

特征聚类的局部敏感稀疏图像修复

薛俊韬,倪晨阳,杨斯雪

(天津大学 电气自动化与信息工程学院,天津 300072)

摘要: 针对图像修复过程中单一的字典迭代时间长、适应性差、修复效果不理想的缺点,提出了一种结合图像特征聚类与字典学习的改进的图像修复方式。首先破损的图像被分割成小块,并产生索引矩阵。然后使用控制核回归权值算法,对其进行图像聚类。通过对图像内在结构与未破损区域信息的挖掘,分割的图像块根据 SKRW 的相似性进行了分类。之后针对不同类型结构的图像,通过自适应局部敏感字典学习的方式,获取每类字典的过完备字典。然后,通过构建自适应局部配适器,提高字典更新的收敛速度与稀疏字典的适应性。因为是通过多个字典匹配不同结构的图像,因此图像的稀疏表示更为准确。各个字典在达到收敛之前不断进行更新,而图像的稀疏因子也会随着改变。在对破损区域进行补丁更换之后,实现了对破损图像的修复。实验结果表明,该算法相较于目前的修复算法,视觉效果和客观评价上更好,且所需的修复时间更短。

关键词: 图像修复; 稀疏表示; 图像聚类; 字典学习; 局部敏感

中图分类号: TP391.41 **文献标志码:** A **DOI:** 10.3788/IRLA201847.1126001

Image inpainting based on feature clustering and locality-sensitive sparse representation

Xue Juntao, Ni Chenyang, Yang Sixue

(School of Electrical and Information Engineering, Tianjin University, Tianjin 300072, China)

Abstract: A novel image inpainting method based on sparse representation which combined image clustering and dictionary learning was proposed to solve the problems of long iteration time, bad adaptation and non-ideal results when using one single dictionary. Firstly, the broken image was divided into blocks and generated index matrix. Then Steering Kernel Regression Weight (SKRW) algorithm was used for image clustering. By exploring the inner structures of image and the information of intact area, blocks were sorted into categories based on their similarities of SKRW. Then each category had their own overcomplete dictionary by self-adaptive locality-sensitive dictionary learning. By building a self-adaptive local adaptor, the rate of convergence and the adaptability of sparse dictionary were improved. Multi-dictionaries were matched with different image structures, so the image would have a more accurate sparse representation. The dictionaries were updated until convergence, along with sparse coefficients as well. The image was finally restored after replacing patches back. Experimental results show that the proposed algorithm can repair the damaged images better than the state-of-the-art algorithms in both visual effect and objective evaluations. In addition, the time consumption is greatly

收稿日期:2018-06-05; 修订日期:2018-07-03

基金项目:国家科技支撑项目(2014BAC26B00)

作者简介:薛俊韬(1973-),女,副教授,博士,主要从事深度学习与计算机视觉等方面的研究。Email:xuejt@tju.edu.cn

reduced in comparison with the other algorithms.

Key words: image inpainting; sparse representation; image clustering; dictionary learning; locality-sensitive

0 引言

图像修复是指发掘图像中已有的信息,对受损区域进行修复,或将图片中某些特征物进行去除处理的技术,其目的是改善图像的视觉效果。近几年来,随着数字图像技术的发展,图像修复被广泛地应用于视频修复、文物复原、目标移除等方面,成为数字图像处理领域的重要分支。

传统的图像修复算法主要包括基于偏微分方程的修复算法和基于纹理信息的修复算法。基于偏微分的修复算法主要有 TV 算法、BSCB 算法和 CCD 算法等,其思路是根据图像的局部信息通过扩散的方式对破损的区域进行修补,但当修复的面积较大时,修复效果会明显变差;基于纹理信息的修复方法从待修复区域边界选取匹配度最好的图像块代替破损区域的图像,这种方法虽然在较大区域的修复上较前者效果更好,但当图片本身的纹理特征不明显时,修复效果会明显下降,且效率降低。近年来随着压缩感知技术的提出,基于稀疏表示的图像修复算法受到了越来越多的青睐。相较传统的图像修复方法,基于稀疏表示的图像修复算法改善了图像修复质量,不仅使修补的图片更加清晰,且边缘的模糊问题也有所改善^[1]。

2006 年, M. Elad 提出了一种基于 K 奇异值分解(K-SVD)的字典学习方法,该方法在图像去噪中得到广泛的应用和推广^[2]。Fadili 等通过 CDL 方法实现对天文图像的去噪处理,该方法相较小波与传统的稀疏方法去噪效果更好,但在字典的原子个数与补丁大小等参数确定上无法做出准确的判定^[3];参考文献[4]将稀疏表示与 Criminisi 算法结合,虽减少了整体稀疏的计算量,但会导致修复的边缘不连续;黄红林^[5]等通过模糊 C 均值聚类和 K-SVD 字典训练进行图像修复,提高了字典的适应性,但由于模糊 C 均值可能收敛到局部极值,不能得到最优解,使得图像聚类的结果不够准确,从而影响字典训练的结果。参考文献[6]利用稀疏表示,将图像进行超分辨率重

