilistic Noise2Void: unsupervised content-aware denoising [Z/OL]. arXiv Preprint, arXiv: 1906.00651, 2019.
- [21] Laine S, Karras T, Lehtinen J, et al. High-quality self-supervised deep image denoising [C] // Proceedings of the Advances in Neural Information Processing Systems, 2019: 6970-6980.
- [22] Wu XH, Liu M, Cao Y, et al. Unpaired learning of deep image denoising [C] // Proceedings of the European Conference on Computer Vision, 2020: 352-368.
- [23] Moran N, Schmidt D, Zhong Y, et al. Noisier2Noise: learning to denoise from unpaired noisy data [C] // Proceedings of the 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2020: 12061-12069.
- [24] Huang T, Li SJ, Jia X, et al. Neighbor2Neighbor: self-supervised denoising from single noisy images [C] // Proceedings of the 2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2021: 14776-14785.
- [25] Mansour Y, Heckel R. Zero-shot Noise2Noise: efficient image denoising without any data [C] // Proceedings of the 2023 IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2023: 14018-14027.
- [26] Wang JC, Di SM, Chen L, et al. Noise2Info: noisy image to information of noise for self-supervised image denoising [C] // Proceedings of the 2023 IEEE/CVF International Conference on Computer Vision, 2023: 16034-16043.
- [27] Pan YZ, Liu X, Liao XY, et al. Random subsamples generation for self-supervised real image denoising [C] // Proceedings of the 2023 IEEE/CVF International Conference on Computer Vision, 2023: 12150-12159.
- [28] Ho J, Jain A, Abbeel P. Denoising diffusion probabilistic models [C] // Proceedings of the Advances in Neural Information Processing Systems, 2020: 6840-6851.
- [29] Zhang D, Zhou FF. Self-supervised image denoising for real-world images with Context-aware Transformer [J]. IEEE Access, 2023, 11: 14340-14349.
- [30] Deng J, Dong W, Socher R, et al. ImageNet: a large-scale hierarchical image database [C] // Proceedings of the 2009 IEEE Conference on Computer Vision and Pattern Recognition, 2009:

- 248-255.
- [31] Franzen R. Kodak lossless true color image suite [DB/OL]. [2023-10-10]. Source: <http://r0k.us/graphics/kodak>.
- [32] Martin D, Fowlkes C, Tal D, et al. A database of human segmented natural images and its application to evaluating segmentation algorithms and measuring ecological statistics [C] // Proceedings of the Eighth IEEE International Conference on Computer Vision, 2021: 416-423.
- [33] Zeyde R, Elad M, Protter M. On single image scale-up using sparse-representations [C] // Proceedings of the International Conference on Curves and Surfaces, 2010: 711-730.
- [34] Zhang YD, Zhu YH, Nichols E, et al. A Poisson-Gaussian denoising dataset with real fluorescence microscopy images [C] // Proceedings of the 2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2019: 11710-11718.
- [35] Ronneberger O, Fischer P, Brox T. U-Net: convolutional networks for biomedical image segmentation [C] // Proceedings of the International Conference on Medical Image Computing and Computer-Assisted Intervention, 2015: 234-241.