

基于局部和非局部正则化的图像压缩感知

朱俊¹ 陈长伟² 苏守宝¹ 常子楠¹

(1. 金陵科技学院计算机工程学院, 南京, 211169; 2. 南京晓庄学院信息工程学院, 南京, 211175)

摘要: 基于低秩正则化的非局部低秩约束(Nonlocal low-rank regularization, NLR)算法利用相似块的结构稀疏性, 获得了目前最好的重构结果。但是它仅仅利用了图像的非局部信息, 忽略了图像像素间的局部信息, 不能有效地重建图像的边缘, 同时 Logdet 函数不能很好地替代矩阵秩, 因为它跟真实解之间存在着不可忽视的差距。因此, 本文提出了一种基于局部和非局部正则化的压缩感知图像重建方法, 同时考虑图像的非局部低秩性和图像像素的局部稀疏梯度性。选择利用 Schatten-p 范数来替代矩阵秩, 同时选择交替方向乘子算法求解产生的非凸优化问题。实验结果表明, 与传统的稀疏性先验重建算法和 NLR 算法相比, 本文算法能够获得更高的图像重构质量。

关键词: 压缩感知; 总变差; 低秩; 交替方向乘子算法

中图分类号: TN911.73 **文献标志码:** A

Image Compressed Sensing Based on Local and Nonlocal Regularizations

Zhu Jun¹, Chen Changwei², Su Shoubao¹, Chang Zinan¹

(1. College of Computer Engineering, Jinling Institute of Technology, Nanjing, 211169, China; 2. Information Engineering Institute, Nanjing Xiaozhuang University, Nanjing, 211175, China)

Abstract: Nonlocal low-rank regularization based approach (NLR) shows the state-of-the-art performance in compressive sensing (CS) recovery which exploits both structured sparsity of similar patches. However, it cannot efficiently preserve the edges because it only exploits the nonlocal regularization and ignores the relationship between pixels. Meanwhile, Logdet function that is used in NLR cannot well approximate the rank, because it is a fixed function and the optimization results obtained by this function essentially deviate from the real solution. A local and nonlocal regularization based CS approach is proposed toward exploiting the local sparse-gradient property of image and low-rank property of similar patches. Schatten-p norm is used as a better non-convex surrogate for the rank function. In addition, the alternating direction method of multipliers method (ADMM) is utilized to solve the resulting nonconvex optimization problem. Experimental results demonstrate that the proposed method outperforms existing state-of-the-art CS algorithms for image recovery.

Key words: compressive sensing (CS); total variation; low-rank; alternating direction method of multipliers

引言

多年来,信号采样的理论基础一直是著名的 Nyquist 采样定理。该定理指出,只有采样率达到信号带宽的两倍以上,才能由采样信号精确重构原始信号。然而,对于超宽带通信和信号处理、核磁共振成像、雷达遥感成像与传感器网络等实际应用,依据该定理采样,会带来庞大的采样数据,给后期的传输和存储带来很大的压力。压缩感知(Compressive sensing, CS)^[1-2]是一种新的信号获取理论,该理论突破了传统的奈奎斯特采样定理,融合了传统的采样与压缩过程,能以远低于传统采样定理需求的采样数目重构原始信号。该理论受到了国内外广大学者的高度关注,成为图像处理领域的热门研究方向,并且已经在压缩成像、空间探测和医学成像等诸多领域得到了广泛的运用。CS 理论通过少量的线性投影直接编码图像信号中包含绝大部分信息的重要分量,实现对原始图像的采样、压缩以及重构。传统的 CS 图像重建算法利用图像在某一变换域的稀疏性先验,因此选择合适的先验知识对于压缩感知图像重建结果至关重要。对于这类算法,图像的重建精度受限于稀疏变换域的选择,图像的稀疏度越高,图像的重建质量就越高。稀疏变换域通常选择为离散余弦变换(Discrete cosine transform, DCT)^[3], Wavelets^[4]以及梯度域(Total variation, TV)^[5-8]。

