

## 一种基于深度学习的自适应医学超声图像去斑方法

付晓薇<sup>\*①②③</sup> 杨雪飞<sup>①②</sup> 陈芳<sup>④</sup> 李曦<sup>⑤</sup>

<sup>①</sup>(武汉大学 计算机科学与技术学院 武汉 430065)

<sup>②</sup>(智能信息处理与实时工业系统湖北省重点实验室 武汉 430065)

<sup>③</sup>(华中科技大学材料成形与模具技术国家重点实验室 武汉 430074)

<sup>④</sup>(武汉科技大学医院超声影像科 武汉 430065)

<sup>⑤</sup>(华中科技大学人工智能与自动化学院 武汉 430074)

**摘要:** 针对传统医学超声图像去斑方法的不足, 该文提出一种自适应多曝光融合框架和前馈卷积神经网络模型图像去斑方法。首先, 制作超声图像训练数据集; 然后, 提出一种自适应增强因子的多曝光融合框架, 增强图像进行有效特征提取; 最后, 通过网络训练去斑模型并获得去斑后的图像。实验结果表明, 该文较已有的方法, 能更有效地滤除医学超声图像中的斑点噪声并更多的保留图像细节。

**关键词:** 超声图像; 深度学习; 多曝光融合框架; 乘性斑点噪声

中图分类号: TN911.73

文献标识码: A

文章编号: 1009-5896(2020)07-1782-08

DOI: 10.11999/JEIT190580

## An Adaptive Medical Ultrasound Images Despeckling Method Based on Deep Learning

FU Xiaowei<sup>\*①②③</sup> YANG Xuefei<sup>①②</sup> CHEN Fang<sup>④</sup> LI Xi<sup>⑤</sup>

<sup>①</sup>(College of Computer Science and Technology, Wuhan University of Science and Technology, Wuhan 430065, China)

<sup>②</sup>(Key Laboratory of Intelligent Information Processing and Real-time Industrial System, Wuhan 430065, China)

<sup>③</sup>(State Key Laboratory of Materials Processing and Die & Mould Technology, Huazhong University of Science and Technology, Wuhan 430074, China)

<sup>④</sup>(Department of Ultrasound and Imaging, Wuhan University of Science and Technology Hospital, Wuhan 430065, China)

<sup>⑤</sup>(School of Artificial Intelligence and Automation, Huazhong University of Science and Technology, Wuhan 430074, China)

**Abstract:** Considering the shortage of traditional medical ultrasound image despeckle methods, an adaptive multi-exposure fusion framework and feedforward convolutional neural network model image despeckle method is proposed. Firstly, an ultrasound image training data set is produced. Then, a multi-exposure fusion framework with adaptive enhancement factors is proposed to enhance the image for effective feature extraction. Finally, a speckle model is trained through the network and a speckle image is obtained. Experimental results show that, compared with the existing methods, this paper can more effectively remove speckle noise in medical ultrasound images and retain more image details.

**Key words:** Ultrasound image; Deep learning; Multi-exposure fusion framework; Multiplicative speckle noise

收稿日期: 2019-07-31; 改回日期: 2020-03-18; 网络出版: 2020-04-11

\*通信作者: 付晓薇 fxw\_wh0409@wust.edu.cn

基金项目: 国家自然科学基金(61873323), 材料成形与模具技术国家重点实验室开放课题研究基金(P2018-016), 湖北省自然科学基金(2017CFB506), 智能信息处理与实时工业系统湖北省重点实验室开放课题项目(2016znss02A, znxx2018ZD01), 大学生科技创新基金项目(18ZRA076)

Foundation Items: The National Natural Science Foundation of China (61873323), The Open Fund Project of State Key Laboratory of Material Processing and Die & Mould Technology (P2018-016), The Natural Science Foundation of Hubei Provincial (2017CFB506), The Open Fund Project of Hubei Province Key Laboratory of Intelligent Information Processing and Real-time Industrial System (2016znss02A, znxx2018ZD01), The University Student Science and Technology Innovation Fund Project (18ZRA076)

## 1 引言

超声成像<sup>[1]</sup>是通过接收和处理从超声探头发射的回声, 其利用声波与活组织的相互作用来产生组织的图像。超声诊断技术被广泛用于医学临床诊断, 医学超声成像具有无创、低成本等优点, 其成像快、简单、便携。然而斑点噪声是超声图像不可避免的属性。由于相干声波的行进路径差异而不可避免地产生的斑点噪声, 不同程度降低医学超声图像的质量, 易导致其对比度、分辨率降低, 影响临床诊断的结果。斑点噪声干扰超声图像细节, 增大图像的定量测量和诊断难度<sup>[2]</sup>。抑制斑点噪声是医学图像特征提取、分析和识别的关键处理步骤。对于医学超声图像的分析, 临床诊断结果和治疗有着重要的影响。

