

带边缘增强的双树复小波阈值去噪方法

唐超¹, 石艳^{2*}¹广州科技职业技术大学信息工程学院, 广东 广州 510550;²岭南师范学院信息工程学院, 广东 湛江 524048

摘要 针对现有的高斯噪声去除方法的边缘保持能力差、去噪图像对比度低等缺陷, 提出一种带边缘增强的双树复小波阈值去噪方法。充分利用双树复小波的平移不变性和多方向选择性等优秀特性, 根据高斯噪声的数学模型, 由假设推导出一种自适应的双树复小波阈值去噪模型; 提出一种多向梯度算子, 对由阈值去噪模型得出的去噪图像进行边缘提取; 最后对边缘图像与去噪图像进行线性有参叠加, 得到边缘增强的去噪图像。实验结果证明, 所提方法具有良好的去噪性能、边缘保持能力和快速的计算效率。

关键词 图像去噪; 双树复小波; 阈值去噪; 边缘增强; 多向梯度算子

中图分类号 TP391 文献标志码 A

DOI: 10.3788/LOP212703

Dual-Tree Complex Wavelet Threshold Denoising Method with Edge Enhancement

Tang Chao¹, Shi Yan^{2*}

¹College of Information Engineering, Guangzhou Vocational and Technical University of Science and Technology, Guangzhou 510550, Guangdong, China;

²School of Information Engineering, Lingnan Normal University, Zhanjiang 524048, Guangdong, China

Abstract This study proposed a dual-tree complex wavelet threshold denoising method with edge enhancement to address the poor edge preservation and low contrast of denoising image in existing Gaussian noise removal methods. The proposed method employed the exceptional dual-tree complex wavelet properties such as translation invariance and multi-directional selectivity. Thus, an adaptive threshold denoising model of dual-tree complex wavelet was presented based on the mathematical model of Gaussian noise and assumption. Furthermore, a multi-directional gradient operator was proposed to obtain an edge image from the denoising image using the threshold denoising model. The edge image was linearly parametrically superimposed on the denoising image to achieve the final denoising image with edge enhancement. The experimental results verify that the proposed method performs well in noise reduction and edge preservation. It also demonstrates that the proposed method has a higher computational efficiency.

Key words image denoising; dual-tree complex wavelet; threshold denoising; edge enhancement; multi-directional gradient operator

1 引言

在成像与图像处理的过程中, 图像经常受到高斯噪声的污染。噪声严重影响图像的处理、分析和应用, 图像去噪非常必要。高斯噪声服从高斯分布, 分布于图像的所有像素上, 去除难度较大^[1]。最初地, 均值滤波算法用于去除高斯噪声, 但是去噪效果较差。针对

已有的去噪方法难以取得满意的去噪效果的问题, Dabov等^[2]于2007年提出了里程碑式的三维协同滤波方法(BM3D)。后来部分学者不断提出各种去噪方法, 欲超越BM3D, 在一定程度上提升了去噪性能, 但又带来了本身固有的缺陷。为了提升去噪方法的鲁棒性和计算效率, 陈家益等^[3]提出了一种基于置信区间的自适应加权均值滤波算法, 根据噪声的特征, 仅仅选

收稿日期: 2021-10-11; 修回日期: 2021-11-26; 录用日期: 2021-12-21; 网络首发日期: 2021-12-31

基金项目: 广州科技职业技术大学校级课题(2021ZR07)

通信作者: *565547388@qq.com

取处于置信区间的像素作为参考值以求加权均值,加权算子同时考虑了灰度相关性与距离相关性。鉴于现有的高斯噪声去除方法难以获得比最小均方方法更好的性能,Wang等^[4]提出了一个在亚高斯和超高斯加性噪声之间切换的准则,该准则有助于算法获得更好的去噪性能,但是针对性质不同的图像,去噪性能差别较大,鲁棒性较差。Jiang等^[5]通过统计分析和实验对噪声进行特征建模,提出了一种基于最大似然估计的高斯噪声抑制方法,但是该方法未能考虑图像的边缘和纹理结构,去噪图像的对比度稍差。

鉴于深度学习在图像处理中的广泛应用,el Helou等^[6]提出了一种去除加性高斯噪声的通用深度学习图像去噪器,其源自于高斯图像的先验假设,是一种优化的融合去噪网络框架,但是计算复杂度较高,难以满足实时图像处理的需求。医学图像去噪对医学图像的特征提取与分析应用尤为重要。为了提升MRI脑肿瘤分类的检测和分裂的精度,Hashemzahi等^[7]提出一种基于卷积U-Net结构的卷积神经网络,以降低MRI图像中高斯噪声的影响,但是其计算速度较慢。低剂量医学成像过程中引入的噪声会影响医生的诊断和研究,于是Maria等^[8]提出了一种基于双树复小波变换和改进的伯努利阈值的医学图像去噪方法,该方法有效地去除了噪声,且增强了图像的视觉效果。Bodduna等^[9]对三维块匹配和非局部贝叶斯去噪方法进行改进,提出了一种结合块匹配和光流的多帧高斯噪声滤波器,其去噪性能媲美文献^[7]提出的方法,且计算速度较快。Abubakar等^[10]对BM3D进行改进,提出一种基于焦平面分割偏振图像的混合去噪算法,其结合BM3D^[2]和K次奇异值分解去噪算法^[11],通过对第一轮协同滤波图像进行净化,以提升第二轮协调滤波的效果。

