

基于最佳线性估计的快速压缩感知图像重建算法

李 然 千宗良 朱秀昌*

(南京邮电大学图像处理与图像通信重点实验室 南京 210003)

摘 要: 针对目前存在的压缩感知(CS)重建算法计算复杂度过高的问题, 该文提出一种基于最佳线性估计的快速 CS 图像重建算法。该算法在编码端进行分块自适应 CS 随机测量, 在解码端根据图像块不同的统计特性, 估计出统计自相关函数矩阵, 进而构造出最佳线性算子用于重建出各个图像块。由于该算法用线性投影的方式替代了传统 CS 重建算法的非线性迭代过程, 使得其大大缩短了图像重建时间。仿真实验结果表明, 对于纹理细节不复杂的图像, 所提出的算法并没有因为其计算复杂度的减少而影响到重建质量, 仍优于目前流行的 CS 重建算法。

关键词: 图像处理; 分块压缩感知; 自适应测量; 最佳线性估计; 统计自相关函数; 快速图像重建

中图分类号: TN911.73

文献标识码: A

文章编号: 1009-5896(2012)12-3006-07

DOI: 10.3724/SP.J.1146.2012.00504

A Fast Compressed-sensing Image Reconstruction Algorithm Based on Best Linear Estimate

Li Ran Gan Zong-liang Zhu Xiu-chang

(Image Processing & Image Communication Key Lab,

Nanjing University of Posts and Telecommunications, Nanjing 210003, China)

Abstract: Because of existing Compressed-Sensing (CS) reconstruction algorithms have high computing complexity, a fast algorithm based on best linear estimate is proposed. It adaptively measures image data with a block-by-block manner at encoder, and reconstructs each block at decoder using the best linear operator which is constituted by statistical autocorrelation function matrix estimated according to various statistical property of image block. This algorithm replaces lots of nonlinear iterations in traditional CS reconstruction algorithm with linear projection, therefore it shorten the time of recovering image. Simulation experimental results indicate that the proposed algorithm not only reduces the time of rebuilding image, but also is better than the current popular CS reconstruction algorithm for images containing uncomplicated textures on the reconstructed image quality.

Key words: Image processing; Block Compressed Sensing(BCS); Adaptive measure; Best linear estimate; Statistical autocorrelation function; Fast image reconstruction

1 引言

近年来, 压缩感知(Compressed Sensing, CS) 成为一个快速发展的研究领域, 受到了广泛关注。Candes 等人^[1,2]和 Donoho^[3]具有突破性的工作表明: 具有稀疏性的信号可由少量随机线性测量值(远低于奈奎斯特采样频率)无失真地复原, 这暗示了可实现低采样率、低能耗、低计算复杂度的数据采集。

然而, 将 CS 运用到 2 维图像处理中时, 面临了两个主要问题: (1)重建图像计算复杂度过大; (2)测量矩阵存储量巨大。针对问题(1), 一些快速 CS 重建算法被提出^[4,5], 以重建性能换取计算复杂度降

低, 使得其用于图像重建时并不理想。针对问题(2), 文献[6-8]提出一种结构随机矩阵, 在降低测量矩阵存储量的同时, 又可快速测量整幅图像, 但结构随机矩阵使用了流行的正交变换矩阵(傅里叶变换、DCT 变换、哈达玛变换), 根据 CS 非相关测量理论, 该矩阵并不具有良好的通用性。独立同分布(i.i.d)高斯测量矩阵与任意固定矩阵都具有低相关度^[9], 所以采用它可设计出通用的 CS 图像编码策略。文献[10]提出了分块 CS (Block Compressed Sensing, BCS)测量与重建, 在使用独立同分布高斯测量矩阵的同时, 又避免了存储量巨大的缺陷, 使得这种方法特别适合于实时的 2 维图像应用。在 BCS 框架下, 文献[11]提出运用方向性变换增加图像稀疏度, 进一步提高了 BCS 重建性能; 文献[12]将多分辨率分析引入到 CS 测量过程, 以增加编码复杂度为代价, 提升了 BCS 重建性能。在上述方法中, 基于块的采

