

基于混合采样的图像分块压缩感知方法^①

吕 沛^{②*} 周仁魁^{*} 刘海英^{***} 何俊华^{*}

(^{*} 中国科学院西安光学精密机械研究所 西安 710119)

(^{**} 中国科学院研究生院 北京 100049)

(^{***} 西安电子科技大学通信工程学院 西安 710071)

摘 要 针对图像压缩感知问题,提出一种基于混合采样的分块压缩感知方法——HBCS 方法。该方法利用基于随机采样和低分辨率采样构造的混合采样矩阵和分块策略,有效地提高了图像采样效率和重构性能。理论证明:混合采样矩阵具有低分辨率采样的直接测量图像低频信息的特性和随机采样的近似最优的重构功能,且以高概率与大多数固定稀疏基不相干,结构简单,非常易于实现;分块策略能保证算法复杂度不随图像尺寸而改变,适合实时处理高分辨率图像。实验结果表明,在相同采样值数目下,该方法采用总变差(TV)重建算法时的重构质量尤其是在图像低频信息恢复方面明显优于其它已有方法。

关键词 信息采样, 压缩感知(CS), 混合采样, 分块策略, 总变差(TV)算法

0 引 言

在传统采样过程中,为了避免信号失真,采样频率不得低于信号最高频率的 2 倍。然而对于数字图像、视频的获取,依照香农/奈奎斯特定理会导致海量采样数据,增加传输和存储的代价。常采用 JPEG, JPEG2000 标准对海量数据进行压缩,以达到减少数据量的目的。然而,这种高速采样再压缩的方式浪费了大量的采样资源,给低功耗、处理能力有限的应用场合(如无线传感器网络^[1])造成巨大压力。近年来,一种新兴的压缩感知(compressed sensing, CS)或压缩采样(compressive sampling)理论^[2-5]为数据采集技术带来了革命性的突破。CS 将采样和压缩合并进行,具有直接信息采样特性,有利于降低采样成本,节省资源开销。目前 CS 仍主要处于理论研究阶段,不适合对大规模信号进行实时采样且图像重构算法的代价很大。为了解决这些问题, Gan 借鉴分块离散余弦变换(DCT)编码思想,提出了分块压缩感知(block compressed sensing, BCS)算法^[6], BCS 算法使用相同的测量矩阵对图像的各个分块子图像进行并行的独立压缩采样,有效提高采

样效率,为 CS 实时处理高分辨率图像提供了可实现方案。为进一步提高图像重构性能, Mun 等人^[7]在 BCS 算法的重构过程中采用复杂的紧框架稀疏表示方法。Romberg^[8]则从采样角度出发,提出一种将随机采样和部分傅里叶采样相结合的混合采样方法,有效提高了采样效率,但硬件实现比较困难。为此,本文提出一种新的基于混合采样的分块压缩感知(Hybrid sampling based BCS, HBCS)方法。该方法不仅可以有效提高采样效率,而且结构简单、非常易于实现,同时可保证算法复杂度不随图像尺寸而改变,适合实时处理高分辨率图像。

1 压缩感知理论

压缩感知(CS)理论^[2-5]是一种充分利用信号稀疏性或可压缩性的全新信号获取和重构理论。它的主要思想是:假设长度为 N 的一维离散时间信号 $\mathbf{x}$, 在某个正交基或紧框架 Ψ 上的变换系数是稀疏或可压缩的: $\mathbf{x} = \Psi\boldsymbol{\theta}$, 变换系数序列 $\boldsymbol{\theta}$ 只有 $K(K \ll N)$ 个非零大系数, 剩余的 $N - K$ 个系数为零或近似为零; 如果用 一个与 Ψ 不相干的 $M \times N(K < M \leq N)$ 测量矩阵 Φ 对 $\mathbf{x}$ 进行非自适应线性测量, 得到 $M \times 1$