图像作为一种特殊的二维信号,一般存在大量的重复模式,具有非局部自相似性,处于不同位置的图像块往往表现出很强的非局部相似性。近年来,许多算法利用各种复杂的稀疏性形式挖掘系数间的高阶相关性,包括非局部稀疏^[8-11]和结构稀疏^[12-14],实验结果表明这些算法能够显著提高重建图像质量。Zhang 等^[15]提出以非局部相似先验构成冗余字典的图像稀疏形式,在图像复原领域取得了很好的效果。董伟生等^[11]提出了一种利用图像结构稀疏性的基于非局部低秩约束的 CS 图像重建算法(Non-local low-rank regularization, NLR),通过对相似图像块的非局部操作,构造具有低秩属性的群组矩阵,通过最小化群组矩阵的秩和选择 Logdet 替代矩阵的秩函数,实现图像的重建。该方法获得了当前最好的图像重构结果。但是它仅仅利用了图像的非局部信息,忽略了图像像素间的局部信息,不能有效地重建图像的边缘,同时,Logdet 函数并不能很好地替代矩阵的秩,因为它跟真实解之间存在着不可忽视的差距。针对上述 NLR 算法的不足,本文提出了一种基于局部和非局部正则化的图像压缩感知方法,同时考虑图像的非局部低秩性和局部梯度稀疏性,能够更好地保留图像的纹理边缘信息,并且重构后的图像具有较好的平滑性。另外,本文选取 Schatten-p 范数^[16-17]近似估计矩阵的秩,并选择交替方向乘子算法解决非凸优化问题。实验结果表明,本文算法可以显著提高图像重构质量,并且有更佳的视觉效果,峰值信噪比可以提高 0.9 dB 以上。

1 基于局部和非局部正则化的图像压缩感知重建算法

1.1 模型构造

假设图像 $x \in \mathbf{R}^n$, 测量矩阵定义为 $\Phi \in \mathbf{R}^{m \times n}$ ($m \ll n$), $y \in \mathbf{R}^m$, CS 力求从少量的测量值 $y \in \mathbf{R}^m$ 恢复图像 x , 满足 $y = \Phi x$ 。因为 $m \ll n$, 矩阵 Φ 是秩亏的, 存在无数多解 $x \in \mathbf{R}^n$ 满足可以产生相同的测量值 y 。为了重构出图像, 需要利用图像的先验知识。本文提出了一种基于局部和非局部正则化的图像压缩感知方法, 同时考虑图像的非局部低秩性和图像像素的局部稀疏梯度属性, 重建优化模型为

$$(x, L_i) = \underset{x, L_i}{\operatorname{argmin}} \|x\|_{\text{TV}} + \eta \sum_i \{ \|P_i x - L_i\|_{\text{F}}^2 + \lambda \operatorname{rank}(L_i) \} \quad \text{s. t.} \quad y = \Phi x \quad (1)$$

式中: $P_i x = [P_{i1} x, P_{i2} x, \dots, P_{ih} x]$ 为群组矩阵 $X_i \in \mathbf{C}^{d \times h}$, 它是由图像块 $x_j \in \mathbf{R}^d$ 的 h 个相似块组成, 并且具有低秩属性, λ 和 η 为正则化参数。本文利用 l_1 范数的总变差 $\|x\|_{\text{TV}} = \|D_1 x\|_1 + \|D_2 x\|_1$ 约束局部

信息,其中 \mathbf{D}_1 和 \mathbf{D}_2 分别为横轴和纵轴的有限差分算子。另外,选取 Schatten- p 范数作为矩阵秩的替代函数,因此式(1)可以重新定义为

$$(\mathbf{x}, \mathbf{L}_i) = \operatorname{argmin}_{\mathbf{x}, \mathbf{L}_i} \|\mathbf{D}_1 \mathbf{x}\|_1 + \|\mathbf{D}_2 \mathbf{x}\|_1 + \eta \sum_i \{ \|\mathbf{X}_i - \mathbf{L}_i\|_{\mathbb{F}}^2 + \lambda \|\mathbf{L}_i\|_{S_p}^p \} \quad \text{s. t.} \quad \mathbf{y} = \Phi \mathbf{x} \quad (2)$$

