

# 自适应非局部 patch 正则化图像恢复

刘红毅<sup>1</sup>, 韦志辉<sup>2</sup>, 张峥嵘<sup>1</sup>

(1. 南京理工大学理学院, 江苏南京 210094; 2. 南京理工大学计算机科学与技术学院, 江苏南京 210094)

**摘 要:** 非局部均值利用图像自相似性, 有效保持了图像的几何结构信息. 提出了非局部 patch 正则和 TV 正则结合的图像恢复模型, 利用改进的结构张量矩阵构造自适应非局部权函数, 根据像素的局部结构计算图像中 patch 的相似性, 提高了图像结构信息的保持性能. 在数值解法上, 采用分裂 Bregman 算法迭代求解模型, 得到简单快速的迭代形式. 数值实验证明所提出方法在提高恢复图像质量和算法效率上都有显著改进.

**关键词:** 图像恢复; 非局部; 正则化; 分裂 Bregman 迭代

**中图分类号:** TP391 **文献标识码:** A **文章编号:** 0372-2112 (2012) 03-0512-06

**电子学报 URL:** <http://www.ejournal.org.cn> **DOI:** 10.3969/j.issn.0372-2112.2012.03.017

## Adaptive Nonlocal Patch Regularization for Image Restoration

LIU Hong-yi<sup>1</sup>, WEI Zhi-hui<sup>2</sup>, ZHANG Zheng-rong<sup>1</sup>

(1. School of Science, Nanjing University of Science and Technology, Nanjing, Jiangsu 210094, China;

2. School of Compute Science and Technology, Nanjing University of Science and Technology, Nanjing, Jiangsu 210094, China)

**Abstract:** Nonlocal means exploits the spatial correlation in an image, and preserves the structure information effectively. Combining the nonlocal patch regularization with TV regularization, we propose a nonlocal patch regularized image restoration model. The improved structure tensor matrix can be used to achieve a data-adaptive weigh function, which can then adjust the similarity match process based on the local structure of a pixel. A more simple and effective algorithm - Split Bregman, is used to solve the model iteratively. Compared with other regularization models, our method performs better in improving the quality of restoration image and the efficiency of the algorithm.

**Key words:** image restoration; nonlocal means; regularization; split Bregman

## 1 引言

图像恢复的目的是改善观察图像质量, 观察图像通常是在噪声、模糊、运动平移等因素影响下得到的退化图像. 原始真实图像是未知的, 所以图像恢复是一个典型的反问题. 反问题的求解需要正则化, 即利用某种先验知识来重建或复原被退化的图像. 如 Bayesian 先验、信息论先验、变换域稀疏性先验等. 图像恢复的 TV 模型建立在假设图像分片光滑的基础上<sup>[1]</sup>, TV 模型在保持边缘和去噪等方面取得了很好效果, 但由于高频系数过于抑制, 重建图像的纹理等几何结构信息过度平滑.

近几年, 一种揭示自然图像自相似的先验知识—非局部思想在图像处理的各个领域都得到了广泛应用<sup>[2]</sup>. 非局部最早是由 Buades 等提出的, 将传统邻域滤波中的空间邻域扩展到更广义的几何意义下的结构邻域, 在

比较大的区域搜索相似 patch(块), 以 patch 之间相似性作为权重. 这种方法克服了传统邻域加权的局限性, 更好利用了图像之间的相似性, 得到的恢复图像在纹理保持和结构保持方面都有很大改善. 但非局部是在整幅图像中搜索相似块, 计算量比较大. 许多学者在提高算法效率上进行了改进. 对图像 patch 聚类再计算权值, 这样大大减少了搜索时间, 提高了算法效率<sup>[3~5]</sup>. 非局部方法中权值即相似性度量的计算在很大程度上影响了算法的性能. 权函数反映 patch 之间或像素点之间的相似性, 与距离成反比, 常用的为指数函数, 也可以采用鲁棒统计中的权函数,  $K$ - $L$  散度等, 更多权函数的改进可以参考<sup>[6~8]</sup>. 权函数中像素间距离计算一般采用  $L^2$  距离, 但  $L^2$  距离具有各向同性, 不能更好体现图像的几何结构. 由各向异性距离所计算的权函数更好衡量了像素之间的相似性, 不仅从空间上, 而且从几何特征上反映了

像素间关系. Takeda 通过协方差矩阵计算像素之间的各向异性距离, 得到具有方向性、自适应的 Steering 核函数<sup>[9]</sup>. Liu 等构造了基于结构张量矩阵的各向异性距离<sup>[10]</sup>, 自适应的选择像素相关邻域.