构图像来进行去噪,但时间复杂度较高;参考文献[7]通过对字典进行聚类,从而减少了不相关原子之间的干扰,但仍无法根据图像大小准确判定最优补丁的大小。此外, Julien Mairal 等^[8]提出了在线字典学习的方式,该方法对于特定的图像能够进行有效的稀疏解码,但需提前对大量的样本进行训练。Naderahmadian, Yashar^[9]通过优化数据集,减少了在线字典更新的迭代次数。因此如何充分利用待修复图像内的已知信息来估计丢失部分,训练有效的学习字典,研究有效的稀疏表示算法,是基于稀疏表示理论的图像修复问题的主要研究方向。

综上所述,针对稀疏表示准确率及算法迭代时间的问题,文中提出一种结合控制核函数聚类与局部敏感的字典学习的图像修复算法,其特点在于:

(1) 针对单一字典稀疏表示的缺点,采用控制核回归函数的方式对图像进行分割聚类,以多字典的方式共同表示出整幅图像;

(2) 将局部敏感的稀疏字典学习引入图像修复中,该方法无需解决 l_1 范数问题,从而加快稀疏表示稀疏的求解;

(3) 改进局部敏感的自适应适配器,利用迭代过程中已有的字典信息,简化字典构成,加速字典更新的收敛。

实验结果表明该方法对于各类破损图像均有较好的修复效果,且在修复时间上更短。

1 稀疏表示理论

假设存在信号 $x \in R^{n \times 1}$, 并给定完备字典 $D = [d_1, d_2, \dots, d_k] \in R^{n \times k}, n < k$, 可将 x 精确地表示为 $x = D\alpha$, 或近似表示为 $x \approx D\alpha$ 。

由于字典 D 是满秩的,所以稀疏表示的主要任务是在保证信号不失真的情况下,使得稀疏表示系数 α 中的非零元素数量最少。此最优化问题可表示为:

$$\min_{\alpha} \|\alpha\|_0 \quad \text{s.t.} \quad x = D\alpha \quad (1)$$

式中: $\|\cdot\|_0$ 是 l_0 范数。由于 l_0 范数可用来统计非零元素的个数,故可以测量 α 的稀疏度。

由于字典是过完备的,稀疏表示问题成为 NP 难问题,计算量很大。知名学者 Donohopi 等已证明在足够稀疏的条件下, l_0 范数可以转化为 l_1 范数的凸函数优化估计问题,即将此问题放松成如公式(2)所示的 l_1 范数问题^[10]。

$$\min_{\alpha} \|\alpha\|_1 \quad \text{s.t.} \quad x=D\alpha \quad (2)$$

在引入拉格朗日算子情况下,公式(2)可转化为公式(3)所示的正则化形式:

$$\min_{\alpha} \|x-D\alpha\|_2^2 + \lambda\|\alpha\|_1 \quad (3)$$

式中: λ 为控制 α 稀疏性的惩罚因子。

字典的选择和构建在稀疏表示中也尤为重要。稀疏字典总体可以分为两类:为特定的目标而设定的预置字典和通过样本训练来得到的适应内容的学习字典^[2]。在某些情况下,预设字典在修复算法中优先级更高,因为这类字典容易获得,结构性较好,当图像中信号较为单一时,能较好地稀疏表示出图像,从而使整个算法的复杂度更低。另一方面,由于稀疏表示的成功与否很大程度上取决于字典对信号的适应程度,所以字典训练也被用来获得适应性更好的字典,如 Sahoo^[11] 等人通过用 SGK 代替传统的 K-SVD,提高了字典训练的速度。通过这种方法获得的字典对图像信号的适应性更好,而算法的时间复杂度和计算量也更大。因此权衡算法的复杂度与最优化,是字典选择的重要问题。

2 文中算法

图像信号是一种包含大量信息和内容的二维信号。传统的稀疏表示方法从全局图像出发,采用稀疏表示算法来处理整幅图片,然而修复的图像中仍然含有模糊和毛刺;另一方面,若将图像进行分块,对每个图像块分别进行稀疏表示,其稀疏表示的准确性会有所提高,但容易受到聚类效果的影响,如参考文献[5]的模糊 C 均值会陷入局部最优的问题,从而影响修复效果。因此文中综合考虑稀疏表示的准确性与复杂度的问题,将图像分割后依次采用控制核回归权值算法聚类和局部敏感的稀疏字典学习方式,最后将各类的图像稀疏表示并加以组合,完成图像修复。

2.1 图像特征聚类

传统的图像聚类方式往往会因灰度值或强度上的微小差异而将相似的结构划分为不同的区域,对

后期字典的学习以及图像的修复质量不利。文中引入控制核回归权值 (Steering Kernel Regression Weight, SKRW)^[12-13] 作为聚类的依据,根据每个像素点对应的控制核权值特征向量,辨别之间的相似性,对图像进行聚类划分。