小波变换以多分辨率分析、时频局部化分析及快速计算等优良特性,成为图像处理和信号处理的一个优秀工具。方斌等^[12]提出了一种基于自适应阈值和可微收缩函数的小波阈值去噪方法,其计算快速,且阈值和收缩函数自适应于信噪强度,具有良好的鲁棒性。Venkata等^[13]提出了结合小波变换、人工神经网络与遗传优化算法的图像去噪方法,该方法根据遗传算法推导出优化阈值,对图像的各小波子带系数进行量化去噪处理。基于二元瑞利分布的重尾尺度混合模型,Saeedzarandi等^[14]提出了一种基于瑞利分布尺度混合与双树复小波幅值模型的图像去噪方法,该方法采用局部自适应的方法估计二元分布的相关参数,利用相邻系数幅值之间的相关性提升去噪效果。

现有的高斯噪声去除算法存在边缘保持能力差、去噪图像对比度低等缺陷,部分算法的计算复杂度较高,难以适应实时的图像处理。因此,本文提出一种带边缘增强的双树复小波阈值去噪方法。充分利用双树复小波的优秀特性,由假设推导出基于高斯噪声的阈

值去除模型。另外提出一种多向梯度算子对去噪图像的边缘进行增强处理。

2 所提方法内容

2.1 双树复小波变换

小波变换通过平移和伸缩对图像和信号进行高频处时间细分和低频处频率细分,从而实现时频局部分化分析、多分辨率分析等性能。对于一定的尺度函数 φ 和小波函数 ψ ,二维离散信号 $f(x,y)$ 的小波变换为

$$W_{\varphi}(0, m, n) = \frac{1}{\sqrt{MN}} \sum_{x=0}^{M-1} \sum_{y=0}^{N-1} f(x, y) \varphi_{0, m, n}(x, y), \quad (1)$$

$$W_{\psi}^i(j, m, n) = \frac{1}{\sqrt{MN}} \sum_{x=0}^{M-1} \sum_{y=0}^{N-1} f(x, y) \psi_{j, m, n}(x, y),$$

$$i = \{H, V, D\}. \quad (2)$$

但是,小波变换存在固有的缺陷:振荡、平移敏感性、频率混叠、缺乏方向选择性。因此Selesnick等^[15]提出了双树复小波变换。复小波表示为

$$\psi_c(t) = \psi_r(t) + j\psi_i(t), \quad (3)$$

式中: $\psi_r(t)$ 和 $\psi_i(t)$ 分别为偶数值的实部和奇数值的虚部。

双树复小波用两路并行的小波变换,一路给出了变换的实部,另一路给出了变换的虚部。两路小波变换分别使用不同的滤波器组,如图1所示,每一组都满足完全重构的条件。图1中, $f_0(n)$ 和 $f_1(n)$ 表示实部小波变换的共轭正交滤波器对, $F_0(n)$ 和 $F_1(n)$ 表示虚部小波变换的共轭积分滤波器对, $\downarrow 2$ 表示隔点采样。分别与 $f_0(n)$ 和 $f_1(n)$ 对应的实数值尺度函数 $\varphi_f(t)$ 和小波函数 $\psi_f(t)$ 的定义为

