

基于自适应块组割先验的噪声图像超分辨率重建

李滔¹ 何小海¹ 卿粼波¹ 滕奇志¹

摘要 要增强噪声图像的分辨率, 传统的串联方式依次进行去噪与超分辨率重建两个步骤, 但去噪算法去除噪声的同时也损失了部分细节信息, 影响了后续超分辨率重建的质量. 为了使低分辨率噪声图像中所有细节信息都能参与超分辨率重建, 本文以非局部中心化稀疏表示 (Nonlocally centralized sparse representation, NCSR) 模型为基础, 提出了基于自适应块组割 (Patch-group-cuts, PG-Cuts) 先验的噪声图像超分辨率重建方法, 同时实现去噪和超分辨率重建功能. 块组割先验基于新颖的三维邻域系统和块组模型, 能够达到图像去噪、边缘平滑和边缘清晰等效果. 重建时以边缘强度为参考对块组割先验进行自适应约束, 由于块组割在平滑区域约束力较低, 采用分区域融合的方式进一步抑制噪声. 本文对合成的低分辨率噪声图像和真实的低分辨率噪声图像进行了重建实验, 实验表明, 基于自适应块组割先验的噪声图像超分辨率重建算法, 在丰富细节的同时能抑制噪声的干扰, 不但具有较高的峰值信噪比和结构相似性等客观评价价值, 而且在非光滑区域具有很好的主观重建效果.

关键词 超分辨率, 稀疏表示, 块组割, 分区域融合

引用格式 李滔, 何小海, 卿粼波, 滕奇志. 基于自适应块组割先验的噪声图像超分辨率重建. 自动化学报, 2017, 43(5): 765–777

DOI 10.16383/j.aas.2017.c160268

Noisy Image Super-resolution Reconstruction with Adaptive Patch-group-cuts Prior

LI Tao¹ HE Xiao-Hai¹ QING Lin-Bo¹ TENG Qi-Zhi¹

Abstract To enhance resolution of a noisy image, the conventional method adopts a cascaded scheme of denoising followed by super-resolution (SR) reconstruction. However, the denoising algorithm inevitably causes some loss of high-frequency information in the image, especially in non-smooth regions, which significantly influences the quality of the subsequent SR reconstruction. To incorporate all the high-frequency information from the noisy low-resolution (LR) images into the SR reconstruction, a noisy image SR method with adaptive patch-group-cuts (PG-Cuts) prior is proposed, based on the nonlocally centralized sparse representation (NCSR) model. The proposed method performs denoising and SR reconstruction simultaneously. The PG-Cuts prior, which is built on a novel 3D neighborhood system and a patch-group model, is able to denoise the image, restore smooth and sharp edges, etc. The edge strength measurement is introduced to adaptively balance the constraint strength of PG-Cuts prior in reconstruction. As PG-Cuts constraint is weak in smooth regions, a region-based fusion scheme is also used to further suppress the noise. Reconstruction experiments are conducted on both synthesized and real noisy LR images. It is demonstrated that the proposed method can restore plenty of details in reconstructed SR images while still suppress the noise, giving not only high scores in objective criteria like PSNR and SSIM, but also very good visual effects in non-smooth regions in subjective evaluations.

Key words Super-resolution (SR), sparse representation, patch group cuts (PG-Cuts), region-based fusion

Citation Li Tao, He Xiao-Hai, Qing Lin-Bo, Teng Qi-Zhi. Noisy image super-resolution reconstruction with adaptive patch-group-cuts prior. *Acta Automatica Sinica*, 2017, 43(5): 765–777

数字图像在形成、传输和存储过程中不可避免会受到噪声的干扰, 同时, 受成像系统硬件条件的约束, 数字图像还可能存在着空间分辨率低的问题. 噪声和低分辨率的存在, 给图像分割、特征提取和识别等

后续处理操作带来技术难度, 图像去噪和超分辨率成为图像处理过程中关键的处理步骤.

图像去噪发展至今涌现了许多前沿算法, 包括基于马尔科夫随机场模型^[1–3]、基于小波变换^[4–5]、基于图像块的非局部相似性^[6–9]等方法. 非局部均值 (Non-local means, NLM) 方法^[6] 在图像中搜索参考块的非局部相似块, 对相似结构进行加权平均实现去噪. BM3D (Block matching and 3-D filtering) 方法^[8] 将多个非局部相似块形成的三维数

收稿日期 2016-03-15 录用日期 2016-08-23
Manuscript received March 15, 2016; accepted August 23, 2016
国家自然科学基金 (61471248) 资助
Supported by National Natural Science Foundation of China (61471248)

本文责任编辑 黄庆明
Recommended by Associate Editor HUANG Qing-Ming
1. 四川大学电子信息学院 成都 610065
1. College of Electronics and Information Engineering, Sichuan University, Chengdu 610065

据结构, 转换到变换域进行协同滤波, 去噪且最大限度地保留了相似块共有的细节结构, 取得了非常突出的去噪效果. CBM3D (Color-block matching and 3-D filtering)^[7] 则是 BM3D 方法^[8] 在彩色图像的扩展.

单幅图像超分辨率作为图像处理领域的一个研究热点, 主要包括三个研究方向: 基于插值的方法^[10-11]、基于重建的方法^[12-14] 和基于学习的方法^[15-18]. 基于插值的方法运算速度快, 但是容易引入模糊和锯齿, 适用于实时性强的应用场景. 基于重建的方法依赖于降质模型和各种结构先验, 先验的使用使重建图像具备相应的自然图像统计特征. 基于学习的方法通过学习和利用低分辨率图像与高分辨率图像之间的关系, 实现分辨率的增强, 在分辨率提高倍数较大时仍具有较好的重建质量.

当低分辨率图像中存在明显的噪声 (文中限定为噪声标准差 $\sigma \geq 10$) 时, 如果忽略噪声的存在直接超分辨率重建, 噪声会被作为细节而加以增强, 且低分辨率图像中独立分布的噪声随着上采样操作在邻域内扩散, 引入了噪声相关性, 导致重建的高分辨率图像质量低下. 因此噪声图像的超分辨率重建需要考虑噪声去除和分辨率提高两个方面, 其对应的降质模型为

$$\mathbf{y} = H\mathbf{x} + \mathbf{n} \quad (1)$$

其中, 降质矩阵 H 包含了模糊和下采样操作, \mathbf{x} 为原始高分辨率图像, \mathbf{n} 为加性噪声, \mathbf{y} 为观测到的低分辨率噪声图像. 由一幅存在明显噪声的低分辨率图像, 恢复得到一幅无噪声的高分辨率图像, 最简单的方法是串联去噪和超分辨率重建. 传统的串联方式是先去噪, 再超分辨率重建. 去噪算法不可避免会模糊图像细节, 损失的这部分有用信息无法在超分辨率重建步骤弥补. 本文将传统串联方式的重建结果称为高分辨率去噪图像, 低分辨率噪声图像直接超分辨率重建的结果称为高分辨率带噪图像. 为了实现噪声图像的超分辨率重建, 文献 [19] 提出将高分辨率去噪图像和高分辨率带噪图像在不同区域不同方向子带上自适应线性组合, 在细节丰富区域的主纹理方向上, 用高分辨率带噪图像有效地替代高分辨率去噪图像. 文献 [19] 重建结果图细节更丰富, 但在细节区域主纹理方向上存在噪声. 本文首先分析了高分辨率去噪图像能量损失的区域分布特性; 随后, 为了恢复非光滑区域上严重损失的信息, 增强细节的同时抑制噪声的干扰, 提出了以非局部中心化稀疏表示模型^[20] 为基础、基于自适应块组割先验的噪声图像超分辨率重建方法. 作为基于重建的单幅图像超分辨率, 本文采用了块组割先验, 它具有平滑边缘和保持边缘的特性, 使结果图中边缘清晰, 且符合自然图像边缘的统计特征. 自适应块组割先验

在平滑区域的约束性较弱, 而传统高分辨率去噪图像在平滑区域的能量损失不大, 因此本文在光滑区域有效地融合高分辨率去噪图像, 使重建图像整体的质量都较高.