2012-05-02 收到, 2012-08-14 改回

国家自然科学基金(61071091), 江苏高校优势学科“信息与通信工程”建设工程项目, 江苏省普通高校研究生科研创新计划(CXZZ12_0466)和江苏省高校自然科学研究项目(12KJB510019)资助课题

*通信作者: 朱秀昌 zhuxc@njupt.edu.cn

集使用相同的测量矩阵，这样就忽略了各块具有不同特征(边缘、纹理等)的实际，最终影响重建质量。文献[13]提出根据块特征自适应变化测量率，有效克服了上述缺陷，获得了较好效果。BCS除了大量地应用于 2 维图像外，低存储量、快重建速度的优势使得它也被广泛地应用于 3 维视频；文献[14]有效利用 BCS 重建算法恢复视频残差，以较低代价获得了良好的视频重建质量；文献[15]提出一种基于分块的字典生成策略，利用帧间相关性为每个块构造字典，加强块稀疏度，提升了 BCS 重建性能；文献[16,17]将传统视频编码的运动估计和运动补偿引入 BCS 重建算法中，也获得了良好效果。总之，可看出在实际的图像与视频应用中，BCS 具有很大优势。

上述各种 BCS 重建算法，虽然获得了良好的图像复原质量，但重建所需时间仍然过慢(需要 2~5 min)，这依旧不适合于实时应用。重建过慢的根本原因在于这些算法都是运用非线性最优化思想设计，其过程中包含了大量迭代，过多迭代影响到重建时间。针对该问题，本文将自适应 CS 分块测量与最佳线性估计相结合，提出一种快速 CS 重建算法。实验结果表明，该算法大大缩短了重建时间，与此同时仍保留了较高的图像重建质量。

本文其他内容安排如下：第 2 节简要回顾图像分块压缩感知；第 3 节详细描述基于最佳线性估计的快速 CS 图像重建算法；第 4 节给出实验仿真结果及其分析；第 5 节对全文进行总结。

2 图像的分块压缩感知

文献[10]提出的 BCS 首先将 $N=I_c \times I_r$ 个像素的图像 x 分成 n 个大小为 $B \times B$ 的块，第 i 个块的列向量形式记为 $x_i, i=1, \dots, n, n=N/B^2$ ，然后对 x_i 应用相同的测量矩阵 Φ_B 进行测量，得到观测值向量 y_i ，其长度为 $M_B(\ll B^2)$ ，记为

$$y_i = \Phi_B x_i, \quad i = 1, 2, \dots, n \quad (1)$$

式中 Φ_B 是 $M_B \times B^2$ 的随机高斯矩阵。于是，得到原图像的 M 个 CS 观测值， $M=n \times M_B$ 。对于整幅图像，总测量矩阵 Φ 是如下的块对角矩阵， n 个对角元素皆为 Φ_B 。

$$\Phi = \begin{bmatrix} \Phi_B & & & \\ & \Phi_B & & \\ & & \ddots & \\ & & & \Phi_B \end{bmatrix} \quad (2)$$

从式(2)可看到，在 BCS 测量中，不需存储 $B \times B$ 的矩阵 Φ ，而仅需存储 $M_B \times B^2$ 的矩阵块 Φ_B 。显然，当 B 较小时，所需存储量小且可快速实现。

3 基于最佳线性估计的快速 CS 图像重建法

本文提出的快速 CS 图像重建法如图 1 所示。首先，对原图像进行块分类，根据不同的块特征，作适当次数的 CS 测量；然后，针对不同特征的块，设计出不同的最佳线性估计器，线性复原出各图像块；最后，将图像块合并成整幅图像。

