

利用纹理信息的图像分块自适应压缩感知

王蓉芳,焦李成,刘 芳,杨淑媛

(西安电子科技大学智能感知与图像理解教育部重点实验室,陕西西安 710071)

摘 要: 与一维信号不同,二维图像有明显的纹理信息.本文分析了不同图像之间,以及同一图像不同子块之间,不同纹理引起的信息量差异,在分块压缩感知算法的基础上,提出了利用纹理信息的图像分块自适应压缩感知算法.自适应性体现在自适应采样和自适应收缩阈值两个方面.引入两种滤波器,分别形成了两种分块自适应压缩感知算法.采用自然和医学两类测试图像,验证了两种新算法的性能.实验结果表明,利用了纹理信息的分块自适应压缩感知算法,在重构图像的质量和视觉效果上,都有明显的优势.

关键词: 分块压缩感知;纹理信息;自适应采样;自适应阈值;滤波器

中图分类号: TN911 **文献标识码:** A **文章编号:** 0372-2112 (2013) 08-1506-09

电子学报 URL: <http://www.ejournal.org.cn> **DOI:** 10.3969/j.issn.0372-2112.2013.08.009

Block-Based Adaptive Compressed Sensing of Image Using Texture Information

WANG Rong-fang, JIAO Li-cheng, LIU Fang, YANG Shu-yuan

(Key Laboratory of Intelligent Perception and Image Understanding of Ministry of Education, Xidian University Xi'an, Shaanxi 710071, China)

Abstract: Different from 1D signals, 2D images have obvious texture information. Based on the basic framework of block-based compressed sensing, we propose a block-based adaptive compressed sensing of image using texture information, which exploits the property that different texture would produce varied information content. The adaptability lies in two aspects: one is the adaptive sampling and another is the adaptive threshold. Two different filters are introduced, which forms two kinds of new algorithms, respectively. The proposed algorithms are applied to nature and medical test images. The results show that our improved algorithms provide superior performance on both the reconstructed image quality and the visual effect.

Key words: block-based compressed sensing; texture information; adaptive sampling; adaptive threshold; filter

1 引言

压缩感知(Compressed Sensing, CS)理论^[1~3]突破了奈奎斯特定理两倍于信号带宽采样率的限制,在采样的同时实现信号的压缩,大大降低对采样速率的要求.自提出以来,在信号处理,计算机科学,电子工程等诸多领域得到极大的关注和广泛的应用^[4].

CS理论指出,如果一个信号 $\underline{x} \in \mathbb{R}^N$ 在某种正交变换 $\Psi \in \mathbb{R}^{N \times N}$ 下,系数 $\underline{\alpha} \in \mathbb{R}^N$ 是稀疏的或可压缩的,则可以通过少量的随机观测 $\underline{y} \in \mathbb{R}^M$ 精确重构原信号. $\Phi \in \mathbb{R}^{M \times N}$ 是观测矩阵.

$$\underline{y} = \Phi \underline{x} = \Phi \Psi \underline{\alpha} \quad (1)$$

由于 $M \ll N$,式(1)是病态的欠定问题,似乎无解.但信号的稀疏性前提和观测矩阵的有限等距性质,都为从 M 个观测中精确重构原信号提供了理论保证^[5].因此

以上欠定问题可以转化为 ℓ_1 范数优化问题(2),也称为基追踪优化(Basis Pursuit, BP)^[6],使问题可解.随之出现了很多求解BP问题的凸优化算法^[6~9].由于BP算法比较耗时,又出现了一些快速的迭代贪婪算法^[10~12].

$$\min_{\underline{\alpha}} \|\underline{\alpha}\|_1, \text{ subject to } \underline{y} = \Phi \Psi^{-1} \underline{\alpha} \quad (2)$$

然而,CS应用到2D图像 $\mathbf{I} \in \mathbb{R}^{\sqrt{N} \times \sqrt{N}}$ 时,观测矩阵 $\Phi_{M \times N}$ 的规模会非常大, N 通常在 $10^4 \sim 10^6$ 之间,使得观测矩阵的存储和相关计算,无论对于凸优化还是迭代贪婪算法,都非常难以实现.文献[13]首次提出基于分块压缩感知(Block Compressed Sensing, BCS)采样的方法,文献[14]在该采样方法的基础上,提出BCS采样和光滑Landweber投影重构(Block-based CS Sampling and Smoothed Projected Landweber Reconstruction, BCS-SPL)的分块压缩感知算法,解决了这一难题.

在 BCS 的采样过程,原图 I 被分成不重叠的 b 个 $B \times B$ 的小图像块,然后用相同的观测矩阵 $\Phi_{m \times n}$ 对每个子块独立观测,得到观测向量集合(3).

$$\{y_i | y_i = \Phi_{m \times n} x_i, i = 1, 2, \dots, b\} \quad (3)$$

其中, $x_i \in \mathbb{R}^n$ 是原图第 i 个子块的灰度值向量. $\Phi_{m \times n}$ 是正交归一的独立同分布随机高斯矩阵, $n = B^2$, $m = \lfloor SR \cdot n \rfloor$, 采样率 $SR = M/N$, $b = N/n$. 在 BCS 的重构过程,凸投影在各个子块上依次进行. 因此,在采样以及重构阶段,存储和计算都在小规模的 $\Phi_{m \times n}$ ($n \ll N$) 上进行,观测矩阵的规模不再随原图 I 的增大而增加,不仅降低了存储和计算成本,还使 CS 不再受计算机硬件条件的限制,可以应用到任意大小的 2D 图像处理中.