控制核权值 $w_{i,j}$ 在引入鲁棒性梯度估计的过程中,可以表征像素之间或者像素与其局部邻域的结构相似性^[14]。其定义为:

$$w_{i,j} = \frac{\sqrt{\det(C_j)}}{2\pi h^2} \exp\left\{-\frac{(p_i-p_j)^T C_j (p_i-p_j)}{2h^2}\right\} \quad (4)$$

式中: $i, j \in N_i$ 为图像中的像素点; N_i 为以像素点 i 为中心的局部邻域; p_i 和 p_j 为像素点 i 和像素点 j 在图像中的位置; h 为控制高斯核支集的全局平滑参数。 C_j 为对像素 j 的垂直梯度和水平梯度估计得到的对称梯度协方差矩阵,其结合了旋转算子、延伸算子和尺度算子,使得图像的结构能够和控制高斯核一致,计算如下:

$$C_j = \gamma_j U_{\theta_j} \Lambda_j U_{\theta_j}^T \quad (5)$$

式中: U_{θ_j} 为旋转因子,用于将高斯函数与其边缘方向 θ_j 对齐; Λ_j 为延伸矩阵; γ_j 为尺度参数。图 1 给出了各参数对于回归核的影响。

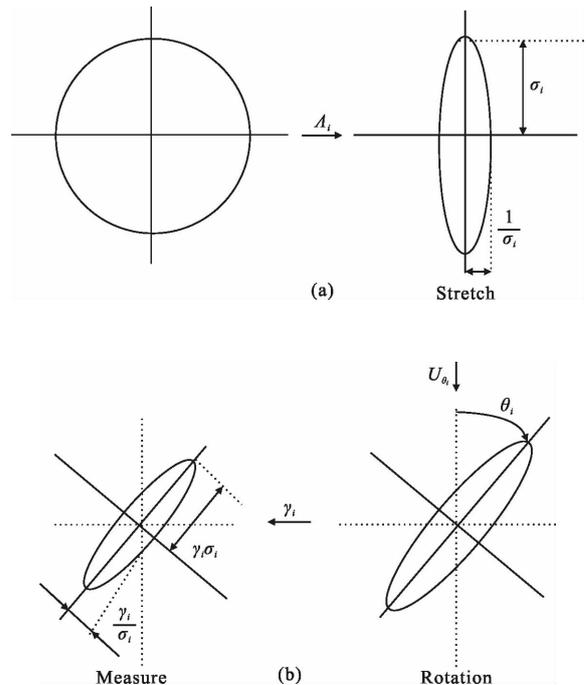


图 1 对称梯度方差矩阵各参数对回归核形状的影响

Fig.1 Effects of the symmetric gradient covariance matrix and its components on the shape of the regression kernel

根据结构间的相似性,可将图像聚类为 K 类。聚类规则为:将图像划分为若干小块,若该小块的权值与某类区域中心权值的距离的 l_2 范数最小,则该图像小块属于该类。距离可以表示为下式:

$$J = \sum_{k=1}^K \sum_{i \in \Omega_i} d^2(\tilde{w}_i, \bar{w}^{(k)}) = \sum_{k=1}^K \sum_{i \in \Omega_i} \|\tilde{w}_i, \bar{w}^{(k)}\|^2 \quad (6)$$

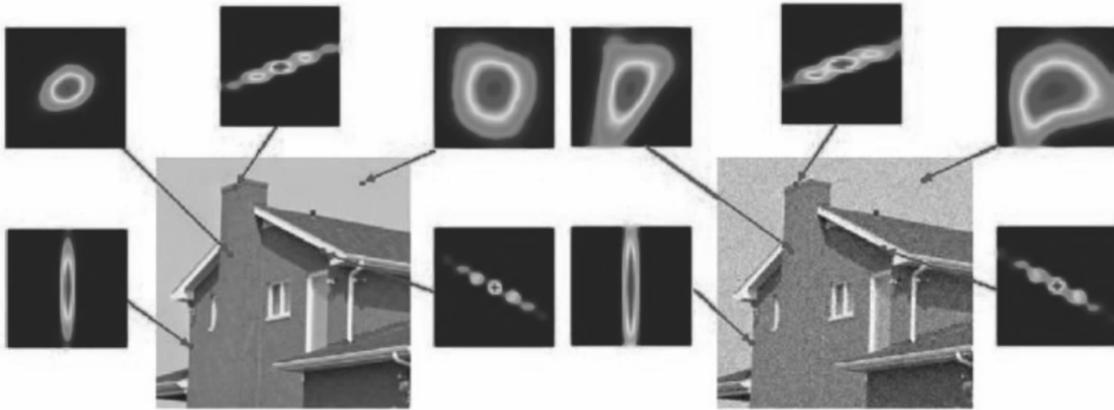
式中: $d^2(\cdot)$ 为类中心与该图像小块两个向量之间的距离; \tilde{w}_i 为属于第 K 类区域中第 i 个小块向量; $\bar{w}^{(k)}$