3.1 图像块分类与自适应 CS 测量

3.1.1 图像块分类 自然图像包含一定的局部特征：平坦、边缘和纹理。对图像进行分块，可用这些特征标识每个块。合理的作法是：对平坦块作少量测量，对边缘、纹理块作相对较多的测量。根据该情况，定义图像块方差公式如式(3)：

$$d_i = \frac{1}{B \times B} \sum_{j=1}^{B \times B} (p_{ij} - \bar{p}_i)^2, \quad \bar{p}_i = \frac{1}{B \times B} \sum_j p_{ij}, \quad i = 1, \dots, n \quad (3)$$

$$\bar{d}_i = \frac{d_i - d_{\min}}{d_{\max} - d_{\min}} \quad (4)$$

$$d_{\min} = \min \{d_1, d_2, \dots, d_n\} \quad (5)$$

$$d_{\max} = \max \{d_1, d_2, \dots, d_n\} \quad (6)$$

式中 p_{ij} 表示第 i 块、第 j 个像素灰度值， d_{\min} 和 d_{\max}

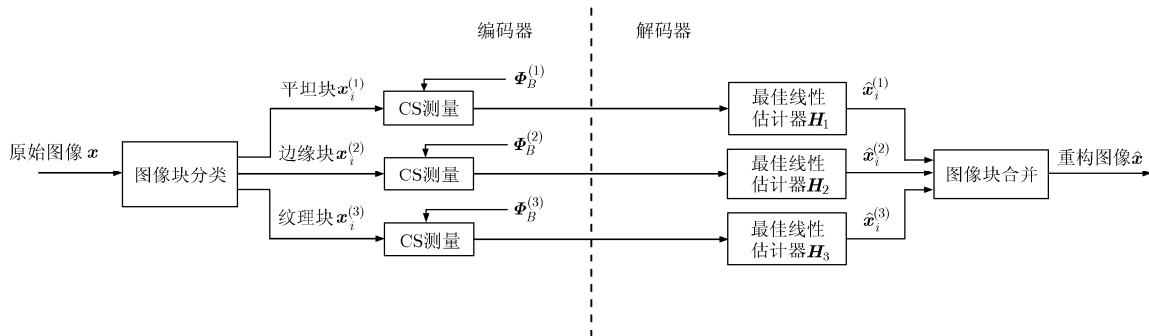


图 1 基于最佳线性估计的快速 CS 图像重建法流程框图

分别表示所有块中方差的最小值和最大值。这样，可得图像块分类准则：

$$\mathbf{x}_i \in \begin{cases} \text{平滑块, } \bar{d}_i \leq T_1 \\ \text{边缘块, } T_1 < \bar{d}_i \leq T_2 \\ \text{纹理块, } \bar{d}_i > T_2 \end{cases} \quad (7)$$

T_1 和 T_2 为分类所设定的阈值，根据经验，可设 $T_1 = 0.1$, $T_2 = 0.3$ 。如图 2(b) 所示， 512×512 的 Mandrill 图按 16×16 分块大小作分类，白色块为纹理块，灰色块为边缘块，黑色块为平坦块，通过与图 2(a) 原始图像对比，可看出，具有复杂纹理的毛发区皆为白色，边缘区大多为灰色块，而对于平坦的脸部区，黑色块较集中，所以依据块方差作为分类标准是合理的。




图 2 512×512 Mandrill 图按 16×16 分块大小分类 (T_1 取 0.1, T_2 取 0.3)

3.1.2 自适应 CS 测量 设固定测量率为 r ，平坦块测量率为 r_1 ，边缘块测量率为 r_2 ，纹理块测量率为 r_3 ；图像总块数为 N ，平坦块个数为 N_1 ，边缘块个数为 N_2 ，纹理块个数为 N_3 ，则有

$$N \times B^2 \times r = N_1 \times B^2 \times r_1 + N_2 \times B^2 \times r_2 + N_3 \times B^2 \times r_3 \quad (8)$$

其中 $r_1 = R$, $r_2 = 3R$, $r_3 = 5R$ 。

整理可得

$$R = \frac{N \times r}{N_1 + 3N_2 + 5N_3} \quad (9)$$

计算出 R 值后，就可确定 r_1 , r_2 和 r_3 。由于设定权重的影响，使得平坦块测量率偏低，纹理块测量率偏高，边缘块测量率适中。

此时，就可根据不同测量率构造适应于不同类型块的测量矩阵。为达到测量矩阵存储量小和保持与参考矩阵 Ψ 高度不相关的目的，采用正交高斯矩阵作为测量矩阵，测量矩阵构造步骤如下：

