

文章编号:1007-5321(2018)01-0081-07

DOI:10.13190/j.jbupt.2017-101

# $L_1$ 范数约束的非局部均值正则图像去模糊模型

冯象初, 刘 鑫, 杨春雨, 王卫卫

(西安电子科技大学 数学与统计学院, 西安 710071)

**摘要:**为了保护图像边缘、细节等信息,建立了 $l_1$ 范数约束的非局部均值正则模型。首先通过实验证明了非局部均值去噪算法余项的概率密度函数具有较强的拖尾性质,符合 Laplace 分布的特点。基于此,使用 $l_1$ 范数约束的非局部均值去噪算法余项作为新的正则项,提出了新的正则模型。然后利用 Bregman 算子分裂算法求解得到相应的优化算法,并且可将新算法看成 Plug-and-Play Priors 算法的推广。实验结果表明,新模型在去除模糊,保护图像边缘、细节等信息方面的性能都优于 $l_2$ 范数约束的非局部均值正则模型和 Plug-and-Play Priors 模型。

**关 键 词:**图像去模糊; 非局部均值算法; 正则模型; Bregman 算子分裂算法

中图分类号: TN929. 53

文献标志码: A

## $L_1$ -Nonlocal Means Regularization Model for Image Deblurring Problem

FENG Xiang-chu, LIU Xin, YANG Chun-yu, WANG Wei-wei

(School of Mathematics and Statistics, Xidian University, Xi'an 710071, China)

**Abstract:** An  $l_1$ -nonlocal means regularization model was proposed in order to preserve the edges and details while deblurring the blurred image. Firstly, the article empirically gave out that the distribution of the residual in the nonlocal means denoising algorithm (differences between the noisy image and the denoised result) is heavy-tailed, which well fits the Laplacian distribution. Based on this observation, a new regularization model was proposed by using the  $l_1$ -norm constrained residual as the new regularization term. Then the corresponding optimization algorithm was designed by utilizing the Bregmanized operator splitting algorithm, which can be regarded as an extension of plug-and-play Priors algorithm. Experiments show that the new model achieves better performance than the  $l_2$ -nonlocal means regularization model and the plug-and-play priors model in terms of both restoration results and preserving the edges and details of the image.

**Key words:** image deblurring; non-local means algorithm; regularization model; Bregmanized operator splitting

图像去模糊是图像恢复<sup>[1]</sup> 中最重要的研究问题之一。通常图像模糊过程可用模型<sup>[2]</sup> 表示为

$$\mathbf{f} = \mathbf{A} * \mathbf{u} + \mathbf{k} \quad (1)$$

其中:  $\mathbf{f} \in \mathbf{R}^N$  ( $N = n \times n$ ) 为含有噪声的模糊观测图像;  $\mathbf{A}$  为模糊卷积算子, 也称为点扩展函数或卷积

核;  $*$  为卷积运算, 它使图像模糊;  $\mathbf{u} \in \mathbf{R}^N$  为原始图像;  $\mathbf{k} \in \mathbf{R}^N$  是方差为  $\sigma^2$ , 均值为 0 的高斯白噪声。图像非盲去模糊的任务<sup>[3]</sup> 是利用已知含有噪声的模糊图像  $\mathbf{f}$  和卷积核  $\mathbf{A}$  估计真实的清晰图像  $\mathbf{u}$ 。

图像去模糊问题是高度病态的。正则化方法通

过加入原始图像的先验信息引入正则项<sup>[4]</sup>,使图像去模糊问题可以得到一个稳定的解。该方法易于求解,因此得到广泛关注。2006 年,Buades 等<sup>[5]</sup>提出了非局部均值(NLM, nonlocal means)正则模型;2013 年,Wang 等<sup>[6]</sup>在 Buades 等<sup>[5]</sup>提出的 NLM 正则模型的基础上,提出了  $l_2$  范数约束的 NLM ( $l_2$ -NLM) 正则模型,并取得了很好的去模糊效果。然而,笔者通过实验验证了 NLM 去噪算法余项的概率密度函数更加逼近 Laplace 分布,而非 Gaussian 分布,因此使用 NLM 去噪算法余项的  $l_1$  范数作为先验约束比  $l_2$  范数更能刻画原始图像的先验信息。基于此,笔者提出了  $l_1$  范数约束的 NLM ( $l_1$ -NLM) 正则模型和相应的优化算法。该算法还可以看成是文献[7-8]中描述的 Plug-and-play priors ( $P^3$ ) 算法的推广。实验结果表明,所提出的模型和算法在去除模糊及保护图像边缘、细节等方面优于目前常用的 NLM 模型(如  $l_2$ -NLM 模型、 $P^3$ -NLM 模型等)。