1.2 数值求解算法

由于式(2)很难直接求解,因此利用交替方向乘子算法将上述复杂问题转化成简单子问题,然后分别求解这些子问题。添加辅助变量 \mathbf{g}_1 和 \mathbf{g}_2 ,式(2)重新定义为

$$(\mathbf{x}, \mathbf{L}_i, \mathbf{g}_s) = \operatorname{argmin}_{\mathbf{x}, \mathbf{L}_i, \mathbf{g}_s} \|\mathbf{g}_1\|_1 + \|\mathbf{g}_2\|_1 + \eta \sum_i \{ \|\mathbf{P}_i \mathbf{x} - \mathbf{L}_i\|_{\mathbb{F}}^2 + \lambda \|\mathbf{L}_i\|_{S_p}^p \} \quad \text{s. t.} \quad \mathbf{y} = \Phi \mathbf{x}, \mathbf{g}_1 = \mathbf{D}_1 \mathbf{x}, \mathbf{g}_2 = \mathbf{D}_2 \mathbf{x} \quad (3)$$

引入拉格朗日乘子,上述约束问题等价于

$$(\mathbf{x}, \mathbf{L}_i, \mathbf{g}_s) = \operatorname{argmin}_{\mathbf{x}, \mathbf{L}_i, \mathbf{g}_s} \|\mathbf{g}_1\|_1 + \|\mathbf{g}_2\|_1 + \eta \sum_i \{ \|\mathbf{P}_i \mathbf{x} - \mathbf{L}_i\|_{\mathbb{F}}^2 + \lambda \|\mathbf{L}_i\|_{S_p}^p \} + \frac{\beta_1}{2} \left\| \Phi \mathbf{x} - \mathbf{y} + \frac{\mathbf{e}}{\beta_1} \right\|_2^2 + \frac{\beta_2}{2} \sum_{s=1}^2 \left\| \mathbf{D}_s \mathbf{x} - \mathbf{g}_s + \frac{\mathbf{b}_s}{\beta_2} \right\|_2^2 \quad (4)$$

式(4)的优化包含如下3个子问题,即

$$\mathbf{g}_s^{k+1} = \operatorname{argmin}_{\mathbf{g}_s} \|\mathbf{g}_1\|_1 + \|\mathbf{g}_2\|_1 + \frac{\beta_2}{2} \sum_{s=1}^2 \left\| \mathbf{D}_s \mathbf{x}^k - \mathbf{g}_s + \frac{\mathbf{b}_s}{\beta_2} \right\|_2^2 \quad (5)$$

$$\mathbf{L}_i^{k+1} = \operatorname{argmin}_{\mathbf{L}_i} \|\mathbf{P}_i \mathbf{x}^k - \mathbf{L}_i\|_{\mathbb{F}}^2 + \lambda \|\mathbf{L}_i\|_{S_p}^p \quad (6)$$

$$\mathbf{x}^{k+1} = \operatorname{argmin}_{\mathbf{x}} \eta \sum_i \|\mathbf{P}_i \mathbf{x} - \mathbf{L}_i^{k+1}\|_{\mathbb{F}}^2 + \frac{\beta_1}{2} \left\| \Phi \mathbf{x} - \mathbf{y} + \frac{\mathbf{e}}{\beta_1} \right\|_2^2 + \frac{\beta_2}{2} \sum_{s=1}^2 \left\| \mathbf{D}_s \mathbf{x} - \mathbf{g}_s^{k+1} + \frac{\mathbf{b}_s}{\beta_2} \right\|_2^2 \quad (7)$$

1.2.1 \mathbf{g}_s 子问题

对于一个典型的 l_1 范数最小化问题 $\min_{\mathbf{a}} \|\mathbf{a}\|_1 + \frac{\gamma}{2} \|\mathbf{a} - \mathbf{b}\|_2^2$,它存在着解析解 $\mathbf{a} = \mathbf{S}_{\frac{1}{\gamma}}(\mathbf{b}) = \max\left\{\text{abs}(\mathbf{b}) - \frac{1}{\gamma}, 0\right\} \times \text{sign}(\mathbf{b})$ 。相应地,梯度 \mathbf{g}_1 和 \mathbf{g}_2 更新公式为

$$\mathbf{g}_1^{k+1} = \mathbf{S}_{\frac{1}{\beta_2}}\left(\mathbf{D}_1 \mathbf{x}^k + \frac{\mathbf{b}_1}{\beta_2}\right) \quad (8)$$

$$\mathbf{g}_2^{k+1} = \mathbf{S}_{\frac{1}{\beta_2}}\left(\mathbf{D}_2 \mathbf{x}^k + \frac{\mathbf{b}_2}{\beta_2}\right) \quad (9)$$