1 高分辨率去噪图像的能量损失分析

噪声图像超分辨率重建, 在如式 (1) 所描述的降质过程中, 模糊和下采样会损失部分信息. 使用传统串联方式, 要得到高分辨率去噪图像, 首要步骤是去噪, 去噪算法去除噪声的同时会造成了边缘细节的模糊, 也会导致信息的损失. 这两类信息的损失都具有较强的区域性分布. 如图 1 所示, 对图 1(a) 中的低分辨率噪声图像采用 CBM3D 方法^[7] 去噪, 然后按 Zeyde 方法^[15] 超分辨率重建, 得到图 1(b) 所示的高分辨率去噪图像. 对图 1(b) 中每个 7×7 大小图像块, 计算其与图 1(c) 原始高分辨率图像对应块的亮度均方根误差 (Root mean square error, RMSE), 得到图 1(d) 所示的能量损失图. 由此可见, 能量在平滑区域损失较弱, 而在边缘等非平滑区损失较强, 高分辨率去噪图像能量损失分布具有很强的区域性.

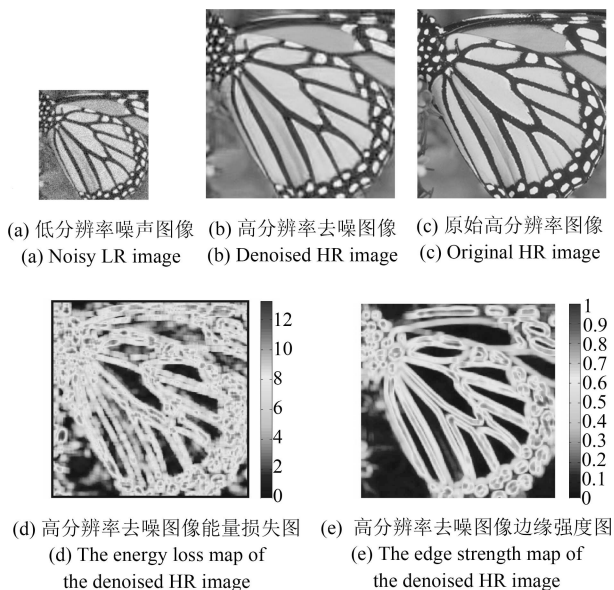


图 1 图像 Butterfly 高分辨率去噪图像能量损失图及边缘强度图

Fig. 1 The energy loss map and the edge strength map of the denoised HR image for image Butterfly

为了利用能量损失的区域性特点, 本文使用图像的边缘强度 (Edge strength, ES) 来逼近能量损失的区域性分布. 边缘强度与梯度相关, 梯度的协方差矩阵能够反映局部区域内边缘主方向和边缘的强弱. 给定参考点 i , 梯度的局部协方差矩阵可表示为

$$Q_i = G_i^T G_i \quad (2)$$

其中

$$G_i = \begin{bmatrix} \vdots & \vdots \\ g_{x_j} & g_{y_j} \\ \vdots & \vdots \end{bmatrix}, (x_j, y_j) \in B_i \quad (3)$$

B_i 是以参考点 i 为中心 $\sqrt{n} \times \sqrt{n}$ 大小的图像块, g_{x_j} 和 g_{y_j} 分别是该图像块沿 x 轴和 y 轴的梯度.

协方差矩阵 Q_i 能有效地反映边缘信息: Q_i 的最大特征值表示块 B_i 内主边的强度, 最大特征值所对应的特征矢量指示了主边的法线方向. 矩阵 G_i 的奇异值分解也能反映相同的边缘信息, 且计算量比 Q_i 的特征值分解更小. 因此, 本文采用 G_i 的奇异值分解, 得到两个奇异值 $s1_i$ 和 $s2_i$, 边缘强度值可表示为

$$f_i = \left(\frac{\max(s1_i, s2_i) + \mu}{n} \right)^\gamma \quad (4)$$

其中, μ 控制边缘强度值的基线, 而 γ 控制 G_i 对边缘强度值的影响强弱. 图 1(b) 对应的边缘强度图如图 1(e) 所示, 通过比较图 1(d) 和图 1(e), 可以看出, 高分辨率去噪图像的边缘强度图正确地逼近了其能量损失的分布.

2 基于自适应块组割先验的噪声图像超分辨率重建

图像和视频中, 边缘作为图像的关键特征, 对图像质量的评估非常重要. 对高分辨率去噪图像能量损失的分析表明, 传统串联方法在非光滑区域存在较大的能量损失, 严重降低了重建图像的质量. 为了提高噪声图像超分辨率重建的质量, 本文在非局部中心化稀疏表示模型基础上, 扩展引入了块组割先验, 能够丰富图像细节且抑制噪声. 根据边缘强度自适应地调节块组割先验的约束度, 在平滑区域上, 为了补偿自适应块组割弱约束度的影响, 进一步有效地融入了高分辨率去噪图像的信息.

2.1 非局部中心化稀疏表示模型

假定 $\Phi \in \mathbf{R}^{m \times K}$ 为有 K 个原子的超完备字典 ($K > m$), 信号 \mathbf{x} 的稀疏表示就是 \mathbf{x} 能用 Φ 中原子的线性组合来近似, 且组合系数是稀疏的 (大部分原子对应的系数为 0). 信号 \mathbf{x} 稀疏系数的求解可通过 l_1 范数最小化得到, 数学形式描述为

$$\alpha_{\mathbf{x}} = \arg \min_{\alpha} \{ \|\mathbf{x} - \Phi \alpha\|_2^2 + \lambda \|\alpha\|_1 \} \quad (5)$$

其中, λ 是正则化项参数, 用来调节 \mathbf{x} 稀疏表示误差和 α 稀疏度间的权重比例.

超分辨率重建时, 稀疏表示模型处理对象为图像块. 对于图像 $\mathbf{x} \in \mathbf{R}^N$, 有图像块 $\mathbf{x}_i =$

$R_i \mathbf{x}$, 其中, R_i 为块提取矩阵. 通过求解 $\alpha_{\mathbf{x},i} = \arg \min_{\alpha_i} \{ \|\mathbf{x}_i - \Phi \alpha_i\|_2^2 + \lambda \|\alpha_i\|_1 \}$, 图像块 \mathbf{x}_i 可稀疏表示为 $\mathbf{x}_i = \Phi \alpha_{\mathbf{x},i}$. 而图像 \mathbf{x} 用所有图像块的稀疏系数集合 $\{\alpha_{\mathbf{x},i}\}$ 表示为

$$\mathbf{x} = \Phi \circ \alpha_{\mathbf{x}} = \left(\sum_{i=1}^N R_i^T R_i \right)^{-1} \sum_{i=1}^N R_i^T \Phi \alpha_{\mathbf{x},i} \quad (6)$$

基于式 (1) 的超分辨率降质模型, 为了由 \mathbf{y} 恢复出 \mathbf{x} , 首先通过式 (7) 得到 \mathbf{y} 关于字典 Φ 的稀疏系数:

$$\alpha_{\mathbf{y}} = \arg \min_{\alpha} \{ \|\mathbf{y} - H \Phi \circ \alpha\|_2^2 + \lambda \|\alpha\|_1 \} \quad (7)$$

然后 $\mathbf{x} = \Phi \circ \alpha_{\mathbf{y}} = \left(\sum_{i=1}^N R_i^T R_i \right)^{-1} \sum_{i=1}^N R_i^T \Phi \alpha_{\mathbf{y},i}$ 恢复得到高分辨率图像.

