

# 一种自适应组稀疏表示的图像修复方法

甘 玲<sup>1</sup> 赵福超<sup>2</sup> 杨 梦<sup>2</sup>

(重庆邮电大学计算机科学与技术学院 重庆 400065)<sup>1</sup> (重庆邮电大学软件工程学院 重庆 400065)<sup>2</sup>

**摘 要** 针对组稀疏表示图像修复方法采用固定大小的图像块,致使修复结果中存在纹理和结构清晰性较差的问题,提出一种基于自适应组稀疏表示的图像修复方法。由于自然图像中纹理和结构信息不同,为了与原方法固定图像块大小的组结构作区分,首先提出一种自适应选取样本图像块大小的方法来构造自适应的组结构;然后以组为单位对其进行奇异值分解,获得该图像块组的自适应学习字典,并利用分裂伯格曼迭代(Split Bregman Iteration)算法求解目标代价函数;最后通过调整组中的图像块数量和迭代次数对每个组的自适应字典和稀疏编码系数进行更新,以获取较好的修复效果。实验结果表明,该方法不仅在峰值信噪比和特征相似性度量上有所提高,同时也提高了修复效率。

**关键词** 图像修复,稀疏表示,自适应学习字典,自适应组

**中图分类号** TP391 **文献标识码** A **DOI** 10.11896/j.issn.1002-137X.2018.08.049

## Self-adaptive Group Sparse Representation Method for Image Inpainting

GAN Ling<sup>1</sup> ZHAO Fu-chao<sup>2</sup> YANG Meng<sup>2</sup>

(College of Computer Science and Technology, Chongqing University of Posts and Telecommunications, Chongqing 400065, China)<sup>1</sup>

(School of Software Engineering, Chongqing University of Posts and Telecommunications, Chongqing 400065, China)<sup>2</sup>

**Abstract** This paper proposed an image inpainting algorithm based on self-adaptive group sparse representation to solve the problem that the texture and structure clarity are poor in the repair results. Due to the difference of texture and structure information in the natural images, in order to distinguish the group structure with the fixed image block size in original algorithm, firstly, a method is proposed to adaptively select the size of sample image patch to construct an adaptive group structure. Secondly, singular value decomposition is conducted in groups to obtain an adaptive learning dictionary of the image patch group, and the Split Bregman Iteration algorithm is used to solve the objective cost function. Finally, the adaptive dictionary and the sparse coding coefficient of each group are updated by adjusting the number of image patches and iterations in the group to get a better restoration effect. The experimental results show that this method not only improves the peak signal to noise ratio and feature similarity index of image, but also improves the repair efficiency.

**Keywords** Image inpainting, Sparse representation, Self-adaptive learning dictionary, Self-adaptive group

## 1 引言

21 世纪,信息科技高速发展,图像的像素越来越高。然而,图像在获取、传输、压缩和存储<sup>[1]</sup>的过程中易受到损坏,因此图像修复越来越重要。图像修复技术也是图像处理和计算机视觉领域的研究热点之一。

图像修复常用的方法主要有 3 类:基于偏微分方程(Partial Differential Equation, PDE)的修复方法、基于纹理结构(Texture Synthesis)的方法和基于稀疏表示理论的图像修复方法。基于偏微分方程的修复模型主要有 BSCB 修复模型<sup>[2]</sup>、整体变分(Total Variation, TV)模型<sup>[3]</sup>等方法。这些方法在修复小面积破损区域方面有较好的效果,但因为其采用

扩散的修复机制而未考虑修复顺序,当修复区域较大时,修复效果变差。基于纹理结构的方法主要包括基于图像分解技术的修复方法<sup>[4]</sup>和基于样本的纹理合成方法<sup>[5]</sup>。此类方法可用于大面积破损区域的修复,但是对于纹理特征不明显的图像的适用性较差。基于稀疏表示理论的图像修复方法主要分为固定基字典和学习型字典的方法<sup>[6]</sup>,后者能更好地适应图像数据,具有较强的自适应能力。其中,典型的学习型字典的算法有基于过完备字典稀疏分解的 K-SVD 修复算法<sup>[7]</sup>、非局部相似度的低秩修复方法<sup>[8]</sup>和非局部集中稀疏表示(NCSR)模型<sup>[9]</sup>等。上述基于稀疏表示的方法主要是基于单个图像块进行编码,并未充分考虑其他相关样本图像的相关信息,先验知识有限,并且忽略了相似块之间的关系,例如自相似性。相较

