

基于灰度共生矩阵的图像自适应分块压缩感知方法

杜秀丽 张 薇 顾斌斌 陈 波 邱少明

(大连大学辽宁省通信网络与信息处理重点实验室 大连 116622)

摘 要 分块压缩感知的提出很好地弥补了大尺寸图像占用资源多、重构耗时长等不足,但重构后的图像存在明显的块效应。针对现有图像纹理复杂度分析不够准确,导致自适应采样率分配后块效应降低不理想的问题,提出了一种基于灰度共生矩阵的图像自适应分块压缩感知方法。该方法通过共生矩阵分析图像的纹理特性,自适应分配采样率,在总采样率不变的前提下使纹理复杂度高的子块获得较高的采样率,纹理复杂度低的子块获得较低的采样率,并用 SAMP(Sparsity Adaptive Matching Pursuit)算法实现重构。仿真结果显示,所提方法能够有效地解决块效应问题,尤其对于局部图像而言,重构图像的画质得到了明显改善。

关键词 分块压缩感知,灰度共生矩阵,熵,采样率

中图分类号 TN911.7 文献标识码 A DOI 10.11896/j.issn.1002-137X.2018.08.050

GLCM-based Adaptive Block Compressed Sensing Method for Image

DU Xiu-li ZHANG Wei GU Bin-bin CHEN Bo QIU Shao-ming

(Key Laboratory of Communications Network and Information Processing, Dalian University, Dalian 116622, China)

Abstract The method of block compressed sensing really makes up for the defects of the consumed resource and time in reconstruction of large-size images. However, there is an obvious block effect in the reconstructed image. Aiming to solve the problem of inaccurate analysis of texture complexity that hinders reduction of the block effect in adaptive sampling compressed sensing method, this paper proposed an adaptive block compressed sensing method based on co-occurrence matrices. The texture feature of image is analyzed by the co-occurrence matrix, and then the sampling rate is adaptively allocated according to the texture feature. Under the premise that the total sampling rate is not changed, the image with complex texture obtains higher sampling rate, and the image with simple texture obtains lower sampling rate. At last, SAMP (Sparsity Adaptive Matching Pursuit) is used to conduct reconstruction. The simulation results show that the proposed method can effectively eliminate the block effect, especially for the partial blocks, and the performance of the reconstructed block is obviously improved.

Keywords Block compressed sensing, Co-occurrence matrices, Entropy, Sampling rate

Candes 和 Donoho 等提出了压缩感知^[1-4] (Compressive Sensing, CS)理论,该理论突破了传统奈奎斯特采样定理的约束,通过观测矩阵把原始信号投影到低维空间,通过重构算法准确恢复出原始信号,这是一种新的信号压缩采样方法。

由压缩感知理论可知,随着图像像素的逐渐增多,测量矩阵的阶数逐渐增大,这不仅造成了存储资源的浪费,而且使重构时间成倍增长,严重阻碍了其在医疗成像^[5]和遥感卫星^[6]等领域(对信息的时效性有严格要求)的应用。分块压缩感知^[7] (Block Compressed Sensing, BCS)算法的提出很好地解决了此类问题,其对大尺寸图像进行分块,通过相同的测量矩阵对各个子块进行压缩采样,降低了测量矩阵的维数,减少了重构时间,保证了信息的时效性。但是,通过分块压缩感知恢

复出的图像有明显的块效应。为此,相关学者提出了一系列消除块效应的算法^[8-12]。文献[8]提出了一种基于灰度均值和方差的识别方法,该方法通过灰度均值和方差判断图像的纹理复杂度,但该研究具有局限性,需要在特定条件下才能实现准确的判定。文献[9]提出了一种基于差分的稀疏度自适应重构算法,对信号与测量矩阵之间的相关系数进行归一化及差分运算,在相同采样率下,所提算法可以获得较好的重构效果。文献[10]提出了一种基于灰度熵的自适应全变分滤波的压缩感知算法,通过图像的灰度熵自适应分配块采样率来提高重构质量,但灰度熵的使用没有考虑图像元素间的相关关系,具有一定的局限性。文献[11]提出了一种基于全变差分自适应采样率正交匹配追踪算法,该算法通过全变差分测

到稿日期:2017-06-23 返修日期:2017-09-14 本文受辽宁省教育厅高速眼图测试关键技术研究(L2014495),辽宁“百千万人才工程”培养经费资助。