为第 K 类所有像素取其平均向量, 作为该类的中心像素。

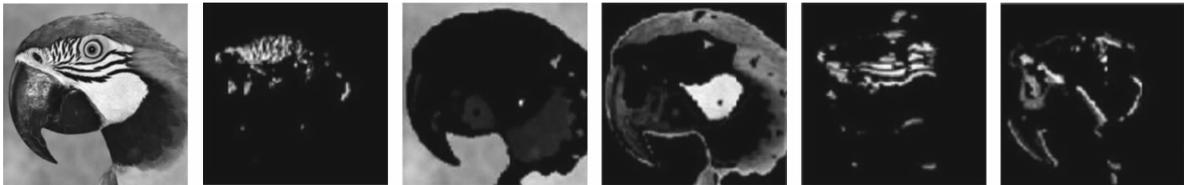
经以上步骤, 图像 X 被划分成为 K 个不同结构, 表示为:

$$X = \bigcup_{k=1}^K \{X_k\} \quad (7)$$

图 2 给出了聚类数为 5, 用控制核回归权值方法聚类的效果。从聚类结果可看出, 即使在相同位置, 但由于噪声的影响仍使其在权值上有较大的区



(a) house 图与其噪声图的控制核回归权值
(a) SKRW of a house figure and its noise figure



(b) parrot 原图与其聚类结果
(b) Original figure of a parrot and its clustering results

图 2 house 图的 SKRW 与 parrot 聚类结果

Fig.2 SKRW of a house figure and clustering results of a parrot

别,说明该方法在图像结构区分度上的优势,同时由图 2(b)可知,该方法与灰度聚类的方法相比,能够很好地将高频特性的部分和相对平滑的低频部分的结构区域划分成为不同的类。在实际过程中,过多的聚类数会导致聚类时间过长,影响算法整体的时间。在一般情况下聚类数以 5~6 为最佳选择,文中在实验中以 5 为聚类数。

2.2 自适应局部敏感字典学习

稀疏表示模型在对噪声与干扰的影响下具有一定的鲁棒性,而字典学习也使稀疏字典在对图像信

息的表达和重构上有了更好的能力。但由于一般的字典学习在每次更新后直接将新的字典用于下一次稀疏编码中,忽略了字典自身的相关性。为克服传统的字典学习过程中信息丢失的问题,在将图像划分为不同特征结构的子区域后,文中采用了局部敏感的稀疏字典学习方式,并改进局部敏感适配器,提出自适应局部敏感的字典学习算法。

2013 年,Wei 等提出了基于局部敏感的字典学习算法 (LSRC)^[15],该方法被广泛地应用于面部识别、图像匹配^[16]等方面。文中将其应用于图像修复过

程中,其算法约束条件如公式(8)所示:

$$\min_{D,A} \|X-DA\|_2^2 + \lambda_{DL} \sum_{i=1}^N \|p_i \odot \alpha_i\|_2^2 \quad (8)$$

式中: \odot 为点乘; λ_{DL} 为衡量局部约束性的正则化参数; $p_i=[p_{i1}, p_{i2}, \dots, p_{ik}]^T$ 为基于 l_2 范数的局部敏感配适器,用来度量字典原子与训练样本之间的距离,其定义为:

$$p_{ik}=\text{dist}(x_i, d_k)=\|x_i-d_k\|_2 \quad (9)$$

该算法不仅确保了数据的稀疏性,且在局部约束性的条件下无需解决 l_0 与 l_1 的范数问题,从而能够更快地达到收敛。文中在此基础上改进了自适应局部配适器,在每次稀疏编码前,用当前的字典稀疏表达出字典中的各个原子,再用稀疏系数重构字典原子,最后使用重构后的字典原子构建局部配适器指导稀疏字典学习,从而保留了原来字典的信息,加速了字典收敛。

2.2.1 自适应局部配适器构造

通过聚类将相似结构的图像进行分类,加强了字典原子之间的相关性。当字典原子间存在线性关系时,其中任意原子可由其他原子线性表达并重构,从而在保证字典原子间的相似性的同时,可以对字典的构成进行简化。

利用上轮迭代的字典,将字典的原子 d_k 用其他原子 $D=[d_1, d_2, \dots, d_{k-1}, d_{k+1}, \dots, d_K]$ 线性表示出,得到 d_k 的线性表达式,求解公式如公式(10)所示:

$$s_k=(D^T D + \gamma I^{-1}) D^T d_k \quad (10)$$

式中: γ 为正数常量; s_k 在表征原子的过程中表示其他原子对 d_k 的影响。此时 $s_k=[s_{k,1}, s_{k,2}, \dots, s_{k,k-1}, 0, s_{k,k+1}, \dots, s_{k,K}]$ 表示了原子之间的相似度。重构后的原子 d_k 可表示为:

$$\tilde{d}_k = D s_k \quad (11)$$

然后计算重构后的原子 \tilde{d}_k 与训练样本 x_i 的欧氏距离,如公式(12)所示:

$$\tilde{p}_{ik}=\text{dist}(x_i, \tilde{d}_k)=\|x_i-\tilde{d}_k\|_2 \quad (12)$$

对字典中的各原子分别进行计算,从而得到自适应局部配适器 $\tilde{p}_i=[\tilde{p}_{i1}, \tilde{p}_{i2}, \dots, \tilde{p}_{ik}]^T$ 。