到稿日期:2017-06-05 返修日期:2017-08-21 本文受国家自然科学基金项目(61272195)资助。

甘 玲(1966—),女,教授,硕士生导师,主要研究方向为计算机图形图像等,E-mail:ganling@cqupt.edu.cn(通信作者);赵福超(1989—),男,硕士,主要研究方向为数字图像处理、智能信息处理;杨 梦(1992—),女,硕士,主要研究方向为数字图像处理、智能信息处理。

而言,张建等<sup>[10]</sup>提出的基于组稀疏表示的图像修复模型考虑到了图像相似块之间的关系,使得修复效果更具鲁棒性。但是,张建等<sup>[10]</sup>在考虑图像相似块之间的关系时,采用固定图像块大小的方法,致使修复结果中纹理和结构的清晰性较差。针对该问题,本文提出一种更为有效的图像修复方法,以提高修复的准确性和修复效率。

## 2 组稀疏表示模型

### 2.1 组结构的建立

考虑到自然图像的局部稀疏性和非局部自相似性,本文采用稀疏表示的单位是组,每个组都是由结构纹理相似的图像块矩阵构成的。组结构建立的模型如图 1 所示。




图 1 组结构建立的模型图

Fig. 1 Model diagram of group structure establishment

对于每个图像  $X$ , 截取  $i$  个图矢量  $X_k \in R^{B_s}$ , 其中  $k=1, 2, 3, \dots, i$ , 图中用小正方形表示在  $L \times L$  的训练窗口中利用欧氏距离搜索  $n$  个与  $X_k$  最佳匹配的样本图像块组成集合  $S_{X_k}$ , 集合  $S_{X_k}$  中的所有块被堆叠成大小为  $B_s \times n$  的矩阵, 由  $X_{G_k} \in R^{B_s \times n}$  表示, 集合  $S_{X_k}$  中的每个图像块作为矩阵的列, 即  $X_{G_k} = \{X_{G_k \otimes 1}, X_{G_k \otimes 2}, \dots, X_{G_k \otimes n}\}$ 。矩阵  $X_{G_k}$  中包含的所有结构类似的块即被命名为组。类似于传统的基于块的稀疏表示  $X_{G_k} = R_{G_k}(X)$ 。通过对所有组求平均, 从  $\{X_{G_k}\}$  中恢复整个图像  $X$  可表示为:

$$X = \sum_{k=1}^n R_{G_k}^T(x_{G_k}) / \sum_{k=1}^n R_{G_k}^T(1_{B_s \times n}) \quad (1)$$

其中,  $/$  代表两个向量的元素分割,  $1_{B_s \times n}$  是元素为 1、大小为  $B_s \times n$  的矩阵。

### 2.2 稀疏表示模型

给定字典  $D_{G_k} = [d_{G_k \otimes 1}, d_{G_k \otimes 2}, \dots, d_{G_k \otimes m}]$ , 其中每个元素  $d_{G_k \otimes i} \in R^{B_s \times n}$  是与组  $X_{G_k}$  同大小的矩阵,  $m$  是字典  $D_{G_k}$  中的元素个数。与基于块的稀疏表示中的字典不同,  $D_{G_k}$  的大小为  $(B_s \times n) \times m$ , 即  $D_{G_k} \in R^{(B_s \times n) \times m}$ 。

每个组  $X_{G_k}$  在  $D_{G_k}$  上的稀疏编码过程是寻找稀疏向量  $\alpha_{G_k} = [\alpha_{G_k \otimes 1}, \alpha_{G_k \otimes 2}, \dots, \alpha_{G_k \otimes m}]$ , 使得  $X_{G_k} = \sum_{i=1}^m \alpha_{G_k \otimes i} d_{G_k \otimes i}$ 。简单起见, 使用  $X_{G_k} = D_{G_k} \alpha_{G_k}$  代表上式, 然后将整个图像用组域中的稀疏码  $\{\alpha_{G_k}\}$  的集合进行稀疏表示。从稀疏码  $\{\alpha_{G_k}\}$  中重构图像  $X$ :

$$X = D_G \alpha_G = \sum_{k=1}^n R_{G_k}^T(D_{G_k} \alpha_{G_k}) / \sum_{k=1}^n R_{G_k}^T(1_{B_s \times n}) \quad (2)$$