1.2.2 \mathbf{L}_i 子问题

由于 $\|\mathbf{L}_i\|_{S_p}^p$ 等价于所有奇异值的 p 次方的和,因此变量 \mathbf{L}_i 的估计通过优化问题求解为

$$\mathbf{L}_i^{k+1} = \operatorname{argmin}_{\mathbf{L}_i} \|\mathbf{P}_i \mathbf{x}^k - \mathbf{L}_i\|_{\mathbb{F}}^2 + \lambda \sum_{j=1}^{n_i} \delta_j^p(\mathbf{L}_i) \quad (10)$$

式中: n_i 为矩阵 \mathbf{L}_i 中奇异值的个数, $\delta_j(\mathbf{L}_i)$ 为矩阵 \mathbf{L}_i 中第 j 个奇异值。为了简便,用 δ_j 表示 $\delta_j(\mathbf{L}_i)$ 。虽然式(10)非凸,但是可以通过如下的局部最小化方法去有效求解(算法1)。令 $f(\boldsymbol{\delta}) = \sum_{j=1}^{n_i} \delta_j^p$,它可以由一阶泰勒展开式近似表示为

$$f(\boldsymbol{\delta}) = f(\boldsymbol{\delta}') + \left(\sum_{j=1}^{n_i} \frac{1}{\boldsymbol{\delta}'_j + 1} \cdot \boldsymbol{\delta} - \boldsymbol{\delta}' \right) \quad (11)$$

$\boldsymbol{\delta}'$ 为第 t 次迭代获得的结果,省略常数项得

$$\mathbf{L}_i^{k+1, t+1} = \operatorname{argmin}_{\mathbf{L}_i} \|\mathbf{P}_i \mathbf{x}^k - \mathbf{L}_i\|_{\mathbb{F}}^2 + \lambda \sum_{j=1}^{n_i} p(\boldsymbol{\delta}_j^{k+1, t})^{p-1} \boldsymbol{\delta}_j \quad (12)$$

式(12)可以通过奇异值阈值(Singular value thresholding, SVT)算法求解,令 $\mathbf{U}\Sigma\mathbf{V}^T$ 为 $\mathbf{P}_i\mathbf{x}^k$ 的奇异值分解, $\mathbf{w}_j^{k+1,t} = \mathbf{p}(\delta_j^{k+1,t})^{p-1}$, 则

$$\mathbf{L}_i^{k+1,t+1} = \text{prox}_{\mathbf{w}_j^{k+1,t}, \frac{\lambda}{2}} \mathbf{P}_i\mathbf{x}^k = \mathbf{U} \max \left\{ \left(\Sigma - \frac{\lambda}{2} \text{diag}(\mathbf{w}_j^{k+1,t}) \right), 0 \right\} \mathbf{V}^T \quad (13)$$

1.2.3 \mathbf{x} 子问题

获得所有辅助变量的估计值之后,图像 \mathbf{x} 重建问题转化为

$$\gamma \mathbf{P}_i^T (\mathbf{P}_i\mathbf{x} - \mathbf{L}_i^{k+1}) + \frac{\beta_1}{2} \Phi^T \left(\Phi\mathbf{x} - \mathbf{y} + \frac{\mathbf{e}}{\beta_1} \right) + \frac{\beta_2}{2} \sum_{s=1}^2 \mathbf{D}_s^T \left(\mathbf{D}_s\mathbf{x} - \mathbf{g}_s^{k+1} + \frac{\mathbf{b}_s}{\beta_2} \right) = 0 \quad (14)$$

对拉格朗日函数 $R(\mathbf{x}) = \gamma \sum_i \|\mathbf{X}_i - \mathbf{L}_i^{k+1}\|_F^2 + \frac{\beta_1}{2} \left\| \Phi\mathbf{x} - \mathbf{y} + \frac{\mathbf{e}}{\beta_1} \right\|_2^2 + \frac{\beta_2}{2} \sum_{s=1}^2 \left\| \mathbf{D}_s\mathbf{x} - \mathbf{g}_s^{k+1} + \frac{\mathbf{b}_s}{\beta_2} \right\|_2^2$ 求解 \mathbf{x} 的导数,并令导数为 0,可得

$$\gamma \mathbf{P}_i^T (\mathbf{P}_i\mathbf{x} - \mathbf{L}_i^{k+1}) + \frac{\beta_1}{2} \Phi^T \left(\mathbf{y} - \Phi\mathbf{x} + \frac{\mathbf{e}}{\beta_1} \right) + \frac{\beta_2}{2} \sum_{s=1}^2 \mathbf{D}_s^T \left(\mathbf{D}_s\mathbf{x} - \mathbf{g}_s^{k+1} + \frac{\mathbf{b}_s}{\beta_2} \right) = 0 \quad (15)$$