① 国家自然科学基金(61040034, 61072065, 61007011)和 111 基地(B08038)资助项目。

② 男, 1980 年生, 博士生, 研究方向: 成像技术, 图像处理; 联系人, E-mail: luupi@163.com
(收稿日期: 2012-02-16)

的测量值向量

$$\mathbf{y} = \Phi \mathbf{x} \quad (1)$$

其中 Φ 与 Ψ 不相干是指 Φ 中的行向量 $\{\phi_i\}$ 不能用 Ψ 中的列向量 $\{\psi_i\}$ 稀疏表示。不相干性越强,相互表示所用的向量越多。反之,相干性越强。

很显然,由于 $\mathbf{y}$ 的维数远远低于 $\mathbf{x}$ 的维数,式(1)有无穷多个解,很难由 $\mathbf{y}$ 精确重构出原信号 $\mathbf{x}$ 。但是,CS 理论证明,在信号稀疏或可压缩的前提下,如果测量矩阵 Φ 和稀疏基 Ψ 不相干,求解欠定方程式(1)的问题可转化为求解 l_1 -范数最小化问题,从而可以从少量的测量值中精确或高概率重构出原信号 $\mathbf{x}$,如基追踪(basis pursuit, BP)算法^[9]:

$$\min \|\Psi^T \mathbf{x}\|_1 \quad \text{s.t.} \quad \Phi \mathbf{x} = \mathbf{y} \quad (2)$$

式中, $\|\cdot\|_1$ 为向量的 l_1 -范数,表示向量中所有元素的绝对值之和,即 $\|\mathbf{v}\|_1 = \sum_{i=1}^N |v_i|$ 。 l_1 -范数最小化实际上是一个凸优化问题,可利用线性规划(LP)方法进行快速求解,如梯度投影稀疏重建(gradient projection for sparse reconstruction, GPSR)算法^[10]。其他的快速算法还有凸集投影(projections onto convex sets, POCS)^[11]、正交匹配追踪(orthogonal matching pursuit, OMP)^[12]等算法。

2 基于混合采样的图像分块压缩感知

为了提高采样效率,本文提出一种基于混合采样的图像分块压缩感知方法。该方法首先采用分块策略把大图像分割成互不重叠的小图像,然后对各个小图像进行混合采样和非线性重构。混合采样是指采用由不同的测量矩阵组成的混合采样矩阵对图像进行非自适应线性测量。本文中采用由两个不同的测量矩阵组成的混合采样矩阵对图像进行测量,记混合采样矩阵为 Φ_H ,两个不同的测量矩阵为 Φ 和 Φ' ,则有 $\Phi_H = [\Phi; \Phi']$ 。考虑到对于具有稀疏梯度的分段平滑图像,采用梯度稀疏基的总变差(total variation, TV)算法具有良好的图像重构性能,故本文选取文献[13]中的 TV 算法作为图像稀疏重建算法。记某个分块小图像为 $\mathbf{x}$,基于混合采样的图像压缩感知方法可以等效为求解下面的优化问题:

$$\min TV(\mathbf{x}) \quad \text{s.t.} \quad \Phi \mathbf{x} = \mathbf{y}, \Phi' \mathbf{x} = \mathbf{y}' \quad (3)$$

式中稀疏基 Ψ 为梯度稀疏基 $TV(\cdot)$, Φ 和 Φ' 表示两个不同的测量矩阵, $\mathbf{y}$ 和 $\mathbf{y}'$ 则分别表示相应的测量值向量。 $TV(\mathbf{x})$ 为图像 $\mathbf{x}$ 梯度的模值之和:

$$TV(\mathbf{x}) = \sum_{i=1}^{m-1} \sum_{j=1}^{n-1} |(\nabla \mathbf{x})_{i,j}| = \sum_{i=1}^{m-1} \sum_{j=1}^{n-1} \sqrt{(\mathbf{D}_h \mathbf{x})_{i,j}^2 + (\mathbf{D}_v \mathbf{x})_{i,j}^2}$$