其中,  $D_G$  表示所有  $D_{G_k}$  的级联,  $\alpha_G$  表示所有  $\alpha_{G_k}$  的级联。通过组稀疏表示(GSR)得出的基于正则化的图像恢复模型如下:

$$\hat{\alpha}_G = \arg \min_{\alpha_G} \frac{1}{2} \| HD_G \alpha_G - y \|_2^2 + \lambda \| \alpha_G \|_0 \quad (3)$$

对于  $\hat{\alpha}_G$ , 重构的图像可以表示为  $\hat{X} = D_G \hat{\alpha}_G$ 。其中,

$\| \cdot \|_0$  是  $l_0$  范数, 用于测量组域中  $G$  的真实稀疏度, 以提高图像修复的质量。

### 2.3 自适应组字典学习

为了使每个组  $X_{G_k}$  可以如实地由字典  $D_{G_k}$  表示, 并且尽可能地稀疏, 基于图像块组的自适应字典学习可以直接表示为:

$$\arg \min_{D_x, \{\alpha_{G_k}\}} \sum_{k=1}^n \| x_{G_k} - D_x \alpha_{G_k} \|_F^2 + \lambda \sum_{k=1}^n \| \alpha_{G_k} \|_p \quad (4)$$

其中,  $p$  取 0 或 1。式(4)是字典  $D_x$  和  $\{\alpha_{G_k}\}$  的联合优化问题, 通过交替优化  $D_x$  和  $\{\alpha_{G_k}\}$  进行求解。

因实际过程中在最优化工程中先估计出一个初始值  $r_{G_k}$ , 然后通过估计的  $r_{G_k}$  学习每个组  $X_{G_k}$  的自适应字典  $D_{G_k}$ , 最后对  $r_{G_k}$  进行奇异值分解, 即:

$$r_{G_k} = U_{G_k} \sum_{G_k} V_{G_k}^T = \sum_{i=1}^M \gamma_{r_{G_k \otimes i}} (u_{G_k \otimes i} v_{G_k \otimes i}^T) \quad (5)$$

其中,  $\gamma_{r_{G_k}} = [\gamma_{r_{G_k \otimes 1}}, \gamma_{r_{G_k \otimes 2}}, \dots, \gamma_{r_{G_k \otimes m}}]$ ,  $\sum_{G_k} = \text{diag}(\gamma_{r_{G_k}})$  是在其主对角线上具有  $\gamma_{G_k}$  元素的对角矩阵,  $u_{G_k \otimes i}, v_{G_k \otimes i}$  分别是  $U_{G_k}$  和  $V_{G_k}$  的列向量。因此,  $X_{G_k}$  的最终自适应学习词典被定义为:

$$D_{G_k} = [d_{G_k \otimes 1}, d_{G_k \otimes 2}, \dots, d_{G_k \otimes m}] \quad (6)$$

本文所使用的组字典学习对于每个组  $X_{G_k}$  是自适应的, 并且效果显著。每个组只需要一次奇异值分解。

$l_0$  范数最优化是非凸和 NP-hard 的, 通常的处理方法是求解其最优凸近似值, 即  $l_1$  范数最优化。 $l_1$  最优化可以通过一些凸优化算法(如迭代收缩/阈值转换法和分裂伯格曼迭代算法)进行有效解决。本文采用分裂伯格曼迭代算法来求解方程(4), 从而实现最优化。

## 3 自适应组稀疏表示的图像修复方法

### 3.1 自适应样本图像块大小的确定

因为块结构稀疏度<sup>[11]</sup>的大小能够反映样本图像块所处区域的特征, 所以用块结构稀疏度作为判定因子来选取合适大小的样本图像块。块结构稀疏度的大小直接关系到选取的样本图像块的大小。块结构稀疏度可定义为:

$$S(k_1) = \sqrt{\left[ \sum_{k_2 \in N_s(k_1)} \omega_{k_1, k_2}^2 \right] \cdot \frac{|N_s(k_1)|}{|N(k_1)|}} \quad (7)$$