但是,文献[13,14]的 BCS 方法,无论在采样还是重构阶段,都没有利用图像自身的纹理信息. 首先,不同图像之间纹理结构不同,有些图像平滑区域较多,有些图像含有较多的边缘,细节区域;其次图像分块后,平滑块,纹理块和边缘块,这些子块之间的纹理结构也是不同的. 本文在 BCS-SPL 算法^[14]的基础上,利用不同图像之间,以及一幅图像不同子块之间,纹理结构的差异,提出了分块自适应压缩感知(Block-based Adaptive Compressed Sensing, BACS)图像重构算法.

BACS 算法的自适应性主要体现在两方面:(1)自适应采样,即每个子块的采样率依据其纹理信息自适应的变化;(2)自适应重构,主要体现在滤波操作中,根据不同图像的纹理信息,随着迭代过程,阈值自适应的收缩减小. 在 BACS 的框架下,引入了两种滤波器,分别形成了两种 BACS 算法. 采用自然图像和医学图像两类数据集,验证了两种新算法的性能.

2 利用纹理信息的自适应采样

图像分块后,不同子块纹理不同,包含的信息量也不同. 理想的采样方法应该是信息量少的块少采样,如平滑块;而信息量多的块多采样,如含有很多细节的纹理块. 这样在总采样率不变的情况下,可以将有限的资源有效地分配给那些纹理更复杂的图像块. 因此,本文不再像原 BCS 采样方法中,所有块都采用相同的采样率,而是根据子块间纹理结构不同引起信息量的差异,计算得到自适应的采样率.

本文采用图像的一维灰度熵作为纹理信息的度量. 图像的一维灰度熵是图像灰度特征的统计形式,表示图像中灰度分布的聚集特征所包含的信息量,可以很好地反映图像中平均信息量的多少^[15]. 令 p_j 表示灰度值为 j 的像素所占的比例,则一维灰度熵定义为:

$$h = - \sum_{j=0}^{255} p_j \cdot \log_2 p_j \quad (4)$$

要计算灰度熵,首先得有图像,而压缩感知已知的是随机观测. 如何从随机观测中快速得到估计图像,进而计算灰度熵,并将其转化为自适应采样率呢? 本文设计了预采样和自适应采样相结合的方法,实现步骤如下,流程说明见图 1.

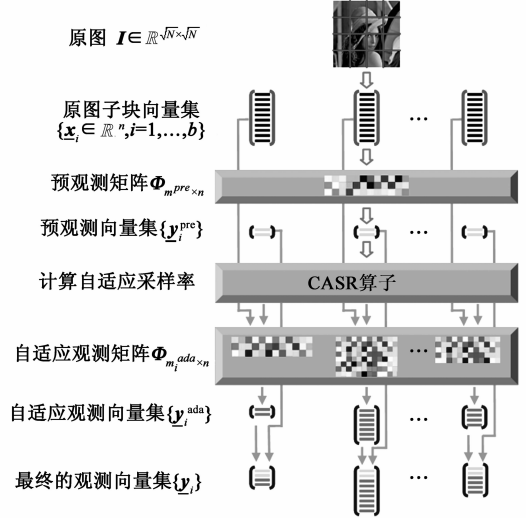


图1 自适应采样模块流程

Step1 预采样:对所有子块用很小的预采样率 $r^{\text{pre}} = \min(SR/2, 0.1)$ 进行一次预采样,得到预观测向量集合. 其中预观测数目 $m^{\text{pre}} = \lfloor r^{\text{pre}} \cdot n \rfloor$, 预观测矩阵 $\Phi_{m^{\text{pre}} \times n}$ 是 $\Phi_{n \times n}$ 的前 m^{pre} 行.

Step2 计算自适应采样率(Calculate Adaptive Sampling Rate, CASR):(1)用最小均方误差线性估计方法(Minimum Mean Square Error, MMSE)^[13],从预观测向量得到每个子块的预估计图像;(2)计算每个预估计图像块的灰度熵 h_i^{pre} ;(3)根据提出的式(5),用灰度熵计算每个子块的自适应采样率.

$$r_i^{\text{ada}} = (SR - r^{\text{pre}}) \cdot b \cdot h_i^{\text{pre}} / \sum_{i=1}^b h_i^{\text{pre}} \quad (5)$$

Step3 自适应采样:对所有子块用计算出的采样率再进行一次自适应采样,得到自适应观测向量集合. 同样的,观测数目 $m_i^{\text{ada}} = \lfloor r_i^{\text{ada}} \cdot n \rfloor$, 自适应观测矩阵 $\Phi_{m_i^{\text{ada}} \times n}$ 是 $\Phi_{n \times n}$ 的前 m_i^{ada} 行. 最后将自适应观测向量和预观测向量合并,得到最终的观测向量集合.

虽然整个过程进行了两次采样,但是 $r^{\text{pre}} + \frac{1}{b} \sum_{i=1}^b r_i^{\text{ada}} = SR$, 所以总采样率没有变化. 而且由于各个子块的两次采样,彼此都是独立进行的,自适应采样模块很容易用滤波器组实现,每个 FIR 滤波器只处理一个 $B \times B$ 的小图像块. 这样并行化后,还可以大大降低自适应采样模块的时间成本.