$$\varphi_f(t) = \sqrt{2} \sum_n f_0(n) \varphi_f(2t - n), \quad (4)$$

$$\psi_f(t) = \sqrt{2} \sum_n f_1(n) \varphi_f(2t - n). \quad (5)$$

分别与 $F_0(n)$ 和 $F_1(n)$ 对应的虚数值尺度函数 $\varphi_F(t)$ 和小波函数 $\psi_F(t)$ 的定义为

$$\varphi_F(t) = \sqrt{2} \sum_n F_0(n) \varphi_F(2t - n), \quad (6)$$

$$\psi_F(t) = \sqrt{2} \sum_n F_1(n) \varphi_F(2t - n). \quad (7)$$

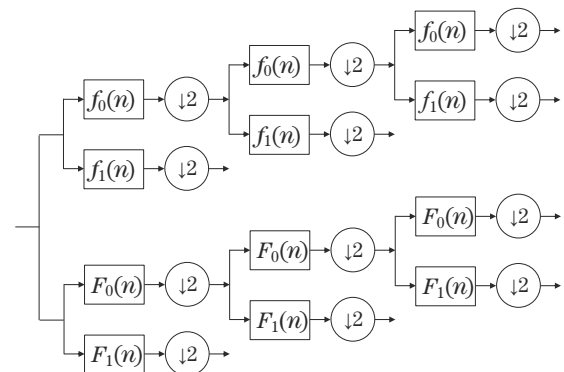


图1 双树复小波变换

Fig. 1 Dual-tree complex wavelet transform

由两路并行的小波变换实现的双树复小波变换满足完全重构条件,继承了小波变换的时频局部化分析、多分辨率分析等优良特性,同时克服了小波变换的缺陷,具有平移不变性和多方向选择性($\pm 15^\circ$ 、 $\pm 45^\circ$ 、 $\pm 75^\circ$),能更有效地对图像进行稀疏表示,避免频率振荡现象,突出显示图像的特征和细节纹理结构。

2.2 双树复小波阈值去噪模型及其去噪方法

高斯噪声服从高斯分布,分布于图像的所有像素,是一种加性噪声,其数学模型为

$$y=x+n, \quad (8)$$

式中: x 、 n 和 y 分别为原图像、高斯噪声和含噪图像, n 服从零均值的高斯分布, $n \sim N(0, \sigma_n)$ 。由于高斯噪声是一种加性噪声,其在双树复小波变换域依然满足线性加的特性。高斯噪声的数学模型在小波域表示为

$$W=\tau w+N, \quad (9)$$

式中: W 、 w 和 N 分别对应 y 、 x 和 n 的双树复小波系数。令 w_{2k} 为 w_{1k} 的父系数,即 w_{2k} 为与 w_{1k} 处于同样位置的第 k 个系数,但在下一尺度,有

$$W_{1k}=w_{1k}+N_{1k}, \quad (10)$$

$$W_{2k}=w_{2k}+N_{2k}。 \quad (11)$$

在去噪的过程中,就是从观察值 W 得到 w 的最优化的估计 \hat{w} 。采用最大后验概率估计方法,由式(9)得

$$\hat{w}(W)=\arg \max_w P_{w|W}(\tau w|W)。 \quad (12)$$

根据贝叶斯估计法则,有

$$\begin{aligned} \hat{w}(W) &= \arg \max_w P_{W|\tau w}(W|\tau w) P_w(\tau w) = \\ &= \arg \max_w P_N(W-\tau w) P_w(\tau w)。 \end{aligned} \quad (13)$$

为了简易计算,式(13)取对数后等价于

$$\hat{w}(W)=\arg \max_w \left\{ \log [P_N(W-\tau w)] + \log P_w(\tau w) \right\}。 \quad (14)$$

高斯噪声相邻尺度的小波系数服从双变量的高斯分布 $P_N(N)=\frac{1}{\sqrt{2\pi}\sigma_N} \exp\left(-\frac{N_{1k}^2+N_{2k}^2}{2\sigma_N^2}\right)$,另外,假设

w 服从非高斯的双变量分布 $P_w(w)=\frac{1}{\sqrt{2\pi}\sigma} \exp\left[-\frac{(|w_1|+|w_2|)/2}{2\sigma_w^2}\right]$,于是根据导数求极值的方法,式(14)等价于

$$\begin{cases} \frac{W_1-\tau w_1}{\sigma_N^2} - \text{sign}(\tau w_1) \frac{1}{4\sigma_w^2} = 0 \\ \frac{W_2-\tau w_2}{\sigma_N^2} - \text{sign}(\tau w_2) \frac{1}{4\sigma_w^2} = 0 \end{cases}。 \quad (15)$$

于是,结合阈值去噪思想,最后得到去噪模型:

$$\begin{cases} \tau w_1 = \text{sign}(W_1) \left(|W_1| - \frac{\sigma_N^2}{4\sigma_w^2} \right)_+ \\ \tau w_2 = \text{sign}(W_2) \left(|W_2| - \frac{\sigma_N^2}{4\sigma_w^2} \right)_+ \end{cases}。 \quad (16)$$

去噪模型在去除噪声的同时,实现小波系数的最大化,保留了有用的小波系数。去噪模型以 $\frac{\sigma_N^2}{4\sigma_w^2}$ 为阈值,自适应于噪声和无噪图像的信号强度。阈值正比于噪声强度,噪声强度越大,阈值越大;阈值反比于无噪图像的信号强度,信号强度越大,阈值越小,保护了图像的有用信号。式(16)中的运算 $(x)_+$ 定义为

$$(x)_+ = \begin{cases} 0, & x < 0 \\ x, & x \geq 0 \end{cases}。 \quad (17)$$

为了对 σ_N 进行估计,运用Donoho等^[16]提出的鲁棒中值估计方法,即

$$\sigma_N = \frac{\text{median}(|W|)}{0.6745}。 \quad (18)$$

另外,含噪图像系数 W 的标准差为

$$\sigma_w = \sqrt{\frac{1}{MN} \sum_{i=1}^M \sum_{j=1}^N [W(i,j) - \text{mean}(W)]^2}, \quad (19)$$