其中,  $\omega_{k_1, k_2}$  为样本块  $k_1$  与样本块  $k_2$  的相似度,  $|N(k)|$  为以  $k$  点为中心的一个邻域块中的元素个数,  $|N_s(k)|$  为集合  $N_s(k)$  中的元素个数。 $N_s(k)$  和  $\omega_{k_1, k_2}$  的定义分别为:

$$N_s(k_1) = \{k_2 | k_2 \in N(k_1) \text{ and } \varphi_{k_2} \subset y \setminus \Omega\} \quad (8)$$

$$\omega_{k_1, k_2} = \frac{1}{Z(k_1)} \exp\left(-\frac{d(k_1, k_2)}{25}\right) \quad (9)$$

其中,  $y$  属于破损图像,  $\Omega$  为待修复区域,  $d$  表示样本块之间已知像素点的均方距离,  $Z(k)$  为归一化常数。

如图 2 所示, 3 种不同结构纹理信息的部分图像样本块所对应的块结构稀疏度值的大小不同, 而且可以看出块结构稀疏度值越大, 对应的样本图像块的结构纹理信息越突出, 反之, 对应的样本图像块的平滑信息越突出。这样, 就可以把块结构稀疏度值作为一个判定因子, 为组结构的建立选择合适大小的样本图像块。

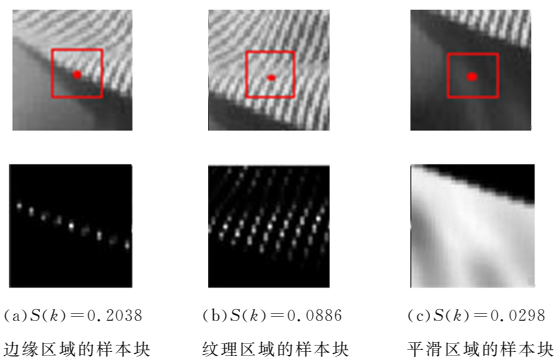


图2 不同样本块的块结构稀疏度

Fig.2 Block structure sparsity of different sample blocks

块结构稀疏度值具有可以反映图像结构纹理信息的特征。根据这一特征进行大量的实验验证,对于图像纹理信息较为复杂的情况,适当减小样本图像块以使修复效果更好,但若减小得过多,则会因图像块中信息量不足而导致修复效果大大减弱;反之,对于图像结构信息较为平滑的情况,则适当增大样本图像块的大小,但如果增大得过多,就会使计算量增加。综合考虑,本文把样本图像块半径  $R$  设置为以下大小:

$$R = \begin{cases} 7, & S(k) \geq \varphi_2 \cdot (k_{\max} - k_{\min}) + k_{\min} \\ 8, & \varphi_1 \cdot (k_{\max} - k_{\min}) + k_{\min} < S(k) < \varphi_2 \cdot (k_{\max} - k_{\min}) + k_{\min} \\ 9, & S(k) \leq \varphi_1 \cdot (k_{\max} - k_{\min}) + k_{\min} \end{cases}$$

其中,  $k_{\max}$  和  $k_{\min}$  为所有点的块结构稀疏度值的最大值和最小值;  $\varphi_1$  与  $\varphi_2$  是经验值,分别取 0.15 和 0.55。至此,便可以针对不同结构和纹理的图像,选取不同大小的样本图像块。

### 3.2 算法流程

首先,使用块结构稀疏度来判定该图像结构纹理的复杂程度,自适应地选择样本图像块大小;其次,在  $L \times L$  邻域内搜索  $n$  块相同大小的最佳匹配块,并组成图像块矩阵,称该矩阵为组;然后,以组为单位进行图像的稀疏表示和自适应字典的学习;最后,通过分裂伯格曼迭代算法迭代收缩求解目标代价函数,直至收敛。具体算法步骤如算法 1 所示。

#### 算法 1 自适应组稀疏表示的图像修复算法

输入: 图像  $y$  和退化算子  $H$

输出: 修复图像

初始化: 正则化参数  $\lambda$ , 组中图像块数量  $n$ , 迭代次数  $N$ ,  $\varphi_1 = 0.15$ ,  $\varphi_2 = 0.55$

If 块结构稀疏度  $S(k) \geq \varphi_2 \cdot (k_{\max} - k_{\min}) + k_{\min}$

$R = 7$

Else if  $\varphi_1 \cdot (k_{\max} - k_{\min}) + k_{\min} < S(k) < \varphi_2 \cdot (k_{\max} - k_{\min}) + k_{\min}$