$\sqrt{(\mathbf{D}_h \mathbf{x})_{i,j}^2 + (\mathbf{D}_v \mathbf{x})_{i,j}^2}$, $\mathbf{D}_h \mathbf{x}$ 和 $\mathbf{D}_v \mathbf{x}$ 分别表示水平和垂直方向梯度, $(\mathbf{D}_h \mathbf{x})_{i,j} = x_{i+1,j} - x_{i,j}$, $(\mathbf{D}_v \mathbf{x})_{i,j} = x_{i,j+1} - x_{i,j}$ 。

易知,保证优化问题式(3)能够获得高重构质量的关键是确保混合采样矩阵 Φ_H 与梯度稀疏基 $TV(\cdot)$ 不相干。由文献[8]可知,要保证混合采样矩阵 Φ_H 与梯度稀疏基 $TV(\cdot)$ 不相干,只需保证 Φ 和 Φ' 分别与梯度稀疏基 $TV(\cdot)$ 不相干即可。第 2.2 节将详细介绍混合采样矩阵的构造。

2.1 分块压缩感知(BCS)

假设一幅图像总共具有 $N = mn$ 个像素,我们希望获得 M 个测量值。BCS 算法将图像分割成互不重叠的大小为 $B \times B$ 的低分辨率子图像,令 $\mathbf{x}_i$ 表示按光栅扫描顺序的第 i 个子图像的列向量形式,则相应的测量值向量 $\mathbf{y}_i$ 可以表示为

$$\mathbf{y}_i = \Phi_B \mathbf{x}_i \quad (4)$$

式中 Φ_B 为 $k \times B^2$ 的测量矩阵, $k = \lfloor MB^2/N \rfloor$ 。对整幅图像而言,测量矩阵 Φ 是一个由 Φ_B 组成的块对角矩阵,如式

$$\Phi = \begin{bmatrix} \Phi_B & & & \\ & \Phi_B & & \\ & & \ddots & \\ & & & \Phi_B \end{bmatrix} \quad (5)$$

所示。式中 Φ 为 $M \times N$ 矩阵, $M \geq k, N \geq B^2$ 。值得注意的是,BCS 算法仅需存储 $k \times B^2$ 矩阵 Φ_B ,而不需存储 $M \times N$ 矩阵 Φ ^[6],且在重构过程中不需要整幅图像所有的压缩采样数据,这对于要求低计算复杂度的实时处理具有重要的意义。BCS 算法一般取分块大小 $B = 32$ 。

2.2 混合采样矩阵设计

由式(3)可知,本文构造的混合采样矩阵 Φ_H 主要由 Φ 和 Φ' 两部分组成,其中 Φ' 选用文献[2, 4]中的随机采样(random sampling, RS)矩阵,这是由于 RS 矩阵与大多数固定稀疏基不相干,能够获得近似最优的重构性能。为了简单起见,这里 RS 矩阵选用二进制 noiselet 矩阵(PN)^[14],PN 矩阵本质上是随机矩阵,它的每个元素以等概率取 1 或 -1,结构简单,非常易于硬件实现。由傅里叶分析可知,图像的绝大多数有用信息集中在低频,如果在采样过程中能够直接测量这些低频信息,必然会有效减少测量值数目和提高重构性能。文献[8]中构造了基于随机采样和部分傅里叶变换(PF)矩阵的混合采样矩阵,PF 矩阵用来测量图像的低频信息(即保

留部分重要的低频系数),有效地改善了恢复图像的质量,但由于 PF 矩阵不是稀疏矩阵,虽然有快速傅里叶变换(FFT)算法,但其计算复杂度仍然较高,硬件实现比较困难。为此,我们提出一种采用低分辨率采样(low-resolution sampling, LRS)矩阵来直接测量图像低频信息的方法,其中 LRS 矩阵采用低复杂度的均值滤波器来实现,记为 Φ 。综上所述本文构造的是基于 RS 矩阵和 LRS 矩阵的混合采样矩阵 Φ_H 。易知 RS 矩阵与梯度稀疏基 $TV(\cdot)$ 不相干,所以要保证混合采样矩阵 Φ_H 与梯度稀疏基 $TV(\cdot)$ 不相干,只需保证 LRS 矩阵与梯度稀疏基 $TV(\cdot)$ 不相干即可。下面首先以 3×3 模板(记 $F=3$)的均值滤波器为例说明 LRS 矩阵的构造过程以及其具备的特点。