很明显, $\alpha_{\mathbf{y}}$ 越接近 $\alpha_{\mathbf{x}}$ 真实值 \mathbf{x} 的重建质量就越高. 文献 [20] 将图像块的非局部相似性扩展到图像块稀疏系数的非局部相似性, 将重建图像中非局部相似块稀疏系数的权重和, 作为 $\alpha_{\mathbf{x},i}$ 的估计值 β_i , 且增加约束项使 $\alpha_{\mathbf{y},i}$ 逼近 β_i , 得到了非局部中心化稀疏表示 (Nonlocally centralized sparse representatio, NCSR) 模型:

$$\alpha_{\mathbf{y}} = \arg \min_{\alpha} \{ \|\mathbf{y} - H \Phi \circ \alpha\|_2^2 + \lambda \sum_i \|\alpha_i - \beta_i\|_1 \} \quad (8)$$

后续研究者在 NCSR 模型基础上进行性能扩展, 例如文献 [21] 加入了图像梯度直方图先验, 使重建图像的梯度分布尽可能接近原始高分辨率图像, 得到了更好的重建质量. NCSR 模型仅适用于无噪或者低噪的场景, 当低分辨率图像中存在明显噪声时, 它把噪声当作细节来增强. 为了避免噪声对重建的影响, 且实现边缘平滑、清晰等目的, 本文在 NCSR 模型基础上, 提出了基于自适应块组割先验的噪声图像超分辨率方法.

2.2 块组割先验及其自适应约束

块组割先验最初由我们提出并使用在多视频时空重建^[22]中, 较好地消除了时空重建时常见的鬼影瑕疵, 缓解了时空重建的病态性. 本文将它用于噪声图像的超分辨率重建, 将简要介绍它所基于的特定三维邻域系统、块组模型和原理, 并说明其在噪声图像重建时发挥的作用. 块组割的详细介绍请参考文献 [22]. 块组割先验通过实现曲面的平滑达到去噪、边缘平滑且清晰等目的. 曲面的平滑可以通过曲面面积最小化实现, 而块组割正是曲面面积最小化的数值求解方式.

2.2.1 三维邻域系统

块组割所用的三维邻域系统定义在如图 2(a) 所示的三维网格图 \mathcal{G} 上. 三维邻域系统可分解为多

个二维子邻域面, 图 2(a) 中用不同颜色表示不同子邻域面. 每个子邻域面内的邻域系统与文献 [23] 中二维邻域系统相似, 如图 2(b) 所示. 方位角 φ_s 是第 s 个子邻域面与第 1 个子邻域面之间的夹角, 在每个子邻域面内, 仰角 θ_t 表示第 t 个邻域矢量与水平轴之间的角度.

图 \mathcal{G} 中, 给定参考点 i , 其对应的 3 维邻域系统可用邻域矢量集 \mathcal{N} 表示, $\mathcal{N} = \{\varrho_{st} \mid 1 \leq s \leq n_s, 1 \leq t \leq n_t\}$, 其中邻域矢量的终点即为 i 的邻域点, 是在角对 $\langle \varphi_s, \theta_t \rangle$ 所决定方向上距离 i 最近的点, n_s 表示子邻域面的数量, n_t 表示在子邻域面上的邻域矢量个数, 邻域矢量的总数为 $n_G = n_s \times n_t$. 由于邻域矢量的无向性, φ_s 和 θ_t 取值区间都为 $[0, \pi)$. 图 2(a) 所示的是 $n_G = 4 \times 8$ 三维邻域系统, 实心点为 i 的邻域点.

角对 $\langle \varphi_s, \theta_t \rangle$ 决定了该方向上的线族 \mathcal{F}_{st} , 每个线族的成员线分布在多个平行面上. 线族 \mathcal{F}_{st} 中每条成员线所能表征的最小截面面积为

$$\Delta S_{st} = \frac{\delta^3}{|\varrho_{st}|} \quad (9)$$

其中, δ 是 \mathcal{G} 的网格尺寸, $|\varrho_{st}|$ 为邻域矢量 ϱ_{st} 的长度.

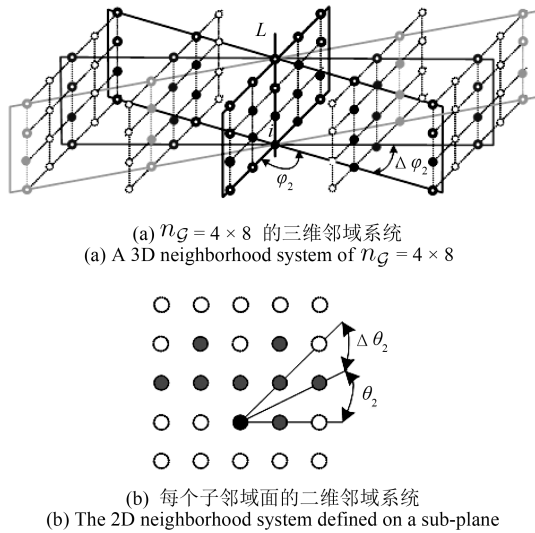


图 2 三维邻域系统示例图

Fig. 2 An example of the 3D neighborhood system

2.2.2 块组模型

三维邻域系统需要依赖三维数据模型为载体. 对于一幅二维图像, 可以利用非局部相似块来构建三维块组 (Patch group, GP) 模型. 自然图像的非局部相似性已被广泛应用在了图像去噪、图像修复、图像超分辨率等应用中. 本文采用欧氏距离来度量非局部块间相似度, 图像块 A 和块 B 的欧氏距离

为 $d_{\epsilon}(A, B) = \sqrt{\sum_{j=1}^n (A_j - B_j)^2 / n}$, 其中, n 表示每个图像块的像素点数量, A_j 和 B_j 为像素位置 j 处亮度值. 图像块的相似度与距离成反比, A 和 B 的相似度为

$$sp(A, B) = \frac{1}{1 + d_{\epsilon}(A, B)} \quad (10)$$

块组模型中, 为了降低计算复杂度, 将相似块搜索范围固定在 $O \times O$ 像素窗口内, 实验中 O 取 31. 从搜索到的相似块中, 选出最相似的 M 个图像块, M 为偶数, 实验中 M 为 6, 如图 3(a) 所示. 参考块放在块组中间位置, 相似块从中间到两端按照相似度递减的方式依次排列, 形成块组 PG_i , 如图 3(b) 所示. 由于参考块和相似块中边缘的位置和亮度都相似, 按这种方式构建块组, $M+1$ 个相似边缘组成如图 3(b) 所示的三维曲面.

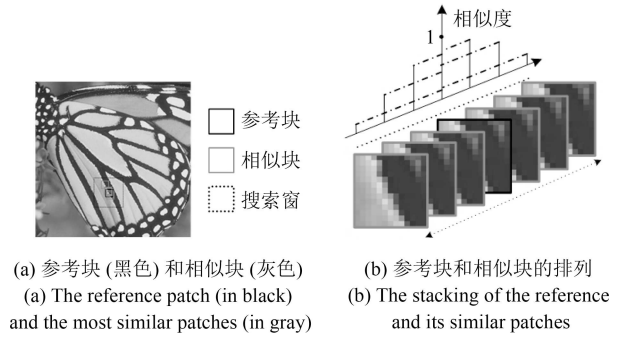


图 3 块组示例图

Fig. 3 A patch group defined on an example image




图 4 曲面的平滑具有去噪功能

Fig. 4 Smoothing surface can suppress edges noise

参考块中的边可视为三维曲面的横截线, 曲面的平滑无疑也会使其包含的线平滑. 同时, 用非局部相似块来构建块组, 在噪声场景下呈现出强鲁棒性. 如图 4 所示, 不同位置的边都受到了噪声的干扰, 引起边缘像素的畸变. 当非局部相似块排列成块组时, 多个受噪声干扰的边形成了崎岖不平的三维曲面. 由于这些边的强相关性和受噪声影响的独立

性, 平滑这个崎岖不平的三维曲面能很容易地去除掉边缘上的噪声.