超声图像的斑点抑制是提高图像质量和诊断准确性的先决条件<sup>[3]</sup>。早期传统的图像去斑方法主要分为3类<sup>[4]</sup>: 空间域方法、各向异性扩散滤波方法和变换域方法。虽然这些方法能去除噪声图像中的斑点, 但它们不能很好地保留原始图像的清晰特征。如: Lee, Kuan滤波器<sup>[5]</sup>, 这些滤波器只能在损失一定的边缘保持信息下降低噪声。3维块匹配滤波算法(Block-Matching and 3D filtering, BM3D)方法<sup>[6]</sup>可以被认为是当前效果较好的方法之一, 但该方法计算复杂度高且忽略了边缘信息<sup>[7]</sup>。文献<sup>[8,9]</sup>提出基于偏微分方程的各向异性扩散滤波方法(Perona-Malik Anisotropic Diffusion, PMAD)和散斑抑制各向异性扩散(Speckle Reducing Anisotropic Diffusion, SRAD)等方法能避免模糊原始图像和线性扩散线性滤波的定位问题, 但该类方法涉及更多迭代, 计算复杂。文献<sup>[10]</sup>使用的基于小波系数的非参数统计模型去斑方法(Non-Parametric Statistical Model, NPSM)是通过建立统计模型滤除图像中的斑点噪声。基于双树复小波变换的双变量收缩去噪方法(Bivariate Dual Tree Complex Wavelet Transform, BI-DTCWT)被应用于医学超声图像去斑<sup>[11]</sup>, 但边缘保持能力仍有限。尽管这些方法具有一定的去斑能力, 但基本都涉及复杂的优化问题和手动参数选择问题<sup>[12]</sup>。近些年, 深度学习的爆炸性发展为医学领域提出了新的思路, 很多学者将深度学习成功的应用于图像去噪。深度学习是一种可以从示例输入中学习并将数据驱动的预测或分类表示为输出的方法的构造。该类别的成功方法包括级联收缩场(Cascade of Shrinkage Fields, CSF)<sup>[13]</sup>、可训练的非线性反应扩散模型(Trainable Nonlinear Reaction Diffusion, TNRD)<sup>[14]</sup>、使用卷积编码器-解码器网络的图像恢复等方法<sup>[15]</sup>等。然而该类方法

本质上仅限于学习图像先验模型。Zhang等人<sup>[16]</sup>提出了一种判别学习模型, 采用残差学习将高斯噪声从噪声图像中分离出来, 从而达到去噪的效果。然而, 该方法是针对高斯加性噪声, 其抑制超声图像噪声能力有限。受此启发, 本文制作超声图像训练集, 通过引入改进的自适应多曝光融合框架提取特征, 构造了深度学习对医学超声图像去除乘性斑点噪声模型, 提出了一种超声医学图像去斑方法。所提方法与传统的医学超声图像去斑技术进行比较。实验结果表明, 本文方法较已有的方法不仅能产生良好的去斑性能, 而且更多地保留图像细节。

## 2 医学超声图像去斑模型

### 2.1 超声图像噪声模型

医学超声图像中的斑点表现为颗粒状且同时存在乘性噪声和加性噪声<sup>[17]</sup>。医学超声图像的斑点模型可以表示为

$$I(x, y) = S(x, y) \cdot \eta_m(x, y) + \eta_a(x, y), (x, y) \in Z^2 \quad (1)$$

其中,  $I(x, y)$ 为含斑点噪声图像,  $S(x, y)$ 为不含斑图像。 $\eta_m(x, y)$ ,  $\eta_a(x, y)$ 分别表示乘性和加性斑点噪声的影响。通常, 超声图像中加性噪声的影响不如乘性噪声的影响明显, 因此, 忽略 $\eta_a(x, y)$ , 可以改写为式(2)

$$I(x, y) = S(x, y) \cdot \eta_m(x, y) \quad (2)$$

然后将乘性噪声通过对数变换为加性噪声, 在式(2)的两边进行对数变换, 定义为

$$f(x, y) = g(x, y) + e(x, y) \quad (3)$$

式中,  $f(\cdot)$ ,  $g(\cdot)$ 和 $e(\cdot)$ 分别表示为 $I(x, y)$ ,  $S(x, y)$ ,  $\eta_m(x, y)$ 的对数变换。