由于 $\mathbf{D}_1^T\mathbf{D}_1, \mathbf{D}_2^T\mathbf{D}_2$ 是循环矩阵,它们分别和 \mathbf{x} 相乘等价于对 \mathbf{x} 做卷积,因此可以用快速傅里叶变换求解式(14)获得图像估计值 \mathbf{x}^{k+1} 。算法 1 流程总结如下。

输入:测量矩阵 Φ ,测量向量 \mathbf{y} ;

初始化: $\mathbf{x}^0 = \mathbf{g}^0 = \mathbf{g}_1^0 = \mathbf{b}_1^0 = \mathbf{b}_2^0 = \mathbf{e}^0 = \text{zeros}(n, 1), \mathbf{L}_i = \text{zeros}(d, h)$ 。

主迭代: While 图像 \mathbf{x} 没有收敛

(a) 利用估计图像 \mathbf{x}^k 对每个图像块 \mathbf{x}_i^k 计算提取矩阵 \mathbf{P}_i ;

(b) 通过式(8,9)估计 \mathbf{g}_s ;

(c) 通过式(12)估计 \mathbf{L}_i ;

(d) 通过式(14)估计 \mathbf{x} ;

(e) 更新拉格朗日乘子:

$$\mathbf{b}_s^{k+1} \leftarrow \mathbf{b}_s^k - \tau\beta_2 (\mathbf{g}_s^{k+1} - \mathbf{D}_s\mathbf{x}^{k+1});$$

$$\mathbf{e}^{k+1} \leftarrow \mathbf{e}^k - \tau\beta_1 (\mathbf{y} - \Phi\mathbf{x}^{k+1})$$

$$k = k + 1$$

End while

输出 \mathbf{x}

2 仿真实验

选取 6 幅图像作为测试图像(如图 1),图像大小均为 256 像素 \times 256 像素。方法中参数设置如下:采样数目比值 m/n ;群组矩阵的大小为 36×45 ,图像块的维数为 36,每个群组中相似块的数目为 45;沿着横轴和纵轴方向每隔 5 个像素点选取重叠参考块 $\mathbf{x}_j \in \mathbf{R}^d$;用峰值信噪比(Peak signal to noise ration, PSNR)评价不同方法。在仿真试验中,算法分别与 TV 方法^[18]、基于三维块匹配算法(Block matching 3-transform, BM3D)的 CS(BM3D)方法^[19]和 NLR^[11]进行比较。TV 方法利用梯度域的稀疏性进行图像重建;BM3D 是一种基于块匹配三维变换迭代收缩的图像重构算法,它是目前已公开发表文献中去噪性能最好的算法之一;NLR 方法利用图像非局部低秩属性,获得了当前文献中最好的重建结果。上述这些方法的源代码都可以从作者主页上下载。为了公平比较这些方法,调整每种算法的参数使得它们获得最优重构结果。本文方法测试 10 次取平均值。6 幅测试图像在采样率分别为 2.5%, 5%, 10%, 15% 和 20% 的比较结果如表 1 所示。由表 1 可以看出,