杜秀丽(1977—),女,博士,教授,CCF 会员,主要研究方向为数字图像处理、压缩感知, E-mail: dxlxts@126.com (通信作者);张 薇(1993—),女,硕士生,主要研究方向为数字图像处理、压缩感知, E-mail: zzzd912912@163.com;顾斌斌(1990—),男,硕士生,主要研究方向为数字图像处理、压缩感知;陈 波(1972—),男,博士,教授,主要研究方向为数字图像处理。

量纹理结构,但全变差分在纹理结构的估量上准确度不高,且使用OMP算法进行重构需要事先获得各个子块的稀疏度。本文提出一种基于灰度共生矩阵的分块压缩感知方法,该方法通过灰度共生矩阵分析图像的纹理特性,不但保证了图像纹理复杂度判断的准确度,而且重构质量也得到了提高。

1 分块压缩感知及纹理分析方法

1.1 分块压缩感知

分块压缩感知把原始图像分成尺寸为 $B \times B$ 的子块,随后把每个子块的纹理复杂度排成一列,记为 x_i ,再用观测矩阵对其采样,得到:

$$y_i = \Phi_a x_i \tag{1}$$

其中, Φ_a 是大小为 $m \times B^2$ 的观测矩阵。那么对于整幅图像来说,观测矩阵 A 是一个块对角矩阵,表示为:

$$A = \begin{bmatrix} \Phi_a & 0 & \cdots & 0 \\ 0 & \Phi_a & \cdots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \cdots & \Phi_a \end{bmatrix} \tag{2}$$

分块压缩感知独立地对每个子块进行采样和重构,降低了计算复杂性,而且每个子块具有相同的测量矩阵 Φ_a ,因此在接收端只用存储 Φ_a 而不必存储整个 A ,从而节约了存储资源。但是在对各个子块进行采样的过程中,由于采用的观测矩阵的维数相同,而块与块之间存在纹理差异,导致稀疏度不均匀,因此子块之间的重构效果不同。当把重构效果不同的子块重构在一张图上时,就会产生虚假边界。如图1(b)所示,相邻子块之间存在模糊阴影,各个块的明暗程度也不同,这就是块效应。




图1 分块重构的块效应对比

Fig. 1 Comparison of locking effect of block reconfiguration

1.2 基于灰度熵的自适应采样率分块压缩感知

自适应采样率分配依据图像子块的纹理特征,将包含信息较多、纹理较为复杂的块定义为纹理块,而包含信息少的块被定义为平滑块。其基本原理如图2所示,给予纹理块较高的采样率,给予平滑块较低的采样率,以减少模糊阴影,降低块效应。



图2 图像自适应分块压缩采样的原理图

Fig. 2 Schematic diagram of compressed sampling of image adaptive block

灰度熵能体现出图像中像素间的离散程度,可以较好地表征图像中平均信息量的大小。设灰度级为 j 的图像元素的

个数为 k_j ,则灰度级 j 对应的概率为:

$$P_j = \frac{k_j}{\sum_{j=0}^{255} k_j} \tag{3}$$

据此可以求出图像的整体灰度熵:

$$h = - \sum_{j=0}^{255} p_j \log_2 p_j \tag{4}$$

对分块图像进行编号,用 i 表示,则每个子块的灰度熵为 h_i 。 h_i 较大说明子块灰度值的离散程度较大,需分配更高的采样率; h_i 较小说明子块灰度值的离散程度较小,需分配更低的采样率。虽然灰度熵的获取比较简单,但其对图像纹理信息的判断存在一定的失误。

2 基于灰度共生矩阵的分块压缩感知

本文提出了一种新的图像自适应分块压缩感知方法,通过灰度共生矩阵来分析图像纹理复杂性以确定子块的采样率。分块压缩感知的模型如图3所示,主要包含BCS分块、基于灰度共生矩阵的采样率分配以及重构端滤波等步骤,在保证重构质量的前提下,能提高方法的适应性。




图3 模型的整体框架

Fig. 3 Overall framework of model

2.1 基于灰度共生矩阵的纹理复杂度度量

分块后的图像子块存在不同的纹理结构,如果用相同的采样率对其进行采样,则对重构端图像较为平滑的子块的重构效果好,而对纹理细节较多的子块则效果不理想。因此,需要给予平滑块较低的采样率,而给予纹理块较高的采样率,以平衡子块之间的重构质量。采样率的分配需要纹理复杂度这个前提条件,而灰度共生矩阵^[13-14]是一种描述图像纹理信息的有效方法。