### 2.2 残差网络

深度学习模型是一类可以通过从低级特征构建高级特征来学习特征层次结构的方式。这种学习方式可以使用有监督或无监督的方法进行训练。深度残差网络<sup>[18]</sup>的基本构建块如图1所示: 假如某网络输入层为 $x$ , 预期输出结果为 $H(x)$ 。若直接利用卷积层拟合一个潜在的恒等映射 $H(x) = x$ 是比较困难的。但如果把网络结构设计成 $H(x) = F(x) + x$ , 就可以把复杂的问题转换为学习一个残差函数 $F(x) = H(x) - x$ , 只需满足 $F(x) = 0$ , 然后就构成了一个恒等映射。因此, 较直接利用卷积层拟合, 这种网络学习起来更加容易。残差学习和批量标准化的结合即可以加快训练的过程, 也可以提高去斑的能力。

### 2.3 自适应多曝光融合框架

低光图像增强的生物启发多曝光融合框架<sup>[19]</sup>增强图像定义为式(4)




图1 残差网络的基本结构

$$\mathbf{R}^c = \widehat{\mathbf{W}} \cdot \mathbf{P}^c + (1 - \widehat{\mathbf{W}}) \cdot g(\mathbf{P}^c, \widehat{k}) \quad (4)$$

$$g(\mathbf{P}^c, \widehat{k}) = e^{b(1-k^a)} \mathbf{P}^{(k^a)} \quad (5)$$

增强问题可分为3个部分:多曝光评估器( $\mathbf{W}$ )、多曝光发生器( $g$ )和多曝光采样器( $k$ )的确定。其中,  $c$ 为颜色通道的索引。 $\mathbf{R}$ 为增强的结果。 $\mathbf{P}$ 为输入图像。 $g(\bullet)$ 为BTF模型定义式; $\widehat{k}$ 为根据图像熵计算出最佳曝光比。 $\widehat{\mathbf{W}}$ 为权重矩阵,其定义为

$$\widehat{\mathbf{W}} = T^u \quad (6)$$

其中,  $T$ 为场景光照图,  $u$ 为控制增强程度的参数。本文根据全局标准差与局部标准差<sup>[20]</sup>,提出了一种自适应增强因子 $u'$ ,其定义为

$$u' = \frac{\sqrt{\frac{1}{M \times N} \sum_{i=1}^M \sum_{j=1}^N (X(i, j) - E)^2}}{\sqrt{\frac{1}{m \times n} \sum_{k=1}^m \sum_{t=1}^n (x(k, t) - e)^2 + \frac{1}{M \times N} \sum_{i=1}^M \sum_{j=1}^N X(i, j)}} \quad (7)$$

其中,  $M \times N$ 表示图像大小,  $m \times n$ 表示局部窗口大小。 $X(i, j)$ 表示第 $i$ 行、第 $j$ 列的像素值。其中局部标准差与全局标准差用来控制增强程度,均值为一个常数,用来均衡整体增强程度。新的权重矩阵 $\widehat{\mathbf{W}}'$ 被定义为

$$\widehat{\mathbf{W}}' = T^{u'} \quad (8)$$

当 $u' = 0$ 时,得到的 $\mathbf{R} = \mathbf{P}$ ,即不进行增强。当 $u' = 1$ 时,低曝光和高曝光像素都得到增强。当 $u' > 1$ 时,像素可能会饱和,导致 $\mathbf{R}$ 细节丢失。自适应增强因子与局部均标准差相关,局部标准差较大,说明隶属高频程度较大, $u'$ 值较大;反之, $u'$ 值较小。

## 2.4 去斑模型架构

根据残差网络原理,本文搭建一种深度卷积网络体系实现医学超声图像去斑。将自适应融合框架与深度学习相结合,以提高模型学习能力。并结合批量标准化与残差学习,以提高模型的学习准确性和训练速度。根据残差学习策略,假设 $H(i)$ 为含斑点的医学超声图像, $F(i)$ 为斑点噪声图像, $i$ 为去斑图像。利用残差学习, $F(i) = H(i) - i$ 找到最优的恒等映射的斑点噪声输出。具体流程如图2所示。




图2 本文流程图

根据文献<sup>[21]</sup>,本文设计的模型架构具有15层深度。通过最小化方程式中的损失函数进行训练,本文的损失函数定义如式(9)所示

$$l(\delta) = \frac{1}{2N} \sum_{x=1}^N \|\boldsymbol{\eta}(\mathbf{I}; \delta) - (\mathbf{I}_x - \mathbf{S}_x)\|_F^2 \quad (9)$$