$R = 8$

Else if 块结构稀疏度  $S(k) \leq \varphi_1 \cdot (k_{\max} - k_{\min}) + k_{\min}$

$R = 9$

End if

While  $i \leq n$  do

    在  $L \times L$  邻域内搜索匹配  $X_k$  的相似块, 并堆叠成组结构  $X_{G_k}$

End while

While  $t \leq N$  do

    For each  $X_{G_k}$

        固定字典  $D_{G_k}$ , 求解稀疏系数  $\alpha_{G_k}$ , 求解优化问题

        固定稀疏系数  $\alpha_{G_k}$ , 更新字典  $D_{G_k}$

    End for

    通过级联所有的字典  $D_{G_k}$  来更新  $D_G^{(t+1)}$ ;

    通过级联所有的  $\alpha_{G_k}$  来更新  $\alpha_G^{(t+1)}$ ;

End while

## 4 实验结果与分析

实验环境为: 一台 6GB 运行内存, Intel i5-3230M 的 CPU 和 2.6GHz 主频的 PC 机, 该 PC 机装有 Windows7 64 位系统和 MATLAB 2010a 仿真软件。主要针对随机像素缺失和局部文本缺失的两种图像进行修复实验。

针对每个组中图像样本块数量对实验结果的影响, 本文对其进行了调整, 调整情况如表 1 中图像块数量一列。因为在实验中发现图像块的数量对实验耗时的影响较大, 图像块数量越多, 实验耗时就越长, 但是图像块数量过少也会影响实验的效果, 降低修复后图像的清晰度, 所以本文在不影响实验效果的前提下, 适当地减少了图像块数量, 大量的实验证明了适当减少图像块数量是可行的。

表 1 参数设置的对比

Table 1 Comparison of parameter settings

| 参数         | 正则化参数 $\lambda$ | 图像块数量 | 迭代次数    | 窗口尺寸 $L$ |
|------------|-----------------|-------|---------|----------|
| 文献[10]中的算法 | 0.082           | 60    | 200/100 | 40       |
| 本文算法       | 0.1             | 50    | 200/100 | 40       |

实验评价指标主要有峰值信噪比 (PSNR) 和特征相似性度量 (FSIM)<sup>[12]</sup>。其中, FSIM 主要针对图像底层特征 (颜色、纹理和形状特征), 该评价指标较稳定、准确。FSIM 的值越趋近于 1, 待测图像的质量就越高, 其表达式如下:

$$FSIM = \frac{\sum_{x \in M} F_L(x) \cdot PC_m(x)}{\sum_{x \in M} PC_m(x)} \quad (10)$$

其中,  $M$  表示整个空域;  $F_L(x) = F_{PC}(x) \cdot F_G(x)$ ,  $F_{PC}(x)$  表示参考图像  $X$  和待测图像  $Y$  的特征相似性,  $F_G(x)$  表示图像  $X$  和  $Y$  的梯度相似性;  $PC_m(x) = \max(PC_1(x), PC_2(x))$ ,  $PC$  表示图像  $X$  和  $Y$  的相位一致性信息。

### 4.1 随机像素缺失图像的修复实验

对于随机像素缺失的情况, 主要对破损率为 80%、大小为  $256 \times 256$  的彩色图像进行实验, 并与文献[8-10]中的方法进行对比, 部分实验结果如图 3 所示。



(a) 待修复图像 (b) 文献[9]算法 (c) 文献[8]算法 (d) 文献[10]算法 (e) 本文方法

图 3 随机像素缺失实验的对比

Fig.3 Comparison of random pixel missing experiment

从图 3 的对比实验效果图可以看出, 采用本文修复方法

的效果在视觉上比其他 3 种方法都有所提升。与其他图像的实验对比结果如表 2 所列,通过对实验数据的分析可以看出,本文方法的修复效果在峰值信噪比和特征相似性度量上相比文献[10]中的方法所提升。自适应组构建过程中,根据图像中的结构纹理信息选择合适大小的图像块,因此对于 Barbara 和 Parrots 这些图像结构纹理复杂的图像,选择的图像块较