对于 m 行 n 列图像 x ($N = mn$), $F=3$ 时,需要进行 $M = \lfloor m/F \rfloor \times \lfloor n/F \rfloor$ 次测量,此时 LRS 矩阵 Φ 可以表示为 $\Phi = [\phi_1^T, \phi_2^T, \dots, \phi_M^T]^T$, 其中 ϕ_i 表示第 i 次的测量行向量。图 1 显示了 LRS 采样的第 1 次测量过程。




图 1 LRS 采样过程

从图 1 可以看出,第 1 次测量时只有左上方的 3×3 小块图像的 9 个像素被采样,剩余的像素均未被采样。为了方便描述,将图像 x 向量化,记为 $\text{vec}(x)$ 。 $\text{vec}(x)$ 的含义是:对于矩阵 $x = [x_{i,j}]$ (其中 $x_{i,j}$ 表示 x 第 i 行第 j 列元素, $i = 1, 2, \dots, m, j = 1, 2, \dots, n$), $\text{vec}(x) = (x_{1,1}, x_{2,1}, \dots, x_{m,1}, x_{1,2}, x_{2,2}, \dots, x_{m,2}, \dots, x_{1,n}, x_{2,n}, \dots, x_{m,n})^T$ 。假设用“1”表示被采样的像素,“0”表示未被采样的像素,则相应的第 1 次测量行向量为 $\phi_1 = (\underbrace{1, 1, 1, 0, 0, \dots, 0}_m, \underbrace{1, 1, 1, 0, 0, \dots, 0}_m, \underbrace{0, 0, \dots, 0}_{m(n-3)})$ 。不失一般性,若图像 x 的 m 行 n 列均为 F (均值滤波器的模板大小)的整数倍,则第 i 次的测量行向量为

$$\phi_i = (\underbrace{0, 0, \dots, 0}_{mbF}, \underbrace{d, d, \dots, d}_F, \underbrace{0, 0, \dots, 0}_{m(n-(1+b)F)}) \quad (6)$$

式中 ϕ_i 的长度为 N , $d = (\underbrace{0, 0, \dots, 0}_{aF}, \underbrace{1, 1, \dots, 1}_F, \underbrace{0, 0, \dots, 0}_{m-(1+a)F})$, $a = \text{fix}((i-1)F/n)$, $b = \text{rem}(i-1, n/F)$ ($\text{fix}(\cdot)$ 表示取整函数, $\text{rem}(\cdot)$ 表示求余函数)。

由式(6)可知, LRS 矩阵是一个非常稀疏的正交二进制矩阵,每一行只有 $F \times F$ 个元素为“1”,剩余元素全为“0”。此外, LRS 矩阵的每一列仅有一个元素非零,所以一次测量即可获得所有的 M 个测量值,采样效率极高,而 PF 矩阵需要 M 次测量才能获得所有的测量值。表 1 显示了 LRS 和 PF 两种不同测量矩阵的计算复杂度。

表 1 计算复杂度比较

矩阵	测量时间	存储量	计算复杂度
LRS	1	N	N
PF ^[8]	M	$O(N \log N)$	$O(N \log N)$

从表 1 中可以看出, LRS 矩阵具有很低的计算复杂度,而 PF 矩阵,即使有快速 FFT 算法,它的计算复杂度仍然要比 LRS 矩阵高。更重要的是,由 LRS 矩阵获得的每个测量值均为图像的局部平均值(只要 Φ 乘以 $\frac{1}{F^2}$),可以有效地获取图像的低频信息,有利于提高重构性能。