其中,  $\delta$ 表示可训练参数,  $\{\mathbf{I}_x, \mathbf{S}_x\}_{x=1}^N$ 是 $N$ 个噪声-干净训练图像对,  $F$ 表示的是Frobenius范数。

图3为网络结构图。首先,采光器根据输入图像自身信息熵获取最佳曝光比 $k$ ;生成器根据模型和曝光比合成曝光图像;评估器自适应分配权值;组合器 $\mathbf{R}$ 根据式(4)生成融合后的图像。根据文献<sup>[22]</sup>中的原则,将卷积滤波器的大小设置为 $3 \times 3$ 。然后,在神经网络第1层中,使用的是64个大小为 $3 \times 3 \times 1$ 的滤波器从斑点噪声图像生成64个特征图,其中 $3 \times 3$ 是在输入图像上卷积的高度和宽度,1是图像通道数。该层最后是ReLu激活功能。然后,2~14层(隐藏层)是具有64个大小为 $3 \times 3 \times 64$ 的滤波器,以再次生成64个特征映射,并结合批量标准化,然后再生成ReLu激活函数。最后,第15层是一个具有大小为 $3 \times 3 \times 64$ 卷积层数的滤波器来重建输出。通过用超声斑点噪声图像,减去模型中利用批量化标准和残差学习的组合中逐渐识别的残差项模型,从而得到去斑后的图像。

## 3 实验结果及分析

### 3.1 实验环境及训练数据

为了检验本文方法的有效性,分别对模拟斑点超声图像和含有真实斑点噪声的超声图像进行大量的实验。实验在MATLAB R2016a编程环境中进行仿真。同时使用MatConvNet包<sup>[23]</sup>训练数据。Mat-

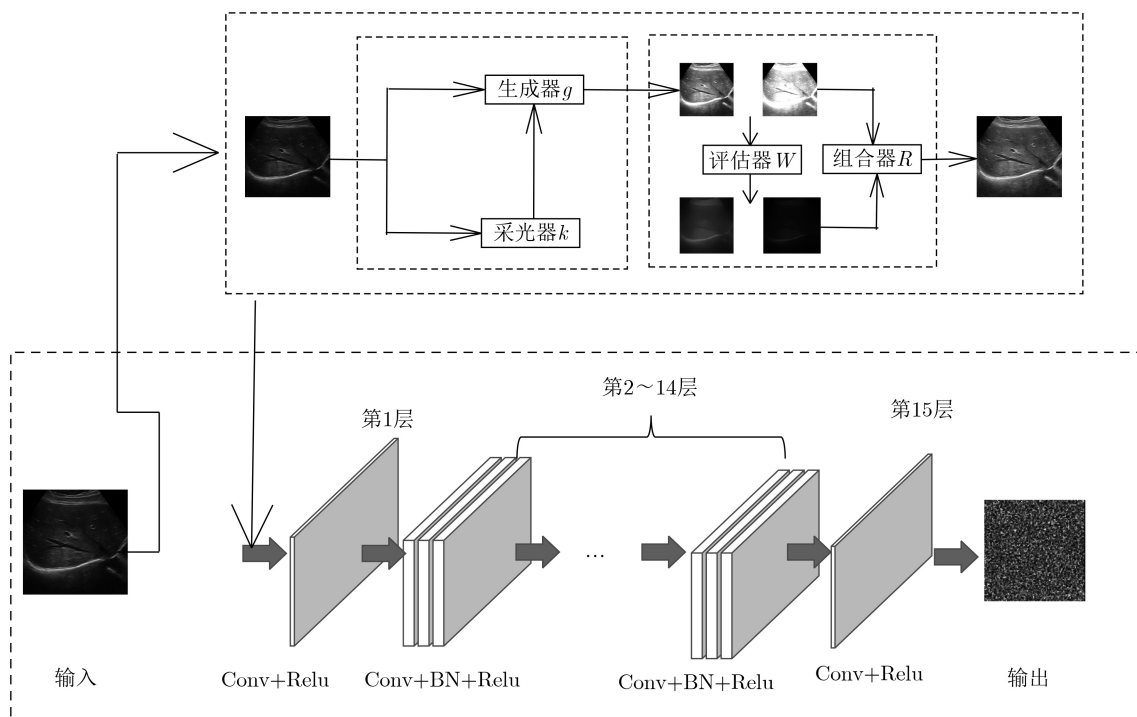


图3 网络结构图

ConvNet是一个开源的MATLAB工具箱,用于计算机视觉和多媒体应用的卷积神经网络训练数据。

由于医学超声图像开源训练样本集较少,本文筛选由医院临床超声影像科的西门子Simens超声诊断系统ACUSON SC2000收集的成像质量较高、抑噪理想的图像用作训练样本。将收集的图像裁剪为 $180 \times 180$ 像素大小。并通过旋转、反转、平移、裁剪等数据扩充方法,将训练样本大小设置为400幅图像。测试数据集为不包括在训练数据集中图像。