3 利用纹理信息的自适应重构

3.1 自适应重构算法的基本框架

BCS-SPL 算法没有直接求解 ℓ_1 范数问题(2), 而是采用凸投影式(6)和滤波式(7)操作交替迭代求解的方法^[14]. 凸投影操作可以找到离超平面 $\mathbf{y} = \Phi \mathbf{x}$ 距离最近的向量, 对应于 $\min_{\mathbf{x}} \frac{1}{2} \|\mathbf{y} - \Phi \mathbf{x}\|_2^2$ 项; 滤波操作利用信号在某个变换域 Ψ 下稀疏的先验, 对应于 $\min_{\mathbf{x}} \|\mathbf{x}\|_1$ 项. 两种方法交替迭代进行, 相当于隐式地求解 ℓ_1 范数问题. 凸投影操作在分块后的小图像块 \mathbf{x} 上进行, 解决了原始大图观测矩阵规模太大, 凸投影无法求解的难题. 滤波操作在不分块的大图 X 上进行, 又能有效减少算法的运行时间.

$$\begin{aligned} \varphi(\mathbf{x}, \mathbf{y}, \Phi) &= \mathbf{x} + \Phi^T(\Phi \Phi^T)^{-1}(\mathbf{y} - \Phi \mathbf{x}) \\ &= \mathbf{x} + \Phi^T(\mathbf{y} - \Phi \mathbf{x}) \end{aligned} \quad (6)$$

$$\tilde{\mathbf{X}} = \mathcal{T}(\mathbf{X}, \Psi, \lambda) \quad (7)$$

本文提出的 BACS 算法, 延续了 BCS-SPL 中凸投影和滤波交替迭代求解的基本框架, 但对其不足做了如下改进:

(1) 去掉了每次迭代中的维纳滤波操作, 仅对初始图像做一次维纳滤波. 在试验中发现, 维纳滤波对于纹理较复杂的区域会起反作用, 使得重构结果过于平滑, 丧失了很多细节信息. 将 BCS-SPL 的维纳滤波, 凸投影, 再滤波, 再凸投影的四步操作, 化简为一次凸投影加一次滤波交替迭代求解.

(2) 滤波操作中, 阈值不再固定不变, 而是根据图像的纹理信息, 自适应地变化.

(3) 初始解不再由 $\Phi^T \mathbf{y}$ 方法得到, 而是用文献[13]中的 MMSE 方法求得. MMSE 方法得到的初始解的质量要比 $\Phi^T \mathbf{y}$ 或伪逆 $\Phi^+ \mathbf{y}$ 好很多.

3.2 利用纹理信息的自适应收缩阈值

原 BCS-SPL 算法的滤波操作, 对不同图像, 在不同的迭代过程, 阈值 λ 始终采用同一固定值. 然而 λ 的值如何选取会对滤波结果产生很大的影响. λ 的值过大, 能很好的滤掉噪声, 但会丧失细节信息; λ 的值过小, 保留了细节的同时也保留了噪声. 因此本文提出 λ 随迭代过程线性递减的取值方法式(8). 随着迭代过程图像质量不断提升, 噪声越来越少, λ 也随之减小, 滤噪的同时很好地保留细节信息. 还有随着采样率的增加, 初始图像的噪声也会下降, 从而设置 λ 的初值 λ^0 随着采样率的增加线性递减.

$$\lambda^g = \rho^{(g-1)} \cdot \lambda^0, \quad \lambda^0 = \lambda^{\text{MAX}} \cdot (1.1 - SR) \quad (8)$$

阈值 λ 的自适应, 更重要地体现在 ρ 值的选取, 设计了可以根据图像纹理信息自适应变化的公式(9).

$$\rho = 1 - \left(\frac{1}{b} \sum_{i=1}^b h_i^{\text{ini}} \right)^2 / 10^3 \quad (9)$$

其中, h_i^{ini} 是第 i 个子块初始估计图像的灰度熵. 对于纹理较简单的图像, 由于熵的均值较小, 从而 ρ 值较大, 随之 λ 递减的较慢. 反之对于纹理较复杂的图像, λ 递减的较快. 这样, 在不同图像的处理过程, 即使初始 λ^0 取相同值, 由于递减速率 ρ 不同, 在迭代中, λ^g 会自适应地调整为简单图像的阈值比复杂图像的阈值大. 这样既能很好地平滑简单图像, 又能让复杂图像更好的保留细节信息.

图 2(a) 是不同采样率下, 10 幅图像 ρ 值的变化. 图 2(b) 是采样率 $SR = 50\%$, 10 幅图像的阈值 λ 随迭代过程递减的曲线图. 从图中可以看出, ρ 值从大到小的排列顺序与图像实际的纹理复杂程度相一致, 较简单的医学 CT 图像的 ρ 值最大, 相应地 λ 也递减的最缓慢. 细节信息较多的复杂自然图像 Mandrill, 其 ρ 值最小, 相应地 λ 也递减的最快速. 达到了预期的阈值 λ 随迭代过程和图像纹理信息自适应取值的目标.

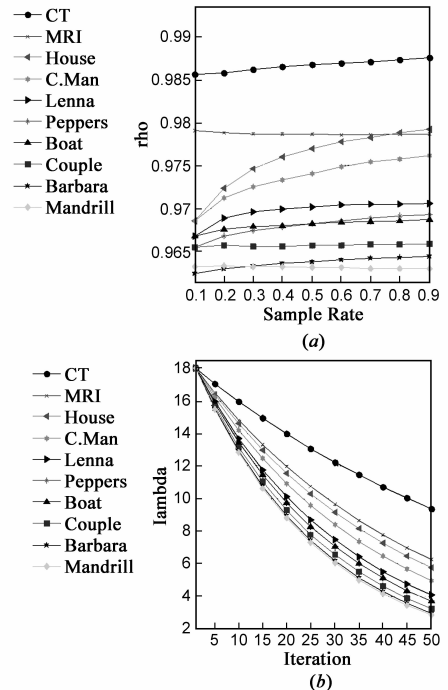


图2 不同图像的自适应阈值比较

3.3 两种滤波器

在滤波操作引入了两种滤波器, 一种是 BCS-SPL 中采用双变量收缩阈值方法的双树离散小波变换 (Dual-tree Discrete Wavelet Transform, DDWT)^[14] 滤波器, 另一种是结合块匹配和 3D 滤波的 (Block-Matching and 3D filtering, BM3D)^[16] 滤波器. 3.2 节提出的阈值自适应收缩方法, 对第一种 DDWT 滤波器, 调整的是双变量收缩里的 λ ; 对第二种 BM3D 滤波器, 调整的是三维变换的阈值