2.2.2 自适应局部敏感字典学习

自适应局部敏感字典学习的数学模型为:

$$\begin{aligned} \min_{D,A} \|X-DA\|_2^2 + \lambda_{DL} \sum_{i=1}^N \|p_i \odot \alpha_i\|_2^2 \\ \text{s.t. } I^T \alpha_i = 1 \quad \forall i=1, \dots, N \end{aligned} \quad (13)$$

其字典学习的主要步骤为:自适应局部配适器构建,稀疏编码与字典更新。在得到自适应局部配适器 $\tilde{p}_i=[\tilde{p}_{i1}, \tilde{p}_{i2}, \dots, \tilde{p}_{ik}]^T$ 后,进行稀疏编码和字典更新。

(1) 稀疏编码

为了求解公式(13)的解,引入拉格朗日函数 $L(\alpha_i, \eta)$,其定义为:

$$\|x_i - D\alpha_i\|_2^2 + \lambda_{DL} \sum_{i=1}^N \|p_i \odot \alpha_i\|_2^2 + \eta(I^T \alpha_i - 1) \quad (14)$$

根据字典 D 与 α 的定义,可将公式(14)化简为以下形式:

$$\alpha_i^T C \alpha_i + \lambda_{DL} \alpha_i^T \text{diag}(p_i)^2 \alpha_i + \eta(I^T \alpha_i - 1) \quad (15)$$

式中: $C=(x_i I^T - D)^T (x_i I^T - D)$, $\text{diag}(p_i)$ 为对角矩阵,其非零元素为 \tilde{p}_i 的表征数值。令 $\partial L(\alpha_i, \eta) / \partial \alpha_i = 0$,有

$$\Phi \alpha_i + \eta I = 0 \quad (16)$$

式中: $\Phi=2(C + \lambda_{DL} \text{diag}(p_i)^2)$ 。将公式(16)左乘 $I^T \Phi^{-1}$,并带入 η ,通过解析法得到公式(13)的解为:

$$\begin{aligned} \tilde{\alpha}_i &= (C + \lambda_{DL} \alpha_i^T \text{diag}(p_i)^2)^{-1} I \\ \alpha_i &= \tilde{\alpha}_i / I^T \tilde{\alpha}_i \end{aligned} \quad (17)$$

该算法的稀疏编码相比于传统的稀疏编码阶段,无需求解 l_1 范数的最小值问题,使过程求解更加简便。

(2) 字典更新

字典更新阶段需要对公式(18)进行求解:

$$F(D) = \min_D \|X-DA\|_F^2 + \lambda_{DL} \sum_{i=1}^N \|p_i \odot \alpha_i\|_2^2 \quad (18)$$

由于公式是一个约束的凸函数最优化问题,对公式进行 d_k 的偏微分求导:

$$\frac{\partial F}{\partial d_k} = \sum_{i=1}^N -2\alpha_{ik}(x_i - D\alpha_i) - 2\lambda_{DL} \alpha_{ik}(x_i - d_k) \odot \frac{\partial \tilde{d}_k}{\partial d_k} \quad (19)$$

在自适应配适器下, $\frac{\partial \tilde{d}_k}{\partial d_k}$ 表示为:

$$\frac{\partial \tilde{d}_k}{\partial d_k} = D((D^T D + \gamma I^{-1}) D^T I) + D \left(\begin{bmatrix} 0 \\ \dots \\ I_k \\ 0 \end{bmatrix} D + D[0 \dots I_k \dots] \right) D + \begin{bmatrix} 0 \\ \dots \\ I_k \\ 0 \end{bmatrix} \quad (20)$$

令公式(19)与公式(20)分别为零, $k=1, 2, \dots, K$,

得到:

$$UD^T=V \quad (21)$$

其中

$$U = \sum_{i=1}^N \begin{pmatrix} (1+\lambda)\alpha_{i1}^2 & \alpha_{i1}\alpha_{i2} & \cdots & \alpha_{i1}\alpha_{iK} \\ \alpha_{i1}\alpha_{i2} & (1+\lambda)\alpha_{i2}^2 & \ddots & \alpha_{i1}\alpha_{iK} \\ \vdots & \vdots & \cdots & \vdots \\ \alpha_{i1}\alpha_{iK} & \alpha_{i2}\alpha_{iK} & \cdots & (1+\lambda)\alpha_{iK}^2 \end{pmatrix} \quad (22)$$

$$V = \sum_{i=1}^N \begin{pmatrix} \alpha_{i1}(1+\lambda\alpha_{i1})(x_i)^T \\ \alpha_{i2}(1+\lambda\alpha_{i2})(x_i)^T \\ \vdots \\ \alpha_{iK}(1+\lambda\alpha_{iK})(x_i)^T \end{pmatrix} \quad (23)$$