式中: $M \times N$ 为含噪图像系数 W 的大小。又由式(9)的加性高斯噪声模型,有 $\sigma_w^2 = \sigma_w^2 + \sigma_N^2$,于是,原图像系数的标准差 σ_w 为

$$\sigma_w = \sqrt{\max(\sigma_w^2 - \sigma_N^2, 0)}。 \quad (20)$$

双树复小波阈值去噪的流程如图2所示。




图2 双树复小波阈值去噪的流程
Fig. 2 Flowchart of dual-tree complex wavelet threshold denoising

2.3 带多向梯度算子边缘增强的阈值去噪方法

双树复小波阈值去噪模型只是根据小波系数的幅值和相位对噪声进行去除,在一定程度上忽略了图像边缘和细节,造成去噪图像模糊。于是有必要对双树复小波阈值去噪后的图像进行边缘增强处理,以提升图像的对比度和清晰度。这里对双树复小波阈值去噪模型和去噪方法进行进一步的提升,对去噪图像进行边缘增强。

借鉴Robert算子、Prewitt算子及Sobel算子,提出一种权值反比于空间距离的多向梯度算子,包括水平、垂直、正对角线、反对角线4个方向的梯度,如图3所示。对于水平梯度算子和垂直梯度算子,相对于四个对角上的像素,左、右和上、下位置的像素在空间距离上离中心像素更近,相关性更强,所以赋予更大的权重,以体现邻域像素对中心像素梯度的贡献大小。而对于正、反对角线梯度算子,也是根据空间距离远近和相关性的强弱赋予邻域像素不同的权重,以体现各邻域像素对

1	0	-1	1	$\sqrt{2}$	1	0	1	$1/\sqrt{2}$	$1/\sqrt{2}$	1	0
$\sqrt{2}$	0	$-\sqrt{2}$	0	0	0	-1	0	1	1	0	-1
1	0	-1	-1	$-\sqrt{2}$	-1	$-1/\sqrt{2}$	-1	0	0	-1	$-1/\sqrt{2}$
(a)	(b)				(c)				(d)		

图 3 多向梯度算子。(a)水平梯度;(b)垂直梯度;(c)正对角梯度;(d)反对角梯度

Fig. 3 Multi-directional gradient operator. (a) Horizontal gradient; (b) vertical gradient; (c) positive diagonal gradient; (d) anti angular gradient

中心像素梯度的不同贡献。这个多方向的梯度算子基本上能够准确有效地反映图像所有方向的边缘梯度。

根据多向梯度算子,从去噪图像提取边缘图像,将其直接与去噪图像叠加,会产生边缘过增强像,造成图像失真和浮雕效果。因此这里采用线性有参叠加,令 X 为去噪图像, E_x 为去噪图像的边缘图像,对 X 的边缘增强为

$$Y = X + E_x / C \quad (21)$$

对于 C 的最优取值,以含噪强度为 $\sigma=20$ 的数据集 Set12 为实验图像。数据集 Set12 包含性质不同的各种图像,包括人物、动物、植物、建筑、航空、航海等图像,其中有平滑区域较多的图像,也有细节区域较多的图像,具有普适性。用不同的 C 值所获得的去噪图像对应的平均峰值信噪比(PSNR)^[17]如图 4 所示。根据实验结果,取 $C=7$ 。




图 4 不同参数 C 对应的平均 PSNR

Fig. 4 Average PSNR corresponding to parameter C

边缘增强的双树复小波阈值去噪的流程如图 5 所示。




图 5 边缘增强的双树复小波阈值去噪流程

Fig. 5 Flowchart of dual-tree complex wavelet threshold denoising with edge enhancement

3 实验结果

实验环境为 3.6 GHz Intel i7 CPU 和 8G RAM 的计算机, Win10 64 位操作系统和 Matlab 2019a 软件。为了验证所提方法的可行性和有效性,对所提方法与在去噪领域具有代表性的文献[2]中的方法、以及最新的文献[8]、文献[13]和文献[14]中的方法进行比较。根据 PSNR、结构相似性(SSIM)^[18]及计算速度比较不同方法的去噪性能和计算效率。实验图像使用数据集 Set12 以及如图 6 所示的医学图像。