2.2.3 块组割 (PGCuts) 和它的自适应约束

为了实现块组模型中曲面的平滑, 需要采用一个量化机制来度量曲面平滑度. 曲面的面积可以用来度量曲面平滑度, 通过曲面面积最小化实现块组模型中曲面的平滑, 而块组割正是以图割来实现曲面面积最小化的数值求解方式.

三维曲面 C^2 的欧氏面积 $|C^2|_\epsilon$ 用 3D Cauchy-Crofton 公式表示为

$$|C^2|_\epsilon = \frac{1}{\pi} \int_{\mathcal{L}} n_{C^2} dl \quad (11)$$

其中, \mathcal{L} 是直线集, n_{C^2} 表示线 l 与曲面 C^2 的交点数量. 在第 2.2.1 节所介绍的三维邻域系统中, 密度 dl 可离散化为 $dl \propto \Delta S_{st} \Delta \theta_t \Delta \varphi_s$. 基于式 (9), 3D Cauchy-Crofton 公式离散化表示为

$$|C^2|_\epsilon = \frac{1}{\pi} \sum_{s=1}^{n_s} \sum_{t=1}^{n_t} n_{C^2}(s, t) \frac{\delta^3}{|\varrho_{st}|} \Delta \theta_t \Delta \varphi_s \quad (12)$$

其中, $n_{C^2}(s, t)$ 表示线族 \mathcal{F}_{st} 与曲面 C^2 的交点数.

计算机视觉中, 图割是一种解决能量最小化问题的有效方法. 图割方法通过构建加权图, 把能量最小化问题转换成最小割问题来实现. 图割的详细理论可参考文献 [24]. 通过构建三维图 \mathcal{G} , 并设定线族 \mathcal{F}_{st} 所对应边的权重为

$$w_{st} = \frac{\delta^3 \cdot \Delta \theta_t \cdot \Delta \varphi_s}{\pi \cdot |\varrho_{st}|} \quad (13)$$

则欧氏面积 $|C^2|_\epsilon$ 可由图 \mathcal{G} 中曲面 C^2 的割表示:

$$|C^2|_\epsilon = \sum_{s=1}^{n_s} \sum_{t=1}^{n_t} n_{C^2}(s, t) \cdot w_{st} = \sum_{s,t} w_{st} \sum_{(p,q) \in \mathcal{N}_{st}} n_{C^2}(l_{pq}) = |C^2|_{\mathcal{G}} \quad (14)$$

其中, $n_{C^2}(l_{pq})$ 表示邻域点 p 和 q 间连线与曲面 C^2 的交点数. 假设 $I(v)$ 表示三维体素 v 的亮度值, 给定常数 c , $I(v)$ 的上水平集为 $V_c(I) = \{v, I(v) \geq c\}$. $V_c(I)$ 的二值曲面为 ∂V_c . 式 (14) 仅能表示二值曲面 ∂V_c 的面积. 要表示三维图中所有亮度曲面的总面积, 需要 c 遍历 0 到 255 的整数, 实际就是对所有能分隔邻域点 p 和 q 的二值曲面 ∂V_c 进行计数, 而能分隔两邻域点的曲面个数为 $|I(p) - I(q)|$, 因此所有亮度曲面的总面积为

$$|\partial V|_\epsilon = |\partial V|_{\mathcal{G}} = \sum_{s,t} w_{st} \sum_{(p,q) \in \mathcal{N}_{st}} |I(p) - I(q)| \quad (15)$$

式 (15) 的图割可度量单一块组内渐进变化的亮度曲面 (软曲面) 平滑度, 依次以图像 \mathbf{x} 中每点为参考点构建对应的块组, 并累加其割度量, 得到块组割为

$$|PG|_\epsilon = |PG|_{\mathcal{G}} = \sum_i |PG_i|_{\mathcal{G}} = \sum_i \sum_{s,t} w_{st} \|R_i^{PG} \mathbf{x} - D_{st} R_i^{PG} \mathbf{x}\|_1 \quad (16)$$

其中, R_i^{PG} 从图像 \mathbf{x} 中提取第 i 个块组. 变量对 $\langle s, t \rangle$ 决定了子邻域系统 \mathcal{N}_{st} . D_{st} 完成子邻域系统 \mathcal{N}_{st} 中邻域矢量两端点所对应的位移. w_{st} 是 \mathcal{N}_{st} 边的权重.

结合式 (8) 和式 (16), 基于块组割先验的噪声图像超分辨率重建模型可表示为

$$\begin{aligned} \alpha_{\mathbf{y}} = \arg \min_{\Phi, \alpha} \{ & \|\mathbf{y} - H\Phi \circ \alpha\|_2^2 + \\ & \sum_i \lambda_1(i) \|\alpha_i - \beta_i\|_1 + \\ & \lambda_2 \sum_i \sum_{s,t} w_{st} \|R_i^{PG} \mathbf{x} - D_{st} R_i^{PG} \mathbf{x}\|_1 \} \quad (17) \end{aligned}$$

通过实现式 (17) 的最小化, 实现目标图像内块组软曲面的面积最小, 从而达到图像去噪、边缘平滑等目的. 式 (17) 中 λ_1 和 λ_2 为正则化参数. 文献 [25] 指出, 在稀疏表示模型中对 l_1 范数稀疏系数的正则化项采用迭代重加权, 能够减小稀疏表示误差. 因此, 本文按照文献 [20, 25–26] 中介绍的方法, 利用图像非局部冗余性迭代更新 λ_1 , 参见式 (25). λ_2 用以调节块组割先验的约束度. λ_2 取较大值, 在强边缘处能够达到比较理想的平滑效果, 而在弱边缘处会导致边缘过渡平滑甚至消失. 相反, λ_2 取较小值, 在弱边缘处能够达到合适的约束效果, 而在强边缘处则约束力不够. 式 (4) 中的边缘强度值能够反映边缘的强弱, 因此本文采用边缘强度值实现块组割先验的自适应约束.

图像 \mathbf{x} 的边缘强度图用对角矩阵 P 表示, 第 i 个块组对应的边缘强度矩阵 $P_i = R_i^{PG} P (R_i^{PG})^T$. 实现了块组割先验自适应约束策略的噪声图像超分辨率重建模型表示为

$$\begin{aligned} \alpha_{\mathbf{y}} = \arg \min_{\Phi, \alpha} \{ & \|\mathbf{y} - H\Phi \circ \alpha\|_2^2 + \\ & \sum_i \lambda_1(i) \|\alpha_i - \beta_i\|_1 + \\ & \lambda_2 \sum_i \sum_{s,t} w_{st} \|P_i (R_i^{PG} \mathbf{x} - D_{st} R_i^{PG} \mathbf{x})\|_1 \} \quad (18) \end{aligned}$$

2.3 分区域融合

以边缘强度实现块组制先验的自适应约束, 能够完善块组制先验对边缘的平滑能力, 但是, 也会降低块组制先验的去噪能力. 因为, 不论是平滑区域还是非平滑区域, 都需要相同强度的去噪性能, 而基于边缘强度的自适应块组制先验在平滑区域的约束强度低, 去噪效果不能满足实际的需求. 假定基于自适应块组制先验的重建图像为 $\hat{\mathbf{x}}$, 高分辨率去噪图像为 \mathbf{x}_{dn} , 考虑到 \mathbf{x}_{dn} 中能量损失的区域性分布, 本文按照式 (19) 分区域融合 $\hat{\mathbf{x}}$ 和 \mathbf{x}_{dn} , 从而完善图像 $\hat{\mathbf{x}}$.

$$\hat{\mathbf{x}} = F \cdot \hat{\mathbf{x}} + (1 - F) \cdot \mathbf{x}_{dn} \quad (19)$$

其中, F 为融合权重矩阵. 图像 \mathbf{x}_{dn} 按照式 (4) 得到边缘强度图 F_0 , 再根据式 (20) 中的阈值函数得到 F , 式 (20) 中 \hat{f} 为预先定义的阈值. 由 F 指导分区域的融合, 非平滑区域 F 取值为 1, 保留了图像 $\hat{\mathbf{x}}$ 在非平滑区的重建效果, 而在平滑区 F 取较小值, 保留了图像 \mathbf{x}_{dn} 在平滑区的去噪效果.