小,在计算时减少了所要计算的像素个数,故消耗的时间大大减少。对比表 3 中的实验时间可以看出,本文算法对结构纹理复杂的 Barbara 和 Bike 等图像的耗时比文献[10]算法的耗时减少了 500 s 左右;而对于结构纹理较为简单的 House 图像,由于所选择的图像块较大,因此其耗时只减少了 250 s 左右。

表 2 随机像素缺失的实验结果对比

Table 2 Comparison of experimental results of random pixel missing

| 图像      | 文献[8]方法 |        | 文献[9]方法 |        | 文献[10]方法 |        | 本文方法    |        |
|---------|---------|--------|---------|--------|----------|--------|---------|--------|
|         | PSNR/dB | FSIM   | PSNR/dB | FSIM   | PSNR/dB  | FSIM   | PSNR/dB | FSIM   |
| Barbara | 39.250  | 0.9902 | 38.497  | 0.9092 | 31.315   | 0.9596 | 31.4740 | 0.9651 |
| House   | 41.203  | 0.9821 | 41.237  | 0.9424 | 35.579   | 0.9742 | 35.9560 | 0.9878 |
| Parrots | 37.842  | 0.9923 | 36.489  | 0.9312 | 29.840   | 0.9531 | 29.9940 | 0.9574 |
| Bike    | 32.193  | 0.9890 | 31.943  | 0.9423 | 24.304   | 0.9435 | 24.9603 | 0.9594 |
| Lena    | 40.294  | 0.9859 | 38.198  | 0.9321 | 34.108   | 0.9795 | 34.5380 | 0.9862 |

表 3 本文方法与文献[10]方法修复图像的耗时对比

Table 3 Comparison of time consuming of this paper and literature [10] for repairing images

| 图像      | 随机像素缺失     |        | 局部文本缺失     |        |
|---------|------------|--------|------------|--------|
|         | 文献[10]中的方法 | 本文方法   | 文献[10]中的方法 | 本文方法   |
| Barbara | 3308.0     | 2722.8 | 1407.4     | 904.1  |
| House   | 3135.9     | 2898.2 | 1668.5     | 1302.1 |
| Parrots | 2775.7     | 2466.3 | 1411.4     | 913.6  |
| Bike    | 2031.5     | 1571.8 | 1480.4     | 1325.5 |
| Lena    | 1930.5     | 1460.8 | 1671.4     | 1297.3 |

4.2 局部文本缺失图像的修复实验

对于局部文本缺失的情况,实验主要对大小为  $256 \times 256$  的彩色图像进行文本信息的去除,然后对其进行修复实验,并分别与其他 3 种方法进行对比。

部分图像的实验结果如图 4 所示,可以看出本文方法的修复结果在视觉效果上优于其他 3 种方法。与其他图像的实验对比结果如表 4 所列,对于大多数图像来说,本文方法的修

复效果优于其他方法。与随机像素缺失图像的修复原理类似,针对文本缺失图像的修复,在构建组结构时也会根据图像中的结构纹理信息选择合适大小的图像样本块,从而减少计算量,提高图像修复的效率,如表 2 中,修复时间平均减少了 200~500 s。可见,无论是针对随机像素缺失的图像还是局部文本缺失的图像,本文方法在修复质量和效率上都有所提升。



(a)待修复 图像 (b)文献[9] 算法 (c)文献[8] 算法 (d)文献[10] 算法 (e)本文方法

图 4 局部文本缺失实验的对比

Fig. 4 Comparison of local text missing experiment

表 4 局部文本缺失的实验结果对比

Table 4 Comparison of experimental results of local text missing

| 图像      | 文献[8]方法 |        | 文献[9]方法 |        | 文献[10]方法 |        | 本文方法    |        |
|---------|---------|--------|---------|--------|----------|--------|---------|--------|
|         | PSNR/dB | FSIM   | PSNR/dB | FSIM   | PSNR/dB  | FSIM   | PSNR/dB | FSIM   |
| Barbara | 39.027  | 0.9803 | 40.367  | 0.9398 | 40.740   | 0.9896 | 41.762  | 0.9908 |
| House   | 41.210  | 0.9894 | 40.971  | 0.9817 | 42.451   | 0.9903 | 42.804  | 0.9934 |
| Parrots | 37.983  | 0.9921 | 37.903  | 0.9589 | 37.8244  | 0.9956 | 38.111  | 0.9907 |
| Bike    | 32.371  | 0.9819 | 31.938  | 0.9682 | 32.589   | 0.9875 | 32.742  | 0.9894 |
| Lena    | 40.341  | 0.9843 | 40.209  | 0.9791 | 40.548   | 0.9831 | 40.558  | 0.9964 |