图像的纹理特性是由不同的图像复杂度在像素域中的个数决定的。因此,必然存在一些复杂度相同的像素点,即某两个像素点之间存在一定的空间关系,通过对该空间关系进行统计分析,来得到用于表示图像纹理信息的矩阵,该矩阵即为灰度共生矩阵。

灰度共生矩阵被描述为灰度为 i 的像素通过某一事先设定好的路径关系 $d = (D_x, D_y)$ 达到灰度为 j 的概率,用 $P_d(i, j)$ ($i, j = 0, 1, 2, \dots, L-1$) 表示。其中, d 表示图像上像素之间的路径关系, L 表示图像的灰度级, i 和 j 表示像素的灰度。不同的 d 表示图像上像素之间的距离和方向不同。 θ 表示矩阵的生成方向,常用的角度有 $0^\circ, 45^\circ, 90^\circ$ 和 135° ,如图4所示。




图4 灰度共生矩阵的像素对

Fig. 4 Pixel pairs of gray covariance matrix

确定图像元素之间的路径关系 d 后,便能获得关系 d 下的灰度共生矩阵。灰度共生矩阵的表达式如式(5)所示:

$$P_d = \begin{bmatrix} P_d(0,0) & P_d(0,1) & \cdots & P_d(0,j) & \cdots & P_d(0,L-1) \\ P_d(1,0) & P_d(1,1) & \cdots & P_d(1,j) & \cdots & P_d(1,L-1) \\ \cdots & \cdots & \cdots & \cdots & \cdots & \cdots \\ P_d(i,0) & P_d(i,1) & \cdots & P_d(i,j) & \cdots & P_d(i,L-1) \\ \cdots & \cdots & \cdots & \cdots & \cdots & \cdots \\ P_d(L-1,0) & P_d(L-1,1) & \cdots & P_d(L-1,j) & \cdots & P_d(L-1,L-1) \end{bmatrix} \quad (5)$$

式(5)中的元素代表着按照某种约束 d 出现的次数。通过分析矩阵,能够获得图像纹理结构、灰度变化幅度和排列规则等信息。但灰度共生矩阵无法直观地显示纹理状况,因此一般需要在矩阵的基础上获得二次统计量,通过二次统计来表示纹理特征。

本文选用熵^[15]来对灰度共生矩阵进行二次统计,并将所得结果作为采样率的参考值。熵是图像拥有信息量的度量,是一种随机性的度量,纹理信息属于图像信息。如果图像中的元素拥有最大的随机性,其对应的灰度共生矩阵中元素大小差异大,则熵值大;如果图像结构十分单一,灰度共生矩阵的值接近于 0,则熵值小。熵能很好地反映图像纹理结构的复杂性。图像灰度越分散,图像纹理越复杂,共生矩阵的熵就越大;图像灰度越均匀,纹理越单一,共生矩阵的熵就越小。熵的计算公式为:

$$f = - \sum_{i=0}^{L-1} \sum_{j=0}^{L-1} P_d(i,j) \log P_d(i,j) \quad (6)$$

2.2 基于灰度共生矩阵的自适应采样率分配

由式(6)得出每个子块的熵后,对采样率的具体分配公式如下:

$$r_i = SR \cdot \left(aver + \frac{f_i - aver}{aver / [\min(f_i) + 0.1] \cdot (2 - SR) / 4} \right) / aver \quad (7)$$

$$aver = \sum_{i=1}^b f_i / b \quad (8)$$

式(7)中括号内的内容表示当前块熵与平均熵的差值,且这个差值有一定的权重,权重系数为分母中与 SR 和最小熵有关的量, SR 表示一幅图像的整体采样率。式(8)中, $aver$ 为所有子块熵的平均值, b 为子块个数。通过式(5)确定图像子块的共生矩阵,通过式(6)确定图像子块的熵值,通过式(7)确定每个子块的采样率。从式(7)可以看出,采样率 r_i 与熵 f_i 成正相关,纹理复杂度越高,采样率就越大;随着 SR 的增加,子块的采样率 r_i 越不均匀。另外,采样率的确定与最小熵值相关,若图像中空白部分或相同部分较多,则采样率分配会比较均匀,从而降低了平滑块和纹理块之间因采样率不均而造成的失真,且各子块的采样率之和等于 SR ,以保证整体采样率不变。