图 6 实验图像。(a) Barbara; (b) Hill; (c) Mammogram; (d) Xray

Fig. 6 Experimental images. (a) Barbara; (b) Hill; (c) Mammogram; (d) Xray

3.1 视觉效果

各算法对含噪强度 $\sigma=30$ 的 Barbara 进行去噪的结果如图 7 所示,括号里的数字分别表示 PSNR 和 SSIM。从图像的视觉效果上可以看出:文献[13]中的方法处理的图像的模糊效果严重,严重破坏了图像的边缘和细节;文献[8]中的方法和文献[14]中的方法的去噪效果相当,都能彻底去除噪声,但是模糊效果依然明显,边缘保持性能有限;虽然文献[8]中的方法与所提方法一样,都利用了双树复小波变换,但是文献[8]中的方法对小波系数进行量化处理时依然用软阈值函数,软阈值的缺陷难以避免;相对地,文献[2]中的方法和所提方法的去噪效果最好,能较好地保持和恢复图像的边缘和纹理结构,两者的去噪性能不相上下。进



图 7 含噪强度 $\sigma=30$ 的 Barbara 去噪图像。(a)含噪强度 30 的 Barbara;(b)文献[2]中的方法 (29.76 dB, 92.67%);(c)文献[8]中的方法(25.69 dB, 84.88%);(d)文献[13]中的方法(24.71 dB, 81.04%);(e)文献[14]中的方法(26.11 dB, 85.48%);(f)所提方法(29.79 dB, 92.71%)

Fig. 7 Denoised image Barbara corrupted with noise of intensity $\sigma=30$. (a) Barbara with noise of intensity 30; (b) method in Ref. [2] (29.76 dB, 92.67%); (c) method in Ref. [8] (25.69 dB, 84.88%); (d) method in Ref. [13] (24.71 dB, 81.04%); (e) method in Ref. [14] (26.11 dB, 85.48%); (f) proposed method (29.79 dB, 92.71%)

一步地,从各去噪图像对应的 PSNR 和 SSIM 值得出的结论与视觉效果基本是一致的。

各算法对含噪强度 $\sigma=50$ 的乳腺图像 Mammogram 进行去噪的结果如图 8 所示,括号里的数字分别表示 PSNR 和 SSIM。乳腺图像的特征是平滑区域较多,而细节区域较少。在噪声强度高达 $\sigma=50$ 的情况下,乳腺图像大部分的信息已被破坏。图 8 显示:文献[13]中的方

法处理的图像的模糊效果严重,从去噪图像只能获取大致的目标轮廓,边缘和细节已丢失;文献[8]中的方法和文献[14]中的方法处理的去噪图像出现部分伪影斑点,图像的对比较低;虽然文献[8]中的方法与所提方法类似,都用了图像增强作后处理,但是文献[8]中的方法对去噪图像进行灰度均衡化,以致图像失真;文献[2]中的方法处理的图像的清晰度较高,但是在目标区域出现大




图 8 含噪强度 $\sigma=50$ 的 Mammogram 去噪图像。(a)含噪强度 50 的 Mammogram;(b)文献[2]中的方法(36.33 dB, 85.55%);(c)文献[8]中的方法(33.59 dB, 78.65%);(d)文献[13]中的方法(33.97 dB, 81.60%);(e)文献[14]中的方法(34.32 dB, 78.44%);(f)所提方法(36.95 dB, 86.92%)

Fig. 8 Denoised image Mammogram corrupted with noise of intensity $\sigma=50$. (a) Mammogram with noise of intensity 50; (b) method in Ref. [2] (36.33 dB, 85.55%); (c) method in Ref. [8] (33.59 dB, 78.65%); (d) method in Ref. [13] (33.97 dB, 81.60%); (e) method in Ref. [14] (34.32 dB, 78.44%); (f) proposed method (36.95 dB, 86.92%)

片的伪影斑块;相对地,所提方法的去噪效果较好,在彻底去除噪声的同时,较好地保持和恢复图像的边缘和细节,背景和细节都较清晰。从各去噪图像对应的 PSNR 和 SSIM 值得出的结论与视觉效果基本是一致的。