最后由公式(21)求得字典 D 。

根据自适应局部敏感字典学习方式,对聚类后的图像分别进行字典学习,然后根据公式(8)得到每

类图像的稀疏表达后,迭代更新各图像块的系数表示。最后根据聚类时构造的索引矩阵 R_i 将各个图像块以不重叠的方式归位,从而完成对图像的修复。

3 实验结果及分析

为验证算法的有效性,文中对具有原始图像的受损图像进行修复。实验分为三组:实验一对加入噪声密度为 0.1 的椒盐噪声的图像进行去噪处理;实验二对存在线性划痕的破损图像进行修复;实验三对小面积块状破损图像进行修补。每组实验分别采用四种不同的图像修复方式,包括文中的图像修复方法、基于偏微分方程的 TV 算法、Criminisi 算法以及基于字典学习的参考文献[17]的方法等。实验在 MATLAB2106a, 处理器 I5,3.3 GHz CPU 环境下进行,修复结果如图 3~5 所示,并在各方法的效果图上

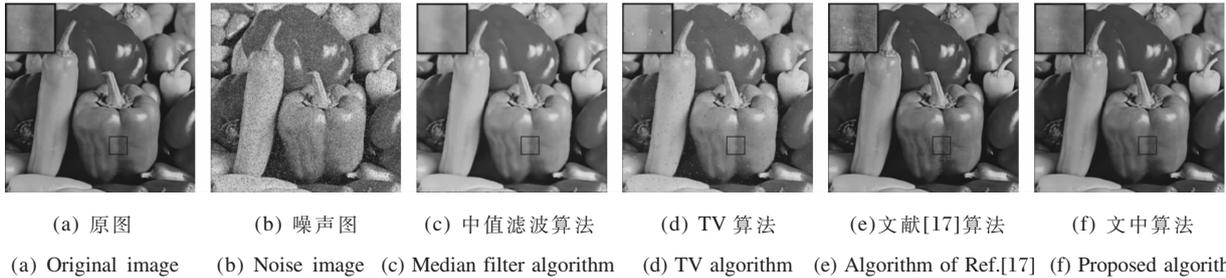


图 3 不同算法的去噪效果图

Fig.3 Denoising results of various algorithms

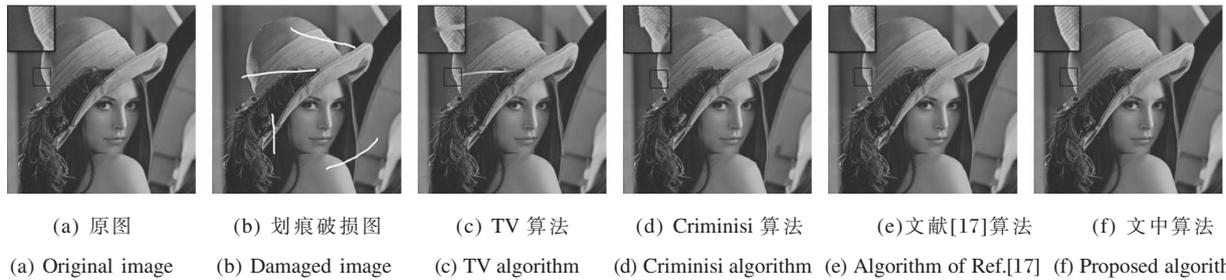


图 4 划痕修复效果

Fig.4 Result of removing scratches

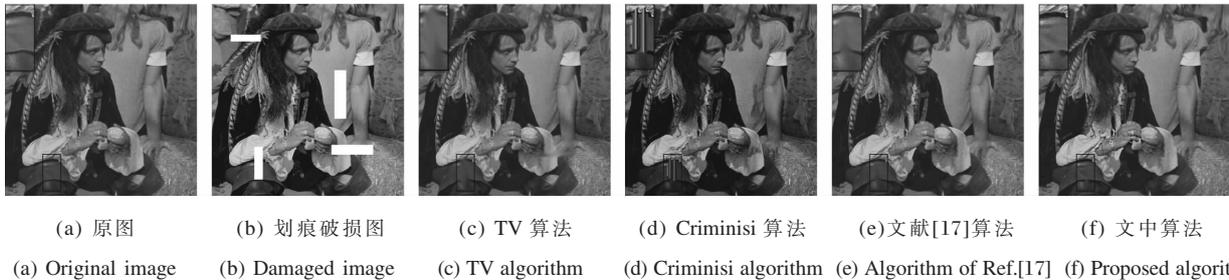


图 5 块状破损修复效果

Fig.5 Result of restoring image of lumpy damages

进行了细节的放大。

从图 3 可以看出,各算法在一定程度上对噪声进行了有效的去除。在视觉效果上,中值滤波虽整体效果良好,修复速度较快,但从细节图可以看出,其在去噪过程中损失了大量的细节,不能达到去噪要求。TV 算法在迭代次数较少的情况下仍然残存噪声,而迭代次数过多,也会导致图像模糊严重。图 3(d)为较为理想情况下的效果图(迭代 100 次),但仍有较为明显的噪声污染;参考文献[17]算法由于在稀疏表示的过程会丢失部分的细节,但相较于传统的修复方式,已经在保证图像质量的同时对噪声进行了去除;而文中算法的结果良好,在保证了图像清晰度的同时,能够把噪声进行有效的去除,且保持了图像的细节信息。