$$F(i, j) = \begin{cases} 1, & F_0(i, j) > \hat{f} \\ F_0(i, j), & F_0(i, j) \leq \hat{f} \end{cases} \quad (20)$$

2.4 算法流程

本文采用迭代最小化来完成式 (18) 的求解. 每一次迭代中, 先求出字典 Φ , 再固定 Φ 求解稀疏系数 α . 假定第 u 次迭代时, 高分辨率图像 \mathbf{x} 的当前估计值为 $\hat{\mathbf{x}}^u$, $\hat{\mathbf{x}}^u$ 多尺度图像集合中所有图像块采用 k -均值聚类为 K 类, 并对每一个类别的图像块用主成分分析 (Principle component analysis, PCA) 训练得到子字典 Φ_k , ($k = 1, \dots, K$). 为 $\hat{\mathbf{x}}^u$ 每一个图像块选取其所属类别的子字典 Φ_k . 固定 Φ , 式 (18) 可简化为式 (21) 中的子优化问题:

$$\begin{aligned} \alpha_{\mathbf{y}} = \arg \min_{\alpha} \{ & \|\mathbf{y} - H\Phi \circ \alpha\|_2^2 + \\ & \sum_i \lambda_1(i) \|\alpha_i - \beta_i\|_1 + \\ & \lambda_2 \sum_i \sum_{s,t} w_{st} \|P_i(R_i^{PG}\mathbf{x} - D_{st}R_i^{PG}\mathbf{x})\|_1 \} \end{aligned} \quad (21)$$

式 (21) 的求解用迭代收缩算法^[27-28] 实现. 第 l 次迭代中, 首先用梯度下降法更新高分辨率图像当前估计值 $\hat{\mathbf{x}}^l$ 为式 (22).

$$\begin{aligned} \hat{\mathbf{x}}^{l+\frac{1}{2}} = \hat{\mathbf{x}}^l + \tau \left(& H^T (\mathbf{y} - H\hat{\mathbf{x}}^l) + \right. \\ & \left. \lambda_2 \sum_i R_i^{PGT} \sum_{s,t} w_{st} (D_{st}^T - I) P_i \times \right. \end{aligned}$$

$$\left. \text{sign} \left(R_i^{PG}\hat{\mathbf{x}}^l - D_{st}R_i^{PG}\hat{\mathbf{x}}^l \right) \right) \quad (22)$$

式 (22) 中 τ 为预先定义的常数. 接着, 第 i 个图像块的稀疏系数 α_i 更新为

$$\alpha_i^{l+\frac{1}{2}} = \Phi_k^T R_i \hat{\mathbf{x}}^{l+\frac{1}{2}} \quad (23)$$

其中, Φ_k 为第 i 个图像块 $R_i \hat{\mathbf{x}}^{l+1/2}$ 所属类的 PCA 子字典. 用 Ω_i 表示第 i 个图像块的非局部相似块集合, β_i 可由稀疏系数集 $\{\alpha_j^{l+1/2}, j \in \Omega_i\}$ 加权和得到, 即

$$\begin{aligned} \beta_i = \sum_{j \in \Omega_i} \rho_{i,j} \alpha_j^{l+\frac{1}{2}} \\ \text{且 } \rho_{i,j} = \frac{1}{Z} \exp \left(\frac{-\|R_i \hat{\mathbf{x}}^{l+\frac{1}{2}} - R_j \hat{\mathbf{x}}^{l+\frac{1}{2}}\|_2^2}{h} \right) \end{aligned} \quad (24)$$

其中, h 为预定义常数, Z 为归一化因子. 利用图像非局部冗余性迭代更新 λ_1 为

$$\lambda_1(i) = \frac{2\sqrt{2}\sigma_n^2}{\sigma_i} \quad (25)$$

其中, σ_n 为噪声标准差, 而 σ_i 为 $\{\alpha_j^{l+\frac{1}{2}} - \beta_i, j \in \Omega_i\}$ 的标准差. 稀疏系数 α_i 用软阈值函数进行收缩:

$$\alpha_i^{l+1} = S_{\lambda_1(i)/d} \left(\alpha_i^{l+\frac{1}{2}} - \beta_i \right) + \beta_i \quad (26)$$

其中, $S_{\lambda_1(i)/d}$ 为软阈值函数, d 为控制常数用以保证收缩函数为凸函数. 高分辨率图像新的估计值 $\hat{\mathbf{x}}^{l+1}$ 为

$$\hat{\mathbf{x}}^{l+1} = \Phi \circ \alpha^{l+1} = \left(\sum_{i=1}^N R_i^T R_i \right)^{-1} \sum_{i=1}^N R_i^T \Phi_k \alpha_i^{l+1} \quad (27)$$

在每一次迭代最后都需要分区域融合, 避免基于自适应块组制先验的重建图像中平滑区噪声多次迭代后扩散到非平滑区.

$$\hat{\mathbf{x}}^{l+1} = F \cdot \hat{\mathbf{x}}^{l+1} + (1 - F) \cdot \mathbf{x}_{dn} \quad (28)$$

为了更清楚地说明本文的重建算法, 算法 1 给出了详细的流程步骤.

算法 1. 基于自适应块组制先验的噪声图像超分辨率重建

输入. 低分辨率噪声图像 \mathbf{y} , 分辨率放大因子 o

输出. 高分辨率图像 \mathbf{x}

1) 将高分辨率去噪图像 \mathbf{x}_{dn} 作为高分辨率图像初始估计值 $\hat{\mathbf{x}}^0$, 设置边缘强度参数 μ 和 γ 、块组制邻域系统参数 n_s 和 n_t 、分区域融合的阈值 \hat{f} , 正则

化参数 λ_1 和 λ_2 、梯度下降法步长参数 τ 、外循环最大迭代次数 K_{\max}^O 、内循环最大迭代次数 K_{\max}^I .

2) 由式 (4) 和式 (20) 得到 \mathbf{x}_{dn} 对应的边缘强度权重图 F .

repeat

3) 用 k -均值聚类和 PCA 更新子字典 $\{\Phi_k, k = 1, \dots, K\}$.

4) 固定 $\{\Phi_k\}$, 实现式 (21) 的最优化问题.

Repeat

a) 由式 (4) 得到高分辨率图像估计值 $\hat{\mathbf{x}}^l$ 的边缘强度对角矩阵 P , 并提取出第 i 个块组的边缘强度矩阵 P_i .

b) 根据式 (22) 更新高分辨率图像的估计值 $\hat{\mathbf{x}}^{l+1/2}$.

c) 根据式 (23) 得到稀疏系数 $\alpha^{l+1/2}$.

d) 由 $\alpha^{l+1/2}$ 分别按照式 (24) 和式 (25) 更新 β_i 和正则化参数 λ_1 .

e) 由式 (26) 的迭代收缩算子将稀疏系数更新为 α^{l+1} .

f) 基于式 (27) 得到高分辨率图像的当前估计 $\hat{\mathbf{x}}^{l+1} = \Phi \circ \alpha^{l+1}$.

g) 按照式 (28) 分区域融合当前估计值 $\hat{\mathbf{x}}^{l+1}$ 与高分辨率去噪图像 \mathbf{x}_{dn} .

until $l \geq K_{\max}^I$

until $u \geq K_{\max}^O$

3 实验结果与分析

为了验证算法的有效性, 本节进行了模拟噪声图像实验和真实噪声图像实验. 实验中本文算法相关参数选取如下: 分辨率放大因子 $o = 2$; 图像块大小为 7×7 ; 边缘强度基线控制参数 $\mu = 0.00001$, 协方差矩阵对边缘强度值影响强弱的控制参数 $\gamma = 0.8$; 块组割先验子邻域面个数 $n_s = 4$, 每个子邻域面内邻域矢量个数 $n_t = 12$; 外循环最大迭代次数 $K_{\max}^O = 5$, 内循环最大迭代次数 $K_{\max}^I = 160$, 梯度下降法步长参数 $\tau = 1$, 正则化参数 $\lambda_2 = 0.04$, 分区域融合的阈值 $\hat{f} = 0.2$.