### 3.2 实验比较及分析

为了实现客观评价,本文采用如下3种评价指标:峰值信噪比(Peak Signal to Noise Ratio, PSNR)、边缘保持度( $\beta$ ),等效视数(Equivalent Number of Looks, ENL)<sup>[24]</sup>作为客观评价指标,检验方法的去斑效果。实验比较的方法分别是BI-DTCWT<sup>[11]</sup>, NPSM<sup>[10]</sup>, NL\_means<sup>[25]</sup>, BM3D<sup>[6]</sup>, Local\_entropy\_qsp<sup>[26]</sup>, DnCNN<sup>[16]</sup>图像去斑方法。

#### 3.2.1 模拟斑点超声图像实验

本文利用<http://telin.ugent.be/~sanja/>提供的方法模拟生成斑点噪声来用于模型训练<sup>[27]</sup>,文献<sup>[27]</sup>指出该模拟斑点噪声程序可较好地模拟生成实际含斑的医学超声图像。

本文进行了大量样本图像实验,分别训练了含噪声标准差为0.5~0.9的训练模型。图4和图5分别是两张含标准差为0.7的模拟斑点肝脏超声图像去斑效果图。图4(a)和图5(a)为含有较少斑点噪声的

肝脏超声原始图像,图4(b)和图5(b)为模拟加斑点噪声后的超声图像,图4(c)—图4(i)、图5(c)—图5(i)分别为BI-DTCWT, NPSM, NL\_means, BM3D, Local\_entropy\_qsp, DnCNN及本文方法的去斑视觉效果。由此可知,本文方法取得了较好的主观去斑效果,且保持了更多的原始图像细节,与原图像更接近。图4(c)—图4(e)、图4(g)以及图5(c)—图5(e)、图5(g)中图像仍含有明显的斑点噪声。图4(f)、图4(h)和图5(f)、图5(h)虽然取得了较好的效果,但较本文方法,细节损失较多。为了客观评价不同方法的抑噪的性能,表1—表4分别给出模拟斑点噪声标准差为0.5~0.9的肝脏图像1和2不同方法的峰值信噪比PSNR、边缘保持度 $\beta$ 的客观评价指标值。如表1—表4所示,本文方法可获得较大的峰值信噪比、边缘保持度,相较于其他方法,PSNR指标值提高了0.5~6dB, $\beta$ 的指标值提高了0.1~0.4 dB。其客观评价结果与主观视觉效果基本一致,本文方法抑斑效果较好。

#### 3.2.2 真实超声图像实验

医学超声图像普遍受到斑点噪声的影响。该组采用大小为 $210 \times 210$ 像素的含有真实斑点的胎儿超声图像作为实验对象,所比较方法的去斑效果如图6所示。图6(c)—图6(i)分别是BI-DTCWT, NPSM, NL\_means, BM3D, Localentropy\_qsp, DnCNN和本文方法去斑效果图。由图6(c)、图6(d)、图6(g)可见,结果中仍含有明显的斑点噪声。图6(e)、




图4 模拟斑点肝脏超声图像1实验比较




图5 模拟斑点肝脏超声图像2实验比较

图6(f)、图6(h)虽然在一定程度上能去除斑点噪声, 但图像存在不同程度的模糊, 损失了一些图像

细节。相比而言, 本文方法在主观视觉上, 可获得较好的平滑效果, 抑制斑点噪声效果更好。本文采

表 1 模拟斑点肝脏超声图像1不同方法PSNR结果(dB)

方法	斑点噪声的标准差 $\sigma$				
	0.5	0.6	0.7	0.8	0.9
BI-DTCWT	35.4225	33.8461	32.5368	31.4265	30.3688
NPSM	34.5827	32.9573	31.5366	30.3250	29.2056
NL-means	34.9289	34.1934	33.3554	32.5658	31.6134
BM3D	36.1701	35.7552	35.2485	34.8951	34.2035
Local_entropy_qsp	<b>36.7812</b>	36.1083	35.4363	35.0726	34.5014
DnCNN	35.7701	35.8394	35.8180	35.6769	35.3885
本文方法	36.7203	<b>36.7139</b>	<b>36.6025</b>	<b>36.3568</b>	<b>35.9492</b>