应用非局部均值进行图像处理的研究热点之一是非局部方法与其它图像去噪方法的结合. 不同的学者对非局部有不同的理解, 有的以此为保真项. Pizarro 等将非局部约束作为保真项, 认为恢复图像和退化图像在某种相似性度量下达到最小, 同时以恢复图像的高阶平滑作为正则项, 提出了非局部数据平滑模型, 将该模型应用于图像 patch 之间的相似性得到更一般的模型<sup>[11]</sup>. Brox 对于非局部的变分模型提出了加速算法<sup>[12]</sup>. 更多的作者将非局部作为正则项约束, Osher 等将 TV 算子扩展到非局部 TV<sup>[13,14]</sup>, 进而到非局部 TV 的正则化模型. 比较 TV 模型, 非局部 TV 更好利用了像素之间的相似性, 恢复图像的纹理保持有更进一步的提高. Dong, Zhang 等结合非局部正则、自回归模型以及稀疏性约束等<sup>[15]</sup>, 有效实现了图像的超分辨率重建. Protter 和 Elad 等在建立图像超分辨率模型时, 将问题分为两部分, 输入低分辨率图像的融合及去模糊问题, 通过结合图像 patch 之间的非局部加权和 TV 范数来耦合两个问题<sup>[16]</sup>.

本文在图像恢复的 TV 模型中加入非局部 patch 自相似性先验, 建立了新的非局部 patch 正则图像恢复模型. 同文献<sup>[15]</sup>中模型相比较, 结合了非局部正则和 TV 正则, 而非稀疏性先验和自回归模型. 另外, 不同于上述模型的一个重要改进是权函数的计算, 利用改进的结构张量矩阵, 构造具有方向性和自适应的权函数, 进一步提高了图像中的结构保持性能. 最后, 对于所提出模型应用分裂 Bregman 迭代进行求解. 得到了快速的算法.

## 2 非局部 patch 正则化先验

自然图像中存在许多相似性 patch, 如图 1, 平坦区域大部分像素或 patch 都是相同的, 纹理区域、边缘等也存在同样的相似性. Baude 等由此提出非局部思想, 扩展像素间相似性到 patch 间相似性. 另外, 非局部意义下的邻域不再是通常意义下的像素邻域, 而是某种相似性度量下 patch 的集合. 如图 2 中,  $P$  点的 patch 可



图1 自然图像中细节的重复性



图2 图像中的自相似patch

通过相似 patch 的加权和来表示,  $P$  点的邻域像素 patch 不仅包含了  $q1, q2$  点还包含了  $q3$ .

设当前像素点为  $\mathbf{x}_i = (x_{i1} \ x_{i2})^T$ , 对于图像进行分块,  $P_{x_i}$  表示以点  $\mathbf{x}_i$  为中心的 patch. 图像中的大量自相似性可表现为像素间的自相似:

$$\mathbf{y}(\mathbf{x}_i) = \sum_{\mathbf{x}_j \in \delta(\mathbf{x}_i)} \mathbf{W}(\mathbf{x}_i, \mathbf{x}_j) \mathbf{y}(\mathbf{x}_j) \quad (1)$$

或图像中 patch 的自相似:

$$\mathbf{P}_{x_i} = \sum_{\mathbf{x}_j \in \delta(\mathbf{x}_i)} \mathbf{W}(\mathbf{x}_i, \mathbf{x}_j) \mathbf{P}_{x_j} \quad (2)$$