## 1 相关工作

### 1.1 NLM 去噪算法

NLM<sup>[9]</sup>去噪算法的主要思想是:重构图像中每个像素点的值由噪声图像中所有像素点的值通过加权平均估计得到,其中权函数是根据对应像素点之间的相似性度量来确定的。由于 NLM 算法在计算每个像素的过程中应用了非局部思想和图像的自相似性,所以取得了很好的去噪效果。

### 1.2 $l_2$ -NLM 正则模型

Buades 等<sup>[5]</sup>在 2006 年创新性地使用  $l_2$  范数约束的 NLM 去噪算法余项作为正则项,即正则项为  $\| \mathbf{u} - \text{NLM}_f(\mathbf{u}) \|_2^2$ ,则该模型可描述为

$$\begin{aligned} \hat{\mathbf{u}} = \operatorname{argmin}_{\mathbf{u}} & \| \mathbf{u} - \text{NLM}_f(\mathbf{u}) \|_2^2 \\ \text{s. t. } & \| \mathbf{A} * \mathbf{u} - \mathbf{f} \|_2^2 \leq \sigma^2 \end{aligned} \quad (2)$$

其中:  $\| \cdot \|_2^2$  表示  $l_2$  范数的二次方;  $\text{NLM}_f(\mathbf{u})$  表示在执行 NLM 去噪算法时,权重值由观测图像  $\mathbf{f}$  计算得到,而像素值由原始图像  $\mathbf{u}$  得到。

Wang 等<sup>[6]</sup>在 Buades 等<sup>[5]</sup>提出的 NLM 正则模型的基础上,通过对 NLM 去噪算法  $\text{NLM}(\cdot)$  的权重进行改进,提出了  $l_2$ -NLM 正则模型。该模型可描述为

$$\begin{aligned} \hat{\mathbf{u}} = \operatorname{argmin}_{\mathbf{u}} & \| \mathbf{u} - \text{NLM}_u(\mathbf{u}) \|_2^2 \\ \text{s. t. } & \| \mathbf{A} * \mathbf{u} - \mathbf{f} \|_2^2 \leq \sigma^2 \end{aligned} \quad (3)$$

其中  $\text{NLM}_u(\mathbf{u})$  表示在执行 NLM 去噪算法时,权重

值和像素值均由原始图像  $\mathbf{u}$  计算得到,并且  $\text{NLM}_u(\mathbf{u})$  可近似估计为

$$\mathbf{u}^{k+1} = \text{NLM}_{u^k}(\mathbf{u}^k) \quad (4)$$

利用 Zhang 等<sup>[10]</sup>提出的 Bregman 算子分裂(BOS, Bregmanized operator splitting)算法对式(3)迭代求解:

$$\left. \begin{aligned} \mathbf{v}^{k+1} &= \mathbf{u}^k - \delta \mathbf{A}^T * (\mathbf{A} * \mathbf{u}^k - \mathbf{f}^k) \\ \mathbf{u}^{k+1} &= \operatorname{argmin}_{\mathbf{u}} (\| \mathbf{u} - \text{NLM}_{v^{k+1}}(\mathbf{v}^{k+1}) \|_2^2 + \lambda \| \mathbf{u} - \mathbf{v}^{k+1} \|_2^2) \\ \mathbf{f}^{k+1} &= \mathbf{f}^k + \mathbf{f} - \mathbf{A} * \mathbf{u}^{k+1} \end{aligned} \right\} \quad (5)$$

其中: $\delta$  为常参数, $\lambda$  为正则化参数, $\mathbf{u}^k$  为迭代恢复图像, $\mathbf{f}^k, \mathbf{v}^k$  为含有噪声的迭代模糊图像。

式(5)中第 2 步可以通过求导得到

$$\mathbf{u}^{k+1} = \frac{1}{1+\lambda} \text{NLM}_{v^{k+1}}(\mathbf{v}^{k+1}) + \frac{\lambda}{1+\lambda} \mathbf{v}^{k+1} \quad (6)$$

式(6)可以理解为 NLM 的结果补充了一个惯性项。所以, $l_2$ -NLM 模型用 BOS 求解可完整写为

$$\left. \begin{aligned} \mathbf{v}^{k+1} &= \mathbf{u}^k - \delta \mathbf{A}^T * (\mathbf{A} * \mathbf{u}^k - \mathbf{f}^k) \\ \mathbf{u}^{k+1} &= \frac{1}{1+\lambda} \text{NLM}_{v^{k+1}}(\mathbf{v}^{k+1}) + \frac{\lambda}{1+\lambda} \mathbf{v}^{k+1} \\ \mathbf{f}^{k+1} &= \mathbf{f}^k + \mathbf{f} - \mathbf{A} * \mathbf{u}^{k+1} \end{aligned} \right\} \quad (7)$$

