

文章编号:1001-9081(2010)08-2080-05

基于空间自适应 Bayesian 缩减的 NSCT 域图像去噪方法

孙 强¹, 高 勇¹, 焦李成²

(1. 西安理工大学 电子工程系, 西安 710048; 2. 西安电子科技大学 智能信息处理研究所, 西安 710071)

(qsunster@gmail.com)

摘要: 提出了一种基于空间自适应 Bayesian 缩减的 NSCT 域图像去噪方法。该方法运用了广义高斯分布对 NSCT 域图像的子带系数进行建模, 并通过构造各向异性的椭圆窗口来描述各个子带内系数的局部背景特性, 从而建立了 NSCT 域空间自适应 Bayesian 缩减机制的图像去噪方法。通过图像去噪实验验证了所提出方法的有效性。同时, 与 4 种具有平移不变性的 Contourlet 去噪方法做了对比, 进一步证实了所提出方法的优良去噪性能。

关键词: 图像去噪; 非下采样 Contourlet 变换; 平移不变性; 空间自适应缩减; 各向异性窗口

中图分类号: TP391.41 文献标志码:A

Image denoising based on spatially adaptive Bayesian shrinkage in NSCT domain

SUN Qiang¹, GAO Yong¹, JIAO Li-cheng²

(1. Department of Electronic Engineering, Xi'an University of Technology, Xi'an Shaanxi 710048, China;

2. Institute of Intelligent Information Processing, Xidian University, Xi'an Shaanxi 710071, China)

Abstract: A new image denoising method via spatially adaptive Bayesian shrinkage in the Nonsubsampled Contourlet Transform (NSCT) domain was proposed in this paper. the generalized Gaussian distribution was utilized to model the statistics of individual NSCT domain detail subbands. Anisotropic elliptic windows were then constructed and applied to the description of the local contextual characteristics of each coefficient located at a certain detail subband. As a result, an NSCT domain image denoising approach with spatially adaptive Bayesian shrinkage mechanism was established. The experimental results demonstrate the effectiveness of the proposed denoising method. Compared with four shift-invariant contourlet-related denoising methods, the proposed method provides preferable denoised results.

Key words: image denoising; Nonsubsampled Contourlet Transform (NSCT); shift invariance; spatially adaptive shrinkage; anisotropic window

0 引言

在图像去噪研究领域, 通过自适应缩减变换域(如离散子波变换)的有噪系数来估计“无噪”系数进而实现去噪一直是该研究领域的主要方向之一, 如子波域的阈值缩减^[1-4]、双变量缩减^[5]以及最近发展的 Bayesian 缩减^[6]等。对于阈值缩减, 一般软阈值方法通常比硬阈值方法去噪效果好, 一直被积极地推广和应用, 但主要的难点是如何选取恰当的阈值^[2-3]以及如何将空间背景信息合理地考虑在内^[4]。双变量缩减^[5]是一种局部自适应的去噪方法, 通过双变量缩减函数描述了系数间的局部相关性。Bayesian 缩减方法^[6]以变换域的某种先验模型为前提, 通过该模型逼近无噪图像子带系数的统计分布。一般来讲, 无论是阈值缩减方法还是 Bayesian 缩减方法, 非下采样变换域去噪方法的性能往往优于下采样变换域的去噪方法^[7], 这源于前者比后者能提供更丰富的、冗余的图像细节信息, 并且具有平移不变性。因此, 通过非下采样变换域的自适应系数缩减可以显著提高图像的去噪性能, 如文献[6]中基于非下采样子波变换(Undecimated Wavelet Transform, UWT)域空间自适应 Bayesian 缩减机制的去噪方法。

众所周知, 在二维空间, 子波分析并不是最稀疏的函数表示方法, 不能很好地刻画二维图像中具有线奇异的几何信息。近年来各种多尺度几何分析(Multiscale Geometrical Analysis, MGA)方法的提出为这一问题的解决带来了新的契机。这些方法在保持子波分析优良的时(空)频局部化特性的同时, 通过构造具有各向异性的基来检测子波所不能充分刻画的几何结构, 很好地保持了图像的奇异性信息, 从而有利于图像去噪质量的提高。Do 和 Vetterli 提出的 Contourlet 变换^[8]就是描述图像奇异性特征的一种 MGA 方法, 它由 Laplacian 金字塔分解和基于方向性滤波器组(Directional Filter Bank, DFB)的方向分解构成。该变换域的硬阈值法在图像去噪的性能表现初步体现了各向异性基刻画图像结构的优势。然而, 这种 Contourlet 变换是一种下采样的变换, 不具有平移不变性, 在利用该变换进行图像去噪时往往导致去噪图像的边缘或脊等奇异性结构处出现伪 Gibbs 现象。尽管通过 Cycle Spinning 技术^[9-10]可以缓解这一问题, 但并不能从根本上解决。