3 SAMP 重构算法

凸优化算法的重构性能虽然优越,但其较高的复杂性加大了硬件操作的难度;相对应地,贪婪迭代算法因计算简单、图像重构性能较好而被广泛应用。贪婪迭代算法中的 OMP 算法比较常用,OMP 算法通过引入正交匹配思想克服了 MP 算法的冗余迭代,使每次迭代所选的原子最优;但 OMP 算法重构需要稀疏度作为先验条件,而图像压缩时并不能得知稀疏度。虽然文献[16]提到用函数来估计稀疏度以解决问题,

但对于不同纹理的图像,估计具有一定局限性,重构效果较差。SAMP 算法在迭代时将迭代结果的变化率作为终止条件,在没有稀疏度这个条件时,也可以获得准确的重构,且重构速度远高于 OMP 算法。

SAMP 算法中,步长 s 需要满足 $s \leq k$,在信号的稀疏度 k 未知的情况下,可以设定 $s = 1$,如果设定的步长过小会造成迭代次数的增多,导致算法复杂度过高,因此需要折中考虑步长 s 。SAMP 算法的步骤如算法 1 所示。

算法 1 SAMP 算法

输入: $M \times N$ 维的感知矩阵 Θ , $M \times 1$ 维的测量向量 y , 步长 s , 原始信号 x

输出: 信号稀疏表示系数 $\hat{\theta}$, 重构信号 \hat{x}

步骤 1 初始化。残差 $r_0 = y - x_0 = 0$, 索引集合 $\Lambda_0 = \emptyset$, $\Theta_0 = \emptyset$, 支撑集 $F = \emptyset$, 支撑集大小 $L = S$, 迭代次数 $t = 1$ 。

步骤 2 找出 Θ 中与 r_{t-1} 匹配度最高的 L 个原子的索引,并计算相关最大化,挑选得到初选集合 J 。

$$J = \arg \max_j \{ |\langle r_{t-1}, \theta_j \rangle|, L \}$$

步骤 3 更新候选集合。

$$\Lambda_t = F_{t-1} \cup \{J\};$$

步骤 4 获得支撑集 F 。

$$F = \arg \max_j \{ |\Theta_{\Lambda_t}^{\dagger} * y|, L \}$$

其中, $\Theta_{\Lambda_t}^{\dagger} = (\Theta_{\Lambda_t}^T \Theta_{\Lambda_t})^{-1} \Theta_{\Lambda_t}^T$ 为 Θ_{Λ_t} 的伪逆, Θ_{Λ_t} 为 Λ_t 对应的感知矩阵 Θ 的列向量组成的子矩阵。

步骤 5 更新残差。

$$r = y - \Theta_F \hat{\theta}_t = y - \Theta_F \Theta_F^{\dagger} * y$$

步骤 6 若 $\|r\|_2 < \epsilon$,则可以认为重构完成,迭代停止,并执行步骤 8;否则执行步骤 7。

步骤 7 若 $\|r\|_2 \geq \|r_{t-1}\|_2$,则进入下一个阶段,改变支撑集的大小,即 $L = L + S$, $t = t + 1$,转入步骤 2,进行下一步迭代;否则, $F_t = F$, $r_t = r$, $t = t + 1$,转入步骤 2。

步骤 8 得到信号的稀疏表示系数估计 $\hat{\theta}$:

$$\hat{\theta} = \Theta^{\dagger} * y$$

其中, $\Theta^{\dagger} = (\Theta^T \Theta)^{-1} \Theta^T$ 。

得到 $\hat{\theta}$ 后,利用稀疏矩阵可得重构信号 $\hat{x} = \Psi \hat{\theta}$ 。

4 实验仿真

为了验证本文提出的灰度共生矩阵度量图像纹理复杂度的有效性,通过方差、灰度熵和灰度共生矩阵熵对图像进行了纹理复杂度的对比。选取的灰度图像 House 的大小为 256×256 像素。进一步,为验证基于灰度共生矩阵的自适应采样率方法的有效性,对灰度图像 House, Lena, CT1, CT2 进行仿真,图像大小均为 256×256 像素,分块大小为 64×64 像素,如图 8 所示。测量矩阵选取高斯随机测量矩阵,对比算法有分块压缩