## 2 $l_1$ -NLM 正则模型

### 2.1 模型的建立

实际上,早在 2005 年 Buades 等<sup>[9]</sup>就将原始图像  $\mathbf{u}$  与其经过去噪算法处理的图像的差定义为方法噪声。由于干净图像  $\mathbf{u}$  经过 NLM 去噪算法处理后基本不变,即  $\text{NLM}(\mathbf{u})$  可以近似看成原始图像  $\mathbf{u}$ ,所以  $\mathbf{u} - \text{NLM}_u(\mathbf{u})$  是稀疏的。与此同时,Buades 等<sup>[9]</sup>给出了一些不同去噪算法作用下的方法噪声图像,如图 1 所示。

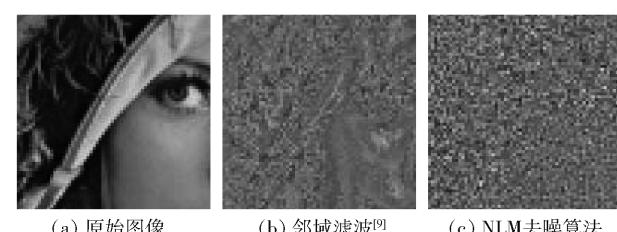


图 1 自然图像的方法噪声实验

基于以上分析, $\mathbf{u} - \text{NLM}_u(\mathbf{u})$  是稀疏的,因此理论上  $\mathbf{u} - \text{NLM}_u(\mathbf{u})$  的概率密度函数应该近似服从 Laplace 分布。为了更加明确地表明上述结论的合理性,笔者对  $\mathbf{u} - \text{NLM}_u(\mathbf{u})$  进行了概率密度函数分

布的拟合实验。为了使验证结果准确合理,选取的10张测试图包括多结构图像、多纹理图像、既有纹理又有结构的图像等,如图2所示。结果表明,其概率密度函数更加逼近 Laplace 分布而非 Gaussian 分布,如图3所示。由于 Gaussian 分布的最大后验估计可以用  $L_2$  范数刻画<sup>[11]</sup>,而 Laplace 分布可以用  $L_1$  范数刻画<sup>[11]</sup>,所以使用  $\mathbf{u} - \text{NLM}_{\mathbf{u}}(\mathbf{u})$  的  $L_1$  范数作为先验约束比  $L_2$  范数作为先验约束更能刻画图像的先验信息。



图2 从上到下、从左到右标签为(a)~(j)的10张测试图

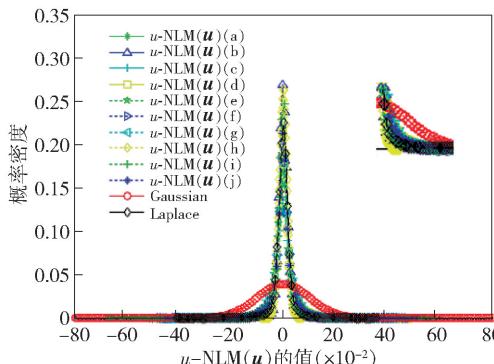


图3 不同图像  $\mathbf{u} - \text{NLM}_{\mathbf{u}}(\mathbf{u})$  的概率密度函数分布

基于此,提出了  $L_1$ -NLM 正则模型:

$$\begin{aligned}\hat{\mathbf{u}} = \arg \min_{\mathbf{u}} & \| \mathbf{u} - \text{NLM}_{\mathbf{u}}(\mathbf{u}) \|_1 \\ \text{s. t. } & \| \mathbf{A} * \mathbf{u} - \mathbf{f} \|_2^2 \leq \sigma^2\end{aligned}\quad (8)$$

其中  $\| \cdot \|_1$  表示  $L_1$  范数。

## 2.2 模型的求解

根据 BOS 算法求解式(8):

$$\mathbf{v}^{k+1} = \mathbf{u}^k - \delta \mathbf{A}^T * (\mathbf{A} * \mathbf{u}^k - \mathbf{f}^k) \quad (9)$$

$$\mathbf{u}^{k+1} = \operatorname{argmin}_{\mathbf{u}} \left( \| \mathbf{u} - \text{NLM}_{\mathbf{v}^{k+1}}(\mathbf{v}^{k+1}) \|_1 + \lambda \| \mathbf{u} - \mathbf{v}^{k+1} \|_2^2 \right) \quad (10)$$

$$\mathbf{f}^{k+1} = \mathbf{f}^k + \mathbf{f} - \mathbf{A} * \mathbf{u}^{k+1} \quad (11)$$

其中关键问题是式(10)的求解。实际上,令  $\mathbf{u} - \text{NLM}_{\mathbf{v}^{k+1}}(\mathbf{v}^{k+1}) = \mathbf{p}$ ,则式(10)可写成

$$\begin{aligned}\mathbf{u}^{k+1} = \operatorname{argmin}_{\mathbf{u}} & \left( \lambda \| \mathbf{p} - (\mathbf{v}^{k+1} - \text{NLM}_{\mathbf{v}^{k+1}}(\mathbf{v}^{k+1})) \|_2^2 + \| \mathbf{p} \|_1 \right)\end{aligned}\quad (12)$$