最近, Cunha 等人^[11]在 Contourlet 变换的基础上提出了非下采样 Contourlet 变换(Nonsubsampled Contourlet Transform, NSCT), 它是一种新的具有完全平移不变性的 MGA 方法, 其中的非下采样金字塔分解和非下采样 DFB 分解确保了该变

收稿日期:2010-02-02;修回日期:2010-03-19。

基金项目:陕西省教育厅专项科研计划项目(08JK378);西安理工大学博士科研启动基金资助项目(105-210721)。

作者简介:孙强(1979-),男,山东滕州人,讲师,博士,主要研究方向:图像处理、机器视觉;高勇(1956-),男,山东宁津人,教授,博士生导师,博士,主要研究方向:超大规模集成电路与新器件;焦李成(1959-),男,陕西白水人,教授,博士生导师,博士,主要研究方向:信号与图像处理、计算智能、机器学习。

换的完全平移不变特性,在用于图像去噪时已初步显示出其非凡的优势^[11,12-15]。在这一背景下,本文提出了一种 NSCT 域的空间自适应 Bayesian 缩减方法,通过 Lena 图像和 Barbara 图像的去噪实验验证其有效性。

1 UWT 域空间自适应 Bayesian 缩减机制

对一幅含有加性高斯白噪声(均值为 0,方差为 σ^2)的图像,在多尺度子波分解后,每个尺度不同方向子带内均有如下表达形式:

$$y_j^B[m,n] = x_j^B[m,n] + n_j^B[m,n] \quad (1)$$

其中: $y_j^B[m,n]$ 、 $x_j^B[m,n]$ 和 $n_j^B[m,n]$ 分别表示尺度 j 内子带 $B \in \{HL, LH, HH\}$ 中位置 $[m,n]$ 的有噪系数、无噪系数和噪声系数。为了叙述的简洁性,在下文中省略式(1)中的子带索引 B 和尺度索引 j 。

基于 UWT 域 Bayesian 缩减的去噪方法中,一个常用的无噪图像子带系数先验统计模型是广义高斯分布(Generalized Gaussian Distribution, GGD)^[4,6,16],其概率密度函数是:

$$f_{GGD}(x) = \frac{\beta}{2\alpha\Gamma(1/\beta)} \exp[-(|x|/\alpha)^\beta]; \\ -\infty < x < \infty \quad (2)$$

其中: $\Gamma(u) = \int_0^\infty t^{u-1} e^{-t} dt$ ($u > 0$) 是 Gamma 函数; α 是尺度参数,控制系数分布的分散程度;参数 β 为形状参数,决定着 GGD 的衰减快慢。对于自然图像,通常有 $\beta \in [0,1]$ ^[6]。在加性高斯白噪声背景下,Simoncelli 等人^[16]给出了有噪图像子带系数直方图的二阶矩和四阶矩与参数 α 和 β 的关系式:

$$\begin{cases} m_2 = \sigma_n^2 + \frac{\alpha^2 \Gamma(3/\beta)}{\Gamma(1/\beta)} \\ m_4 = 3\sigma_n^4 + \frac{6\sigma_n^2 \alpha^2 \Gamma(3/\beta)}{\Gamma(1/\beta)} + \frac{\alpha^4 \Gamma(5/\beta)}{\Gamma(1/\beta)} \end{cases} \quad (3)$$

在噪声方差 σ_n^2 已知的条件下,参数 α 和 β 就可以通过上式求出。在下采样的正交子波变换域, $\sigma_n^2 = \sigma^2$;在非下采样子波域,Flower 给出了噪声方差在变换前后的关系式^[17]。在文献[6]中,Pizurica 以噪声方差已知为前提给出了下采样和非下采样子波域的空间自适应 Bayesian 缩减方案。

记 T 是判定无噪系数 x 是否含有意义信号的门限。通过建立下面两个假设:

$$\begin{cases} H_1: |x| > T, & \text{存在有意义信号} \\ H_0: |x| \leq T, & \text{不存在有意义信号} \end{cases} \quad (4)$$

空间自适应 Bayesian 缩减估计器的表达式为^[6]:

$$\hat{x}_l = P(H_1, z_l) y_l = \frac{\eta_l \xi_l \mu}{1 + \eta_l \xi_l \mu} y_l \quad (5)$$