感知(BCS)-稀疏度自适应匹配追踪(Sparsity Adaptive MP, SAMP)重构算法和文献[9]所提的灰度熵。为了降低求取共生矩阵的计算量,将原始图像进行灰度级压缩,从256级量化成16级(文献[13]已验证灰度级压缩后,图像的纹理复杂度不会有误差),并获取每个子块的共生矩阵(方向取为0度)。

4.1 纹理复杂度对比

文献[10]用 P 表示灰度值为 j 的像素点在整幅图像中的比例;相对来说,本文熵的获取简单,但对图像纹理信息的判断有一定的失误。例如,图5中3幅图像的灰度直方图是一样的,一半是黑像素点,一半是白像素点,但实际上3幅图像的纹理复杂度是不同的,且复杂度依次递增。从表1可以看出,方差计算所得结果依次递减,存在误差;文献[10]给出的灰度熵计算所得的结果相同,都不能很好地区分此类图像的纹理复杂度。




图5 具有相同直方图的简单图像

Fig.5 Simple image with same histogram

表1 实验图像的复杂度统计

Table 1 Statistics of experimental image complexity

图1	本文熵(0)	方差	灰度熵
(a)	0.76	16092	1.19
(b)	0.82	15817	1.19
(c)	1.03	15708	1.19

表2 不同纹理复杂度判别方法的数值比较

Table 2 Numerical comparison of different texture complexity discrimination methods

	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16
方差	594.64	2627.30	1170.85	589.77	1695.47	798.95	3171.07	2336.58	2779.35	834.36	1938.13	1657.20	2243.45	96.34	1620.86	1712.51
灰度熵	2.71	5.50	3.35	2.46	4.29	5.89	7.12	6.70	6.06	5.72	6.74	6.67	6.16	4.98	6.99	6.83
共生矩阵	0.10	2.05	0.57	0.08	1.36	2.21	3.22	2.86	2.54	2.23	2.95	2.77	2.49	1.44	2.88	2.89




图7 不同方法的纹理复杂度对比曲线

Fig.7 Comparison curve of different texture of complexity methods

从图7可以看出,灰度共生矩阵曲线中,块1和块4对应的值较小,块7、块8、块9、块11、块12、块13、块15和块16对应的值较大,与图像子块的纹理复杂度情况相符;方差曲线中,块14对应的值最小,而从图6中来看,虽然块14的纹理比较简单,但较块1和块4是复杂的,因此方差法存在一定的误差;灰度熵曲线的趋势和灰度共生矩阵曲线是一致的,但对比两条曲线可以看出,灰度熵曲线的变化幅度较小,判别精度较差。

以典型的自然图像为例进行对比,图像 House 是一幅大小为 256×256 像素的 Matlab 常用仿真图像,首先将其分成 64×64 像素的16个子块(见图6),分别用方差、灰度熵和本文提出的灰度共生矩阵判断各个子块的复杂度,再通过式(6)获得灰度共生矩阵的二次统计量,结果如表2所列。

从图6可以看出,块1和块4的色调单一、纹理简单,从表2中16个子块对应的共生矩阵熵值来看,块1和块4的值也较小;块7、块8、块9、块11、块12、块13、块15和块16的色调丰富、纹理复杂,其对应表2中的共生矩阵熵值也较大,能够很好地区分纹理的复杂度。从图6中还可以看出,块5、块6、块7的纹理复杂度是依次递增的,而表2中方差法对这3个子块的判别中,块6的纹理是最小的,存在误差;块11比块15、块16更复杂,灰度共生矩阵法和方差法对块11的判别值都高于块15、块16,而表2中灰度熵法对块11的判别值低于块15、块16,存在一定的误差。对不同纹理复杂度判别方法的数值进行量化后并不会对图像子块的纹理复杂度判断造成影响。为了更加直观地比较几种纹理复杂度判断方法的性能,将表2中的数据绘制成曲线,如图7所示(将表2中方差值缩小1000倍,灰度熵值缩小3倍进行绘制)。