下面来证明 LRS 矩阵 Φ 与梯度稀疏基 $TV(\cdot)$ 不相干。根据两组正交基之间相干程度的定义^[14]:

$$\mu(\Phi, \Psi) = \sqrt{N} \max_{k,j} |\langle \phi_k, \psi_j \rangle| \quad (7)$$

其中 ϕ_k, ψ_j 分别为 Φ, Ψ 的行向量和列向量 ($\|\phi_k\|_2 = 1, k \in \{1, 2, \dots, M\}, \|\psi_j\|_2 = 1, j \in \{1, 2, \dots, N\}$), 不失一般性,我们首先来证明 LRS 矩阵 Φ 与大多数固定稀疏基 Ψ 不相干。为了简单起见,不妨设 Φ 中每一个行向量只有 s 个元素为“1”,对 Φ 进行归一化,即每行乘以因子 $\frac{1}{\sqrt{s}}$, 易知

$$\max_{k,r} |\phi_k(r)| = \frac{1}{\sqrt{s}} (r \in R = \{r_1, r_2, \dots, r_m\}, R \subset \{1, 2, \dots, N\}).$$

假设 Ψ 中每一列至少有 αN ($0 < \alpha \leq 1$) 个非零元素,则有 $|\psi_j(r)| \leq \frac{1}{\sqrt{\beta N}} (r \in \{1, 2, \dots, N\}, 0 < \beta \leq \alpha)$ 。下面来计算 $\mu(\Phi, \Psi)$ 。由于

$$\begin{aligned} |\langle \phi_k, \psi_j \rangle| &= \left| \sum_{r=1}^N \phi_k(r) \psi_j(r) \right| \\ &= \left| \sum_{r \in R} \phi_k(r) \psi_j(r) \right| \end{aligned}$$

$$\leq s \cdot \frac{1}{\sqrt{s}} \cdot \frac{1}{\sqrt{\beta N}} = \frac{\sqrt{s}}{\sqrt{\beta N}}$$

所以

$$\begin{aligned} \mu(\Phi, \Psi) &= \sqrt{N} \max_{k,j} |\langle \phi_k, \psi_j \rangle| \\ &\leq \sqrt{N} \frac{\sqrt{s}}{\sqrt{\beta N}} = \sqrt{\frac{s}{\beta}} \end{aligned} \quad (8)$$

由式(8)可知, LRS 矩阵 Φ 和大多数固定稀疏基 Ψ 之间的相干程度不高于 $\sqrt{\frac{s}{\beta}}$, 由于 s 很小, β 近似为 1, 所以 $\mu(\Phi, \Psi)$ 一般很小, 从而证明了 LRS 矩阵 Φ 与大多数固定稀疏基 Ψ 不相干。若 Ψ 选用梯度稀疏基 $TV(\cdot)$, 则有 $\mu(\Phi, \Psi) = \sqrt{s}(\beta = 1)$ 。易知在本文设计的 LRS 矩阵中, $s = F \times F$, 当 $F = 3$ 时, 有 $\mu(\Phi, \Psi) = 3$, 这就保证了 LRS 矩阵 Φ 与梯度稀疏基 $TV(\cdot)$ 不相干。

综上所述, 我们证明了本文方法构造的基于 RS 矩阵和 LRS 矩阵的混合采样矩阵与梯度稀疏基 $TV(\cdot)$ 不相干, 能够很好地满足 CS 测量矩阵的要求。最后在图像重构时, 使用文献[13]中的 TV 重建算法即可由混合采样数据通过求解优化问题式(3)恢复出原图像。

3 实验及性能分析

在 MATLAB 环境下选用标准灰度图像 Lena (1024 × 1024, 8 bit) 对本文方法进行实验。实验中采用 32 × 32 分块, TV 重建算法^[15]。表 2 显示了采样率 $M/N = 20\%$ (其中 N 为信号长度, M 为测量值向量长度) 时, Lena 在不同均值滤波器模板大小 (F) 下的峰值信噪比 (PSNR) 和结构相似度 (SSIM)^[15] 性能。