表 3 模拟斑点肝脏超声图像1不同方法 $\beta$ 结果

方法	斑点噪声的标准差 $\sigma$				
	0.5	0.6	0.7	0.8	0.9
BI-DTCWT	0.6416	0.5611	0.4823	0.4291	0.3846
NPSM	0.5972	0.5154	0.4352	0.3817	0.3393
NL-means	0.4522	0.4102	0.3564	0.3262	0.2949
BM3D	0.5969	0.5820	0.5685	0.5477	0.5016
Local_entropy_qsp	0.6540	0.6287	0.5991	0.5842	0.5621
DnCNN	0.7803	0.7726	0.7595	0.7393	0.7106
本文方法	<b>0.8128</b>	<b>0.8011</b>	<b>0.7831</b>	<b>0.7564</b>	<b>0.7208</b>

表 2 模拟斑点肝脏超声图像2不同方法PSNR结果(dB)

方法	斑点噪声的标准差 $\sigma$				
	0.5	0.6	0.7	0.8	0.9
BI-DTCWT	31.0477	29.5409	28.0856	27.4342	26.2056
NPSM	31.5374	30.0985	28.6745	27.6699	26.6843
NL-means	32.7360	31.7539	30.4860	29.5105	28.4174
BM3D	33.8786	33.3096	32.5436	32.0199	31.2079
Local_entropy_qsp	34.3157	33.2426	32.1706	31.5329	30.8599
DnCNN	34.9760	35.0382	34.8497	34.3851	33.6562
本文方法	<b>35.9280</b>	<b>35.9170</b>	<b>35.6289</b>	<b>35.0301</b>	<b>34.1677</b>

表 4 模拟斑点肝脏超声图像2不同方法 $\beta$ 结果

方法	斑点噪声的标准差 $\sigma$				
	0.5	0.6	0.7	0.8	0.9
BI-DTCWT	0.7078	0.6359	0.5612	0.5099	0.4661
NPSM	0.6830	0.6197	0.5479	0.4990	0.4517
NL-means	0.7191	0.6761	0.6037	0.5449	0.4899
BM3D	0.8030	0.7950	0.7826	0.7683	0.7355
Local_entropy_qsp	0.8263	0.8090	0.7787	0.7567	0.7384
DnCNN	0.9286	0.9238	0.9156	0.9029	0.8812
本文方法	<b>0.9394</b>	<b>0.9325</b>	<b>0.9217</b>	<b>0.9653</b>	<b>0.8836</b>




图 6 真实医学超声图像去斑后结果比较

用等效视数作为真实超声图像去斑的评价指标。其中白色方框为标记的同质区域。

表5列出了对真实超声图像进行相关方法处理后的ENL等效视数值比较结果。表6中50张含真实斑点的超声图像分别来自我校附属医院医学超声科EPIQ5彩色多普勒超声诊断仪临床采集的随机25张图像和Sirindhorn国际技术研究所的生物学工程部门<sup>[28]</sup>提供的随机25张图像。实验对每张图标记一个同质区域,并统计每种方法ENL平均值。由表6可知,本文方法能获得较大的等效视数指标值,与主观上观察的去斑效果一致,本文方法在有效抑制斑点噪声的同时保持了更多的图像细节。

表5 真实斑点超声图像不同方法ENL结果

方法	ENL等效视数值
BI-DTCWT	61.2209
NPSM	64.6016
NL-means	109.5584
BM3D	93.4877
Local_entropy_qsp	79.1016
DnCNN	132.9184
本文方法	<b>134.3287</b>

表6 50张真实斑点超声图像不同方法ENL平均值比较

方法	ENL等效视数值平均值
BI-DTCWT	75.5182
NPSM	75.5941
NL-means	110.6393
BM3D	110.9127
Local_entropy_qsp	93.7911
DnCNN	140.3622
本文方法	<b>147.0689</b>

## 4 结论

本文将提出的自适应增强因子的多曝光融合框架和深度学习相结合,从输入图像数据中学习其特征结构,然后应用到医学超声图像中,从而达到去斑的效果。并结合批量标准化和残差网络,加快训练过程,提高了模型的性能。通过与现有的图像去噪算法的对比,所提方法具有更好的医学超声图像细节保持能力,去斑效果显著。与此同时,还可以提高信噪比和图像的质量。本方法为医学超声图像去斑提供了一种新的有效思路,为随后的医学超声图像去斑处理奠定良好的基础。

## 参考文献

[1] KANAYAMA Y and YANO M. Ultrasound diagnosis

apparatus and ultrasound imaging method[P]. USA Patent, 10231710, 2019.