其中: $\eta_l = \frac{f(y_l | H_1)}{f(y_l | H_0)}$, $\xi_l = \frac{f(z_l | H_1)}{f(z_l | H_0)}$, $\mu = \frac{P(H_1)}{P(H_0)}$ 。

其中: z_l 是一个表征空间位置 $l = [m,n]$ 处局部背景特征的量,称为局部空间活动指示器(Locally Spatial Activity Indicator, LSAI),其定义为 $z_l = \frac{1}{N} \sum_{k \in \delta(l)} \omega_k$,这里 $\omega_l = |y_l|$, $\delta(l)$ 是在某一窗口内位置 $l = [m,n]$ 的局部邻域,文献[6]采用了具有各向同性的方形窗口计算 z_l 。此外,式(5)中的乘积项 $\eta_l \xi_l \mu$ 称为广义似然比, η_l 、 ξ_l 和 μ 分别称为子带似然比、先验比和全局先验因子,这 3 个量在 GGD 模型下均有明确的解析形式,详细推导过程参见文献[6]。

Barbara 图像的 NSCT 域第一尺度($2\pi/8, 3\pi/8$)子带方向

的直方图及其 GGD ($\alpha = 0.1972, \beta = 0.4518$) 逼近如图 1 所示。

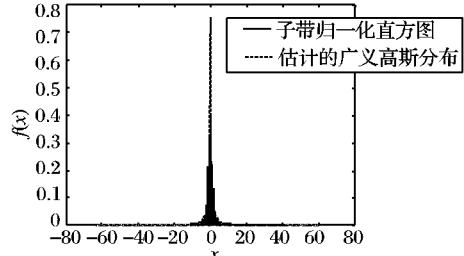


图 1 Barbara 的 NSCT 域第一尺度子带方向的直方图及其 GGD 逼近

2 图像的 NSCT 及其子带统计特性

2.1 非下采样 Contourlet 变换

NSCT^[11]是在 Contourlet 变换^[8]的基础上发展起来的一种崭新的 MGA 方法,是一种灵活的多尺度、多方向变换,具有完全平移不变特性,弥补了原有 Contourlet 变换缺乏平移不变性的不足。

通常,NSCT 变换的实现需通过非下采样的金字塔分解和非下采样的 DFB 分解来完成。图 2(a)给出了二维图像 NSCT 变换的示意图。图 2(b)是二维频率平面的三级频带划分示意图,从里到外对应低通和具有 4,4,8 个方向的带通部分。

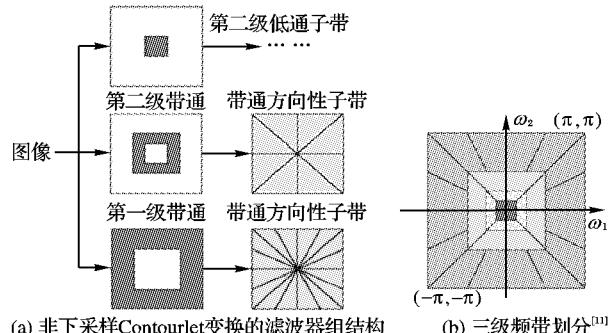


图 2 NSCT 和频带划分示意图

2.2 NSCT 域的图像子带统计特性

NSCT 不仅继承了 Contourlet 变换捕捉图像线奇异特征的优点,而且具有完全的平移不变性,这为变换域图像去噪性能的提高提供了新的契机。图 3 是 zoneplate 图像在 NSCT 域分解后第一级 8 个子带方向的系数分布图,其中白色部分对应于各个方向的细节。可以看出,该图像在 NSCT 域各个方向的线奇异特征(如 zoneplate 图像的环形边缘)在每个子带内分别得到了很好地“刻画”。

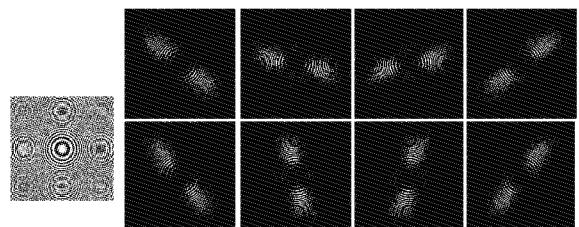


图 3 图像 zoneplate 在 NSCT 域第一级 8 个子带方向的细节图

图 1 给出了 Barbara 图像在经过 NSCT 后第一尺度内($2\pi/8, 3\pi/8$)子带方向上的归一化直方图。可以看出:该直方图与子带系数的直方图有着相似的非高斯分布表现形式。因此,可以利用 GGD 对该直方图进行逼近。具体通过参数 $\alpha = 0.1972, \beta = 0.4518$ 的 GGD 能够很好地进行逼近。