表 2 Lena 的 PSNR 和 SSIM 性能比较 ($M/N = 20\%$)

F	0	3	4	5
PSNR (dB)	35.47	37.92	36.75	36.17
SSIM	0.8790	0.9274	0.9062	0.9005

从表中可以看出, $F = 0$ 时的图像重建效果最差, PSNR 只有 35.47dB, 比 $F = 3$ 的 PSNR (37.92dB) 减少了 2.45dB, SSIM 指标也相应地降低了约 0.05。这里 $F = 0$ 表示不采用低分辨率采样 (LRS), 混合采样矩阵退化为仅由随机采样 (RS) 矩阵组成。为了方便描述, 记 $F = 0$ 时的方法为 BCS-

TV (采用 TV 重建算法的分块压缩感知方法), $F \neq 0$ 时的方法为 HBCS-TV (采用 TV 重建算法的基于混合采样的分块压缩感知方法)。容易看到, 由于 HBCS-TV 有效利用了 (LRS) 直接测量图像的低频信息, 获得了更优的重构性能。同时也看到, F 的取值对重构性能影响较大, $F = 3$ 时的重构性能最好, 故在以后的实验中, 如果不做特别说明, HBCS-TV 方法均取 $F = 3$ 。其中 $F \neq 0$ 时, 混合采样数据由两部分组成: RS 数据和 LRS 数据。记图像信号长度为 N ($N = mn$, m 为图像行数, n 为图像列数), 需要获取的混合采样数据个数为 M , 均值滤波器模板大小为 F , RS 数据个数为 M_1 , 低分辨率采样数据个数为 M_2 , 则有 $M = M_1 + M_2$, 其中 $M_2 = \lfloor m/F \rfloor \times \lfloor n/F \rfloor$ 。

为更直观地比较恢复图像的质量, 图 2 显示了 $M/N = 20\%$ 时, Lena 的重建图像和经过直方图均衡化处理后的差值图像。



(a) $F = 3$ (PSNR = 37.92dB, SSIM = 0.9274);
(b) $F = 0$ (PSNR = 35.47dB, SSIM = 0.8790)

图 2 $M/N = 20\%$, Lena 的重建图像 (第一行) 和其对应的差值图像 (第二行)

从图 2 可知, HBCS-TV 得到的差值图像的灰度值变化范围较小, 特别是在图像平滑区域 (如脸部), 明显要低于 BCS-TV 差值图像的灰度值变化范围, 说明 HBCS-TV 可以更好地恢复图像的低频信息, 充分表明混合采样方法可以获得比单一随机采样更高的重构性能。

此外, HBCS-TV 方法对硬件处理能力要求较

低,这是因为采用了分块策略,测量矩阵不随图像尺寸而改变,所以在测量过程中占用的时间和内存空间都很小。在相同资源的条件下,HBCS-TV 可以处理的图像尺寸远远大于 CS-TV 方法,一般来讲处理尺寸在 512×512 以上的图像比较合适。以 MATLAB 环境为例,表 3 给出了在 Intel 双核 2.93GHz CPU 的环境下,BCS-TV 和 HBCS-TV 两种方法对不同尺寸 Lena 图像的测量时间。图 3 则给出了 HBCS-TV 和 CS-TV 两种方法中测量矩阵对存储空间的需求对比。从表 3 可以看出,采用随机采样和低分辨率采样两种采样方法混合的 HBCS-TV 算法与仅采用单一的随机采样方法的 BCS-TV 算法相比,获得更高图像重构性能同时,测量时间要略长一些。

表 3 BCS-TV 和 HBCS-TV 针对不同尺寸图像的测量时间

测量时间(s)	256 × 256	512 × 512	1024 × 1024	2048 × 2048
BCS-TV	0.0373	0.1747	0.7683	4.2321
HBCS-TV	0.0594	0.2443	1.0975	5.4018