(1) 生成 $B^2 \times B^2$ 随机矩阵 Θ ，其中每一个元素均服从标准高斯分布。

(2) 利用施密特正交化法，使随机矩阵 Θ 的列向

量相互正交。

(3) 由平坦、边缘和纹理块的测量率，分别确定出它们的测量次数 M_1 , M_2 和 M_3 。

(4) 分别从 Θ 中随机挑选出 M_1 , M_2 和 M_3 行，生成平坦、边缘和纹理块的测量矩阵 $\Phi_B^{(1)}$, $\Phi_B^{(2)}$ 和 $\Phi_B^{(3)}$ 。

根据文献[9,18]， Θ 的任意 m 行组成的矩阵 Θ_Ω ($|\Omega|=m$)，在满足条件 $m \geq C \cdot S(\lg B^4)^4$ 时，与任意固定的正交参考矩阵 Ψ ，以极大概率保持高度不相关，其中， S 为图像块在 Ψ 下系数的稀疏度， B^4 为图像块像素的总个数， C 为取值较小的常数。如此，只要 M_1 , M_2 和 M_3 充分大，就能保证平坦、边缘和纹理块的测量矩阵 $\Phi_B^{(1)}$, $\Phi_B^{(2)}$ 和 $\Phi_B^{(3)}$ 与参考矩阵 Ψ 高度不相关，以确保重建算法可有效收敛。同时，也可看出只需构造出 Θ 即可生成平坦、边缘和纹理块的测量矩阵 $\Phi_B^{(1)}$, $\Phi_B^{(2)}$ 和 $\Phi_B^{(3)}$ ，所以仍保证了测量矩阵的低存储量。

3.2 最佳线性估计

传统 CS 重建法均使用非线性最优化方法复原图像，该重建过程包含大量迭代过程，使计算复杂度较高，不适合于实时 CS 图像重建任务。文献[10]提出一种基于最小均方误差 (Minimum Mean Square Error, MMSE) 的线性估计手段，作为其 BCS 重建算法初始解，获得了良好效果。实际上，这种初始解获得来源于最佳线性估计原理^[19]，如图 3 所示。




图 3 最佳线性估计原理

将图像块数据 \mathbf{x} 看作为随机向量，CS 测量数据 \mathbf{y} 是 \mathbf{x} 使用测量矩阵 Φ_B 作线性投影而来，可得

$$\mathbf{R}_{xy} = E[\mathbf{x}\mathbf{y}^T] = E[\mathbf{x}(\Phi_B \mathbf{x})^T] = E[\mathbf{x}\mathbf{x}^T] \Phi_B^T = \mathbf{R}_{xx} \Phi_B^T \quad (10)$$

由于 Φ_B 是通过正交高斯随机矩阵 Θ 随机挑选出若干行生成的，所以其具有受限等距性 (Restricted Isometry Property, RIP)^[9,20]，块 \mathbf{x} 的像素间存在相关性，所以 $\mathbf{R}_{xx} \neq 0$ 。根据 Φ_B 的 RIP，由式(11)知 $\mathbf{R}_{xy} \neq 0$ ，即 \mathbf{x} 与 \mathbf{y} 存在相关性。因此，可由最佳估计原理，从 CS 测量数据 \mathbf{y} 中估计出与图像块 \mathbf{x} 相关的部分。

设 \mathbf{y} 经线性变换 H 后得到关于 \mathbf{x} 的线性估计 $\hat{\mathbf{x}}$ 及估计误差 \mathbf{e} 为

$$\hat{\mathbf{x}} = H\mathbf{y} \quad (11)$$

$$\mathbf{e} = \mathbf{x} - \hat{\mathbf{x}} = \mathbf{x} - H\mathbf{y} \quad (12)$$