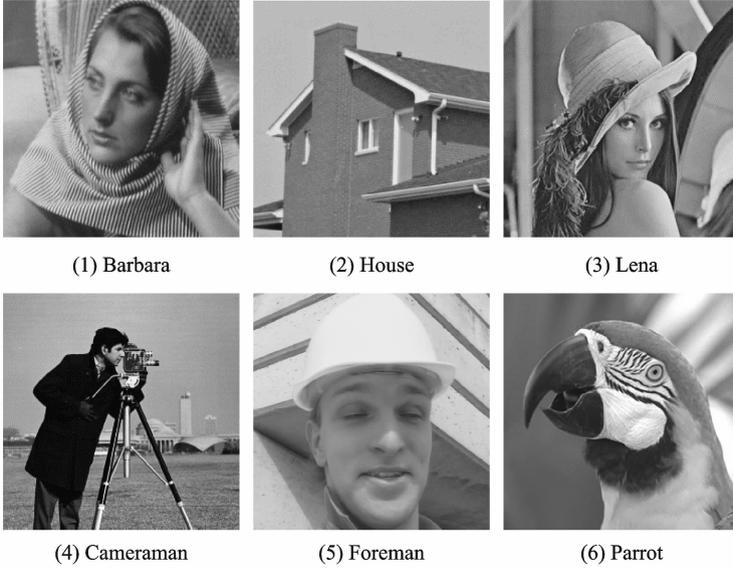


图 1 6 幅测试图像

Fig. 1 Six test images

表 1 不同算法在不同图像上的峰值信噪比

Tab. 1 PSNR results of different algorithms on different images dB

图像	算法	采样率/%				
		2.5	5	10	15	20
Barbara	TV	21.56	22.79	24.78	26.72	28.87
	BM3D	22.43	24.34	28.99	33.29	36.07
	NLR	24.25	29.79	35.47	38.17	40.00
	本文	24.91	30.78	36.72	39.65	41.68
House	TV	29.31	30.50	33.63	35.54	37.20
	BM3D	29.95	32.56	35.96	38.10	39.76
	NLR	32.43	34.80	38.39	40.62	42.49
	本文	33.02	34.88	39.35	41.80	43.88
Lena	TV	25.02	26.48	29.63	32.32	34.74
	BM3D	25.64	27.02	31.84	35.51	38.22
	NLR	26.84	30.69	35.75	38.95	41.38
	本文	27.38	32.56	37.18	41.24	43.63
Cameraman	TV	22.16	25.09	28.63	31.48	34.20
	BM3D	23.43	27.12	30.27	33.88	36.91
	NLR	24.72	28.36	32.30	36.10	39.16
	本文	26.17	29.63	33.86	38.01	41.17
Foreman	TV	30.21	32.50	36.02	38.34	40.49
	BM3D	31.02	33.10	36.85	39.00	40.73
	NLR	33.34	35.70	39.39	41.98	44.02
	本文	34.24	36.35	40.27	43.08	45.36
Parrot	TV	24.56	27.65	31.84	34.76	37.00
	BM3D	25.54	29.13	33.63	36.62	38.79
	NLR	28.97	32.18	36.56	39.56	41.44
	本文	30.19	33.42	37.97	41.01	43.10

(1)平均来说,NLR算法的重建性能要优于TV和BM3D方法;(2)本文算法同时考虑了图像的局部和非局部信息,获得了最高的PSNR值;(3)在测试图像Foreman上,仅利用2.5%采样数目的情况下,本文方法的PSNR值分别比TV,BM3D和NLR高3.85,2.99和0.90 dB。

为了直观比较各算法重建图像的视觉效果,图2,3给出了采样率为2.5%时,测试图像对应的重建结果。可以看出,TV方法难以重建复杂纹理信息,因为它仅仅利用了梯度域的稀疏性。BM3D在边缘部分的失真非常大,因为它仅利用随机逼近方法去重建测量值中未观测到的部分。相比之下,本文方法能够较好地保持原始图像的局部结构特征,而且还能很好地处理复杂的纹理结构。