图6 House 图像分块

Fig.6 House image block

4.2 重构效果仿真结果分析

表3列出了本文所提算法与BCS-SAMP算法、灰度熵算法在整体采样率 M/N 分别取0.3, 0.4和0.5的情况下图像的峰值信噪比。

表3 各方案下图像 PSNR 的对比

Table 3 Comparison of image PSNR of each scheme

图像	方案	整体采样率					
		0.3		0.4		0.5	
		全局	局部	全局	局部	全局	局部
House	BCS-SAMP	23.8	26.4	24.3	27.0	24.9	29.6
	灰度熵	24.1	28.7	25.0	29.3	25.7	31.3
	本文方案	24.7	30.2	25.2	30.7	25.8	32.6
Lena	BCS-SAMP	29.5	26.2	30.5	26.8	31.4	27.6
	灰度熵	30.0	26.9	30.9	27.9	31.8	28.4
	本文方案	30.2	27.8	31.3	28.5	32.1	29.2
CT1	BCS-SAMP	18.1	13.9	18.5	14.1	19.1	14.3
	灰度熵	19.0	15.8	19.4	16.3	19.9	16.7
	本文方案	19.5	16.7	20.2	17.4	20.4	17.5
CT2	BCS-SAMP	15.2	14.2	15.7	14.8	16.8	15.6
	灰度熵	15.7	15.4	16.6	16.2	17.6	17.5
	本文方案	16.0	16.0	17.3	16.8	18.3	18.1

表 3 中,全局表示的是图像整体的 PSNR 值,局部是图像中的一个子块(见图 8),原图上所标注的块即局部对比块,选取依据是所选块的熵值在各图像子块中的值最大。

由表 3 可知,对于全局对比下的重构图像,本文所提算法较 BCS-SAMP 算法的峰值信噪比提升了 0.7~1.7 dB,较灰度熵算法提升了 0.1~0.8 dB;在局部对比下,本文所提算法较 BCS-SAMP 算法的峰值信噪比提升了 1.6~3.8 dB,较灰度熵算法提升了 0.6~1.5 dB。从 4 幅灰度图像间的对比来看,峰值信噪比提升最多的是 House 图像,当 M/N 取 0.3 时,局部峰值信噪比较 BCS-SAMP 算法提升了 3.8 dB,较灰

度熵算法提升了 1.5 dB;House 图像重构后比 Lena 图像的峰值信噪比提升了 1.1 dB~2.2 dB,主要原因为 Lena 图像比较平坦,子块之间的采样率差别不是很明显。CT1 图像局部峰值信噪比较 BCS-SAMP 算法提升了 2.8~3.3 dB,较灰度熵算法提升了 0.8~1.1 dB;CT2 图像局部峰值信噪比较 BCS-SAMP 算法提升了 1.8~2.5 dB,较灰度熵算法提升 0.6 dB。由对比可知,CT1 图像的重构效果优于 CT2 图像,主要原因为 CT1 图像灰度对比明显,纹理复杂度相对较小,而 CT2 图像包含的内容较为丰富,但灰度变化不明显,子块之间的采样率差别相对较小。




图 8 测试图片视觉效果的对

Fig. 8 Comparison of visual effects of test images

从表 3 中还可以看出,图像重构后局部质量比全局质量提高更多。造成这一现象的原因是,本文所提的算法在采样率自适应分配时,给予纹理复杂的子块较大的采样率,提高了原本重构质量较差的子块的重构效果;相应地,降低了原本重构质量较好的子块的重构效果,使整体的重构效果得到了均衡。

进一步,通过重构后的图像对比,本文模型在重构后的块效应得到了明显的降低,较其他两种算法,图像纹理信息重构得更加完整,尤其对于纹理较为复杂的局部子块而言,重构效果得到明显提高,如 Lena 头发上的线条和 CT 中局部暗影线,这在医疗成像领域中具有重大意义,在医疗影像中有很好的应用前景。

结束语 本文深入学习和研究了分块压缩感知理论,分析了现有自适应采样算法的不足,提出了一种基于灰度共生矩阵的图像自适应分块压缩感知方法,利用灰度共生矩阵衡量图像纹理复杂度,优化自适应采样率分配,有效降低了块效应,且能更好地保留图像的纹理细节信息。基于自然图像和医疗图像等不同种类的测试数据进行仿真,大量的对比实验和结果分析表明,与 BCS-SAMP 算法、灰度熵算法相比,无论是全局图像还是局部图像,本文算法都有明显的优势,且局部