其中  $\mathbf{W}(\mathbf{x}_i, \mathbf{x}_j)$  为权函数, 满足  $\sum_{\mathbf{x}_j \in \delta(\mathbf{x}_i)} \mathbf{W}(\mathbf{x}_i, \mathbf{x}_j) = 1$ , 衡量像素  $\mathbf{x}_i$  和  $\mathbf{x}_j$  之间或 patch  $\mathbf{P}_{x_i}$  与  $\mathbf{P}_{x_j}$  之间的相似性. 权函数可以有多种表达形式, 一般与点  $\mathbf{x}_i$  和  $\mathbf{x}_j$  的距离成反比, 通常取高斯函数.  $\mathbf{x}_i$  的相关邻域:

$$\delta(\mathbf{x}_i) = \{\mathbf{x}_j \mid \mathbf{W}(\mathbf{x}_i, \mathbf{x}_j) > T\} \quad (3)$$

是与 patch  $\mathbf{P}_{x_i}$  相似性大于阈值  $T$  的所有像素点  $\mathbf{x}_i$  的集合.

像素点之间的自相似性式(1)对应于图像非局部自相似性正则约束:

$$\min(\sum_i (\mathbf{y}(\mathbf{x}_i) - \sum_{\mathbf{x}_j \in \delta(\mathbf{x}_i)} \mathbf{W}(\mathbf{x}_i, \mathbf{x}_j) \mathbf{y}(\mathbf{x}_j))^2) \quad (4)$$

同样的, patch 自相似性式(2)对应于图像非局部 patch 自相似性正则约束:

$$\min(\sum_i (\mathbf{P}_{x_i} - \sum_{\mathbf{x}_j \in \delta(\mathbf{x}_i)} \mathbf{W}(\mathbf{x}_i, \mathbf{x}_j) \mathbf{P}_{x_j})^2) \quad (5)$$

patch 自相似性约束式(5)表示去噪图像中的 patch 之间具有强相关性, 通过相关邻域 patch 的加权, 构成了对于 patch  $\mathbf{P}_{x_i}$  的估计, 同时图像中所有像素点的 patch 都与周围邻域 patch 的相似性达到最大. 通过 patch 的自相似性约束, 克服了孤立像素点估计相似性不准确的问题, 对于边缘、纹理等图像结构信息得到很好的保真.

## 3 自适应非局部 patch 正则图像恢复模型

### 3.1 自适应权函数

在已有的权函数中, 大都采用  $L^2$  距离下的高斯函数, Liu 等提出方向性自适应的权函数:

$$\mathbf{W}_S(\mathbf{x}_i, \mathbf{x}_j) = \frac{\sqrt{\det(\mathbf{S}_j)}}{2\pi h^2 \mu_j^2} \exp\left\{-\frac{(\mathbf{x}_i - \mathbf{x}_j)^T \mathbf{S}_j (\mathbf{x}_i - \mathbf{x}_j)}{2h^2 \mu_j^2}\right\} \quad (6)$$

其中  $\mathbf{S}_j$  为点  $\mathbf{x}_j$  处的改进的结构张量矩阵, 详见文献<sup>[10]</sup>.

权值  $\mathbf{W}_S$  度量了像素点  $\mathbf{x}_i$  和  $\mathbf{x}_j$  的相关性, 像素间各向异性距离成反比. 通过结构张量矩阵反映的图像灰度和梯度信息, 实现了自适应选择像素的非局部相关邻域  $\delta(\mathbf{x}_i)$ , 如果是边缘点, 则沿着边缘方向搜索相似 patch, 此时邻域可以为椭圆, 其长短轴由改进结构张量矩阵的特征值决定. 像素点的相关邻域充分考虑到

了方向性和几何结构性,为 patch 间的权值计算提供了更加可靠的估计,从而对于图像结构和方向信息具有更强的保持性能。

在进行 patch 相似性匹配时,采用上述数据自适应权函数,得到自适应非局部 patch 正则约束:

$$\sum_i (P_{x_i} - \sum_{x_j \in \delta(x_i)} W_S(x_i, x_j) P_{x_j})^2 \quad (7)$$

### 3.2 模型提出

设  $\mathbf{z}$  为观测图像,  $\mathbf{D}$  为降采样因子,  $\mathbf{H}$  为退化算子,  $\mathbf{n}$  为噪声,图像的退化模型为:

$$\mathbf{z} = \mathbf{D}\mathbf{H}\mathbf{y} + \mathbf{n} \quad (8)$$

图像恢复的目的是从中恢复真实图像  $\mathbf{y}$ , 其最小二乘的图像恢复模型为:

$$\mathbf{y}^* = \arg \min_y (\|\mathbf{z} - \mathbf{D}\mathbf{H}\mathbf{y}\|_2^2) \quad (9)$$