λ_{3D} . 原文的 BM3D 方法,由两个步骤组成,为了降低时间成本,本文只采用步骤 1 基本估计.其余参数均取默认值,滤波器算法的实现直接采用两种方法的原始代码*

4 分块自适应压缩感知算法描述和时间复杂度分析

4.1 算法的实现策略

本节给出 BACS 算法的具体实现步骤.如果在重构阶段的滤波操作采用不同的滤波器 \mathcal{T} ,就可以形成基于 BACS 框架下不同的新算法.算法的终止条件为达到最大迭代次数 G_{\max} .

Algorithm: Block-Based Adaptive Compressed Sensing

Stage1: 自适应采样

Input: 原图 I , 采样率 SR , 预采样率 r^{pre} , 块大小 B , 高斯随机观测矩阵 $\Phi^{n \times n}$

- 1: $I \mapsto \{\underline{x}_i^{\text{ori}} | \underline{x}_i^{\text{ori}} \in \mathbb{R}^{n \times 1}\}$
- 2: $\{\underline{y}_i^{\text{pre}}\} = \Phi_{m_i^{\text{pre}} \times n} \{\underline{x}_i^{\text{ori}}\}$
- 3: $\{r_i^{\text{ada}}\} = \text{CASR}(\{\underline{y}_i^{\text{pre}}\}, SR, r^{\text{pre}})$
- 4: for each block i , $\{\underline{y}_i^{\text{ada}} | \underline{y}_i^{\text{ada}} = \Phi_{m_i^{\text{ada}} \times n} \underline{x}_i^{\text{ori}}\}$

Output: 观测向量集合 $\{\underline{y}_i | \underline{y}_i = [\underline{y}_i^{\text{pre}}; \underline{y}_i^{\text{ada}}]\}$

Stage2: 自适应重构

Input: 高斯随机观测矩阵 $\Phi^{n \times n}$, 观测向量集合 $\{\underline{y}_i\}$, λ^{MAX}

Initialization: 用 MMSE 方法得到初始解 $\{\underline{x}_i^{\text{ini}}\}$, 计算每个初始解的一维灰度熵 $\{h_i^{\text{ini}}\}$, 根据公式(9)计算 ρ . 令 $\{\underline{x}_i^1 | \underline{x}_i^1 = \text{Wiener}(\underline{x}_i^{\text{ini}})\}$, $g = 1$.

Repeat

- 1: for each block i , $\{\tilde{\underline{x}}_i^g | \tilde{\underline{x}}_i^g = \mathcal{P}(\underline{x}_i^g, \underline{y}, \Phi_{m_i \times n}^g)\}$
- 2: $\lambda^g = \rho^{(g-1)} \cdot \lambda^0$
- 3: $\{\tilde{\underline{x}}_i^g\} \mapsto \tilde{\mathbf{X}}^g, \mathbf{X}^{\lfloor g+1 \rfloor} = \mathcal{T}(\tilde{\mathbf{X}}^g, \lambda^g), \mathbf{X}^{g+1} \mapsto \{\underline{x}_i^{g+1}\}$
- 4: $g = g + 1$

Until stopping criterion is satisfied

Output: $\mathbf{X}^* = \mathbf{X}^{\lfloor g+1 \rfloor}$

4.2 算法时间复杂度分析

由于本文的 BACS 算法是在 BCS-SPL 算法基本框架上的改进,因此重点对比分析两种算法时间复杂度的差别. BACS 和 BCS-SPL 算法,总运行时间都由采样时间 T_S 和重构时间 T_R 两部分组成.

BCS-SPL 的采样时间为 $T_S^{\text{BCS-SPL}} = b \cdot O(mn)$. BACS 中,虽然执行了预期和自适应两次采样,但总采样率没变,所以两次采样的总时间也是 $b \cdot O(mn)$. 但是比 BCS-SPL,多出了计算自适应采样率算子的时间 T_{CASR} . 该算子中,灰度熵和采样率的计算时间,复杂度都是常数阶 $O(1)$,主要消耗是 MMSE 操作的时间. 根据 MMSE

的实现公式和符号 O 的运算规则,推导化简得出 $T_{\text{MMSE}} = O(m^{\text{pre}} n^2)$. 两项合并, BACS 的采样时间为 $T_S^{\text{BACS}} = b \cdot O(mn) + b \cdot O(m^{\text{pre}} n^2)$.