模拟实验中, 为了合成低分辨率噪声图像, 把高分辨率测试图像模糊在 o 倍下采样, 并加上随机噪声. 由于本文关注的重点是噪声, 所以在低分辨率噪声图像生成过程中采用小模糊核 (5×5 大小, 标准差为 1 的高斯模糊核), 避免过度模糊对重建质量产生影响. 随机噪声是标准差分别为 10、15、20、25 和 30 的高斯白噪声. 实验中, 本文算法将与双三次插值 (Bicubic)、先去噪再双三次插值 (Denoise+Bicubic, D+B)、先去噪再用 Zeyde^[15] 重建 (Denoise+Zeyde^[15], D+Z)、Singh^[19] 和 NCSR^[20]

方法比较. Denoise+Bicubic 和 Denoise+Zeyde^[15] 即为传统的串联方法, 区别在于分辨率增强用了不同的算法. 本文对 Denoise+Zeyde^[15] 和 Singh^[19] 方法重建结果增加了迭代反投影^[29] 步骤, 去除其轻微的模糊. NCSR^[20] 方法基于图像的非局部相似性, 因此具有超分辨率重建和有限的去噪功能, 为了比较的公平性, NCSR^[20] 方法中也增加了第 2.3 节分区域融合的处理, 因而本文算法相比 NCSR^[20] 方法, 性能的提升主要体现在非平滑区域.

3.1 性能评估

峰值信噪比 (Peak signal to noise ratio, PSNR) 和结构相似度 (Structural similarity, SSIM) 是两个常用的图像质量评价指标. PSNR 和 SSIM 值越大表明重建图像质量越高. 在噪声标准差分别为 15、20 和 25 情况下, 各个算法重建结果的 PSNR 和 SSIM 值依次由表 1 和表 2 列出. Denoise+Bicubic 和 Denoise+Zeyde^[15] 方法先去除低分辨率图像中的噪声, 再增强其分辨率, 取得的性能优于对低分辨率噪声图像直接插值放大的 Bicubic 方法. Singh^[19] 方法基于 Denoise+Zeyde^[15] 方法, 并选择性地在细节区域主纹理方向取消 Denoise 步骤, 避免了部分由 Denoise 损失的信息, 但是单纯地取消 Denoise 步骤, 无疑会导致在主纹理方向上噪声随细节一同得以保留, 并被随后的 Zeyde^[15] 步骤增强, 噪声增强降低的性能抵消了细节保留提升的性能, 因此 Singh^[19] 相比 Denoise+Zeyde^[15] 方法性能提升的幅度很小. NCSR^[20] 方法中, 低分辨率噪声图像所有细节信息都参与超分辨率重建, 且重建过程中能通过类似于非局部均值的方法抑制噪声, 低噪声情况下能够获取较高的重建性能. 但是, 非局部均值方法中, 给定参考点, 对该点进行降噪约束的是所有非局部相似块中相同位置的点, 相当于块组中的一维噪声约束, 噪声抑制性有限. 因而大噪声情况下, NCSR^[20] 方法无法抑制重建过程中被增强的噪声, 导致性能下降. 本文方法的块组割先验, 其特定的三维邻域系统有助于块组模型中三维噪声约束, 因而本文方法在大噪声情况下仍然适用. 在我们所选用的经验参数下, 除大噪声的 Lena 图像 ($\sigma = 25$ 时) 重建性能略低之外, 本文方法重建结果的 PSNR 和 SSIM 值普遍优于其他算法. 除 Bicubic 外, 其余算法重建性能随噪声标准差的变换趋势在图 5 中给出. 随着噪声增大, 所有算法的重建质量都随之下降, 但本文方法始终保持着优先的性能. NCSR^[20] 方法在大噪声情况下去噪能力有限, 随着噪声的增大性能下降趋势陡峭, 而本文算法保持了比较平缓的下降趋势.

Soft-cut-metric (SCM)^[30] 是图像边缘平滑度

的评价指标, SCM 值越低图像边缘越平滑. 由于 NCSR^[20] 和本文方法都基于非局部中心化稀疏表示模型, 表 3 通过比较 NCSR^[20] 和本文方法 SCM 值的差异, 反映了块组割先验在提升图像边缘平滑度上的有效性.

图 6 给出了噪声标准差为 15 时图像 Racing 的重建结果, 图 7 是噪声标准差为 25 时 Butterfly 的重建结果, 为了更直观的比较, 给出了矩形框区域对应的视觉放大图和边缘图. 边缘图的计算公式为 $1/(1 + \eta(g_x^2 + g_y^2))$, g_x 和 g_y 分别表示图像在 x 和 y

表 1 噪声图像超分辨率重建结果比较 (PSNR (dB))

Table 1 PSNR (dB) comparison of different SR methods on noisy LR images

标准差	算法	Sail	Woman	Racing	Bridge	Man	Church	Butterfly	Lena	Ppt	Status	Average
15	Bicubic	28.36	27.43	25.17	25.32	25.18	27.16	23.29	27.48	23.27	25.76	25.84
	D + B	30.61	28.94	25.77	25.86	25.53	28.56	23.47	28.88	23.66	26.28	26.76
	D + Z	31.50	30.78	27.03	27.10	27.73	30.59	25.72	30.18	25.90	28.71	28.52
	Singh	31.58	30.82	27.05	27.14	27.89	30.66	25.81	30.24	25.91	28.71	28.58
	NCSR	31.64	31.58	27.50	27.61	29.42	32.04	27.75	30.42	27.52	29.46	29.49
	Proposed	32.01	31.83	27.78	27.74	29.52	32.65	27.90	30.64	28.43	29.63	29.81
20	Bicubic	26.89	26.26	24.43	24.59	24.50	26.13	22.78	26.28	22.85	24.97	24.97
	D + B	30.32	28.67	25.55	25.61	25.19	28.38	23.23	28.57	23.54	25.94	26.50
	D + Z	31.03	30.27	26.65	26.69	27.04	30.23	25.21	29.65	25.64	27.97	28.04
	Singh	31.10	30.30	26.67	26.73	27.21	30.30	25.30	29.68	25.65	27.90	28.08
	NCSR	30.81	30.62	26.83	26.92	28.20	30.84	26.78	29.21	26.38	28.28	28.49
	Proposed	31.12	30.98	27.13	27.17	28.41	31.85	27.01	29.72	27.67	28.51	28.96
25	Bicubic	25.53	25.14	23.63	23.81	23.79	25.08	22.22	25.13	22.36	24.15	24.08
	D + B	30.04	28.40	25.34	25.39	24.85	28.19	22.99	28.28	23.40	25.60	26.25
	D + Z	30.62	29.81	26.31	26.33	26.39	29.87	24.73	29.18	25.36	27.31	27.59
	Singh	30.64	29.83	26.31	26.37	26.58	29.92	24.82	29.19	25.37	27.20	27.62
	NCSR	29.71	29.77	26.20	26.28	27.05	29.78	25.95	28.29	25.48	27.35	27.59
	Proposed	30.72	30.34	26.63	26.72	27.47	31.00	26.33	29.11	26.80	27.90	28.30

表 2 噪声图像超分辨率重建结果比较 (SSIM)