图 3 存储空间占用对比

从图 3 可以看出,随着图像尺寸的增加,CS-TV 的资源消耗成指数级增加,而 HBCS-TV 则一直维持在较低的水平上。在资源有限的情况下,例如只有 2G 内存时,当图像大小为 256×256 像素,采样率 $M/N = 50\%$ 时,CS-TV 方法的观测矩阵 Φ 所需存储空间为 2G (元素类型为 double 型),说明 256×256 的图像大小是 CS-TV 方法的处理上限,而 HBCS-TV 可以利用 30M 左右的内存处理 1024×1024 或更大的图像。HBCS-TV 针对不同尺寸 Lena 图像的 PSNR 性能如图 4 所示。




图 4 HBCS-TV 针对不同尺寸的 PSNR 性能

为了进一步验证本文方法的性能,在相同的计算平台(Intel 双核 2.93GHz/2G 内存)下对 1024×1024 的 Lena 图像做了 5 组实验,即 HBCS-TV 算法、BCS-TV 算法、凸集投影 (POCS) 算法^[11]、梯度投影稀疏重建 (GPSR) 算法^[10]、正交匹配追踪 (OMP) 算法^[12] 的实验。图 5 显示了 Lena 图像在不同采样率下 5 种重构算法的 PSNR 性能。其中 POCS 算法和 OMP 算法中也采用 32×32 分块。HBCS-TV 算法在采样率 $M/N = 10\%$ 时,取 $F=4$,其他情况取 $F=3$ 。




图 5 Lena 的 PSNR 性能比较

从图 5 中可以看出,HBCS-TV 获得了最好的性能。与 BCS-TV 相比,HBCS-TV 的 PSNR 提高了大约 2dB,这是因为 HBCS-TV 方法采用基于随机采样和低分辨率采样的混合采样矩阵,而低分辨率采样可以很好地保留图像的低频信息。同时也可以看到, $M/N < 30\%$ 时,基于贪婪思想的快速 OMP 算法恢复的图像质量很差,难以满足实际应用要求。为更直观地比较恢复图像的质量,图 6 显示了 $M/N = 30\%$ 时,Lena 的重建效果。



(a) 原始图像; (b) HBCS-TV (PSNR = 39.65dB, SSIM = 0.9466; (c) BCS-TV (PSNR = 37.71dB, SSIM = 0.9247)
(d) POCS (PSNR = 36.95dB, SSIM = 0.9135) (e) GPSR (PSNR = 35.39dB, SSIM = 0.0.8501) (f) OMP (PSNR = 26.41dB, SSIM = 0.0.7447)

图 6 $M/N = 30\%$, Lena 的重建图像

从图 6 中也可以看出, HBCS-TV 的重建图像质量最高, 整体效果明显优于 BCS-TV 的重建图像质量, 而 OMP 的重构效果最差。

4 结 论

在解决图像压缩感知问题上, 采用低分辨率采样和随机采样相混合的分块压缩感知方法比其他方法优越。利用低分辨率采样具有直接测量图像低频信息的特性构造的基于随机采样和低分辨率采样的混合采样矩阵与大多数固定稀疏基不相干, 而且结构简单、非常易于硬件实现, 同时分块策略保证算法复杂度不随图像尺寸而改变, 适合实时处理高分辨率图像。实验结果表明, 采用 TV 重建算法可以有效提高重构质量。HBCS 算法目前需要进一步解决的问题是, 针对已设计的混合采样矩阵, 如何构造出更加稳定的、更高性能的重构算法来进一步提升恢复图像的质量。