两种算法的重构时间主要由初始化 T_{INI} , 凸投影 $T_{\mathcal{P}}$, 维纳滤波 $T_{\mathcal{W}}$ 和所采用的某种滤波器 $T_{\mathcal{T}}$ 的时间组成. 根据各自的实现步骤和 O 的运算规则,推导化简得出结果如下:

$$T_R^{\text{BCS-SPL}} = T_{\text{INI}} + G_{\max}(T_{\mathcal{W}} + b \cdot T_{\mathcal{P}} + T_{\mathcal{T}} + b \cdot T_{\mathcal{P}}) \\ = b \cdot O(mn) + G_{\max}(T_{\mathcal{W}} + 2b \cdot O(mn) + T_{\mathcal{T}}) \quad (10)$$

$$T_R^{\text{BACS}} = T_{\text{INI}} + G_{\max}(b \cdot T_{\mathcal{P}} + T_{\mathcal{T}}) \\ = (b \cdot O(mn^2) + T_{\mathcal{W}}) + G_{\max}(b \cdot O(mn) + T_{\mathcal{T}}) \quad (11)$$

由于 $T_{\mathcal{W}}$ 和 $T_{\mathcal{T}}$ 的时间复杂度依赖其具体的实现方法,因此不再给出 O 的表示结果. 对比两个公式可以看出,在 $T_{\mathcal{T}}$ 相同的情况下, BACS 的初始化时间较长,但每迭代一次的时间要远远少于 BCS-SPL. 综合以上采样和重构的分析结果,得出 BACS 的总运行时间为:

$$T^{\text{BACS}} = (b \cdot O(mn) + b \cdot O(m^{\text{pre}} n^2)) \\ + (b \cdot O(mn^2) + T_{\mathcal{W}}) + G_{\max}(b \cdot O(mn) + T_{\mathcal{T}}) \quad (12)$$

从该公式也可以清楚的看出,如果对各个块的处理采用并行的滤波器组实现,则公式中的分块数 $b = 1$, 算法总体运行时间约为原来的 $1/b$, 可以大大降低时间成本.

5 实验仿真与结果分析

实验中用到的测试图像有,八幅自然图像 Lenna, Barbara, Peppers, Mandrill, Couple, Boat, Camera Man 和 House, 以及 MRI 和 CT 两幅医学图像. 十幅图像中, Camera Man 和 House 大小是 256×256 , 其余八幅都是 512×512 .

对比算法有:原算法 BCS-SPL-DDWT^[14], 快速贝叶斯压缩感知 (fast Bayesian Compressive Sensing, fast-BCS)^[7], 压缩采样匹配追踪 (Compressive Sampling Matching Pursuit, CoSaMP)^[12], 梯度投影稀疏重构 (Gradient Projection for Sparse Reconstruction, GPSR)^[9], 基于模型的 CoSaMP (Model-CoSaMP)^[17] 和树结构小波压缩感知 (Tree-Structure Wavelet Compressive Sensing, TSWCS)^[8]. 所有实验都在 MATLAB R2010a 环境下完成,硬件条件为英特尔双核 CPU, 频率 1.83GHz, 内存 1.97GB.

5.1 参数设置

首先是分块大小 B 的设置. 小的 B 值, 所需内存空间小, 算法运行速度快; 大的 B 值, 重构结果性能较好.

* BCS-SPL-DDWT: <http://www.ece.msstate.edu/~fowler/BCSSPL/>, BM3D: <http://www.cs.tut.fi/~foi/GCF-BM3D>

本文沿用文献[13]中的经验取值,令 $B = 32$. 三种 BCS 算法,终止条件均为最大迭代次数 $G_{\max} = 50$. 本文的 BACS 算法,需要设置的参数只有 λ^{\max} . 对于 BACS-DDWT,取 $\lambda^{\max} = 30$,对于 BACS-BM3D,取 $\lambda^{\max} = 10$. Model-CoSaMP 和 CoSaMP 中,稀疏等级设置为 $K = M/5$. 其余未提到的参数均采用默认值. 所有结果均为每种算法独立运行 5 次后的平均值.

5.2 BACS 中不同改进策略的实验对比结果与分析

BACS 方法中,用到的策略有自适应采样和自适应收缩阈值. 为了分别验证两种策略对算法的改进效果,

表 1 BACS 不同改进策略的对比结果

Reconstruction Algorithm	SR = 30%						SR = 50%					
	Barbara		House		MRI Image		Barbara		House		MRI Image	
	PSNR (dB)	Time (s)	PSNR (dB)	Time (s)	PSNR (dB)	Time (s)	PSNR (dB)	Time (s)	PSNR (dB)	Time (s)	PSNR (dB)	Time (s)
BCS-SPL-DDWT	25.63	93.1	32.82	30.1	32.06	93.2	28.83	95.2	36.32	30.6	40.28	96.4
asrBCS-SPL-DDWT	26.16	101.8	33.89	39.4	37.03	110.7	29.87	106.84	37.58	44.50	44.91	119.80
BACS-DDWT($\lambda_{\text{fix}} = 15$)	27.98	124.1	36.35	40.4	42.05	134.3	32.00	206.2	38.92	65.7	46.66	251.4
BACS-DDWT*	29.70	116.4	36.41	38.6	42.39	126.8	35.42	167.89	39.16	54.60	47.60	200.66
BACS-BM3D($\lambda_{\text{fix}} = 5$)	28.68	136.7	35.19	40.2	38.96	135.0	32.23	235.7	38.03	68.1	43.66	251.6
BACS-BM3D*	33.10	149.0	37.10	40.9	40.74	115.0	37.64	218.92	40.33	60.23	46.52	209.70

注:带 * 号的是本文提出的两种算法

对比表 1 中 BCS-SPL-DDWT 和 asrBCS-SPL-DDWT 的结果可以看出,自适应采样策略比固定采样,对于三幅图像,在两种采样率下 PSNR 值都有所提高,尤其对于平滑子块较多的 House 和 MRI 图像,改进性能更显著. 这正是因为该策略可以自适应地将大量平滑块的采样率调整到复杂的边缘和细节块,实现了对有限资源更合理的分配. 图 3 中各个子块采样率调整前后的对比结果,也正说明了这一点.