Table 2 SSIM comparison of different SR methods on noisy LR images

标准差	算法	Sail	Woman	Racing	Bridge	Man	Church	Butterfly	Lena	Ppt	Status	Average
15	Bicubic	0.6101	0.6587	0.6102	0.6277	0.7203	0.6725	0.7225	0.6523	0.8180	0.7716	0.6864
	D + B	0.8475	0.8536	0.7028	0.7332	0.8572	0.8988	0.8122	0.8075	0.9380	0.8519	0.8303
	D + Z	0.8648	0.8728	0.7347	0.7704	0.8895	0.9173	0.8577	0.8297	0.9654	0.8870	0.8589
	Singh	0.8669	0.8729	0.7356	0.7724	0.8903	0.9175	0.8572	0.8300	0.9655	0.8838	0.8592
	NCSR	0.8653	0.8764	0.7448	0.7844	0.9083	0.9276	0.8898	0.8183	0.9742	0.8915	0.8681
	Proposed	0.8731	0.8816	0.7496	0.7867	0.9156	0.9333	0.8986	0.8311	0.9771	0.8975	0.8744
20	Bicubic	0.5054	0.5656	0.5402	0.5584	0.6510	0.5781	0.6661	0.5659	0.7556	0.7138	0.6100
	D + B	0.8380	0.8449	0.6885	0.7179	0.8437	0.8948	0.7999	0.7951	0.9325	0.8393	0.8195
	D + Z	0.8515	0.8616	0.7165	0.7499	0.8717	0.9116	0.8415	0.8132	0.9590	0.8697	0.8446
	Singh	0.8522	0.8612	0.7171	0.7524	0.8718	0.9111	0.8393	0.8115	0.9590	0.8634	0.8439
	NCSR	0.8395	0.8590	0.7198	0.7567	0.8836	0.9144	0.8629	0.7743	0.9642	0.8637	0.8438
	Proposed	0.8558	0.8680	0.7285	0.7650	0.8936	0.9253	0.8785	0.8014	0.9690	0.8742	0.8559
25	Bicubic	0.4197	0.4884	0.4774	0.4963	0.5917	0.4994	0.6162	0.4916	0.6973	0.6595	0.5437
	D + B	0.8294	0.8371	0.6767	0.7050	0.8304	0.8906	0.7878	0.7843	0.9262	0.8266	0.8094
	D + Z	0.8397	0.8519	0.7011	0.7330	0.8543	0.9053	0.8257	0.7994	0.9520	0.8542	0.8317
	Singh	0.8364	0.8507	0.7012	0.7354	0.8540	0.9034	0.8222	0.7957	0.9519	0.8451	0.8296
	NCSR	0.8118	0.8423	0.6969	0.7318	0.8576	0.9002	0.8371	0.7387	0.9536	0.8379	0.8208
	Proposed	0.8416	0.8577	0.7113	0.7463	0.8745	0.9156	0.8618	0.7837	0.9595	0.8598	0.8412

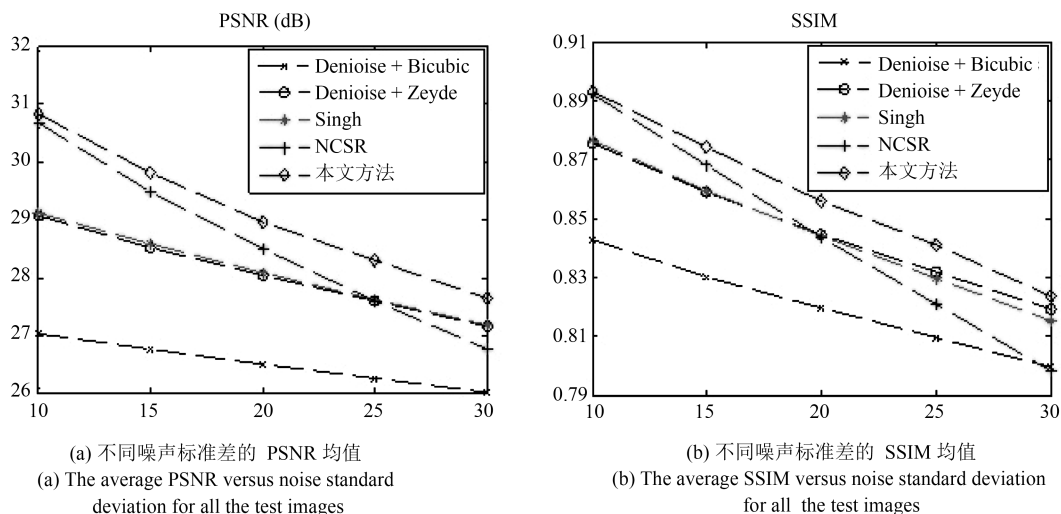


图 5 不同噪声标准差的 PSNR 均值和 SSIM 均值

Fig. 5 The average PSNR/SSIM values versus noise standard deviation for all the test images




图 6 噪声图像 Church 超分辨率结果比较 (括号内的数字分别表示 PSNR 和 SSIM)

Fig. 6 SR results of noisy LR image Church (PSNR and SSIM values are shown in bracket)

表 3 重建高分辨率图像 SCM 值比较 ($\sigma = 20$)

Table 3 SCM comparison of the reconstructed HR image ($\sigma = 20$)

算法	Sail	Woman	Racing	Bridge	Man	Church	Butterfly	Lena	Ppt	Status
NCSR	1.35	1.92	2.62	2.51	4.08	2.00	5.96	2.46	3.50	5.24
Proposed	1.09	1.71	2.27	2.22	3.80	1.79	5.46	2.08	3.19	4.94

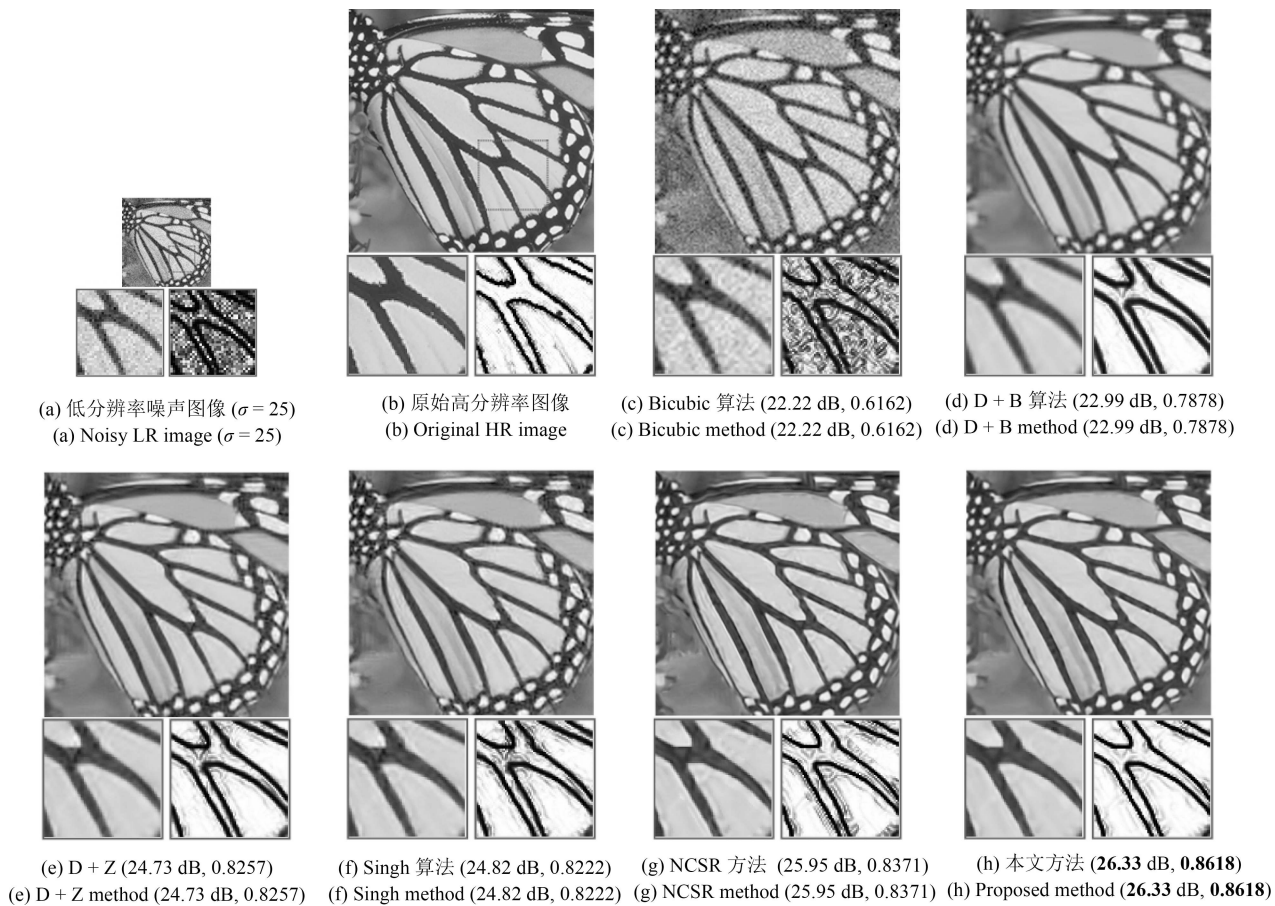


图7 噪声图像 Butterfly 超分辨率结果比较 (括号内的数字分别表示 PSNR 和 SSIM)