此模型的解不唯一,需要加入正则化约束. 若加入 TV 约束,则得到图像恢复的 ROF 模型:

$$\mathbf{y}^* = \arg \min_y (\|\mathbf{z} - \mathbf{D}\mathbf{H}\mathbf{y}\|_2^2 + \beta \|\nabla \mathbf{y}\|_1) \quad (10)$$

这是一种广泛应用的模型,其中第一项为  $L^2$  范数的数据保真项,要求经过退化后的真实图像  $\mathbf{y}$  和观测图像  $\mathbf{z}$  在  $L^2$  范数意义下最相似. 第二项为 TV 正则项,TV 项正则是对图像分片光滑的先验,用以保持边缘. 正则化参数  $\lambda$  在保真项和正则项取得平衡,  $\beta$  越大,图像越光滑.

TV 模型可以达到很好平滑(去噪)效果,但不能保持纹理等几何结构. 图像纹理具有强重复性及结构方向性,非局部以相似性作为权重,因而可以达到很好的纹理保持效果. 将非局部自相似性约束和 TV 正则项结合,提出了自适应非局部 patch 正则化图像恢复模型:

$$\mathbf{y}^* = \arg \min_y (\|\mathbf{z} - \mathbf{D}\mathbf{H}\mathbf{y}\|_2^2 + \alpha \sum_i (\|P_{x_i} - \sum_{x_j \in \delta(x_i)} W_S(x_i, x_j) P_{x_j}\|_2^2 + \beta \|\nabla \mathbf{y}\|_1)) \quad (11)$$

模型中第一项为  $L^2$  范数的数据保真项,第二项为方向性非局部 patch 自相似正则项约束,当前像素点  $x_i$  对应的 patch  $P_{x_i}$  可以由其邻域  $\delta(x_i)$  内相似的 patch  $P_{x_j}$  来估计,权值取决于像素点之间的自适应权函数  $W_S$ . 权函数  $W_S$  在 patch 自相似性度量中加入结构张量信息,自适应的、更加准确的计算了 patch 之间的相似性. 第二项的加入有效利用了图像的自身相似性及图像中 patch 自相似性,对于图像中的纹理或几何结构部分具有良好的保持性能. 第三项为传统的 TV 正则项,  $\alpha, \beta$  为正则化参数.

相比较文献[15]提出的非局部正则、自回归以及稀疏性的图像恢复模型,本文模型在 patch 正则化先验中加入方向性,自适应的得到更准确的相似性度量,同时,结合 TV 正则而非稀疏性,算法复杂度得到简化.

### 3.3 模型的分裂 Bregman 解法

在模型求解过程中,参考文献[15]中的方法,采用以下的记号,对模型进行简化.

记  $\mathbf{A}$  由权函数构成的非局部矩阵

$$\mathbf{A} = (a_{ij})_{N^2 \times M^2} a_{ij} = \begin{cases} W(x_i, x_j), & x_j \in \delta(x_i) \\ 0, & x_j \notin \delta(x_i) \end{cases} \quad (12)$$

则模型式(11)可写成矩阵形式:

$$\mathbf{y}^* = \arg \min_y \|\mathbf{z} - \mathbf{D}\mathbf{H}\mathbf{y}\|_2^2 + \alpha \|\mathbf{I} - \mathbf{A}\mathbf{y}\|_2^2 + \beta \|\nabla \mathbf{y}\|_1 \quad (13)$$

结合式(13)中的第一项和第二项:

$$\mathbf{y}^* = \arg \min_y \left( \left\| \begin{bmatrix} \mathbf{z} \\ 0 \end{bmatrix} - \begin{bmatrix} \mathbf{D}\mathbf{H} \\ \alpha(\mathbf{I} - \mathbf{A}) \end{bmatrix} \mathbf{y} \right\|_2^2 + \beta \|\nabla \mathbf{y}\|_1 \right) \quad (14)$$