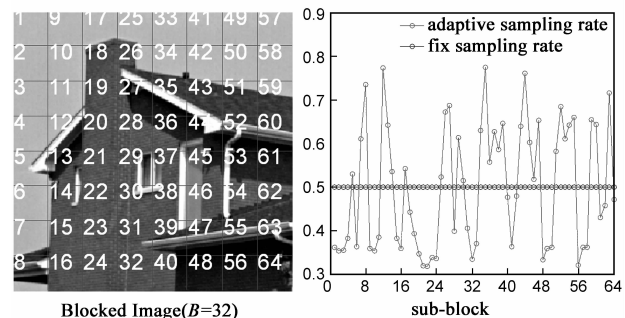


图 3 House 调整后的自适应采样率(SR=50%)

表 1 中后四种算法的对比结果显示,无论对于滤波器 DDWT 还是 BM3D,采用自适应收缩阈值策略的 BACS 算法,得到的重构图像的 PSNR 值,都比阈值固定算法的高. 尤其对于纹理子块较多的 Barbara 图像, BACS-DDWT 比固定阈值, PSNR 提高了 1.72dB, BACS-BM3D 比固定阈值, PSNR 提高了 4.42dB,改进性能都很显著. 图

对原算法做如下调整. 一种是将文中提出的自适应采样策略应用到原 BCS-SPL-DDWT 算法中,改动后的新算法简称为 asrBCS-SPL-DDWT. 另一种是将 BACS 算法中的阈值 λ 更改为固定取值,两种滤波器对应的调整后的算法分别为 BACS-DDWT($\lambda_{\text{fix}} = 15$)和 BACS-BM3D($\lambda_{\text{fix}} = 5$). 选择有代表性的 Barbara, House, 和医学 MRI 三幅图像验证两种策略的性能. 表 1 中给出了六种算法在采样率 $SR = 30\%$ 和 $SR = 50\%$ 时,各自重构图像的 PSNR 和运行时间.

4 是 Barbara 重构结果的局部放大对比图,从视觉效果来看,采用自适应收缩阈值策略重构的图像,纹理更清晰,脸部围巾等处的细节信息更鲜明.




图 4 Barbara 重构结果局部放大图(SR=30%)

5.3 BACS 的整体性能实验对比结果与分析

用前面提到的十幅自然和医学测试图像,以及六种 CS 重构算法,对比验证本文提出的两种 BACS-DDWT 和 BACS-BM3D 算法的整体性能.

图 5(a)-(j)是八种算法对不同图像,在变化的采样率下重构结果的 PSNR 值. 从图 5 中看出,对所有图像,在所有采样率下, BACS-DDWT 和 BACS-BM3D 的重构图像的质量,比原 BCS-SPL-DDWT 算法,都有显著提高,更是远远优于其他五种基于小波变换的算法. 尤其对于较难处理的含有许多杂乱的细小纹理的 Mandrill 图(图 5(d)),两种新算法也都取得了明显的改进效果.