选择线性算子 H 的准则是使估计误差均方差最小，表示为

$$H_{\text{opt}} = \arg \min_H \{ \mathbf{R}_{ee} = E(\mathbf{e}\mathbf{e}^T) = E[(\mathbf{x} - H\mathbf{y})(\mathbf{x} - H\mathbf{y})^T] \} \quad (13)$$

\mathbf{R}_{ee} 对 H 求导，并令其等于 0，可解出最佳线性估计所要求的 H 为

$$H_{\text{opt}} = \mathbf{R}_{xy} \mathbf{R}_{yy}^{-1} = E[\mathbf{x}\mathbf{y}^T] E^{-1}[\mathbf{y}\mathbf{y}^T] \quad (14)$$

联立式(1)可得

$$H_{\text{opt}} = \mathbf{R}_{xx} \Phi_B^T (\Phi_B \mathbf{R}_{xx} \Phi_B^T)^{-1} \quad (15)$$

其中 \mathbf{R}_{xx} 为图像块像素间统计自相关函数矩阵：

$$\mathbf{R}_{xx} = E[\mathbf{x}\mathbf{x}^T] = \begin{bmatrix} E(x_1x_1) & E(x_1x_2) & \cdots & E(x_1x_{B^2}) \\ E(x_2x_1) & E(x_2x_2) & \cdots & E(x_2x_{B^2}) \\ \vdots & \vdots & \ddots & \vdots \\ E(x_{B^2}x_1) & E(x_{B^2}x_2) & \cdots & E(x_{B^2}x_{B^2}) \end{bmatrix} \quad (16)$$

根据文献[21]，该矩阵的元素可由式(17)估计：

$$\mathbf{R}_{xx}(i, j) = E[x_i x_j] = \rho^\delta \quad (17)$$

$$\delta = \text{dis}(x_i, x_j) = \sqrt{(n_1 - n_2)^2 + (m_1 - m_2)^2} \quad (18)$$

式中 (n_1, m_1) 为像素 x_i 的空间位置， (n_2, m_2) 为像素 x_j 的空间位置， δ 为 x_i 与 x_j 的欧式距离，相关系数 ρ 取 0.9 至 1.0 之间。

由于各图像块统计特性不相同，例如，平坦块像素间相关程度要远大于纹理块，所以对于不同特征的块， ρ 取值应有所不同。根据该情况，使平坦块 ρ 值取 0.997，边缘块 ρ 值取 0.993，纹理块 ρ 值取 0.990。图 4 显示了由多幅图像统计出的平坦、边缘、纹理块样本自相关函数值与式(16)取上述 ρ 值估计出的自相关函数值的比较，图中横坐标为图像块对角线上像素的坐标值，纵坐标为图像块的左上角像素 $x(1,1)$ 分别与对角线上其他像素的自相关函数值，可看出估计值与实际值偏差不大，因此， ρ 的取值应该是合理的。

一旦最佳线性估计器 H_{opt} 求出，每个图像块只作简单的矩阵-向量内积，就可得到对原始图像块的估计。将图像分割为 n 个互不重叠的图像块，只需作 n 次矩阵-向量内积运算就可完成对整幅图像的重建，总计算量仅需 $M \times B^2$ 次乘和 $M \times B^2$ 次加，远远小于传统 CS 重建法。