实验二对划痕图像进行修补,当破损较小时,TV 算法通过扩散的方式对划痕进行去除,但由于信息不足,帽子处的划痕并没有完全修复,且其他部分修复效果也不理想;Criminisi 算法通过对周围信息匹配,选取最优的图像块进行修补,但在匹配使无法保证图像的连续性,因此在图 4(d)细节处出现了断裂;参考文献[17]算法在部分细节处仍有细小的模糊;而文中算法在分类与训练过程中尽可能多地保留了原始信息,因此相较其他方法,效果更好,模糊更小。

在对块状破损的实验中,由于块状破损可看做大面积的划痕,故 TV 算法在对破损位置上能够进

行大致的修复,但由于破损位置信息不足,导致多处的模糊;Criminisi 算法在对大面积的破损上,相比 TV 算法有明显改善,其修复思路是在根据破损位置周边的纹理结构来进行修补,在向破损中心修复时,最佳图像块的选取会对图像修补有很大影响。由于图 5(b)本身在纹理结构上区别不明显,因此在修补的时候,初始修补位置的错误导致修复出现了明显的错误;参考文献[17]算法有较好的表现,虽然在膝盖与发辫处仍有模糊,但对破损位置的修复能够满足要求;文中的修复算法在细节处与原图基本接近,证实了该算法在修复上的有效性。

为客观对比文中算法的优越性,在每个实验中另选取两幅图片,以峰值信噪比(Peak Signal to Noise Ratio, PSNR) 和特征结构相似度 (Feature Structural Similarity, FSIM)^[18]为客观评价标准。

用于客观评价的实验材料图片如图 6 所示。其中图 6 (a)、(b)为实验一中噪声密度为 0.1 的椒盐噪声图片;图 6(c)、(d)为用于实验二的两幅划痕图片;图 6(e)、(f)为实验三中添加了 3×3 块状掩膜的图片,掩膜大小均为 50×50 像素。其客观评价如表 1~3 所示。表 4 为各算法在图像修复上的时间复杂度对比。

从表 1~3 中可以看出,文中算法在去噪、去划痕与修复块状破损上都有较高的 PSNR 与 FISM,证明了文中算法的优越性,且表 4 也证明了该算法在修

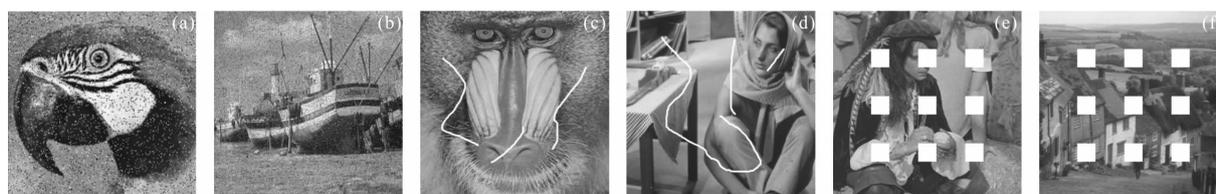


图 6 用于客观评价的实验图片

Fig.6 Images for objective evaluation

表 1 去噪实验的图像质量评价

Tab.1 Image quality evaluations of denoising experiment

Image	PSNR/dB				FSIM			
	Median filter	TV	Ref.[17]	Proposed	Median filter	TV	Ref.[17]	Proposed
Fig.3(b)	27.41	25.37	25.57	28.21	0.829 8	0.645 7	0.848	0.892 7
Fig.6(a)	22.19	21.78	22.66	24.36	0.801 9	0.665 5	0.847 8	0.901 6
Fig.6(b)	25.73	23.86	26.14	26.45	0.755 4	0.615 1	0.779 6	0.795 4

表 2 划痕破损修复实验的图像质量评价

Tab.2 Image quality evaluations of restoring image damaged by scratches

Image	PSNR/dB				FSIM			
	TV	Criminisi	Ref.[17]	Proposed	TV	Criminisi	Ref.[17]	Proposed
Fig.4(b)	23.67	26.15	28.15	28.63	0.988 8	0.972 1	0.984 6	0.990 4
Fig.6(c)	27.62	29.12	32.53	32.89	0.890 9	0.927 4	0.930 12	0.938 4
Fig.6(d)	24.31	28.54	33.58	35.42	0.868 9	0.899 1	0.913 4	0.918 6

表 3 块状破损修复实验的图像质量评价

Tab.3 Image quality evaluations of restoring image of lumpy damages

Image	PSNR/dB				FSIM			
	TV	Criminisi	Ref.[17]	Proposed	TV	Criminisi	Ref.[17]	Proposed
Fig.5(b)	27.66	28.23	30.57	31.02	0.925 8	0.942 0	0.947 4	0.949 1
Fig.6(e)	17.79	20.42	22.46	24.67	0.908 4	0.923 5	0.936 4	0.940 3
Fig.6(f)	15.35	17.02	26.57	28.58	0.931 0	0.932 8	0.949 8	0.951 2