**结束语** 针对组稀疏表示图像修复方法在构建组结构时采用固定大小的图像块而致使修复结果中存在纹理和结构清晰性较差的问题,提出了一种自适应地选取合适大小的样本图像块来构建组结构的方法,并在其邻域中搜索最匹配的  $n$  块图像,进而组成一个自适应图像块大小的组;然后对每个组进行奇异值分解,获得该组的自适应字典;接着利用分裂伯格曼迭代算法对每个组的自适应字典、稀疏编码系数进行更新,直至收敛;最后通过调整组域中图像块的数量来使得修复效果达到最佳。文中所提算法在保证峰值信噪比和特征相似性度量都有所提升的情况下,提升了修复效率;但该方法也存在迭代次数太多、对色彩和光照较强的图像修复效果不佳的缺陷。未来还需进一步改善,结合新的方法,使其适应更多的图

像,以实现更好的修复效果。

参 考 文 献

[1] WANG G H.Geometry-aware Image Completion[D]. Hefei: University of Science and Technology of China, 2015. (in Chinese)  
王贵杭. 基于几何信息的图像修复[D]. 合肥:中国科学技术大学, 2015.

[2] MARCELO B, GUILLERMO S, VICENT C, et al. Image inpainting[C]// The 27th International Conference on Computer Graphics and Interactive Techniques. New Orleans, USA, 2000: 417-424.

- [3] CHAN T F, SHEN J. Mathematical Models for Local Nontexture Inpaintings [J]. *Siam Journal on Applied Mathematics*, 2002, 62(3): 1019-1043.
- [4] VESE L A, OSHER S J. Modeling Textures with Total Variation Minimization and Oscillating Patterns in Image Processing [J]. *Journal of Scientific Computing*, 2003, 19(1): 553-572.
- [5] GROSSAUER H. A Combined PDE and Texture Synthesis Approach to Inpainting [C] // *Computer Vision-ECCV 2004, European Conference on Computer Vision, Prague, Czech Republic, 2004*. DBLP, 2004: 214-224.
- [6] JI H L, YANG Q W. Image inpainting algorithm based on group-structured sparse representation [J]. *Computer Engineering and Applications*, 2016, 52(18): 14-17. (in Chinese)  
计宏磊, 杨清文. 基于群结构稀疏表示的图像修复 [J]. *计算机工程与应用*, 2016, 52(18): 14-17.
- [7] AHARON M, ELAD M, BRUCKSTEIN A. K-SVD: An algorithm for designing overcomplete dictionaries for sparse representation [J]. *IEEE Transactions on Signal Processing*, 2006, 54(11): 4311-4322.
- [8] DONG W, SHI G, LI X. Nonlocal image restoration with bilateral variance estimation; a low-rank approach [J]. *IEEE Transactions on Image Processing*, 2013, 22(2): 700-711.
- [9] DONG W, ZHANG L, SHI G M, et al. Nonlocally centralized sparse representation for image restoration [J]. *IEEE Transactions on Image Processing*, 2013, 22(4): 1620-1630.
- [10] ZHANG J, ZHAO D, GAO W. Group-based sparse representation for image restoration [J]. *IEEE Transactions on Image Processing*, 2014, 23(8): 3336-3351.
- [11] XU Z, SUN J. Image inpainting by patch propagation using patch sparsity [J]. *IEEE Transactions on Image Processing*, 2010, 19(5): 1153-1165.
- [12] ZHANG L, ZHANG D, MOU X Q, et al. FSIM: A Feature Similarity Index for Image Quality Assessment [J]. *IEEE Transactions on Image Processing*, 2011, 20(8): 2378-2386.