4 实验仿真结果及分析

从以下 5 个数据库(Debbie, Lena, Cameraman, Peppers 和 Mandrill)分别调取 1 幅 512×512 灰度图像测试本文提出的基于最佳线性估计的快速 CS 图像重建算法。所使用的测试图像具有不同程度的细节，其中 Debbie 图含有大量的平坦区，边缘与纹理都较简单；Lena 图与 Cameraman 图也含有较大的平坦区，但边缘、纹理较 Debbie 图更加丰富；Peppers 图具有大量的边缘和平坦区，而纹理细节较少；Mandrill 图含有大量的毛发纹理，边缘和平坦区较少。与本文算法相比较的重建算法为：文献[11]所提出的运用方向性变换的 BCS-SPL 重建算法，即 BCS-SPL-DDWT 和 BCS-SPL-CT；文献[2,22]所提出的 TV 算法，对整幅图像作 CS 重建是不现实的(512×512 图像的重建时间高达 $30 \text{ h}^{[10]}$)，为了减少重构时间，采用分块 CS 重建策略，将其命名为 BCS-TV；文献[4]所提出基于梯度投影的快速 CS 重建算法——GPSR，由于 GPSR 重建速度较快，可采用文献[6]提出的随机傅里叶矩阵(Scrambled Fourier Ensemble, SFE)对整幅图像作测量，再利用 GPSR 算法重建，将其命名为 SFE-GPSR。分块尺寸 B 的大小，凭经验取为 32，CS 测量率(M/N)取 0.1 到 0.5。由于测量矩阵具有随机性，重构图像的质量和速度会因此而改变，所以 PSNR 值和重构时间都是独立地进行 5 次测试的平均值。

表 1 列出了以上所提到的各种算法重建出图像的 PSNR 值。可看到对于含有大量平坦区的图像 Debbie, Cameraman 和 Lena，无论低测量率还是高




图 4 自相关函数估计值与样本自相关函数值的比较

表1 各种算法重建图像的PSNR值(dB)

重建算法	CS 测量率				
	0.1	0.2	0.3	0.4	0.5
Debbie					
本文算法	36.78	40.76	43.65	46.58	48.90
BCS-SPL-DDWT	28.58	30.94	32.00	32.68	33.52
BCS-SPL-CT	24.17	35.31	41.68	44.46	46.90
BCS-TV	33.71	38.13	41.21	43.90	46.34
SFE-GPSR	29.78	35.35	38.78	41.38	43.55
Cameraman					
本文算法	27.11	30.81	33.33	35.44	38.24
BCS-SPL-DDWT	24.04	28.28	31.30	33.86	36.22
BCS-SPL-CT	24.58	28.13	30.82	33.12	35.37
BCS-TV	25.09	28.58	31.21	33.58	35.79
SFE-GPSR	24.39	27.03	30.28	33.18	36.02
Lena					
本文算法	28.87	31.64	33.67	35.30	37.17
BCS-SPL-DDWT	28.31	31.37	33.50	35.20	36.78
BCS-SPL-CT	28.17	31.02	32.99	34.68	36.25
BCS-TV	27.86	30.60	32.56	34.25	35.89
SFE-GPSR	24.69	28.54	31.53	33.69	35.82
Peppers					
本文算法	27.95	30.30	32.0	33.4	34.79
BCS-SPL-DDWT	28.88	31.44	32.89	34.06	35.18
BCS-SPL-CT	28.56	31.04	32.57	33.77	34.88
BCS-TV	28.52	31.21	32.74	33.96	35.17
SFE-GPSR	24.58	28.19	30.19	31.76	33.21
Mandrill					
本文算法	20.38	22.06	23.50	24.94	26.54
BCS-SPL-DDWT	22.94	24.87	26.69	28.42	30.28
BCS-SPL-CT	22.87	24.97	26.95	28.90	30.93
BCS-TV	22.31	24.34	26.08	27.77	29.45
SFE-GPSR	20.11	22.23	24.37	26.99	30.06

测量率, 本文所提出算法重建图像的 PSNR 值均比其他算法高, 尤其对于 Debbie 图像, 在低测量率 0.1 下, 重建图像的 PSNR 值也可达 36.78 dB, 但对于含有边缘与纹理较高的图像 Peppers 和 Mandrill, 所提出算法并不优于其他算法: 对于 Peppers 图, 重建性能除比 SFE-GPSR 算法高出少许外, 均略低于其他算法; 对于 Mandrill 图, 重建图像质量是所有算法中最差的, 与最优的复原质量相比, 低了 1~3 dB。导致这种情况的原因主要是所提出算法恢复纹理块效果并不理想, 恢复纹理块效果差的原因有两个: (1)测量次数不足精确恢复; (2)纹理块自相关函数矩阵的估计值与真实情况偏差较大(从图 4(c)可看出)。通过增加纹理块测量次数和调整估计自相关函数矩阵的 ρ 值, 都可在一定程度缓解该状况。图 5 显示了 CS 测量率为 0.2 时, 各种算法重建出的 Cameraman 图像, 通过主观上的对比可看出, 所提出算法对于纹理不复杂的图像在低测量率下复原图像时, 不会存在大量块效应, 主观视觉质量良好。