这是  $L_1$  正则下的逼近问题,使用软阈值方法求解<sup>[12]</sup>,得到

$$\mathbf{u}^{k+1} = T_{\frac{1}{2\lambda}}(\mathbf{v}^{k+1} - \text{NLM}_{\mathbf{v}^{k+1}}(\mathbf{v}^{k+1})) + \text{NLM}_{\mathbf{v}^{k+1}}(\mathbf{v}^{k+1}) \quad (13)$$

其中  $T_\alpha: \mathbf{R}^n \rightarrow \mathbf{R}^n$  定义<sup>[12]</sup>为

$$T_\alpha(x_i) = \max\{|x_i| - \alpha, 0\} \operatorname{sgn}(x_i)$$

式(13)可以理解为 NLM 的结果补充了一个阈值项,则式(9)~式(11)可以整理为

$$\mathbf{v}^{k+1} = \mathbf{u}^k - \delta \mathbf{A}^T * (\mathbf{A} * \mathbf{u}^k - \mathbf{f}^k) \quad (14)$$

$$\mathbf{u}^{k+1} = T_{\frac{1}{2\lambda}}(\mathbf{v}^{k+1} - \text{NLM}_{\mathbf{v}^{k+1}}(\mathbf{v}^{k+1})) + \text{NLM}_{\mathbf{v}^{k+1}}(\mathbf{v}^{k+1}) \quad (15)$$

$$\mathbf{f}^{k+1} = \mathbf{f}^k + \mathbf{f} - \mathbf{A} * \mathbf{u}^{k+1} \quad (16)$$

根据式(14)~式(16), $L_1$ -NLM 模型的求解可描述为算法 1。对  $L_1$ -NLM 模型和  $L_2$ -NLM 模型分别使用 BOS 算法迭代求解后发现, $L_1$ -NLM 算法与  $L_2$ -NLM 算法的不同点仅在式(15)和式(6),这表明新模型在计算复杂性上和原来的模型相当,但处理的意义却明显不同。式(6)为迭代噪声模糊图像  $\mathbf{v}^{k+1}$  经 NLM 去噪算法处理后的图像与  $\mathbf{v}^{k+1}$  加权平均,而式(15)增加了  $\mathbf{v}^{k+1}$  经 NLM 去噪算法处理后的图像与  $\mathbf{v}^{k+1}$  残差的阈值。相比  $L_2$ -NLM 模型的简单加权平均而言, $L_1$ -NLM 模型加入的残差的阈值中既去除了噪声,同时又含有丰富的边缘细节信息,这与迭代正则化<sup>[13]</sup>的思想是完全一致的,因而能达到更好地保护图像边缘和细节信息的目的。

### 算法 1 $L_1$ -NLM 正则图像去模糊算法

输入:含噪模糊图  $\mathbf{f}$ ,模糊核  $\mathbf{A}$ ,参数  $\sigma, \delta$

预处理:Tikhonov 正则去卷积方法<sup>[14]</sup>对  $\mathbf{f}$  进行处理,得  $\mathbf{u}^0$ 。

初始值: $k=0, \mathbf{u}^0, \mathbf{f}^0 = \mathbf{f}, \mathbf{f}$ 。

**while**  $k \leq$  迭代次数

    更新  $\mathbf{v}$ :

$$\mathbf{v}^{k+1} = \mathbf{u}^k - \delta \mathbf{A}^T * (\mathbf{A} * \mathbf{u}^k - \mathbf{f}^k)$$

    更新  $\mathbf{u}$ :

$$\mathbf{u}^{k+1} = T_{\frac{1}{2\lambda}}(\mathbf{v}^{k+1} - \text{NLM}_{\mathbf{v}^{k+1}}(\mathbf{v}^{k+1})) +$$

$$\text{NLM}_{\mathbf{v}^{k+1}}(\mathbf{v}^{k+1})$$

    更新  $\mathbf{f}$ :

$$\mathbf{f}^{k+1} = \mathbf{f}^k + \mathbf{f} - \mathbf{A} * \mathbf{u}^{k+1}$$

    更新  $k$ :

$$k++$$

**end**

输出: $\mathbf{u}^k$ 。

值得注意的是,当  $\lambda = 0$  时,式(15)可退化为

$$\mathbf{u}^{k+1} = \text{NLM}_{v^{k+1}}(\mathbf{v}^{k+1}) \quad (17)$$

退化算法可完整写为

$$\left. \begin{array}{l} \mathbf{v}^{k+1} = \mathbf{u}^k - \delta \mathbf{A}^T * (\mathbf{A} * \mathbf{u}^k - \mathbf{f}^k) \\ \mathbf{u}^{k+1} = \text{NLM}_{v^{k+1}}(\mathbf{v}^{k+1}) \\ \mathbf{f}^{k+1} = \mathbf{f}^k + \mathbf{f} - \mathbf{A} * \mathbf{u}^{k+1} \end{array} \right\} \quad (18)$$