(上接第 257 页)

### 参考文献

- [1] REN S, HE K, GIRSHICK R, et al. Faster R-CNN: towards real time object detection with region proposal networks [C] // *International Conference on Neural Information Processing Systems*. MIT Press, 2015: 91-99.
- [2] HE K, ZHANG X, REN S, et al. Deep Residual Learning for Image Recognition [C] // *Computer Vision and Pattern Recognition*. IEEE, 2016: 770-778.
- [3] HOFMANN M, WOLF D, RIGOLL G. Hypergraphs for Joint Multi-view Reconstruction and Multi-object Tracking [C] // *Computer Vision and Pattern Recognition*. IEEE, 2013: 3650-3657.
- [4] DICLE C, CAMPS O I, SZNAIER M. The Way They Move: Tracking Multiple Targets with Similar Appearance [C] // *IEEE International Conference on Computer Vision*. IEEE, 2014: 2304-2311.
- [5] KIM C, LI F, CIPTADI A, et al. Multiple Hypothesis Tracking Revisited [C] // *IEEE International Conference on Computer Vision*. IEEE, 2015: 4696-4704.
- [6] REZATOFIGHI S H, MILAN A, ZHANG Z, et al. Joint Probabilistic Data Association Revisited [C] // *IEEE International Conference on Computer Vision*. IEEE, 2015: 3047-3055.
- [7] BAE S H, YOON K J. Robust Online Multi-object Tracking Based on Tracklet Confidence and Online Discriminative Appearance Learning [C] // *IEEE Conference on Computer Vision and Pattern Recognition*. IEEE Computer Society, 2014: 1218-1225.
- [8] XIANG Y, ALAHI A, SAVARESE S. Learning to Track; Online Multi-object Tracking by Decision Making [C] // *IEEE International Conference on Computer Vision*. IEEE, 2015: 4705-4713.
- [9] BEWLEY A, GE Z, OTT L, et al. Simple online and realtime tracking [C] // *IEEE International Conference on Image Processing*. IEEE, 2016: 3464-3468.
- [10] CHEN J G, QIN X S, MA L L. Fast GM-PHD Filter for Multi-target Tracking [J]. *Computer Science*, 2016, 43(3): 317-321. (in Chinese)  
陈金广, 秦晓姗, 马丽丽. 快速多目标跟踪 GM-PHD 滤波算法 [J]. *计算机科学*, 2016, 43(3): 317-321.
- [11] JU H Y, YANG M H, LIM J, et al. Bayesian Multi-object Tracking Using Motion Context from Multiple Objects [C] // *Applications of Computer Vision*. IEEE, 2015: 33-40.
- [12] YANG M, JIA Y. Temporal Dynamic Appearance Modeling for Online Multi-Person Tracking [J]. *Computer Vision & Image Understanding*, 2015, 31(9): 626-633.
- [13] BENFOLD B, REID I. Stable multi-target tracking in real-time surveillance video [C] // *Computer Vision and Pattern Recognition*. IEEE, 2011: 3457-3464.
- [14] KUHN H W. The Hungarian method for the assignment problem [J]. *Naval Research Logistics*, 2005, 52(1): 7-21.
- [15] BREITENSTEIN M D, REICHLIN F, LEIBE B, et al. Online Multiperson Tracking-by-Detection from a Single, Uncalibrated Camera [J]. *IEEE Transactions on Pattern Analysis & Machine Intelligence*, 2011, 33(9): 1820-1833.
- [16] YUAN D L, JI Q G. Multiple Object Tracking Algorithm via Collaborative Motion Status Estimation [J]. *Computer Science*, 2017, 44(Z11): 154-159. (in Chinese)  
袁大龙, 纪庆革. 协同运动状态估计的多目标跟踪算法 [J]. *计算机科学*, 2017, 44(Z11): 154-159.
- [17] BIRCHFIELD S T, RANGARAJAN S. Spatiograms versus Histograms for Region-Based Tracking [C] // *IEEE Computer Society Conference on Computer Vision and Pattern Recognition*. IEEE, 2005: 1158-1163.
- [18] CONAIRE C O, O'CONNOR N E, SMEATON A F. An Improved Spatiogram Similarity Measure for Robust Object Localisation [J]. *IEEE International Conference on Acoustics*, 2007, 1(4): 1069-1072.
- [19] YANG B, NEVATIA R. Online Learned Discriminative Part-Based Appearance Models for Multi-human Tracking [C] // *European Conference on Computer Vision*. Springer-Verlag, 2012: 484-498.
- [20] LEMENAGER E, BOUET T, BRAIBANT V. Kalman filtering; a new approach for building global approximations. Application to the inverse optimization of an explosively formed penetrator (EEP) [J]. *Structural Optimization*, 1997, 14(2/3): 158-164.