对于其他子带方向,系数的分布具有类似的表现形式,都可以通过 GGD 进行建模。实质上,这类尖峰值、重拖尾形状的非高斯系数分布形式是与 NSCT 作为二维数据空间一种稀疏的函数表示形式相吻合的。因此,有了这一建模基础,完全可以将 UWT 域的 Bayesian 缩减机制推广到 NSCT 域中去。

对于 NSCT 域子带内噪声方差的估计,目前还没有明确的解析形式。Cunha 等人^[11]给出了利用 Monte-Carlo 技术的噪声方差估计方法,作为一种近似的求解方案。基于这一技术的噪声方差估计也被用在下文给出的去噪方法中。

3 NSCT 域空间自适应 Bayesian 缩减

NSCT 和 Contourlet 变换都采用具有各向异性的 Contourlet 基来捕捉图像的方向性信息。在 NSCT 域不同的方向子带内,系数的能量分布集中于不同的方向上。与子波域仅有水平、垂直和对角 3 个方向子带相比,NSCT 具有更为丰富的方向选择性,而且也具有灵活性——方向数可根据具体应用灵活地调节。因此,在将 UWT 域的空间自适应 Bayesian 缩减方法推广到 NSCT 域时,必须充分利用 NSCT 的这种多方向选择特性才能切实地提高系数的缩减性能,从而改善图像去噪的质量。鉴于此,提出利用具有各向异性的椭圆窗口来描述子带系数的局部背景特性,建立系数的局部空间活动标识器 (Local Spatial Activity Indicator, LSAI),从而实现缩减方法对各个方向子带的自适应性。同时将给出椭圆窗口尺寸参数和形状参数的选取准则,并在第 4 章确定这些参数的具体取值。

3.1 各向异性椭圆窗口的定义

文献[6]给出的 UWT 域空间自适应 Bayesian 缩减方法采用固定尺寸的方形窗口来确立 LSAI。实际上,这类方形窗口是各向同性的,不能自适应子波域三个子带的方向选择性。在 NSCT 域中,多方向选择特性更为显著,它是 Contourlet 变换优于子波变换的主要方面,这就进一步要求窗口的方向应该与子带系数的能量分布趋势相一致。文献[18]给出了基于方向性窗口的子波域双重局部维纳滤波器,为子波域的水平、垂直和对角子带分别定制了不同的椭圆窗口,用于改进局部维纳滤波器的去噪性能。然而,其中的椭圆窗口只能为水平、垂直和对角 3 个方向子带所利用,具有局限性。在本文中,提出了更具有普遍意义的各向异性椭圆窗口,用于建立子带系数的 LSAI。窗口的形状取为椭圆形,主要是考虑到这种封闭形状的窗口具有明确而灵活的解析表达式,易于描述和推广。

图 4 所示的是一个逆时针旋转角度为 θ 的椭圆形窗口,其表达式定义为:

$$W(r, a) = \left\{ (m, n) \in \mathbb{Z}^2 \mid (m \cos \theta + n \sin \theta)^2 + a^2 (-m \sin \theta + n \cos \theta)^2 \leq r^2 \right\} \quad (6)$$

其中: r 和 a 均为正实数, r 是尺寸参数, r 越大,窗口内样本数目越多; a 是形状参数,越接近 1,椭圆程度越弱,即越趋于圆形。当 $\theta = 0^\circ$ 和 $\theta = 90^\circ$ 时,式(6)则对应于文献[18]定义的为水平子带和垂直子带所采用的方向窗口。对于对角子带,其方向窗口通过 $\theta = 45^\circ$ 和 $\theta = 135^\circ$ 共同来确立。因此,通过式(6)调节 θ 的值能够更好地用于各种具有多方向选择性的变换。

图 5 给出了 8 个椭圆窗口的示意图(尺寸参数和形状参

数均为 $r=6, a=2$),分别与图 2 中 NSCT 域第一级 8 个子带方向相对应。需要说明的是,在 NSCT 域中 Contourlet 基函数在不同的分解等级具有不同范围的支撑区域:频率等级越高,支撑区域越长越窄;反之,支撑区域越短越宽。因此,在不同的分解等级,椭圆窗口的尺寸参数和形状参数都需要自适应地调整,从而才能更准确地捕捉图像在不同分解级的细节信息。在下一节,我们将给出选择这两个参数的依据。