采用记号:  $\tilde{\mathbf{z}} = \begin{bmatrix} \mathbf{z} \\ 0 \end{bmatrix}$ ,  $\mathbf{K} = \begin{bmatrix} \mathbf{D}\mathbf{H} \\ \alpha(\mathbf{I} - \mathbf{A}) \end{bmatrix}$ , 则式(14)可简洁的表示为:

$$\mathbf{y}^* = \arg \min_y (\|\tilde{\mathbf{z}} - \mathbf{K}\mathbf{y}\|_2^2 + \beta \|\nabla \mathbf{y}\|_1) \quad (15)$$

模型式(15)是一般的图像恢复问题,有很多的解法:迭代阈值法,向前向后分裂法, Bregman 迭代法,梯度下降法等. 在此采用分裂 Bregman 迭代来求解.

文献[17]提出分裂 Bregman 方法,该方法能够快速求解全变差正则化的 PDE 图像恢复问题,如图像去噪、恢复、MRI 重建等等问题,成功地解决了一直困扰 TV 模型的计算复杂高问题. 分裂 Bregman 方法的基本思想是引入辅助变量,替换原目标泛函中较难处理部分,如不可分离项、非光滑项、非线性项等等,从而简化问题的求解,并添加辅助变量与替换部分之间的等式约束,保证新问题与原问题同解.

对模型式(15), Split-Bregman 算法建立的模型如下:

$$\mathbf{y}^* = \arg \min_y (\|\tilde{\mathbf{z}} - \mathbf{K}\mathbf{y}\|_2^2 + \beta \|\mathbf{d}\|_1) \quad \text{s.t.} \quad \mathbf{d} = \nabla \mathbf{y} \quad (16)$$

将此等式约束问题式(16)转化为非等式约束:

$$\min_{y, d} (\|\tilde{\mathbf{z}} - \mathbf{K}\mathbf{y}\|_2^2 + \beta \|\mathbf{d}\|_1 + \lambda \|\mathbf{d} - \nabla \mathbf{y}\|_2^2) \quad (17)$$

得到分裂 Bregman 算法:

$$(\mathbf{y}^{n+1}, \mathbf{d}^{n+1}) = \arg \min_{y, d} (\|\tilde{\mathbf{z}} - \mathbf{K}\mathbf{y}\|_2^2 + \beta \|\mathbf{d}\|_1 + \lambda \|\mathbf{d} - \nabla \mathbf{y} - \mathbf{b}^n\|_2^2) \quad (18)$$

$$\mathbf{b}^{n+1} = \mathbf{b}^n + (\nabla \mathbf{y}^{n+1} - \mathbf{d}^{n+1}) \quad (19)$$

分裂  $L^1$  和  $L^2$  范数,式(18)转化为两个子问题的求解:

$$\mathbf{y}^{n+1} = \arg \min_y (\|\tilde{\mathbf{z}} - \mathbf{K}\mathbf{y}\|_2^2 + \lambda \|\mathbf{d}^n - \nabla \mathbf{y} - \mathbf{b}^n\|_2^2) \quad (20)$$

$$\mathbf{d}^{n+1} = \arg \min_d (\beta \|\mathbf{d}\|_1 + \lambda \|\mathbf{d} - \nabla \mathbf{y} - \mathbf{b}^n\|_2^2) \quad (21)$$

问题式(20)关于  $\mathbf{y}$  是二次的,求导后变为线性问题,可直接用最速下降法等求解:

$$\mathbf{y}^{n+1} = \mathbf{y}^n + \mathbf{K}^T(\mathbf{K}\mathbf{y}^n - \tilde{\mathbf{z}} - \lambda \operatorname{div}(\nabla \mathbf{y} + \mathbf{b}^n - \mathbf{d}^n)) \quad (22)$$

式(21)是  $L^1$  问题,等价于软阈值:

$$\mathbf{d}^{n+1} = \operatorname{shrink}(\nabla \mathbf{y} + \mathbf{b}^n, \beta/\lambda) \quad (23)$$

其中 shrink 为软阈值函数:

$$\operatorname{shrink}(v, \gamma) = \operatorname{sign}(v) \max(|v| - \gamma, 0) \quad (24)$$

综上,模型式(15)的分裂 Bregman 迭代算法流程如下:

方向性非局部 patch 正则化模型分裂 Bregman 迭代算法:

输入:观测图像  $\mathbf{z}$ , 矩阵  $\mathbf{K}$ , 正则化参数  $\alpha, \beta$ , 松弛参数  $\lambda, \mathbf{y}^0 = \mathbf{z}, \mathbf{b}^0 = 0, \mathbf{d}^0 = 0$ .