图像的效果更为明显,这在医疗影像、卫星云图等领域有很大的应用价值。

参考文献

- [1] CANDS E J. Compressive sampling[C]//Proceedings of the International Congress of Mathematicians. Madrid, Spain, 2006: 1433-1452.
- [2] DONOHO D L. Compressed sensing[J]. IEEE Trans on Information Theory, 2006, 52(4): 1289-1306.
- [3] DONOHO D L, TSAIG Y. Extensions of compressed sensing [J]. Signal Processing, 2006, 86(3): 533-548.
- [4] CANDS E J, WAKIN M B. An Introduction to Compressive Sampling[J]. IEEE Signal Process, 2008, 25(2): 21-30.
- [5] LI L C, LI D J. Sparse array SAR 3D imaging for continuous scene based on compressed sensing[J]. Journal of Electronics & Information Technology, 2014, 36(9): 2166-2172.
- [6] LUSTIG M, DONOHO D L, SANTOS J M, et al. Compressed sensing MRI[J]. IEEE Signal Processing Magazine, 2008, 25(2): 72-82.
- [7] GAN L. Block compressed sensing of natural images[C]// 2007 15th International Conference on Digital Signal Processing. Cardiff, UK: IEEE, 2007: 403-406.

- [8] YU G F, ZOU S W, QIN C. Application Research of Image Gray Information in Automatic Separation of Coal and Gangue[J]. *Industry and Mine Automation*, 2012, 38(2): 36-39. (in Chinese)
于国防, 邹士威, 秦聪. 图像灰度信息在煤矸石自动分选中的应用[J]. *工矿自动化*, 2012, 38(2): 36-39.
- [9] ZHANG F Z, ZHAO R Z, CEN Y G, et al. Adaptive Sparse Recovery Based on Difference Algorithm [J]. *Journal of Computer-Aided Design and Computer Graphics*, 2015, 27(6): 1047-1052. (in Chinese)
张凤珍, 赵瑞珍, 岑翼刚, 等. 基于差分的稀疏度自适应重构算法[J]. *计算机辅助设计与图形学学报*, 2015, 27(6): 1047-1052.
- [10] WANG Y, ZHOU C, XIONG C Y, et al. Enhanced Block Compressed Sensing of Images Based on Total Variation Using Texture Information[J]. *Computer Science*, 2016, 43(2): 307-315. (in Chinese)
王玥, 周城, 熊承义, 等. 基于纹理自适应全变分滤波的图像分块压缩感知优化算法[J]. *计算机科学*, 2016, 43(2): 307-315.
- [11] CAI X, XIE Z G, HUANG H W, et al. An Adaptive Reconstruction Algorithm for Image Block Compressed Sensing Under Low Sampling Rate [J]. *Journal of Chinese Mini-Micro Computer Systems*, 2016, 37(3): 612-616. (in Chinese)
蔡旭, 谢正光, 黄宏伟, 等. 一种自适应低采样率图像分块压缩感知算法[J]. *小型微型计算机系统*, 2016, 37(3): 612-616.
- [12] LI Z T, XIE J X, ZHU G M, et al. Block-Based Projection Matrix Design for Compressed Sensing[J]. *Chinese Journal of Electronics*, 2016, 25(3): 551-555.
- [13] GAO C C, HUI X W. GLCM-Based Texture Feature Extraction [J]. *Computer Systems and Applications*, 2010, 19(6): 195-198. (in Chinese)
高程程, 惠晓威. 基于灰度共生矩阵的纹理特征提取[J]. *计算机系统应用*, 2010, 19(6): 195-198.
- [14] FENG J H, YANG Y J. Research on Extracting Texture Feature Image Based on Co-occurrence Matrix[J]. *Beijing Surveying and Mapping*, 2007(3): 19-22. (in Chinese)
冯建辉, 杨玉静. 基于灰度共生矩阵提取纹理特征图像的研究[J]. *北京测绘*, 2007(3): 19-22.
- [15] WANG R F, JIAO L C, LIU F, et al. Block-Based Adaptive Compressed Sensing of Image Using Texture Information [J]. *Electronic Journal*, 2013, 41(8): 1506-1514. (in Chinese)
王蓉芳, 焦李成, 刘芳, 等. 利用纹理信息的图像分块自适应压缩感知[J]. *电子学报*, 2013, 41(8): 1506-1514.
- [16] LANG L Y, WANG Y, LI S Q. Image Reconstruction Based on Improved OMP Algorithm in Compressive Sensing [J]. *Video Engineering*, 2015, 39(6): 8-12. (in Chinese)
郎利影, 王勇, 李思骞. 基于压缩感知 OMP 改进算法的图像重构[J]. *电视技术*, 2015, 39(6): 8-12.
- (上接第 263 页)
- [21] ZHU W, LIANG S, WEI Y, et al. Saliency optimization from robust background detection[C]// *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. Columbus, USA: IEEE, 2014: 2814-2821.