- [2] ZHOU Yingyue, ZANG Hongbin, XU Su, *et al.* An iterative speckle filtering algorithm for ultrasound images based on bayesian nonlocal means filter model[J]. *Biomedical Signal Processing and Control*, 2019, 48: 104–117. doi: [10.1016/j.bspc.2018.09.011](https://doi.org/10.1016/j.bspc.2018.09.011).
- [3] JOEL T and SIVAKUMAR R. An extensive review on Despeckling of medical ultrasound images using various transformation techniques[J]. *Applied Acoustics*, 2018, 138: 18–27. doi: [10.1016/j.apacoust.2018.03.023](https://doi.org/10.1016/j.apacoust.2018.03.023).
- [4] 沈民奋, 陈婷婷, 张琼, 等. 医用超声图像散斑去噪方法综述[J]. *中国医疗器械信息*, 2013, 19(3): 17–22. doi: [10.3969/j.issn.1006-6586.2013.03.003](https://doi.org/10.3969/j.issn.1006-6586.2013.03.003).
- SHEN Minfen, CHEN Tingting, ZHANG Qiong, *et al.* The review of speckle denoising in medical ultrasound imaging[J]. *China Medical Device Information*, 2013, 19(3): 17–22. doi: [10.3969/j.issn.1006-6586.2013.03.003](https://doi.org/10.3969/j.issn.1006-6586.2013.03.003).
- [5] KUAN D, SAWCHUK A, STRAND T, *et al.* Adaptive restoration of images with speckle[J]. *IEEE Transactions on Acoustics, Speech, and Signal Processing*, 1987, 35(3): 373–383. doi: [10.1109/TASSP.1987.1165131](https://doi.org/10.1109/TASSP.1987.1165131).
- [6] 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. doi: [10.1109/TIP.2007.901238](https://doi.org/10.1109/TIP.2007.901238).
- [7] 肖佳, 张俊华, 梅礼晔. 改进的三维块匹配去噪算法[J]. *计算机科学*, 2019, 46(6): 288–294. doi: [10.11896/j.issn.1002-137X.2019.06.043](https://doi.org/10.11896/j.issn.1002-137X.2019.06.043).
- XIAO Jia, ZHANG Junhua, and MEI Liye. Improved block-matching 3D denoising algorithm[J]. *Computer Science*, 2019, 46(6): 288–294. doi: [10.11896/j.issn.1002-137X.2019.06.043](https://doi.org/10.11896/j.issn.1002-137X.2019.06.043).
- [8] PERONA P and MALIK J. Scale-space and edge detection using anisotropic diffusion[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 1990, 12(7): 629–639. doi: [10.1109/34.56205](https://doi.org/10.1109/34.56205).
- [9] YU Yongjian and ACTON S T. Speckle reducing anisotropic diffusion[J]. *IEEE Transactions on Image Processing*, 2002, 11(11): 1260–1270. doi: [10.1109/TIP.2002.804276](https://doi.org/10.1109/TIP.2002.804276).
- [10] TIAN Jing and CHEN Li. Image despeckling using a non-parametric statistical model of wavelet coefficients[J]. *Biomedical Signal Processing and Control*, 2011, 6(4): 432–437. doi: [10.1016/j.bspc.2010.11.006](https://doi.org/10.1016/j.bspc.2010.11.006).
- [11] SENDUR L and SELESNICK I W. Bivariate shrinkage functions for wavelet-based denoising exploiting interscale dependency[J]. *IEEE Transactions on Signal Processing*, 2002, 50(11): 2744–2756. doi: [10.1109/TSP.2002.804091](https://doi.org/10.1109/TSP.2002.804091).
- [12] BURGER H C, SCHULER C J, and HARMELING S.