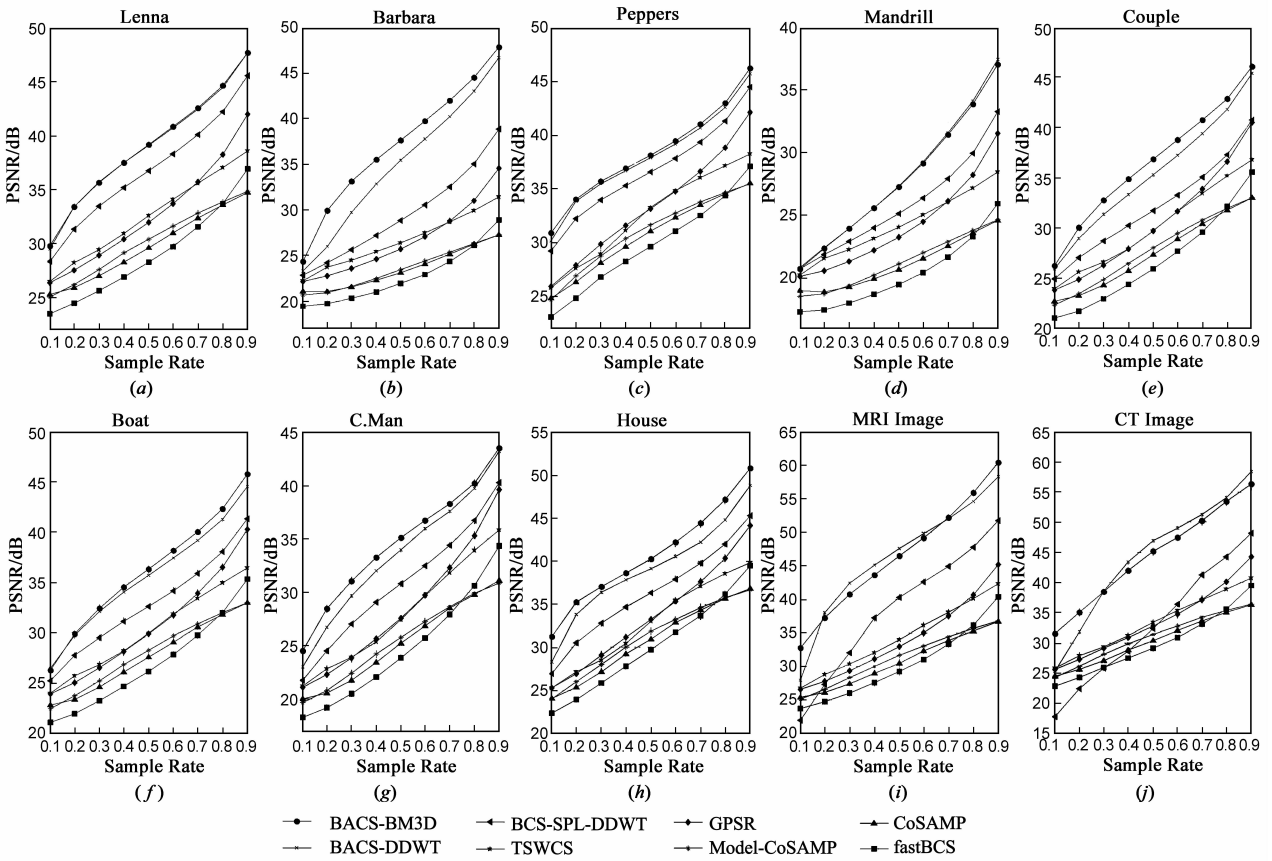


图5 不同算法重构图像质量比较曲线图

为了比较 BACS-DDWT 和 BACS-BM3D 与其他六种算法的时间成本,表 2 中给出八种算法在采样率 $SR = 40\%$ 时,对四幅自然图像和两幅医学图像的重构结果的 PSNR 值和运行时间.对比表 2 中的结果看出,迭代贪婪类的算法 CoSaMP 的时间最快,但重构结果的质量不好.TSWCS 算法在五种基于小波变换的算法中,重构结果质量最好,但是运行时间太长,即使对于 256×256 的










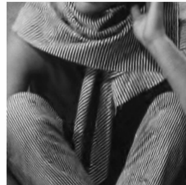
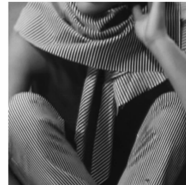
















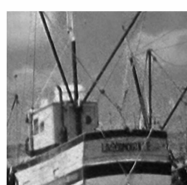








图像,运行时间也超过了 10^3 s,而且其重构质量也远远不如三种 BCS 算法的结果.文中提出的两种 BACS 算法,由于加入了一些改进策略,所以比 BCS-SPL-DDWT 的运行时间长,约为原算法的两倍,但还是远远低于 fastBCS, GPSR, Model-CoSaMP 和 TSWCS 四种算法的运行时间.且比 BCS-SPL-DDWT,平均 PSNR 提高了约 6dB.

表 2 BACS 整体性能的对比结果 ($SR = 40\%$)

Reconstruction Algorithm	Lenna		Barbara		Mandrill		House		CT Image		MRI Image		Mean	
	PSNR (dB)	Time (s)	PSNR (dB)	Time (s)	PSNR (dB)	Time (s)	PSNR (dB)	Time (s)	PSNR (dB)	Time (s)	PSNR (dB)	Time (s)	PSNR (dB)	Time (s)
fastBCS	26.87	590.1	21.02	596.5	18.68	616.8	27.79	142.8	27.59	579.3	27.49	358.2	24.91	480.6
CoSaMP	28.26	59.8	22.29	97.6	19.94	126.7	29.25	12.2	28.95	96.3	28.78	71.4	26.25	77.3
GPSR	30.39	640.2	24.58	687.4	22.23	849.3	31.17	147.2	31.07	497.7	30.88	291.2	28.39	518.8
Model-CoSaMP	29.14	369.8	22.51	618.0	20.25	791.6	30.06	85.2	29.98	560.0	29.84	420.6	26.96	474.2
TSWCS	30.91	4611.7	25.39	4610.0	23.16	4681.8	30.49	1148.3	31.97	4640.1	31.23	4258.7	28.86	3991.8
BCS-SPL-DDWT	35.17	94.5	27.19	94.8	23.99	94.2	34.66	30.7	37.19	95.2	28.66	95.9	31.14	84.2
BACS-DDWT	37.51	144.8	32.84	142.4	25.60	141.5	37.85	47.2	45.14	163.6	43.39	182.9	37.06	137.1
BACS-BM3D	37.48	153.3	35.49	173.9	25.59	168.8	38.67	48.7	43.65	157.1	41.94	175.3	37.14	146.2

为了比较重构图像的视觉效果,图 6,图 7 中分别给出了五种算法 Model-CoSaMP, TSWCS, BCS-SPL-DDWT,

BACS-DDWT 和 BACS-BM3D,对八幅自然图像和两幅医学图像重构最好结果的局部放大图。

Original Image	Model-CoSaMP	TSWCS	BCS-SPL-DDWT	BACS-DDWT	BACS-BM3D
 (a) Lenna	 PSNR=27.69dB	 PSNR=29.46dB	 PSNR=33.53dB	 PSNR=35.77dB	 PSNR=35.72dB
 (b) Barbara	 PSNR=21.67dB	 PSNR=24.51dB	 PSNR=25.70dB	 PSNR=29.77dB	 PSNR=33.16dB
 (c) Peppers	 PSNR=28.79dB	 PSNR=28.97dB	 PSNR=33.98dB	 PSNR=35.52dB	 PSNR=35.72dB
 (d) Mandrill	 PSNR=19.46dB	 PSNR=22.31dB	 PSNR=22.96dB	 PSNR=23.97dB	 PSNR=23.95dB
 (e) Couple	 PSNR=24.94dB	 PSNR=26.64dB	 PSNR=28.75dB	 PSNR=31.29dB	 PSNR=32.85dB
 (f) Boat	 PSNR=25.25dB	 PSNR=26.87dB	 PSNR=29.61dB	 PSNR=32.15dB	 PSNR=32.44dB
 (g) Camera Man	 PSNR=22.63dB	 PSNR=23.40dB	 PSNR=27.12dB	 PSNR=29.72dB	 PSNR=31.21dB




图6 自然图像重构结果局部放大图(SR=30%)




图7 医学图像重构结果局部放大图(SR=20%)

从图 6 和图 7 中可以看出,无论对于自然图像,还是医学图像,两种 BACS 算法对平滑,边缘,和细节等不同纹理结构的区域,得到的重构结果都要优于其他三种算法,图像质量更高,视觉效果更好.尤其 BACS-BM3D 算法,由于 BM3D 滤波器中利用了图像的非局部自相似性,要比 BACS-DDWT 算法的性能更优.