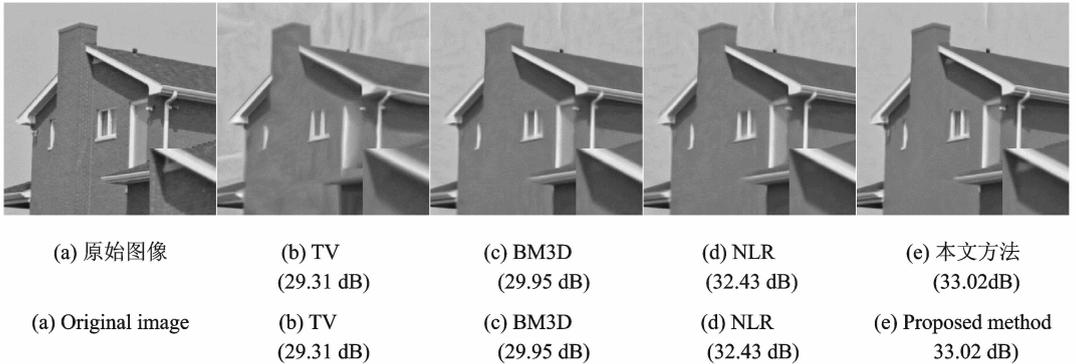


图2 图像House在2.5%采样率下的重建结果

Fig. 2 CS recovered House images with 2.5% measurements

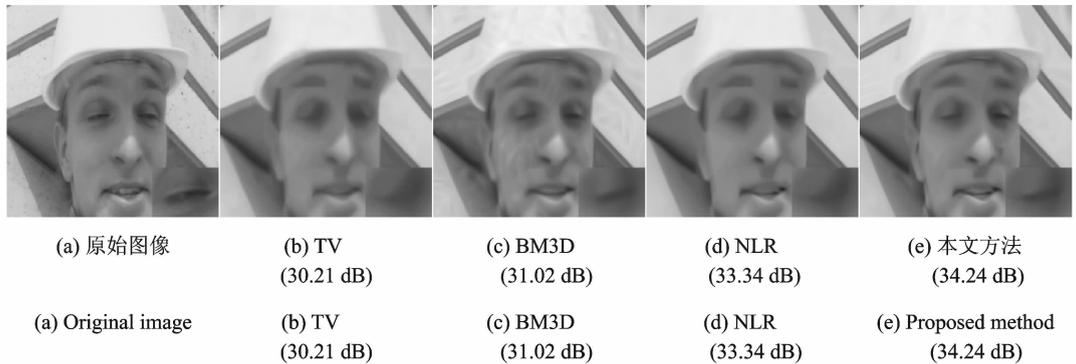


图3 图像Foreman的重建结果

Fig. 3 CS recovered Foreman images with 2.5% measurements

3 局部和非局部正则化的贡献分析

分别比较仅利用梯度稀疏性的TV算法、仅利用非局部低秩性的NLR算法以及同时挖掘局部和非局部信息的本文算法,增长-1的结果是本文算法和TV算法之差,对应非局部正则化的贡献;增长-2是本文算法与NLR算法之差,对应局部正则化的贡献。对比结果如表2所示,实验结果表明,局部和非局部正则化对于图像重建都有作用,两者缺一不可。

表 2 局部和非局部正则化的贡献分析

Tab. 2 Contribution analysis of local and nonlocal regularizations dB

图像	算法	采样率/%				
		2.5	5	10	15	20
Barbara	TV	21.56	22.79	24.78	26.72	28.87
	NLR	24.25	29.79	35.47	38.17	40.00
	本文	24.91	30.78	36.72	39.65	41.68
House	TV	29.31	30.50	33.63	35.54	37.20
	NLR	32.43	34.80	38.39	40.62	42.49
	本文	33.02	34.88	39.35	41.80	43.88
Lena	TV	25.02	26.48	29.63	32.32	34.74
	NLR	26.84	30.69	35.75	38.95	41.38
	Ours	27.38	32.56	37.18	41.24	43.63
Cameraman	TV	22.16	25.09	28.63	31.48	34.20
	NLR	24.72	28.36	32.30	36.10	39.16
	本文	26.17	29.63	33.86	38.01	41.17
Foreman	TV	30.21	32.50	36.02	38.34	40.49
	NLR	33.34	35.70	39.39	41.98	44.02
	本文	34.24	36.35	40.27	43.08	45.36
Parrots	TV	24.56	27.65	31.84	34.76	37.00
	NLR	28.97	32.18	36.56	39.56	41.44
	本文	30.19	33.42	37.97	41.01	43.10
Average	TV	25.47	27.50	30.76	33.19	35.42
	NLR	26.34	28.88	32.92	36.07	38.41
	Ours	29.32	32.94	37.56	40.80	43.14
增长-1		3.85	5.44	6.81	7.61	7.72
增长-2		2.99	4.06	4.64	4.73	4.73

4 结束语

本文在利用图像低秩性的基础上,引入局部信息作为图像额外的补充信息,提出了基于局部和非局部正则化的压缩感知图像重建算法,同时挖掘局部梯度稀疏性和非局部低秩性,并采用交替方向乘法将多个正则项优化问题分解成多个简单的子问题,更高效地求解产生的非凸优化问题。实验结果表明,与传统的稀疏性先验重建算法和 NLR 算法相比,本文算法在客观指标 PSNR 和主观视觉效果方面都有显著的提高。