这与文献[7-8]中描述的 Plug-and-Play Priors 算法一致,记为  $P^3$ -NLM 算法。 $l_2$ -NLM 算法、 $l_1$ -NLM 算法、 $P^3$ -NLM 算法的区别仅在式(6)、式(15)、式(17)。相对于式(17)而言,式(6)和式(15)均有余项加回到恢复图像中,该余项中均含有丰富的边缘细节信息,所以理论上  $l_2$ -NLM 模型和  $l_1$ -NLM 模型比  $P^3$ -NLM 模型在保护图像边缘、细节信息方面有更好的性能。

### 3 仿真实验及分析

在仿真实验中,所用的图像均为  $256 \times 256$  的灰度图,如图 4 所示。为了验证所提模型和算法的性能表现,实验设定以下 3 组初始条件。

A 组: 实验所用图像均加有  $7 \times 7$  的均值模糊核和标准差为 5 的高斯白噪声。

B 组: 实验所用图像均加有  $9 \times 9$  的均值模糊核和标准差为 5 的高斯白噪声。

C 组: 实验所用图像均加有  $7 \times 7$  的均值模糊核和标准差为 10 的高斯白噪声。

与其对比的模型有 Buades 等<sup>[5]</sup>提出的非局部正则模型、 $P^3$ -NLM 模型<sup>[7]</sup>、 $l_2$ -NLM 模型<sup>[6]</sup>。采用以上模型作为对比,原因如下:

1) 以上模型是可实现的,并且会得到一个稳定的结果。



图 4 实验所用的测试图

注:从上到下、从左到右 15 张实验图分别为 Lenna、Peppers、Man、Boat、Barbara、Baboon、House、Hill、Patches、Couple、Bank、Hat、Reagan、Women、Columbia

2) 所提新模型是以上模型的改进,且都是基于正则化方法所提出的。

采用 2 两个标准来衡量实验恢复图像的质量,①数值结果,即峰值信噪比<sup>[15]</sup>(PSNR, peak signal to noise ratio)、结构相似度<sup>[15]</sup>(SSIM, structural similarity index metric);②视觉效果。并且,所有实验均在 Windows 7 操作系统下,4 GB 内存、Inter-Xeon 2.40 GHz 的计算机上由 Matlab2012b 完成。为了保证测试的有效性,在所有的测试实验中的参数均保持一致,即  $\delta = 1.01, \lambda = 0.015, k = 10$ 。

表 1 和表 2 给出了在相同模糊和噪声强度下 Buades 等<sup>[5]</sup>提出的非局部正则模型、 $P^3$ -NLM 模型、 $l_2$ -NLM 模型和  $l_1$ -NLM 模型对 15 张测试图去模糊的具体表现,包括 PSNR 值和 SSIM 值。从实验结果可以看出,和 Buades 等<sup>[5]</sup>提出的非局部正则模型相比,所提出的  $l_1$ -NLM 模型 PSNR 平均值比其高 1 dB 左右,SSIM 平均值比其高 0.6 左右;与  $P^3$ -NLM 模型相比, $l_1$ -NLM 模型的 PSNR 平均值比其高 0.3 dB 左右,SSIM 平均值比其高 0.02 左右;和  $l_2$ -NLM 模型相比, $l_1$ -NLM 模型的 PSNR 平均值比其高 0.2 dB 左右,SSIM 平均值比其高 0.02 左右。因此, $l_1$ -NLM 模型的 PSNR 值和 SSIM 值相对于其他模型均有提

表 1 A 组实验条件下不同去模糊方法的 PSNR 值

图像	Blur	Buades <sup>[5]</sup>	$P^3$ -NLM	$l_2$ -NLM	$l_1$ -NLM	dB
Lenna	23.02	26.44	26.94	27.09	27.31	
Peppers	23.89	27.63	28.59	28.68	28.72	
Man	21.36	24.44	25.25	25.33	25.80	
Boat	22.41	24.36	25.84	25.97	26.07	
Barbara	23.81	25.65	26.68	26.72	27.04	
Baboon	22.12	23.08	23.41	23.53	23.75	
House	25.06	29.63	30.39	30.42	30.61	
Hill	24.08	27.11	27.74	27.81	27.89	
Patches	19.04	21.32	21.94	22.08	22.33	
Couple	22.71	25.46	26.03	26.11	26.16	
Bank	19.56	24.30	24.88	24.98	25.25	
Hat	24.15	26.69	27.50	27.54	27.77	
Reagan	23.92	25.27	26.06	26.10	26.29	
Women	27.28	30.58	31.27	31.32	31.53	
Columbia	22.31	25.85	26.58	26.65	26.84	
<b>Average</b>	<b>22.98</b>	<b>25.85</b>	<b>26.61</b>	<b>26.69</b>	<b>26.89</b>	