3.2 PSNR 和 SSIM

各算法对含各种强度噪声的图像 Hill 进行去噪所得的 PSNR 和 SSIM 值如图 9 所示。随噪声强度的增

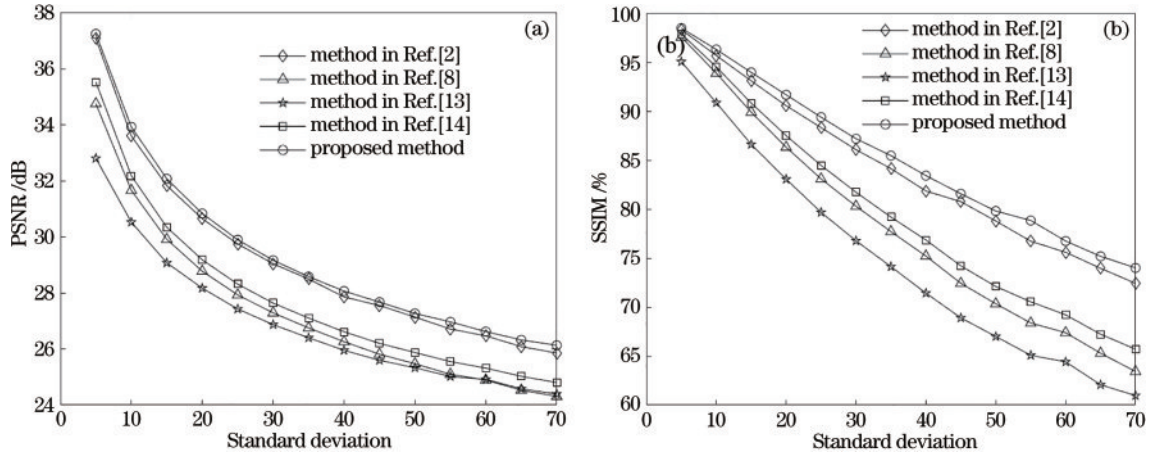


图 9 对含各种强度噪声的图像 Hill 去噪得到的 PSNR 和 SSIM。(a)峰值信噪比;(b)结构相似性

Fig. 9 PSNR and SSIM of denoising image Hill corrupted with various intensity noise. (a) PSNR; (b) SSIM

对于图像 Xray,背景的平滑区域较大,而目标区域的边缘和细节较多。各算法对含各种强度噪声的图像 Xray 进行去噪所得的 PSNR 和 SSIM 如图 10 所示。对于 PSNR,文献[8]中的方法、文献[13]中的方法和文献[14]中的方法相差不大,但与文献[2]中的方法和所提方法有一定的差距。文献[2]中的方法和所提方

大,各算法的去噪效果一致走低。其中文献[13]中的方法的去噪效果最差,文献[8]中的方法其次,文献[14]中的方法的性能可接受。相对地,文献[2]中的方法和所提方法的去噪性能最好。虽然文献[2]中的方法和所提方法的去噪性能不相上下,但是所提方法的 PSNR 还是比文献[2]中的方法高出约 0.25 dB,SSIM 高出约 3 个百分点。

法的 PSNR 值最高,两者相差微小,所提方法比文献[2]中的方法高出约 0.15 dB。对于 SSIM,文献[8]中的方法和文献[14]中的方法较低,文献[13]中的方法的 SSIM 处于中等水平。文献[2]中的方法和所提方法的 SSIM 最高,两者的 SSIM 相差不大,文献[2]中的方法比所提方法高出约 1.5 个百分点。

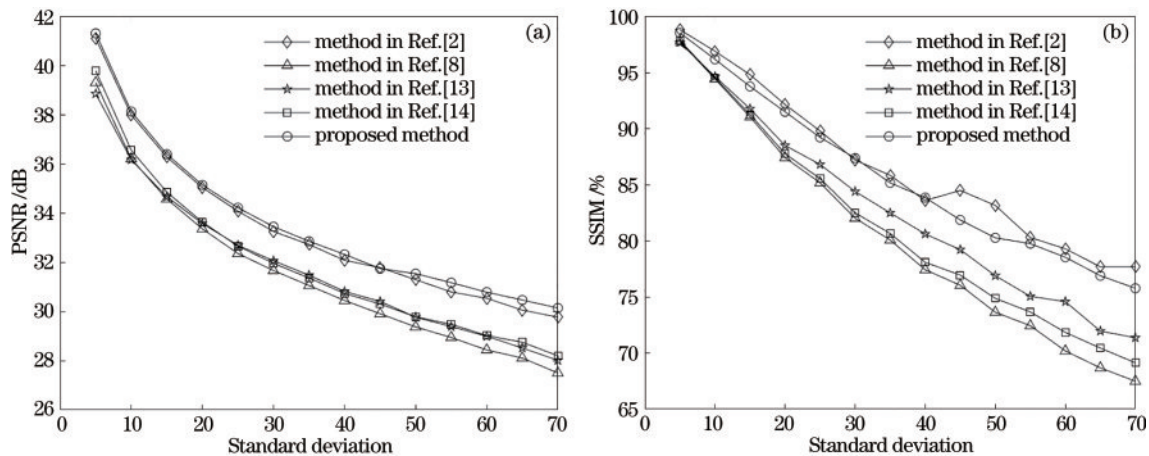


图 10 对含各种强度噪声的图像 Xray 去噪得到的 PSNR 和 SSIM。(a)峰值信噪比;(b)结构相似性

Fig. 10 PSNR and SSIM of denoising image Xray corrupted with various intensity noise. (a) PSNR; (b) SSIM

由于所提方法由两个过程组成:双树复小波阈值去噪模型和多向梯度算子的边缘增强。为了单独验证两者对去噪性能的贡献,将不带边缘增强的双树复小波阈值去噪模型简称为所提方法 1,而将带边缘增强的去噪模型简称为所提方法 2,在数据集 Set12 上,再次验证各方法的去噪性能。各方法的