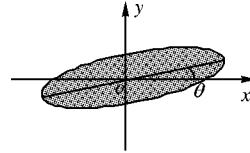


图 4 逆时针旋转角度为 θ 的椭圆窗口

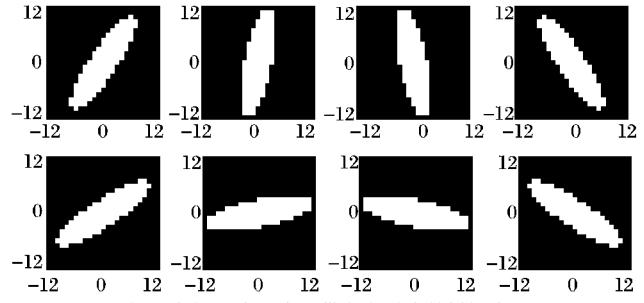


图 5 与图 3 中 8 个子带方向对应的椭圆窗口

3.2 椭圆窗口参数的选择

按照式(6),以某一参照系数为中心构成的椭圆窗口中,样本点的数目应为 $\# [W(r, a)] = \lfloor \pi r^2 \rfloor$,这里 $\lfloor \cdot \rfloor$ 表示向下取整,这表明窗口内样本点数目仅仅与参数 r 有关。

在 NSCT 域,随着分解尺度的增加,各个子带内系数能量的集中程度逐渐减弱,而局部系数间的能量相关性逐渐增强,这种现象在 UWT 域中也有类似的表现。因此,随着分解尺度的增加,窗口尺寸应逐渐增大,即增大 r 的值。同时,考虑到 Contourlet 基函数的支撑区域随着分解等级的增加会变短变宽,形状参数 a 的值应适当变小。但是, a 的值不能小于 1,否则就会出现椭圆窗口的方向与对应子带系数的能量分布趋势不一致的情况。另外,在选择参数 r 和 a 时还需考虑含噪图像的噪声强度:通常,噪声强度增大, r 也应随之适当增大。

4 实验结果与分析

为了验证本文方法的有效性,我们采用了图像去噪中常用的标准 Barbara ($512 \times 512 \times 8$ b) 和 Lena ($512 \times 512 \times 8$ b) 图像,并对这两幅图像分别加入标准差为 10、15 和 20 的零均值加性高斯白噪声,共产生 6 幅有噪的图像,作为测试数据。在对这些图像进行 NSCT 时,均采用文献[11]给出的金字塔分解滤波器组和方向性分解滤波器组,分解等级为 3,分解方向数从粗分辨率到细分辨率依次为 2、4、8。为了公平比较,将文献[6]中的 UWT 域 Bayesian 缩减方法进行了改进,采用文献[18]定义的椭圆窗口建立子波系数的 LSAI。整个实验通过峰值信噪比 PSNR 作为定量的性能评价准则。

4.1 椭圆窗口参数的确定

实验中,首先对 UWT 域的 Bayesian 缩减方法^[6]进行改进:3 个分解等级使用尺寸不同的自适应方形窗口进行系数缩减,从最精细尺度到粗糙尺度依次使用尺寸为 $7 \times 7, 9 \times 9$ 和 11×11 的窗口。从表 1~2 可以看出,与文献[6]中采用统

一窗口相比(每个尺度的子带方向均采用尺寸为 7×7 的方形窗口),自适应方形窗口的使用能够提高图像的去噪性能。将相同的窗口设置(7×7 , 9×9 和 11×11)应用到NSCT域Bayesian缩减方法时,NSCT域方法比UWT域方法的去噪性能更好。特别是对于Barbara图像,平均能提高0.3 dB,这得益于NSCT对图像分解采用的是具有各向异性的contourlet基,对纹理较丰富的Barbara图像可以更好地发挥自身的多方向选择特性。

表1 Barbara去噪的UWT域和NSCT域方法比较 dB

窗口形状	噪声标准差		
	10	15	20
有噪图像	28.12	24.59	22.09
UWT域方形窗口 ^[6]	33.46	31.19	29.53
UWT域自适应方形窗口	33.58	31.40	29.85
NSCT域自适应方形窗口	33.82	31.77	30.33
UWT域自适应椭圆形窗口	33.80	31.67	30.16
NSCT域自适应椭圆形窗口	34.12	32.10	30.71