参考文献:

- [1] Donoho D L. Compressed sensing [J]. *IEEE Trans Inf Theory*, 2006,52(4):1289-1306.
- [2] Candès E J, Wakin M B. An introduction to compressive sampling[J]. *IEEE Signal Processing Magazine*, 2008,25(2):21-30.
- [3] Zhang J, Zhao D, Zhao C, et al. Compressed sensing recovery via collaborative sparsity[C]//Data Compression Conference (DCC). Snowbird, Utah, USA: IEEE, 2012;287-296.
- [4] He L, Carin L. Exploiting structure in wavelet-based Bayesian compressive sensing[J]. *IEEE Transactions on Signal Processing*, 2009,57(9):3488-3497.

- [5] Bioucas D J M, Figueiredo M A T. A new TwIST: Two-step iterative shrinkage/thresholding algorithms for image restoration[J]. IEEE Transactions on Image Processing, 2007,16(12):2992-3004.
- [6] Becker S, Bobin J, Candès E J. NESTA: A fast and accurate first-order method for sparse recovery [J]. SIAM Journal on Imaging Sciences, 2011,4(1):1-39.
- [7] Xu J, Ma J, Zhang D, et al. Improved total variation minimization method for compressive sensing by intra-prediction[J]. Signal Processing, 2012,92(11):2614-2623.
- [8] Bertalmio M, Caselles V, Rougé B, et al. TV based image restoration with local constraints[J]. Journal of Scientific Computing, 2003,19(1/2/3):95-122.
- [9] Buades A, Coll B, Morel J M. A review of image denoising algorithms with a new one [J]. Multiscale Modeling & Simulation, 2005,4(2):490-530.
- [10] Dabov K, Foi A, Katkovnik V, et al. Image denoising by sparse 3-D transform-domain collaborative filtering[J]. IEEE Transactions on Image Processing, 2007,16(8):2080-2095.
- [11] Dong W S, Shi G, Li X, et al. Compressive sensing via nonlocal low-rank regularization[J]. IEEE Transactions on Image Processing, 2014,23:3618-3632.
- [12] Dong W, Shi G, Li X, et al. Image reconstruction with locally adaptive sparsity and nonlocal robust regularization[J]. Signal Processing: Image Communication, 2012,27(10):1109-1122.
- [13] Mairal J, Bach F, Ponce J, et al. Non-local sparse models for image restoration[C]//IEEE International Conference on Computer Vision. Kyoto, Japan: IEEE, 2009:2272-2279.
- [14] Huang J, Zhang T, Metaxas D. Learning with structured sparsity[J]. The Journal of Machine Learning Research, 2011,12:3371-3412.
- [15] Zhang J, Zhao D, Gao W. Group-based sparse representation for image restoration[J]. IEEE Transactions on Image Processing, 2014,23(8):3336-3351.
- [16] Wang J, Wang M, Hu X, et al. Visual data denoising with a unified Schatten-p norm and l_q norm regularized principal component pursuit[J]. Pattern Recognition, 2015,48(10):3135-3144.
- [17] Feng L, Sun H, Sun Q, et al. Image compressive sensing via truncated Schatten-p norm regularization[J]. Signal Processing Image Communication, 2016,47:28-41.
- [18] Shu X, Ahuja N. Hybrid compressive sampling via a new total variation TV1[C]//European Conference on Computer Vision. Heraklion, Crete, Greece: [s. n.], 2010:393-404.
- [19] Egiazarian K, Foi A, Katkovnik V. Compressed sensing image reconstruction via recursive spatially adaptive filtering[C]//IEEE Int Conf Image Process. San Antonio, TX, USA: IEEE, 2007:549-552.

作者简介:



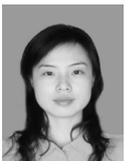
朱俊(1981-),男,博士,讲师,研究方向:模式识别与图像处理技术,E-mail:zhujun@jit.edu.cn.



陈长伟(1975-),男,高级实验师,研究方向:模式识别与图像处理技术。



苏守宝(1964-),男,教授,研究方向:智能计算与专家系统。



常子楠(1979-),女,副教授,研究方向:智能计算与网络信息安全。