升。由表3~表6所示结果可看出,其他的模糊尺度和噪声水平下的实验,  $l_1$ -NLM 模型也得到了相对较优的数值结果。

表2 A组实验条件下不同去模糊方法的SSIM值

图像	Blur	Buades <sup>[5]</sup>	$P^3$ -NLM	$l_2$ -NLM	$l_1$ -NLM
Lenna	0.589	0.701	0.744	0.747	0.763
Peppers	0.664	0.771	0.818	0.821	0.837
Man	0.529	0.709	0.759	0.760	0.775
Boat	0.490	0.668	0.713	0.715	0.731
Barbara	0.590	0.702	0.750	0.752	0.767
Baboon	0.366	0.503	0.532	0.536	0.560
House	0.608	0.748	0.792	0.793	0.812
Hill	0.528	0.675	0.725	0.724	0.741
Patches	0.423	0.602	0.646	0.650	0.664
Couple	0.463	0.659	0.700	0.709	0.726
Bank	0.515	0.733	0.765	0.767	0.785
Hat	0.637	0.735	0.776	0.782	0.799
Reagan	0.636	0.734	0.769	0.775	0.793
Women	0.717	0.786	0.826	0.831	0.848
Columbia	0.577	0.757	0.792	0.794	0.815
<b>Average</b>	<b>0.555</b>	<b>0.699</b>	<b>0.740</b>	<b>0.744</b>	<b>0.761</b>

表3 B组实验条件下不同去模糊方法的PSNR值

图像	Blur	Buades <sup>[5]</sup>	$P^3$ -NLM	$l_2$ -NLM	$l_1$ -NLM
Lenna	22.98	25.62	26.31	26.37	26.59
Peppers	22.52	26.58	27.30	27.32	27.59
Man	20.59	23.67	24.56	24.60	24.72
Boat	21.45	24.10	24.85	24.89	25.07
Barbara	22.27	25.13	25.94	26.00	26.15
Baboon	21.05	22.21	23.00	23.02	23.13
House	23.71	29.06	29.92	29.98	30.16
Hill	23.08	25.85	26.74	26.77	26.92
Patches	18.86	19.64	20.35	20.36	20.51
Couple	21.87	24.33	25.19	25.23	25.46
Bank	18.56	22.71	23.60	23.66	23.84
Hat	22.71	25.36	26.17	26.21	26.42
Reagan	23.13	24.79	25.49	25.53	25.70
Women	25.97	29.88	30.73	30.75	30.89
Columbia	21.00	25.42	26.16	26.12	26.34
<b>Average</b>	<b>21.97</b>	<b>24.96</b>	<b>26.75</b>	<b>25.78</b>	<b>25.97</b>

表4 B组实验条件下不同去模糊方法的SSIM值

图像	Blur	Buades <sup>[5]</sup>	$P^3$ -NLM	$l_2$ -NLM	$l_1$ -NLM
Lenna	0.540	0.661	0.719	0.721	0.743
Peppers	0.601	0.752	0.800	0.802	0.820
Man	0.493	0.694	0.734	0.738	0.762
Boat	0.442	0.675	0.671	0.673	0.686
Barbara	0.525	0.663	0.718	0.720	0.739
Baboon	0.318	0.422	0.470	0.472	0.490
House	0.559	0.746	0.791	0.795	0.814
Hill	0.460	0.625	0.667	0.669	0.690
Patches	0.314	0.550	0.602	0.604	0.621
Couple	0.406	0.611	0.661	0.666	0.687
Bank	0.448	0.700	0.738	0.741	0.764
Hat	0.549	0.677	0.717	0.718	0.742
Reagan	0.601	0.709	0.756	0.759	0.777
Women	0.686	0.768	0.813	0.814	0.831
Columbia	0.513	0.732	0.786	0.788	0.807
<b>Average</b>	<b>0.497</b>	<b>0.665</b>	<b>0.709</b>	<b>0.712</b>	<b>0.731</b>

表5 C组实验条件下不同去模糊方法的PSNR值

图像	Blur	Buades <sup>[5]</sup>	$P^3$ -NLM	$l_2$ -NLM	$l_1$ -NLM
Lenna	22.88	24.02	24.45	24.47	24.60
Peppers	22.82	24.12	24.61	24.65	24.78
Man	20.73	22.75	23.21	23.26	23.39
Boat	21.62	22.74	23.27	23.31	23.46
Barbara	22.49	23.36	23.94	23.96	24.09
Baboon	20.37	21.57	22.15	22.18	22.29
House	23.69	25.83	26.40	26.43	26.57
Hill	22.97	23.80	24.37	24.40	24.51
Patches	18.66	20.03	20.61	20.62	20.77
Couple	21.87	22.66	23.17	23.22	23.38
Bank	19.14	22.19	22.72	22.74	22.91
Hat	23.09	25.11	25.66	25.68	25.82
Reagan	22.84	23.64	24.19	24.22	24.37
Women	25.18	25.72	26.20	26.21	26.45
Columbia	20.51	21.38	21.77	21.79	22.04
<b>Average</b>	<b>21.92</b>	<b>23.26</b>	<b>23.78</b>	<b>23.81</b>	<b>23.96</b>