表2 Lena去噪的UWT域和NSCT域方法比较 dB

窗口形状	噪声标准差		
	10	15	20
有噪图像	28.13	24.60	22.12
UWT域方形窗口 ^[6]	35.24	33.46	32.20
UWT域自适应方形窗口	35.35	33.60	32.39
NSCT域自适应方形窗口	35.46	33.76	32.61
UWT域自适应椭圆形窗口	35.44	33.73	32.55
NSCT域自适应椭圆形窗口	35.50	33.83	32.72

为了更加充分利用NSCT的多方向选择性优势,改善图像去噪的质量,我们在NSCT域缩减方法中采用本文提出的各向异性椭圆窗口。椭圆窗口涉及到两个参数 r 和 a ,其中 r 决定窗口内样本点的数目。记 r_1 和 a_1 分别为最精细尺度内椭圆窗口参数 r 和 a 的取值。按照3.2节 r 的选择原则,在实验中从细尺度到粗尺度依次采用 r_1, r_1+1, r_1+2 作为三个分解尺度 r 的取值。考虑到在通过尺寸变化的方形窗口(即上述 7×7 , 9×9 和 11×11 窗口设置)建立LSAI的缩减方案中, r_1 取为7可以获得最佳的去噪效果,以 $\lceil \sqrt{\frac{7 \times 7}{\pi}} \rceil$ 作为使用椭圆窗口时最精细尺度 r 的取值,即 $r_1 = \lceil \sqrt{\frac{7 \times 7}{\pi}} \rceil = 4$,这里 $\lceil \cdot \rceil$ 表示向上取整。表3~4给出了噪声方差为20的条件下不同 r_1 和 a_1 组合情况下NSCT域缩减方法性能的对比。当 $a_1=1$ 时,3个分解等级均采用 $a=1$;当 $a_1=2$ 或 $a_1=3$ 时,从细尺度到粗尺度依次采用 a_1, a_1, a_1-1 作为3个分解尺度 a 的取值。基本上, r_1 为3、4和5, a_1 为2和3时PSNR的值变化不大。在噪声强度适中时(如噪声标准差 $\sigma=20$), $r_1=4$ 与 $a_1=2$ 这个参数组能带来比较高的PSNR值。

表3 参数对Barbara(噪声标准差为20)去噪性能影响 dB

r_1	$a_1=1$		$a_1=2$		$a_1=3$	
	UWT	NSCT	UWT	NSCT	UWT	NSCT
2	29.530	30.220	29.972	30.459	30.047	30.609
3	29.963	30.575	30.121	30.652	30.141	30.675
4	30.045	30.598	30.162	30.711	30.152	30.703
5	30.060	30.640	30.133	30.670	30.089	30.642
6	30.055	30.607	30.104	30.438	30.035	30.583

表1~2给出了在UWT域和NSCT域中采用方向性椭圆窗口按照Bayesian缩减原理去噪所获得的PSNR值。可以看出,无论在UWT域还是在NSCT域,基于自适应椭圆窗口描述系数局部背景特性的Bayesian缩减去噪方法比基于自适应方形窗口的方法均可以提高去噪的性能。而且,NSCT域方法的去噪性能在不同的噪声设置下均优出UWT方法,这说明在NSCT域采用方向性窗口是更有效的,能够充分发挥NSCT的多方向选择性。图6~7给出的Barbara图像和Lena图像的去噪图像也从视觉上进一步展示了其有效性。