表 2 列出了各种算法重建 512×512 Cameraman 图像所消耗的时间。运行算法的硬件平台为主频为 2.20 GHz 的双核 CPU 计算机, 软件平台为 32 位的 Windows7 操作系统和 Matlab 7.6 仿真实验软件。可明显地看出, 本文所提出算法的重建时间远低于其他算法, 平均时间仅为 2 s, 所以十分适合于实时的 CS 图像重建任务。

5 结束语

本文所提出的基于最佳线性估计的快速 CS 重建法, 在编码端采用自适应分块高斯随机测量, 在解码端根据不同块的统计特性, 估计出统计自相关函数矩阵, 再利用该矩阵构造出最佳线性算子, 并作各图像块的最佳线性估计。该算法突破了传统的非线性 CS 重建, 仅使用简单的线性投影恢复原始信号, 大大缩短了图像重建时间, 特别适合于实时

表2 各种算法重建图像所消耗的时间(s)

CS 测量率	重建算法				
	本文算法	BCS-SPL-DDWT	BCS-SPL-CT	BCS-TV	SFE-GPSR
0.1	0.6	107.6	87.9	349.7	21.9
0.2	1.2	59.2	50.9	594.0	18.3
0.3	2.0	44.3	35.3	863.4	14.7
0.4	3.0	38.2	24.9	1028.8	13.2
0.5	3.4	26.8	25.2	1131.2	12.1
平均时间	2.0	55.2	44.8	793.4	16.0




图 5 512×512 Cameraman 图像, CS 测量率为 0.2, 各算法重构出的图像对比

的 CS 图像重建任务。实验结果也表明, 对于纹理细节不复杂的图像, 该快速 CS 测量算法并未因其计算复杂度的减少而影响重建质量, 仍优于目前流行的 CS 重建算法。

当然, 基于最佳线性估计的快速 CS 重建法仍有一些缺陷。(1)对于含有大量纹理细节的图像, 本文所提出的算法虽可快速重建图像, 但重建图像质量并不理想。(2)未考虑到 CS 测量过程混噪情形, 所以该算法不具有鲁棒性。(3)在实际应用中, 本文所提出算法在编码端进行的是自适应分块随机测量, 因此就不得不将分块信息传输到解码端, 这在一定程度上增加了比特开销。另外, 分块信息对于图像重建十分重要, 所以分块信息的丢失将极大地影响图像恢复, 这也使得本文所提出的方法存在一定的风险。这些缺陷会在进一步的工作中得到完善。

参 考 文 献

- [1] Candes E J, Romberg T, and Tao T. Robust uncertainty principles: exact signal reconstruction from highly incomplete frequency information[J]. *IEEE Transactions on Information Theory*, 2006, 52(2): 489-509.
- [2] Candes E J, Romberg J, and Tao T. Stable signal recovery from incomplete and inaccurate measurements[J]. *Communications on Pure and Applied Mathematics*, 2006, 59(8): 1207-1223.
- [3] Donoho D L. Compressed sensing[J]. *IEEE Transactions on Information Theory*, 2006, 52(4): 1289-1306.
- [4] Figueiredo M A T, Nowak R D, and Wright S J. Gradient projection for sparse reconstruction: application to compressed sensing and other inverse problems[J]. *IEEE Journal Selected Topics in Signal Processing*, 2007, 1(4): 586-597.
- [5] Do T T, Gan L, Nguyen N, *et al.* Sparsity adaptive matching pursuit algorithm for practical compressed sensing[C]. *Asilomar Conference on Signals, Systems and Computer*, Pacific Grove, CA, 2008, 10: 581-587.
- [6] Candes E J and Romberg J. Robust signal recovery from incomplete observations[C]. *IEEE International Conference on Image Processing*, Atlanta, GA, USA, 2006: 1281-1284.
- [7] Do T, Gan L, Nguyen N, *et al.* Fast and efficient compressive sensing using structurally random matrices[J]. *IEEE Transactions on Signal Processing*, 2012, 60(1): 139-154.
- [8] Gan L, Do T and Tran T D. Fast compressive imaging using scrambled block Hadamard ensemble[C]. *Processings of the European Signal Processing Conference*, Lausanne, Switzerland, August 2008: 1-5.
- [9] Candes E J and Wakin M. An introduction to compressive