图5、图6分别给出了部分图像经上述方法处理后的视觉效果对比结果。从局部放大信息(图像右上角)所示结果可知,  $l_1$ -NLM 模型对 Lenna 图像

表 6 C 组实验条件下不同去模糊方法的 SSIM 值

图像	Blur	Buades <sup>[5]</sup>	$P^3$ -NLM	$l_2$ -NLM	$l_1$ -NLM
Lenna	0.427	0.528	0.556	0.558	0.570
Peppers	0.490	0.579	0.614	0.615	0.627
Man	0.349	0.500	0.530	0.534	0.546
Boat	0.361	0.514	0.558	0.561	0.563
Barbara	0.397	0.565	0.597	0.600	0.612
Baboon	0.310	0.421	0.455	0.459	0.467
House	0.415	0.549	0.586	0.587	0.600
Hill	0.400	0.463	0.500	0.501	0.512
Patches	0.411	0.528	0.560	0.564	0.579
Couple	0.354	0.514	0.545	0.547	0.560
Bank	0.380	0.577	0.611	0.613	0.625
Hat	0.402	0.462	0.492	0.496	0.509
Reagan	0.445	0.535	0.573	0.575	0.589
Women	0.421	0.531	0.558	0.560	0.573
Columbia	0.418	0.526	0.554	0.558	0.572
Average	<b>0.399</b>	<b>0.519</b>	<b>0.552</b>	<b>0.555</b>	<b>0.567</b>

中的人脸细节特征和 Man 图像中的建筑物边缘有很好的保护作用。

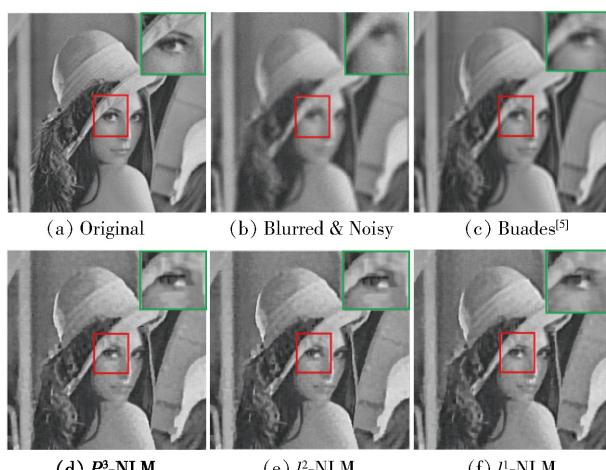


图 5 A 组实验条件下不同方法对 Lenna 处理视觉效果

## 4 结束语

基于正则化图像去模糊问题中正则项的好坏直接影响图像去模糊效果。笔者通过验证  $u$ -NLM <sub>$u$</sub> ( $u$ ) 的概率密度函数近似逼近 Laplace 分布, 在  $l_2$ -NLM 模型的基础上提出了  $l_1$ -NLM 模型, 该模型能够更好地刻画图像的先验信息。然后, 结合 BOS 算法给出了  $l_1$ -NLM 优化算法。实验结果表明, 所提出的新模型和算法与同类其他图像去模糊方法相比, 具有更好的效果。