6 总结与后续工作

二维图像有明显的纹理信息.如每幅图像都含有平滑,边缘和细节等不同纹理结构的区域.本文正是研究利用不同区域之间纹理信息的差别,在分块压缩感知算法的基础上,提出了两种改进的分块自适应压缩感知算法 BACS-DDWT 和 BACS-BM3D.采用八幅自然图像和两幅医学图像,验证了两种新算法的性能.与其他六种压缩感知重构算法的对比实验结果表明,结合了自适应采样和自适应收缩阈值策略的分块自适应压缩感知算法,在重构图像的质量和视觉效果上,都有明显的优势.

后续工作打算从以下两方面展开.首先,BACS-DDWT 和 BACS-BM3D 两种算法得到的不同实验结果表明,好的滤波器可以提升 BACS 算法的整体性能.目前在图像去噪领域,有很多成熟的滤波器算法,这些算法都可以很容易的结合到 BACS 框架中,从而形成不同的分块自适应压缩感知算法.其次,在 BACS 算法中,由于

图像分块以及采用 MMSE 方法后,能够快速得到质量较好的初始图像,而不再仅仅是观测向量.因此,CS 图像重构问题可以转化为对初始图像的处理问题,这样在图像增强,图像复原,图像去噪等这些图像处理领域中的一些新的好方法,就可以应用到 CS 图像重构问题中,为 CS 重构算法的改进带来新的视角.

参考文献

- [1] 焦李成,等.压缩感知回顾与展望[J].电子学报,2011,39(7):1651-1662.
JIAO Li-cheng, et al. Development and prospect of compressive sensing[J]. Acta Electronica Sinica, 2011, 39(7): 1651-1662. (in Chinese)
- [2] Donoho D L. Compressed sensing[J]. IEEE Transaction on Information Theory, 2006, 52(4): 1289-1306.
- [3] Baraniuk R G. Compressive sensing[J]. IEEE Signal Processing Magazine, 2007, 24(4): 118-120.
- [4] Eldar Y C, et al. Compressed Sensing: Theory and Applications[M]. New York: Cambridge University Press, 2012. 1-544.
- [5] Candès E J. The restricted isometry property and its implications for compressed sensing[J]. Comptes Rendus Mathématique, 2008, 346(9): 589-592.
- [6] Chen S S, et al. Atomic decomposition by basis pursuit[J]. Society for Industrial and Applied Mathematics Review,

- 2001, 43(1): 129 – 159.
- [7] Ji S, et al. Bayesian compressive sensing and projection optimization[A]. Proceedings of the 24th International Conference Machine Learning[C]. Corvallis, OR – USA, 2007. 377 – 384.
- [8] He L, Carin L. Exploiting structure in wavelet-based Bayesian compressive sensing[J]. IEEE Transaction on Signal Processing, 2009, 57(9): 3488 – 3497.
- [9] Figueiredo M A T, et al. Gradient projection for sparse reconstruction: application to compressed sensing and other inverse problems[J]. IEEE Journal on Selected Areas in Communications, 2007, 1(4): 586 – 597.
- [10] Pati Y C, et al. Orthogonal matching pursuit: recursive function approximation with applications to wavelet decomposition[A]. Proceedings of the 27th Asilomar Conference on Signals, Systems and Computers[C]. Los Alamitos, CA, IEEE Comput Soc Press, 1993. 40 – 44.
- [11] Donoho D L, et al. Sparse solution of underdetermined linear equations by stagewise orthogonal matching pursuit[J]. IEEE Transaction on Information Theory, 2012, 58(2): 1094 – 1121.
- [12] Needell D, Tropp J A. CoSaMP; iterative signal recovery from incomplete and inaccurate samples[J]. Applied and Computational Harmonic Analysis, 2009, 26(3): 301 – 321.
- [13] Gan L. Block compressed sensing of natural images[A]. Proceedings of the 15th International Conference on Digital Signal Processing[C]. Cardiff, UK, 2007. 403 – 406.
- [14] Sungkwang M, Fowler J E. Block compressed sensing of images using directional transforms[A]. Proceedings of the 16th IEEE International Conference on Image Processing[C]. Cairo, Egypt, 2009. 3021 – 3024.
- [15] Jeon B J, Kim J H. Performance evaluation of teeth image recognition system based on difference image entropy[A]. Proceedings of the 3rd International Conference on Convergence and Hybrid Information Technology[C]. Busan, South Korea, 2008. 967 – 972.
- [16] Dabov K, et al. Image denoising by sparse 3D transform – domain collaborative filtering[J]. IEEE Transaction on Image Processing, 2007, 16(8): 2080 – 2095.
- [17] Baraniuk R G, et al. Model-based compressive sensing[J]. IEEE Transaction on Information Theory, 2010, 56(4): 1982 – 2001.

作者简介



王蓉芳 女, 1978 年生于甘肃. 西安电子科技大学电子工程学院在读博士生. 主要研究领域为智能信号与图像处理, 自然计算, 压缩感知等.
E-mail: rongfang_w@gmail.com



焦李成 男, 1959 年生于陕西, 西安电子科技大学电子工程学院院长, 智能感知与图像理解教育部重点实验室主任, 博导, IEEE 高级会员, CCF 高级会员. 主要研究领域为智能算法, 机器学习, 非线性科学, 小波理论及其应用等.
E-mail: lchjiao@mail.xidian.edu.cn