- [22] LU S, MAHADEVAN V, VASCONCELOS N. Learning Optimal Seeds for Diffusion-Based Salient Object Detection [C]// *Computer Vision and Pattern Recognition*. IEEE, 2014: 2790-2797.
- [23] ACHANTA R, SHAJI A, SMITH K, et al. Slic superpixels compared to state-of-the-art superpixel methods [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2012, 34(11): 2274-2281.
- [24] ZHANG Q, SHEN X, XU L, et al. Rolling Guidance Filter [M]// *Computer Vision-ECCV 2014*. 2014: 815-830.
- [25] TIBSHIRANI R. Regression shrinkage and selection via the lasso: A retrospective[J]. *Journal of the Royal Statistical Society*, 2011, 73(3): 267-288.
- [26] LU S, MAHADEVAN V, VASCONCELOS N. Learning Optimal Seeds for Diffusion-Based Salient Object Detection [C]// *Computer Vision and Pattern Recognition*. IEEE, 2014: 2790-2797.
- [27] MARGOLIN R, TAL A, ZELNIK-MANOR L. What makes a patch distinct? [C]// *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. Portland, USA, 2013: 1139-1146.
- [28] SHEN X, WU Y. A Unified Approach to Salient Object Detection via Low Rank Matrix Recovery[J]. *Computer Vision and Pattern Recognition*, 2012, 23(10): 853-860.
- [29] YAN J, ZHU M, LIU H, et al. Visual Saliency Detection via Sparse Pursuit [J]. *IEEE Signal Processing Letters*, 2010, 17(8): 739-742.
- [30] QIN Y, LU H, XU Y, et al. Saliency detection via cellular automata[C]// *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. Boston, USA, 2015: 111-119.
- [31] KIM T H, LEE K M, SANG U L. Learning Full Pairwise Affinities for Spectral Segmentation[J]. *IEEE Transactions on Pattern Analysis & Machine Intelligence*, 2013, 35(7): 1690-1703.
- [32] ACHANTA R, HEMAMI S, ESTRADA F, et al. Frequency-tuned salient region detection[C]// *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. Miami, USA: IEEE, 2009: 1597-1604.
- [33] LIU T, SUN J, ZHENG N, et al. Learning to detect a salient object[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2011, 33(2): 353-367.
- [34] ALPERT S, GALUN M, BRANDT A, et al. Image segmentation by probabilistic bottom-up aggregation and cue integration [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2012, 34(2): 315-327.
- [35] LI G, YU Y. Visual Saliency Detection Based on Multiscale Deep CNN Features[J]. *IEEE Transactions on Image Processing A Publication of the IEEE Signal Processing Society*, 2016, 25(11): 5012-5024.
- [36] LI G, YU Y. Deep Contrast Learning for Salient Object Detection [C]// *Computer Vision and Pattern Recognition*. IEEE, 2016: 478-487.
- [37] LIU N, HAN J. DHSNet: Deep Hierarchical Saliency Network for Salient Object Detection [C]// *Computer Vision and Pattern Recognition*. IEEE, 2016: 678-686.
- [38] ZHANG P, WANG D, LU H, et al. Amulet: Aggregating Multi-level Convolutional Features for Salient Object Detection [J]. eprint arXiv:1708.02001.
- [39] GOPALAKRISHNAN V, HU Y, RAJAN D. Random Walks on Graphs for Salient Object Detection in Images [J]. *IEEE Transactions on Image Processing A Publication of the IEEE Signal Processing Society*, 2010, 19(12): 3232-3242.
- [40] YANG C, ZHANG L, LU H, et al. Saliency Detection via Graph-Based Manifold Ranking [C]// *Computer Vision and Pattern Recognition*. IEEE, 2013: 3166-3173.