迭代:对  $n = 0, 1, 2, \dots$

**Step1** 求解子问题式(21)得到  $\mathbf{d}^{n+1}$ ;

**Step2** 求解子问题式(19)得到  $\mathbf{b}^{n+1}$ ;

**Step3** 求解子问题式(22)迭代得到  $\mathbf{y}^{n+1}$ , 若  $\mathbf{y}^{n+1}$  满足迭代终止条件, 则迭代终止; 否则,  $n := n + 1$ , 转至 Step1.

输出:恢复图像  $\mathbf{y}^* = \mathbf{y}^{n+1}$ .

## 4 实验结果与分析

为了检验本文方法的有效性,进行了两组数值实验:图像去噪和单幅图像超分辨率重建.

### 4.1 图像去噪实验

在图像去噪实验中,比较本文方法、文献[1]中的 TV 模型以及文献[15]中非局部稀疏性结合的正则模型(NLSP).去噪实验的数据选用  $256 \times 256$  大小的 Lena、Woman、Cameraman 图像,分别加入标准差  $\sigma = 10$  和  $\sigma = 20$  的高斯白噪声,如图 3 所示.




图3 测试图像及噪声图像

为了客观评价图像去噪效果,采用的定量评价指标峰值信噪比(PSNR)和结构相似性指标(SSIM),PSNR 与 SSIM 定义如下:

大小为  $M \times N$  的噪声图像  $\mathbf{f}$  和去噪图像  $\mathbf{u}$  的 PSNR 定义为:

$$\text{PSNR} = 10 \log_{10} \frac{255^2}{\frac{1}{M \times N} \sum_{i=1}^M \sum_{j=1}^N [f(i, j) - u(i, j)]^2} \quad (25)$$

$$\text{SSIM} = \frac{(2\mu_f \mu_u + c_1)(2\sigma_{fu} + c_2)}{(\mu_f^2 + \mu_u^2 + c_1)(\sigma_f^2 + \sigma_u^2 + c_2)} \quad (26)$$

其中  $\mu_f, \mu_u$  分别为图像  $\mathbf{f}, \mathbf{u}$  的均值, 对应方差为  $\sigma_f, \sigma_u$ ,  $\sigma_{fu}$  为协方差.

图 4, 图 5 比较了 TV 方法、NLSP 方法以及本文方法对图 3 中的 Cameraman 和 Woman 图像的去噪结果. 图 4 中, 本文方法去除了大量噪声, 去噪图像细节清晰, 边缘比较锐化, 同时残差图像中照相机三角支架只有很少一部分可见, 对于几何结构强边缘的保持达到了较好效果. TV 虽然较好去除了噪声, 同时保持了图像中的强边缘结构. 然而图像的弱边缘和纹理等小尺度被磨光, 表现在残差图像中残留的部分最多. NLSP 方法也达到了比较好的去噪效果, 同时图像中的边缘和纹理部分保持较好, 略高于 TV 的, 具有比较高的结构保持性能. 但由于采用了自回归模型, 图像像素邻域内灰度差别比较大的区域出现了失真, 对应的残差图像中区域出现了亮点. 三种方法的 PSNR 依次为: 31.4945、29.3779、31.9716, 同时本文算法的 SSIM 最大: 0.8626. 从图 5 中对 Woman 图像的去噪效果来看, 本文方法仍在去噪同时更好保持了图像中的方向性边缘及纹理结




图4 Cameraman图像去噪结果比较




图5 Woman图像去噪结果比较

构,对应到残差图像中,本文方法残留的边缘及纹理信息最少.图 5 中三种方法 PSNR 依次为:24.1724、25.3035、25.4639,SSIM 依次为:0.6950、0.7171、0.7242.