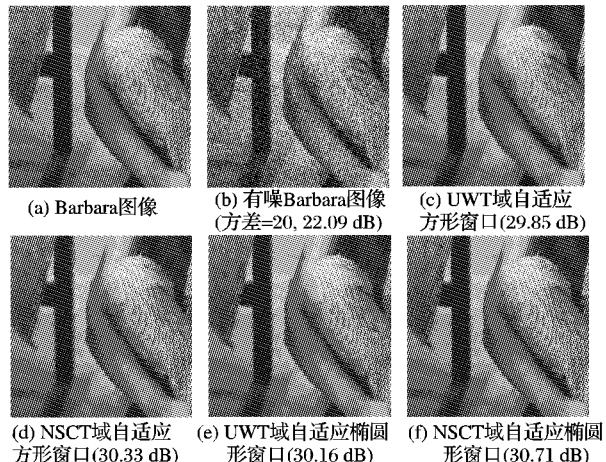


图6 Barbara图像的空间自适应Bayesian缩减结果

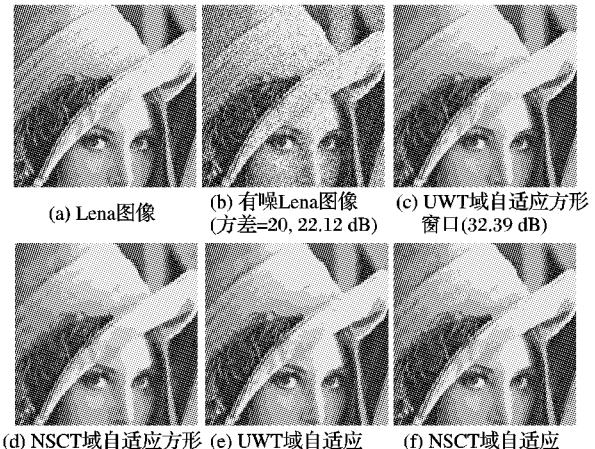


图7 Lena图像的空间自适应Bayesian缩减结果

表4 参数对Lena图像(噪声标准差为20)去噪性能影响 dB

r_1	$a_1=1$		$a_1=2$		$a_1=3$	
	UWT	NSCT	UWT	NSCT	UWT	NSCT
2	31.949	32.221	32.355	32.429	32.419	32.605
3	32.346	32.494	32.512	32.671	32.526	32.651
4	32.427	32.571	32.554	32.723	32.535	32.699
5	32.441	32.608	32.519	32.687	32.478	32.638
6	32.429	32.580	32.482	32.535	32.418	32.556

4.2 去噪性能的对比

图8给出的是本文方法与4种具有平移不变特性的Contourlet变换域去噪方法的比较情况。

这4种对比方法中,NSCT-LAS和TICT-HT分别表示NSCT域的局部自适应缩减^[11]和基于平移不变Contourlet变换的硬阈值方法^[19];而CT-CS^[9]和CT-RCS^[10]表示通过cycle spinning技术和递归cycle spinning技术建立的两种具有平移不变特性的Contourlet变换域去噪方法。可以看出,本文提出

的 NSCT 域去噪方法在不同的噪声强度下去噪性能均优于上述四种 Contourlet 域方法, 进一步表明了基于自适应椭圆窗口对 NSCT 域系数进行 Bayesian 缩减的有效性。

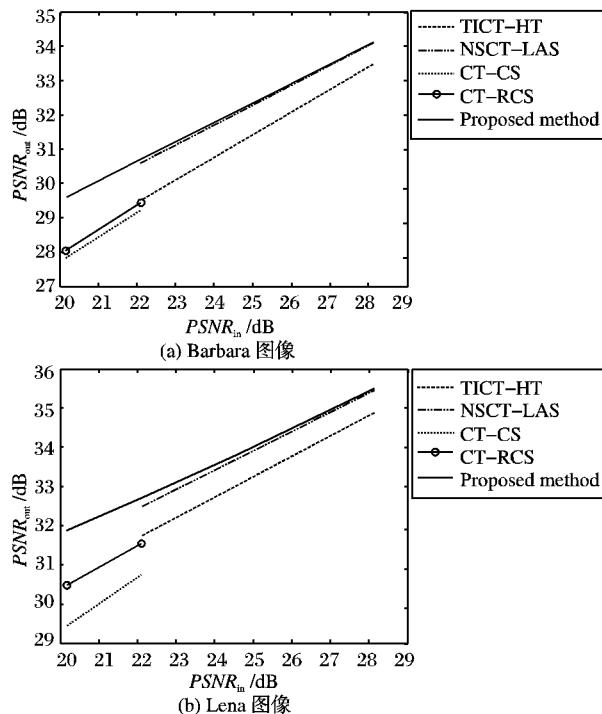


图 8 本文方法与 4 种具有平移不变特性的 Contourlet 去噪方法比较

5 结语

本文提出了一种基于非下采样 Contourlet 变换域空间自适应 Bayesian 缩减的图像去噪方法。首先, 利用广义高斯分布描述 NSCT 域子带系数的统计特性。然后, 使用了具有各向异性的椭圆窗口描述 NSCT 域子带系数的局部背景特性, 建立了局部空间活动指示器。同时, 我们给出了椭圆窗口尺寸参数 r 和形状参数 a 的选取原则, 以及在本文方法中的具体取值。通过 Barbara 和 Lena 图像的去噪实验证实了基于各向异性椭圆窗口的缩减方法在性能上优于基于各向同性方形窗口的缩减方法, 而且这类方向性窗口可以很好地自适应 NSCT 的多方向选择性, 提高 NSCT 域缩减方法的性能。与四种具有平移不变性的 Contourlet 去噪方法做了对比, 进一步验证了本文方法的有效性。