PSNR 和 SSIM 取 Set12 数据集集中所有图像 PSNR 和 SSIM 的平均值。

各算法对含各种强度噪声的 Set12 数据集进行去噪的平均 PSNR 和平均 SSIM 如图 11 所示。除了所提方法 1、所提方法 2 和文献[2]中的方法外,文献[8]、文献[13]和文献[14]中的方法的去噪性能并不高,特别是

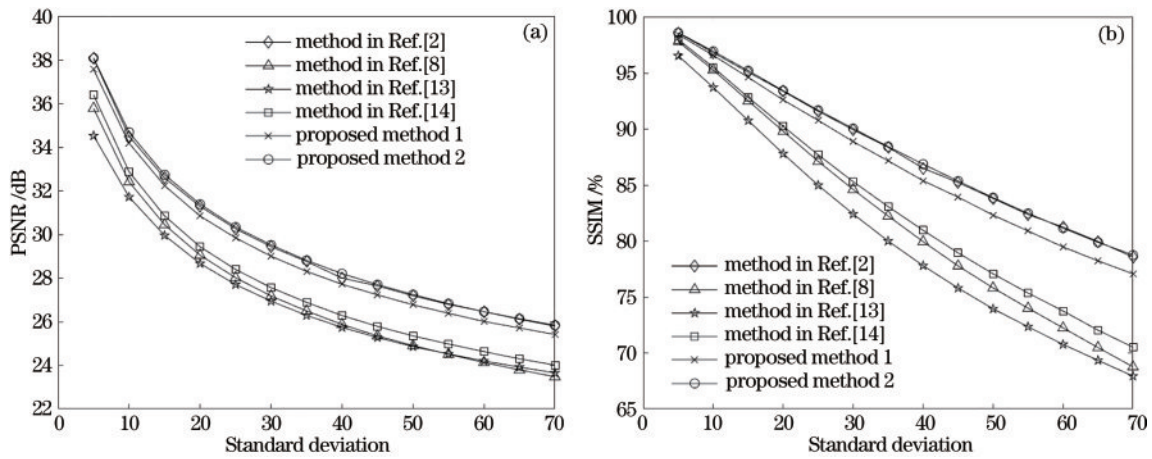


图 11 对含各种强度噪声的 Set12 数据集去噪得到的 PSNR 和 SSIM。(a) 峰值信噪比; (b) 结构相似性

Fig. 11 PSNR and SSIM of denoising Set12 dataset corrupted with various intensity noise. (a) PSNR; (b) SSIM

文献[13]中的方法,去噪性能较差。所提方法2与文献[2]中的方法去噪性能最好,PSNR和SSIM两者难分高低。另外,从所提方法1与所提方法2对应的PSNR和SSIM曲线可以看出,没有边缘增强的阈值去噪模型还是不及有边缘增强的去噪模型。从主、客观实验数据的比较可以看出:所提方法比现有的多数方法取得了更好的去噪效果,作为图像去噪领域里程碑式的方法文献[2]中的方法,虽然所提方法相对于它没有明显的优势,但是基本上与其持平,对于部分图像甚至超过了它。

3.3 计算速度

各方法分别对含不同强度噪声的 Set12 数据集进

行去噪,对所有图像的平均时间如表1所示,其中最后一行单独列出所提方法的边缘增强的耗时。一般地,去除高强度噪声的耗时略高于去除低强度噪声的耗时;文献[13]中的方法耗时最多,难以满足实时的图像处理与应用要求;文献[2]中的方法和文献[14]中的方法的计算速度中等;文献[8]中的方法和所提方法的计算速度最快;在噪声强度较低时,文献[8]中的方法的计算速度领先于所提方法,而在噪声强度较高时,所提方法领先。从而可知,所提方法不但具有良好的去噪性能,且具有较高的计算效率,可以满足高去噪性能和实时图像处理的需求。

表 1 各方法对含不同强度噪声的 Set12 数据集的平均计算时间

Table 1 Average time of each method on Set12 dataset corrupted with various intensity noise

unit: s

Method	5	10	15	20	25	30	35	40	45	50	55	60	65	70
Method in Ref. [2]	3.47	3.48	3.64	3.57	3.59	2.63	3.65	3.69	4.19	4.14	4.20	4.19	4.28	4.11
Method in Ref. [8]	2.75	2.77	2.79	2.95	2.98	3.14	3.19	3.38	3.54	3.44	3.61	3.60	3.72	3.81
Method in Ref. [13]	12.8	13.0	13.2	13.5	1.34	13.8	13.7	13.6	13.9	14.0	14.3	14.2	14.3	14.2
Method in Ref. [14]	4.72	4.77	4.74	4.95	5.15	5.24	5.29	5.27	5.35	5.39	5.55	5.68	5.79	5.71
Proposed method	2.83	3.05	2.84	2.80	2.83	2.79	2.86	2.94	2.95	2.95	2.87	2.86	2.96	2.75
Edge enhancement	1.75	1.84	1.77	1.77	1.80	1.82	1.81	1.83	1.81	1.80	1.79	1.82	1.83	1.78