表 1 给出了不同噪声水平下,三种方法去噪结果的 PSNR 和 SSIM.本文方法具有最高 PSNR,同时 SSIM 达到最大,进一步说明了方法在去噪同时很好保持了图像的结构信息.

表 1 不同噪声情形下去噪图像 PSNR 与 SSIM 比较

图像	标准差	TV		NLSP		本文方法	
		PSNR	SSIM	PSNR	SSIM	PSNR	SSIM
Lena	10	32.4178	0.8947	32.6898	0.8808	33.0046	0.9042
Lena	20	28.9775	0.8219	29.3357	0.8320	29.5956	0.8395
Cammerman	10	31.4945	0.8476	29.3779	0.7822	31.9716	0.8626
Cammerman	20	27.7914	0.7727	27.5237	0.7771	28.2578	0.7932
Woman	10	28.8248	0.8791	29.3361	0.8695	29.5856	0.8872
Woman	20	24.1724	0.6950	25.3035	0.7171	25.4639	0.7242

4.2 图像超分辨率实验

单幅图像的超分辨率实验中,对一幅经过 2 倍降采样、高斯模糊、噪声污染的退化图像进行恢复.表 2、3 分别给出了无噪声污染和有噪声污染的退化情况下三种方法的 PSNR 与 SSIM 比较.

表 2 无噪声情形下超分辨率恢复图像 PSNR 与 SSIM 比较

Image	TV		NLSP		本文方法	
	PSNR	SSIM	PSNR	SSIM	PSNR	SSIM
Lena	31.2604	0.9135	30.9372	0.9172	31.2217	0.9210
Cameraman	27.2605	0.8810	26.9636	0.8856	27.4522	0.8894
Woman	21.7410	0.5497	22.0812	0.5562	22.5336	0.5670

表 3 有噪声情形下超分辨率恢复图像 PSNR 与 SSIM 比较

Image	TV		NLSP		本文方法	
	PSNR	SSIM	PSNR	SSIM	PSNR	SSIM
Lena	27.8469	0.7659	27.6894	0.8045	27.8566	0.8056
Cameraman	24.8900	0.7123	24.8967	0.7745	25.3981	0.7865
Woman	20.3021	0.4210	20.9240	0.4384	20.9470	0.4435

当退化过程中不含有噪声时,对于不同图像,TV 方法可以达到比较高的 PSNR,但对应的 SSIM 却比较低.这是由于 TV 方法在重建图像时,只考虑了边的保持性,丢失了部分纹理等结构信息.相对于 TV 模型,NLSP 方法的 PSNR 比较低,但自回归和非局部项保证了结构信息的良好保持,得到比较大的 SSIM,特别是丰富纹理的 Woman 图像,本文方法和 NLSP 方法都得到了纹理重建的良好视觉效果.本文方法继承了 TV 保持边缘的优点,非局部自相似性约束以及自适应权函数保证了算法在保持方向性结构信息方面优于其它两种方法,恢复图像中强弱边缘及纹理部分都得到了有效保持,具有较高的 SSIM.

当含有少量噪声时( $\sigma = 5$ ),本文方法有效抑制了噪声,具有良好的去模糊、去噪性能,同时能够得到边

缘纹理等结构的清晰重建,在结构保持方面优于明显其他两种方法.

综上,与其它两种方法相比较,本文算法具有良好的视觉重建效果以及较好的结构保持性能.

最后我们比较三种方法的执行效率,NLSP 方法需要进行自回归模型参数的学习,故计算量较大,平均为 630s,TV 方法的执行时间平均为 147s,由于采用了分裂 Bregman 迭代,本文算法具有最高的执行效率,平均时间为 83s.

5 结论

针对图像恢复模型,提出了非局部 patch 正则和 TV 正则结合的图像恢复模型,进一步改进了非局部中权函数的计算,利用各向异性距离,方向性自适应的调节邻域的搜索.并采用分裂 Bregman 迭代进行高效求解,得到了快速的数值解法.分别进行了图像去噪和恢复两组实验,实验结果表明本文方法在图像去噪和恢复中很好保持了图像的几何结构,得到的恢复图像不仅具有良好的视觉效果,而且达到了较高的 PSNR 和 SSIM.