复时间上的优势。

表 4 修复算法平均时间对比(单位:s)

Tab.4 Comparison of algorithms' average time in restoring image(Unit:s)

Image	Size	Damage rate	TV	Criminisi	Ref.[17]	Proposed
Fig.4(b)	512×512	1.05%	18	397	357	304
Fig.6(c)	512×512	1.12%	19	425	367	302
Fig.6(d)	512×512	1.67%	19	717	385	314
Fig.5(b)	512×512	3.90%	68	541	494	395
Fig.6(e)	512×512	8.58%	96	972	501	425
Fig.6(f)	512×512	8.58%	101	975	505	418

4 结 论

结合图像聚类和字典学习,提出了一种新的基于稀疏表示的图像修复方法。在聚类上应用控制核回归函数做聚类标准,在字典学习上采用局部敏感的稀疏字典学习,改进了自适应适配器,从而提高字典原子间的关联性,加快字典更新的收敛。实验结果证明该算法在各类破损图像上均有较好的适应性和鲁棒性,修复效果上有更好的视觉效果和结构相似

度。同时,自适应的局部敏感字典学习也使修复过程的时间复杂度更小。

参 考 文 献:

- [1] Elad M, Figueiredo M A T, Ma Y. On the role of sparse and redundant representations in image processing [J]. *Proceedings of the IEEE*, 2010, 98(6): 972-982.
- [2] Michal Aharon, Michael Elad, Alfred Bruckstein. K-SVD: An algorithm for designing overcomplete dictionaries for sparse representation [J]. *IEEE Transactions on Signal Processing*, 2006, 54(11): 4311-4322.
- [3] Beckouche J, Starck J L, Fadili J. Astronomical image denoising using dictionary learning [J]. *Astronomy & Astrophysics*, 2013, 556(7): 132.
- [4] Hu Gaolong, Xiong Ling. Criminisi-based sparse representation for image inpainting [C]//2017 IEEE Third International Conference on Multimedia Big Data, 2017: 389-393.
- [5] Huang Linjiang, Liu Hong, Tao Shaojie. An improved inpainting algorithm based on K-SVD dictionary[J]. *Journal of Anhui University(Natural Science Edition)*, 2013, 37(3): 69-74. (in Chinese)
- [6] Han Yulan, Zhao Yongping, Wang Qisong, et al.

- Reconstruction of super resolution for noise image under the sparse representation [J]. *Optics and Precision Engineering*, 2017, 25(6): 1619–1626. (in Chinese)
- [7] Xu Kai, Wang Nannan, Gao Xinbo. Image inpainting based on sparse representation with dictionary pre-clustering[C]//7th Chinese Conference on Pattern Recognition, 2016: 245–258.
- [8] Mairal Julien, Bach Francis, Ponce Jean, et al. Online dictionary learning for sparse coding [C]//26th Annual International Conference on Machine Learning, 2009: 689–696.
- [9] Naderahmadian Yashar, Beheshti Soosan, Tinati Mohammad Ali. Correlation based online dictionary learning algorithm [J]. *IEEE Transactions on Signal Processing*, 2015, 64(3): 592–602.
- [10] Marquez M A, Mojica E, Arguello H. Data sinogram sparse reconstruction based on steering kernel regression and filtering strategies[C]//SPIE, 2016, 9847: 98470Z.
- [11] Sahoo S K, Makur A. Replacing K –SVD with SGK: Dictionary training for sparse representation of images[C]// 2015 IEEE International Conference on Digital Signal Processing, 2015(2): 614–617.
- [12] Verhack R, Sikora T, Lange, L, et al. A universal image coding approach using sparse steered Mixture-of-Experts regression[C]//2016 IEEE International Conference on Image Processing, 2016: 2142–2146.
- [13] Marquez M A, Mojica E, Arguello H. Data sinogram sparse reconstruction based on steering kernel regression and filtering strategies[C]//SPIE, 2016, 9847: 98470Z.
- [14] Zhang Kaibing, Gao Xinbo. Single image super-resolution with non-local means and steering Kernel regression [J]. *IEEE Transactions on Image Processing*, 2012, 21 (11): 4544–4556.
- [15] Wei Chiapo, Chao Yuwei, Yeh Yiren, et al. Locality-sensitive dictionary learning for sparse representation based classification[J]. *Pattern*, 2013, 46(5): 1277–1287.
- [16] Guo Jun, Guo Yangqing, Li Yi, et al. Locality sensitive discriminative dictionary learning [C]//IEEE International Conference on Image Processing, 2015: 1558–1562.
- [17] Rao T J V S, Rao M V G, Aswini T V N L. Image inpainting with group based sparse representation using self adaptive dictionary learning [C]//International Conference on Signal Processing & Communication Engineering Systems, 2015: 301–305.
- [18] Zhang Lin, Zhang Lei, Mou Xuanqin, et al. FSIM: a feature similarity index for image quality assessment [J]. *IEEE Transactions on Image Processing*, 2011, 20(8): 2378–2386.