参考文献

- [1] Balouchestani M, Raahemifar K, Krishnan S. Compressed sensing in wireless sensor networks: survey. *Canadian Journal on Multimedia and Wireless Networks*, 2011, 2(1):1-4
- [2] Baraniuk R. A lecture on compressive sensing. *IEEE Signal Processing Magazine*, 2007, 24(4):118-121
- [3] Rauhut H. Compressive sensing and structured random matrices. *Radon Series on Computational and Applied Mathematics*, 2011, 9:1-94
- [4] Davenport M, Duarte M, Eldar Y, et al. Compressed sensing: theory and applications, Cambridge University Press, 2011. 1-68
- [5] 石光明, 刘丹华, 高大化等. 压缩感知理论及其研究进展. *电子学报*, 2009, 37(5):1070-7081
- [6] Gan L. Block compressed sensing of natural images. In: *Proceedings of IEEE International Conference on Digital Signal Processing (DSP)*, Cardiff, UK, 2007. 403-406
- [7] Mun S, Fowler J E. Block compressed sensing of images using directional transforms. In: *Proceedings of IEEE International Conference on Image Processing (ICIP)*, Cairo, Egypt, 2009. 3021-3024
- [8] Romberg J. Imaging via compressive sampling. *IEEE Signal Processing Magazine*, 2008, 25(2):14-20
- [9] Fira M, Goras L. Biomedical signal compression based on basis pursuit. *International Journal of Advanced Science and Technology*, 2010, 4:53-64
- [10] Figueiredo M A T, Nowak R D, Wright S J. Gradient projection for sparse reconstruction: application to compressed sensing and other inverse problems. *IEEE Journal of Selected Topics in Signal Processing: Special Issue*

- on *Convex Optimization Methods for Signal Processing*, 2007, 1(4):586-598
- [11] Candès E J, Romberg J. Practical signal recovery from random projections. <http://www.acm.caltech.edu/~emmanuel/papers/PracticalRecovery.pdf>; Caltech, 2011
- [12] Tropp J, Gilbert A. Signal recovery from random measurements via orthogonal matching pursuit. *IEEE Transactions on Information Theory*, 2007, 53(12):4655-4666
- [13] Willett R M, Harmany Z T, Marcia R F. Possion image reconstruction with total variation regularization. In: *Proceedings of IEEE International Conference on Image Processing*, Hong Kong, China, 2010. 4177-4180
- [14] Candès E J, Romberg J. Sparsity and incoherence in compressive sampling. *Inverse Problem*, 2007, 23(3):969-986
- [15] Wang Z, Bovik A C, Hamid R S, et al. Image quality assessment: from error measurement to structural similarity. *IEEE Transaction on Image Processing*, 2004, 3(4):600-612
- [13] Willett R M, Harmany Z T, Marcia R F. Possion image

A method for block compressed sensing of images based on hybrid sampling

Lv Pei^{***}, Zhou Renkui^{*}, Liu Haiying^{***}, He Junhua^{*}

(^{*} Xi'an Institute of Optics and Precision Mechanics of Chinese Academy of Sciences, Xi'an 710119)

(^{**} Graduate School of Chinese Academy of Sciences, Beijing 100049)

(^{***} School of Telecommunication Engineering, Xidian University, Xi'an 710071)

Abstract

The compressed sensing of images was studied, and a new method for block compressed sensing (BCS) of images based on Hybrid sampling, called the HBCS for short, was proposed to improve the performance of image reconstruction. The method uses a hybrid sampling matrix random sampling (RS) and low-resolution sampling (LRS) to complementally measure the image information data with the high sensing efficiency. The hybrid sampling matrix with a simple structure was proved theoretically to be incoherent with most fixed sparsity bases. And the block strategy of the method ensures that the complexity of measurement and reconstruction processes does not change with the image size, so the method is simple and easy to implement, and is suitable for large-scale applications. The experimental results show that the proposed method can achieve much better results than many state-of-the-art algorithms in terms of both PSNR and visual perception when using the total variation (TV) reconstruction algorithm.

Key words: information sampling, compressed sensing (CS), hybrid sampling, block strategy, total variation (TV) algorithm