参考文献

[1] L I Rudin, S Osher, E Fatemi. Nonlinear total variation based noise removal algorithms [J]. Physical D, 1992, 60(5): 259 – 268.

[2] A Buades, B Coll, J Morel. A review of image denoising algorithms, with a new one [J]. SIAM Multiscale Modeling and Simulation, 2005, 4(2): 290 – 530.

[3] B Goossens, H Luong, et al. An improved nonlocal image denosing algorithm[A]. Proc Int Workshop on Local and Non-Local Approximation in Image Processing [C]. Lausanne: IEEE Press, 2008. 134 – 156.

[4] K Dabov, A Foi, et al. Image denoising by sparse 3D transform-domain collaborative filtering [J]. IEEE Trans Image Process, 2007, 16(8): 2080 – 2095.

[5] K Viadimir, F Alessandro, et al. From local kernel to nonlocal multiple-model image denoising [J]. International Journal of Compute Vision, 2010, 86(1): 1 – 32.

[6] J Tian, W Y Yu, S L Xie. On the kernel selection of nonlocal filtering for image denoising [A]. Proc Int Conf Machine Learning and Cybernetics [C]. Kunming: IEEE Press, 2008. 2964 – 2969.

[7] J D Peter, V K Govindan, T M Abraham. Robust estimation approach for nonlocal means denoising based on structural similar patches [J]. Int Journal of Open Problem Compt Math, 2009, 2 (2): 293 – 310.

[8] 孙伟峰, 彭玉华. 一种改进的非局部平均去噪方法[J]. 电

- 子学报, 2010, 38(4): 923 – 928.
- Sun Wei-feng, Peng Yu-hua. An improved nonlocal means denoising approach[J]. Acta Electronica Sinica, 2010, 38(4): 923 – 928. (in Chinese)
- [9] H Takeda, S Farsiu, P Milanfar. Kernel regression for image processing and reconstruction [J]. IEEE Trans Image Process, 2007, 16(2): 349 – 366.
- [10] H Y Liu, Z H Wei. An edge-adaptive structure tensor kernel regression for image interpolation[A]. Proc Int Conference on Future Computer and Communication [C]. Wuhan: IEEE Press, 2010. 2681 – 2684.
- [11] L Pizarro, P Mrazek, et al. Generalized nonlocal image smoothing[J]. Int Journal Compute Vision, 2010, 90(1): 62 – 87.
- [12] T Brox, O Kleinschmidt, D Cremers. Efficient nonlocal means for denoising of textural patterns [J]. IEEE Trans Image Process, 2008, 17(7): 1057 – 1092.
- [13] S Kindermann, S Osher, P W Jones. Deblurring and denoising of images by nonlocal functionals[J]. SIAM Multiscale Modeling and Simulation 2005, 4(4): 1091 – 1115.
- [14] Y F Lou, X Q Zhang, S Osher. Image restoration via nonlocal operators [J]. Journal of Scientific Computing, 2009, 42(2): 185 – 197.
- [15] W Dong, L Zhang, et al. Image deblurring and super-resolution by adaptive sparse domain selection and adaptive regularization [J]. IEEE Trans Image Process, 2011, 20(7): 1838 – 1857.
- [16] M Protter M Elad, et al. Generalizing the nonlocal-means to super-resolution reconstruction [J]. IEEE Image Processing 2009, 18(1): 36 – 51.
- [17] T Goldstein, S Osher. The split Bregman method for l1 regularized problems [J]. SIAM Journal on Imaging Sciences, 2009, 2(2): 323 – 343.

### 作者简介



**刘红毅** 女, 生于 1974 年, 讲师, 主要研究方向为图像建模, 多尺度分析, 图像去噪与恢复.

E-mail: hylu@mail.njust.edu.cn



**韦志辉** 男, 生于 1963 年, 教授, 博士生导师, 主要研究领域为图像建模理论与分析, 遥感图像处理, 压缩感知的图像重建.

E-mail: gswei@mail.njust.edu.cn



**张峥嵘** 女, 生于 1977 年, 讲师, 主要研究方向为图像恢复, 变分法图像处理.

E-mail: zhengrongzhang6@hotmail.com