本文方法的不足之处是计算量较大。不过对于离线去噪的应用, 这一不足不会产生太大的影响, 具有一定的实际意义。值得一提的是, 各向异性椭圆窗口不仅可以用于 NSCT 域, 对于其他多尺度多方向变换都具有一定的推广意义。

参考文献:

- [1] DONOHO D L, JOHNSTONE I M. Ideal spatial adaptation via wavelet shrinkage [J]. Biometrika, 1994, 81(3): 425–455.
- [2] 潘泉, 戴冠中, 张洪才, 等. 基于阈值决策的子波域去噪方法 [J]. 电子学报, 1998, 26(1): 115–117.
- [3] 曲天书, 戴逸松, 王树勋. 基于 SURE 无偏估计的自适应小波阈值去噪 [J]. 电子学报, 2002, 30(2): 266–268.
- [4] CHANG S G, YU B, VETTERLI M. Spatially adaptive wavelet thresholding with context modeling for image denoising [J]. IEEE Transaction Image Processing, 2000, 9(9): 1522–1531.
- [5] SENDUR L, SELESNICK I W. Bivariate shrinkage with local variance estimation [J]. IEEE Signal Processing Letters, 2002, 9(12): 438–441.
- [6] PIZURICA A, PHILIPS W. Estimating the probability of the presence of a signal of interest in multiresolution single-and multiband image denoising [J]. IEEE Transactions on Image Processing, 2006, 15(3): 654–665.
- [7] 谢杰成, 张大力, 徐文立. 小波图像去噪综述 [J]. 中国图象图形学报, 2002, 7A(3): 209–217.
- [8] DO M N, VETTERLI M. The contourlet transform: An efficient directional multiresolution image representation [J]. IEEE Transactions on Image Processing, 2005, 14(12): 2091–2106.
- [9] ESLAMI R, RADHA H. The contourlet transform for image denoising using cycle spinning [C]// 37th Asilomar Conference on Signals, Systems and Computers. [S. l]: IEEE, 2003, 2: 1982–1986.
- [10] 梁栋, 沈敏, 高清维, 等. 一种基于 Contourlet 递归 Cycle Spinning 的图像去噪方法 [J]. 电子学报, 2005, 33(11): 2044–2046.
- [11] CUNHA A L, ZHOU J C, DO M N. The nonsubsampled contourlet transform: theory, design, and applications [J]. IEEE Transactions on Image Processing, 2006, 15(10): 3089–3101.
- [12] 边策, 钟桦, 焦李成. 基于非下采样 Contourlet 变换和双变量模型的图像去噪 [J]. 电子与信息学报, 2009, 31(3): 561–565.
- [13] 武晓玥, 郭宝龙, 唐璐, 等. 一种新的基于非下采样 Contourlet 变换的自适应图像去噪算法 [J]. 光学学报, 2009, 29(8): 2147–2152.
- [14] 周汉飞, 王孝通, 徐晓刚. 基于高斯比例混合模型的图像非下采样 Contourlet 域去噪 [J]. 电子与信息学报, 2009, 31(8): 1796–1800.
- [15] 韩亮, 李勇明, 温罗生, 等. 基于非下采样 Contourlet 域高斯尺度混合模型的图像降噪 [J]. 光电子·激光, 2009, 20(8): 1123–1128.
- [16] SIMONCELLI E P, ADELSON E H. Noise removal via Bayesian wavelet coring [C]// 3rd International Conference on Image Processing. Lausanne, Switzerland: IEEE, 1996, 1: 379–382.
- [17] FOWLER J E. The redundant discrete wavelet transform and additive noise [J]. IEEE Signal Processing Letters, 2005, 12(9): 629–632.
- [18] SHUI P L. Image denosing algorithm via doubly local Wiener filtering with directional Windows in wavelet domain [J]. IEEE Signal Processing Letters, 2005, 12(10): 681–684.
- [19] ESLAMI R, RADHA H. Translation-invariant contourlet transform and its application to image denoising [J]. IEEE Transactions on Image Processing, 2006, 15(11): 3362–3374.

(上接第 2076 页)

- [10] ROGERS A, CORKILL D D, JENNINGS N R. Agent Technologies for Sensor Networks [J]. IEEE Intelligent Systems, 2009, 24(2): 13–17.
- [11] DAVID J C. MACKAY. Information theory, inference, and learning algorithms [M]. Cambridge: Cambridge University Press, 2003.
- [12] KIM J H, PEARL J. A computational model for combined causal and diagnostic reasoning in inference systems [J]. IEEE Transactions on Systems, Man and Cybernetics, Part A: Systems and Humans, 1996, 26(6): 826–831.