- Image denoising: Can plain neural networks compete with BM3D?[C]. 2012 IEEE Conference on Computer Vision and Pattern Recognition, Providence, USA, 2012: 2392–2399.
- [13] SCHMIDT U and ROTH S. Shrinkage fields for effective image restoration[C]. The IEEE Conference on Computer Vision and Pattern Recognition, Columbus, USA, 2014: 2774–2781.
- [14] CHEN Yunjin and POCK T. Trainable nonlinear reaction diffusion: A flexible framework for fast and effective image restoration[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2017, 39(6): 1256–1272. doi: [10.1109/TPAMI.2016.2596743](https://doi.org/10.1109/TPAMI.2016.2596743).
- [15] MAO Xiaojiao, SHEN Chunhua, and YANG Yubin. Image restoration using very deep convolutional encoder-decoder networks with symmetric skip connections[C]. Advances in Neural Information Processing Systems, Red Hook, USA, 2016: 2802–2810.
- [16] ZHANG Kai, ZUO Wangmeng, CHEN Yunjin, *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. doi: [10.1109/TIP.2017.2662206](https://doi.org/10.1109/TIP.2017.2662206).
- [17] NADEEM M, HUSSAIN A, and MUNIR A. Fuzzy logic based computational model for speckle noise removal in ultrasound images[J]. *Multimedia Tools and Applications*, 2019, 78(9): 18531–18548.
- [18] 吕晓琪, 吴凉, 谷宇, 等. 基于深度卷积神经网络的低剂量CT肺部去噪[J]. *电子与信息学报*, 2018, 40(6): 1353–1359. doi: [10.11999/JEIT170769](https://doi.org/10.11999/JEIT170769).
- LÜ Xiaoqi, WU Liang, GU Yu, *et al.* Low dose CT lung denoising model based on deep convolution neural network[J]. *Journal of Electronics & Information Technology*, 2018, 40(6): 1353–1359. doi: [10.11999/JEIT170769](https://doi.org/10.11999/JEIT170769).
- [19] YING Zhenqiang, LI Ge, REN Yurui, *et al.* A new image contrast enhancement algorithm using exposure fusion framework[C]. The 17th International Conference on Computer Analysis of Images and Patterns, Ystad, Sweden, 2017: 36–46.
- [20] ZHENG D, WANG J, and XIAO Z. Image enhancement based on local standard deviation[J]. *Journal of Information and Computational Science*, 2005, 2(2): 429–437.
- [21] JIFARA W, JIANG Feng, RHO S, *et al.* Medical image denoising using convolutional neural network: A residual learning approach[J]. *The Journal of Supercomputing*, 2019, 75(2): 704–718. doi: [10.1007/s11227-017-2080-0](https://doi.org/10.1007/s11227-017-2080-0).
- [22] SIMONYAN K and ZISSERMAN A. Very deep convolutional networks for large-scale image recognition[J]. arXiv, 2014, 1409.1556.
- [23] VEDALDI A and LENC K. MatconvNet: Convolutional neural networks for MATLAB[C]. The 23rd ACM International Conference on Multimedia, Brisbane, Australia, 2015: 689–692.
- [24] FU Xiaowei, WANG Yi, CHEN Li, *et al.* An image despeckling approach using quantum-inspired statistics in dual-tree complex wavelet domain[J]. *Biomedical Signal Processing and Control*, 2015, 18: 30–35. doi: [10.1016/j.bspc.2014.11.005](https://doi.org/10.1016/j.bspc.2014.11.005).
- [25] BUADES A, COLL B, and MOREL J M. A non-local algorithm for image denoising[C]. 2005 IEEE Computer Society Conference on Computer Vision and Pattern Recognition, San Diego, USA, 2005: 60–65.
- [26] 付晓薇, 代芸, 陈黎, 等. 基于局部熵的量子衍生医学超声图像去斑[J]. *电子与信息学报*, 2015, 37(3): 560–566. doi: [10.11999/JEIT140587](https://doi.org/10.11999/JEIT140587).
- FU Xiaowei, DAI Wei, CHEN Li, *et al.* Quantum-inspired despeckling of medical ultrasound images based on local entropy[J]. *Journal of Electronics & Information Technology*, 2015, 37(3): 560–566. doi: [10.11999/JEIT140587](https://doi.org/10.11999/JEIT140587).
- [27] PIZURICA A, PHILIPS W, LEMAHIEU I, *et al.* A versatile wavelet domain noise filtration technique for medical imaging[J]. *IEEE Transactions on Medical Imaging*, 2003, 22(3): 323–331. doi: [10.1109/TMI.2003.809588](https://doi.org/10.1109/TMI.2003.809588).
- [28] RODTOOK A and MAKHANOV S S. Multi-feature gradient vector flow snakes for adaptive segmentation of the ultrasound images of breast cancer[J]. *Journal of Visual Communication and Image Representation*, 2013, 24(8): 1414–1430. doi: [10.1016/j.jvcir.2013.09.009](https://doi.org/10.1016/j.jvcir.2013.09.009).
- 付晓薇: 女, 1977年生, 教授, 研究方向为图像处理、计算机视觉、信号处理与分析。
- 杨雪飞: 女, 1994年生, 硕士生, 研究方向为图像处理、深度学习。
- 陈芳: 女, 1972年生, 研究方向为肌骨超声图像的调节。
- 李曦: 男, 1977年生, 教授, 研究方向为计算机应用, 复杂非线性系统的建模和控制。