4 结 论

鉴于大部分的现有高斯噪声去除方法难以满足高去噪性能和高对比度的要求,提出了一种带边缘增强的双树复小波阈值去噪方法。由双树复小波系数与高斯噪声的数学模型,推导出一种双树复小波阈值去噪模型,另外提出一种多向的梯度算子对图像进行后去噪增强,以提升图像的对比度。实验结果证明,所提方

法在去噪性能和边缘保持上优于大部分的现有方法。对所提方法进行进一步的改进,应用于图像超分辨率重建,是下一步的研究方向。

参 考 文 献

- [1] Shah Z H, Müller M, Wang T C, et al. Deep-learning based denoising and reconstruction of super-resolution structured illumination microscopy images[J]. Photonics

- Research, 2021, 9(5): B168-B181.
- [2] 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.
- [3] 陈家益, 黄楠, 熊刚强, 等. 基于置信区间的自适应加权均值滤波算法[J]. 南京理工大学学报, 2017, 41(3): 307-312.
Chen J Y, Huang N, Xiong G Q, et al. Adaptive weighted mean filtering algorithm based on confidence interval[J]. Journal of Nanjing University of Science and Technology, 2017, 41(3): 307-312.
- [4] Wang G, Xue R, Zhao J. Switching criterion for sub-and super-Gaussian additive noise in adaptive filtering[J]. Signal Processing, 2018, 150: 166-170.
- [5] Jiang B, Meng K, Youcef-Toumi K. Quantification and reduction of Poisson-Gaussian mixed noise induced errors in ellipsometry[J]. Optics Express, 2021, 29(17): 27057-27070.
- [6] el Helou M, Sússtrunk S. Blind universal Bayesian image denoising with Gaussian noise level learning[J]. IEEE Transactions on Image Processing, 2020, 29: 4885-4897.
- [7] Hashemzahi R, Mahdavi S J S, Kheirabadi M, et al. Y-net: a reducing Gaussian noise convolutional neural network for MRI brain tumor classification with NADE concatenation[J]. Biomedical Physics & Engineering Express, 2021, 7(5): 055006.
- [8] Maria H H, Jossy A M, Malarvizhi G, et al. Analysis of lifting scheme based double density dual-tree complex wavelet transform for de-noising medical images[J]. Optik, 2021, 241: 166883.
- [9] Bodduna K, Weickert J. Removing multi-frame Gaussian noise by combining patch-based filters with optical flow [J]. Journal of Electronic Imaging, 2021, 30(3): 033031.
- [10] Abubakar A, Zhao X J, Takruri M, et al. A hybrid denoising algorithm of BM3D and KSVD for Gaussian noise in DoFP polarization images[J]. IEEE Access, 2020, 8: 57451-57459.
- [11] Xie W, Jiao L C, Zhao J. PolSAR image classification via D-KSVD and NSCT-domain features extraction[J]. IEEE Geoscience and Remote Sensing Letters, 2016, 13(2): 227-231.
- [12] 方斌, 陈家益, 石艳. 基于可微收缩函数与自适应阈值的小波去噪[J]. 光学技术, 2021, 47(3): 359-365.
Fang B, Chen J Y, Shi Y. Wavelet denoising based on differentiable shrinkage function and adaptive threshold [J]. Optical Technique, 2021, 47(3): 359-365.
- [13] Venkata Lavanya P, Venkata Narasimhulu C, Satya Prasad K. Image denoising using an artificial neural network and genetic optimization algorithm based dual-tree complex wavelet transform[M]//Reddy V S, Prasad V K, Wang J C, et al. Soft computing and signal processing. Advances in intelligent systems and computing. Singapore: Springer, 2022, 1340: 393-401.
- [14] Saeedzarandi M, Nezamabadi-Pour H, Jamalizadeh A. Dual-tree complex wavelet coefficient magnitude modeling using scale mixtures of Rayleigh distribution for image denoising[J]. Circuits, Systems, and Signal Processing, 2020, 39(6): 2968-2993.
- [15] Selesnick I W, Baraniuk R G, Kingsbury N C. The dual-tree complex wavelet transform[J]. IEEE Signal Processing Magazine, 2005, 22(6): 123-151.
- [16] Donoho D L. De-noising by soft-thresholding[J]. IEEE Transactions on Information Theory, 1995, 41(3): 613-627.
- [17] Xu B B, Li H M, Gao S L, et al. Metalens-integrated compact imaging devices for wide-field microscopy[J]. Advanced Photonics, 2020, 2(6): 066004.
- [18] Zeng Z P, Ma J, Xu C H. Cross-cumulant enhanced radiality nanoscopy for multicolor superresolution subcellular imaging[J]. Photonics Research, 2020, 8(6): 893-898.