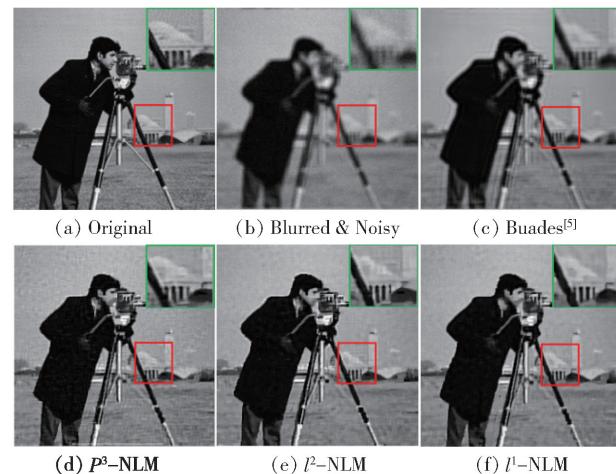


图 6 A 组实验条件下不同方法对 Man 处理视觉效果

的视觉效果和数值表现。

## 参考文献:

- [1] Banham M R, Katsaggelos A K. Digital image restoration [J]. IEEE Signal Processing Magazine, 1997, 14(2): 24-41.
- [2] Teodoro A M, Bioucas-Dias J M, Figueiredo M A T. Image restoration and reconstruction using variable splitting and class-adapted image priors [C] // IEEE International Conference on Image Processing. Phoenix: IEEE, 2016: 3518-3522.
- [3] Xu Jianlou, Feng Aifen, Hao Yan, et al. Image deblurring and denoising by an improved variational model [J]. AEU-International Journal of Electronics and Communications, 2016, 70(9): 1128-1133.
- [4] Lou Yifei, Zhang Xiaoqun, Osher S, et al. Image recovery via nonlocal operators [J]. Journal of Scientific Computing, 2010, 42(2): 185-197.
- [5] Buades A, Coll B, Morel J M. Image enhancement by non-local reverse heat equation [J]. Preprint CMLA, 2006(22): 2001-2016.
- [6] Wang Zhiming, Bao Hong. A new regularization model based on non-local means for image deblurring [J]. Applied Mechanics and Materials, 2013(411): 1164-1169.
- [7] Sreehari S, Venkatakrishnan S V, Wohlberg B, et al. Plug-and-play priors for bright field electron tomography and sparse interpolation [J]. IEEE Transactions on Computational Imaging, 2016, 2(4): 408-423.
- [8] Chan S H, Wang Xiran, Elgendi O A. Plug-and-play ADMM for image restoration: fixed-point convergence and applications [J]. IEEE Transactions on Computational Imaging, 2017, 3(1): 84-98.
- [9] Buades A, Coll B, Morel J M. A non-local algorithm for

- image denoising [ C ] // IEEE Conference on Computer Vision and Pattern Recognition. San Diego: IEEE, 2005: 60-65.
- [10] Zhang Xiaoqun, Burger M, Bresson X, et al. Bregmanized nonlocal regularization for deconvolution and sparse reconstruction [ J ]. Siam Journal on Imaging Sciences, 2010, 3(3): 253-276.
- [11] Lanza A, Morigi S, Sgallari F, et al. Variational image denoising while constraining the distribution of the residual [ J ]. Electronic Transactions on Numerical Analysis, 2014(42): 64-84.
- [12] Zuo Wangmeng, Gu Shuhang, Ren Dongwei, et al. Learning iteration-wise generalized shrinkage thresholding operators for blind deconvolution [ J ]. IEEE Trans-
- actions on Image Processing, 2016, 25 (4): 1751-1764.
- [13] Osher S, Burger M, Goldfarb D, et al. An iterative regularization method for total variation-based image restoration [ J ]. Multiscale Modeling and Simulation, 2005, 4(2): 460-489.
- [14] Tikhonov A N, Arsenin V Y. Solution of ill-posed problems [ J ]. Mathematics of Computation, 1977, 32 (144): 491-491.
- [15] Feng Xiangchu, Li Xiaohui, Wang Weiwei, et al. Improvement of BM3D algorithm based on wavelet and directed diffusion [ C ] // International Conference on Machine Vision and Information Technology. Singapore: IEEE, 2017: 28-33.

(上接第 58 页)

- [14] 朱思峰, 刘芳, 柴争义. 基于免疫计算的 WCDMA 网络基站选址优化 [ J ]. 电子与信息学报, 2011, 33 (6): 1492-1495.  
Zhu Sifeng, Liu Fang, Chai Zhengyi. A novel immune algorithm for WCDMA base station locations optimization [ J ]. Journal of Electronics & Information Technology, 2011, 33(6): 1492-1495.
- [15] 朱思峰, 刘芳, 柴争义, 等. 基于免疫计算的 IEEE 802.16 j 网络基站及中继站选址优化 [ J ]. 计算机研究与发展, 2012, 49(8): 1649-1654.  
Zhu Sifeng, Liu Fang, Chai Zhengyi, et al. Optimization of IEEE802.16j network element and relay station location based on immune computing [ J ]. Computer Research and Development, 2012, 49(8): 1649-1654.
- [16] Chen Yingying, Francisco J A, Trappe W, et al. A practical approach to landmark deployment for indoor localization [ C ] // 2006 3<sup>rd</sup> Annual IEEE Communications Society on Sensor and Ad Hoc Communications and Networks. [ S.l. ]: IEEE, 2006: 365-373.
- [17] Bais A, Kiwan H, Morgan Y. On optimal placement of short range base stations for indoor position estimation [ J ]. Journal of Applied Research and Technology, 2014, 12(5): 886-897.
- [18] 丁虎. 蜂窝网室内定位技术及网元规划 [ J ]. 机电设备, 2017, 34(4): 65-72.  
Ding Hu. Cellular indoor location technology and network element planning [ J ]. Electrical Equipment, 2017, 34(4): 65-72.