- sampling[J]. *IEEE Signal Processing Magazine*, 2008, 25(2): 21-30.
- [10] Gan L. Block compressed sensing of natural images[C]. International Conference on Digital Signal Processing, Cardiff, UK, July 2007: 403-406.
- [11] Mun S and Fowler J E. Block compressed sensing of images using directional transforms[C]. International Conference on Image Processing, Cairo, Egypt, November 2009: 3021-3024.
- [12] Fowler J E, Mun S, and Tramel E W. Multiscale block compressed sensing with smoother projected Landweber reconstruction[C]. 19th European Signal Processing Conference, Barcelona, Spain, August 2011: 564-568.
- [13] Wang A, Liu L, Zeng B, *et al.* Progressive image coding based on an adaptive block compressed sensing[J]. *IEICE Electronics Express*, 2011, 8(8): 575-581.
- [14] Sungkwang M and Fowler J E. Residual reconstruction for block-based compressed sensing of video[C]. Data Compression Conference, Snowbird, UT, March 2011: 183-192.
- [15] Liu Hai-xiao, Song Bin, and Qiu Zhi-liang. A dictionary generation scheme for block-based compressed video sensing[C]. IEEE International Conference on Signal Processing, Communications and Computing, Xi'an, China, October 2011: 1-5.
- [16] Luo Ping, Lu Qin, and Luo Wu-sheng. Motion estimation using a compressive sensing architecture for H.264/AVC[C]. International Conference on Multimedia Technology, Hangzhou, China, July 2011: 3133-3135.
- [17] Tramel E W and Fowler J E. Video compressed sensing with multihypothesis[C]. Proceedings of the Data Compression Conference, Snowbird, UT, April 2011: 193-202.
- [18] Candes E J and Romberg J. Sparsity and incoherence in compressive sampling[J]. *Inverse Problem*, 2007, 23(3): 969-985.
- [19] 姚天任, 孙洪. 现代数字信号处理[M]. 武汉: 华中科技大学出版社, 1999: 2-3.
Yao Tian-ren and Sun Hong. Advanced Digital Processing[M]. Wuhan: Huazhong University of Science and Technology Press, 1999: 2-3.
- [20] Baraniuk R, Davenport M, Devore M, *et al.* A simple proof of the restricted isometry property for random matrices[J]. *Constructive Approximation*, 2008, 28(3): 253-263.
- [21] 朱秀昌, 刘峰, 胡栋. 数字图像处理与图像通信[M]. 北京: 北京邮电大学出版社, 2002: 161-163.
Zhu Xiu-chang, Liu Feng, and Hu Dong. Digital Image Processing and Image Communications[M]. Beijing: Beijing University of Posts and Telecommunications Press, 2002: 161-163.
- [22] Candes E J and Romberg J. l_1 -magic: recovery of sparse signals via convex programming[OL]. www.acm.caltech.edu/l1magic/, 2011, 10.
- 李 然: 男, 1988年生, 博士生, 研究方向为图像处理与多媒体通信.
- 干宗良: 男, 1979年生, 讲师, 研究方向为分布式视频编码、图像(视频)信号处理.
- 朱秀昌: 男, 1947年生, 教授, 博士生导师, 长期从事图像通信方面的科研和教学工作.