Fig. 7 SR results of noisy LR image Butterfly (PSNR and SSIM values are shown in bracket)

方向的梯度. η 控制了梯度差异在边缘图中的呈现效果, η 过小, 边缘图不能很好地表征平滑区域与边缘区域的梯度差异, 而 η 过大, 强边缘和弱边缘的梯度差异无法较好体现, 因此本实验中 η 取经验值 0.01, 此时边缘图能较好呈现梯度差异性. 从图 6 和图 7 可以看出, 本文方法重建结果在非光滑区域更好地恢复了细节、有效抑制了噪声、边缘平滑且清晰, 而分区域融合使平滑区域也呈现较好的重建质量.

真实噪声图像实验中, 低分辨率噪声图像由 SAMSUNG GT-I9508 手持设备拍摄 (ISO 1000, 曝光时间 1/17s). 图 8 比较了真实噪声图像的超分辨率重建结果, 可得到跟模拟实验相同的评价结果.

3.2 运行时间

本节进行算法运行时间的比较. Bicubic 方法的运行时间可以忽略不计, 因此不再列出. 所有算法的运行环境都相同 (Intel CPU 4.0 GHz, 16 GB 内存). 针对 4 幅具有代表性尺寸的模拟测试图像, 表 4 记录了噪声标准差为 20, 分辨率放大因子分别

表 4 噪声图像超分辨率重建运行时间 (s) 比较 ($\sigma = 20$)
Table 4 Comparison of the running time (s) of different SR methods on noisy LR images ($\sigma = 20$)

图像	放大因子/尺寸	D+B	D+Z	Singh	NCSR	Proposed
Man	2/320×480	0.5	1.3×10	0.5×10 ²	0.6×10 ³	1.4×10 ³
	3/480×720	0.5	2.5×10	1.0×10 ²	1.6×10 ³	3.4×10 ³
	4/640×960	0.5	6.4×10	2.1×10 ²	2.9×10 ³	6.1×10 ³
Butterfly	2/256×256	0.2	0.5×10	0.2×10 ²	0.2×10 ³	0.5×10 ³
	3/384×384	0.2	1.0×10	0.4×10 ²	0.5×10 ³	1.3×10 ³
	4/512×512	0.2	2.7×10	0.9×10 ²	0.8×10 ³	2.2×10 ³
Ppt	2/656×528	1.2	2.7×10	1.1×10 ²	1.4×10 ³	3.5×10 ³
	3/984×792	1.2	5.5×10	2.1×10 ²	3.8×10 ³	8.4×10 ³
	4/1312×1056	1.2	14.7×10	4.8×10 ²	4.9×10 ³	14.6×10 ³
Status	2/170×138	0.05	0.2×10	0.08×10 ²	0.05×10 ³	0.2×10 ³
	3/255×207	0.05	0.4×10	0.13×10 ²	0.16×10 ³	0.5×10 ³
	4/340×276	0.05	0.9×10	0.3×10 ²	0.23×10 ³	0.8×10 ³

为 2、3、4 时各个重建算法的运行时间. 可以看出, Denoise+Bicubic 方法运行速度最快, 且其主要耗

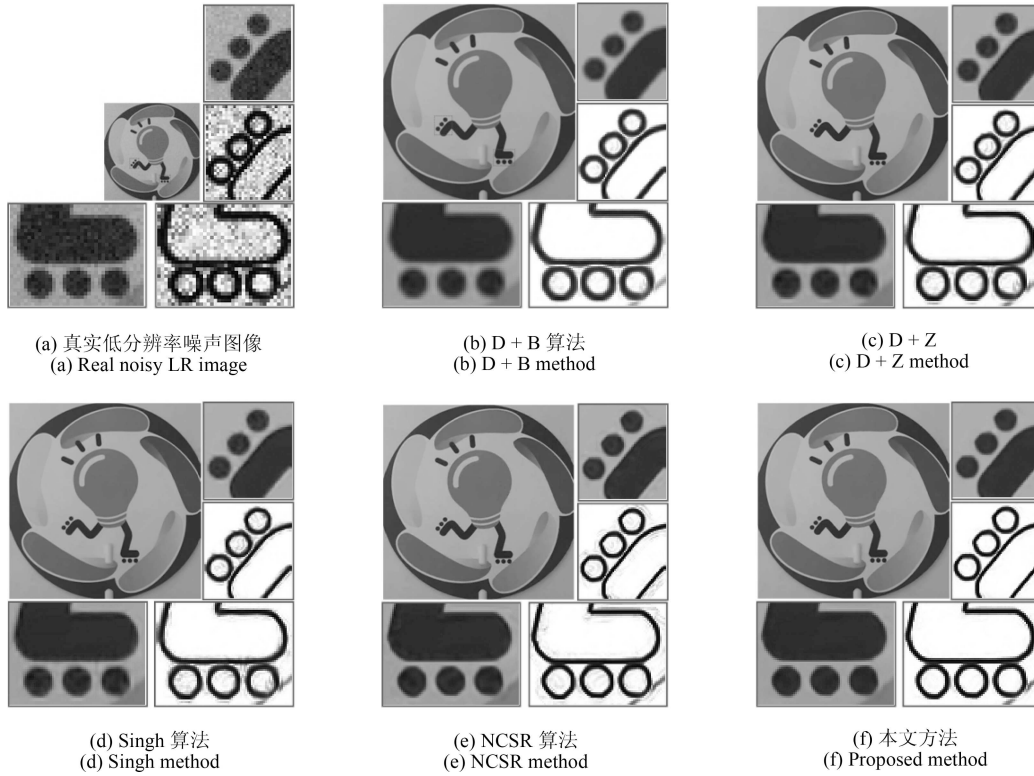


图 8 真实噪声图像 fan 超分辨率结果比较
 Fig. 8 SR results of real noisy LR image fan

时步骤 Denoise 的处理对象为低分辨率图像, 所以 Denoise+Bicubic 方法的运行时间不随放大因子变化. 本文方法主要耗时部分是非局部中心化稀疏表示模型的迭代求解过程以及块组割先验的计算, 时间复杂度为 $O(o^2n)$, 其中, o 为放大因子, n 为低分辨率图像的像素点数目.

在相对 Denoise + Zeyde^[15] 和 Singh^[19] 方法提升约 0.5 dB PSNR 的同时, 付出了一个量级的时间消耗代价; 而本文的算法在相对 NCSR^[20] 方法提升相同 PSNR 性能的同时, 只付出了仅 2 ~ 4 倍的时间消耗代价, 算法性能的提升效率更高.

4 结论

为了同时解决图像中存在的强噪声和低分辨率问题, 本文提出了基于自适应块组割先验的噪声图像超分辨率重建算法. 在非局部中心化稀疏表示模型基础上使用块组割先验, 并用边缘强度自适应地调节块组割先验对重建过程的约束作用. 块组割先验以割的方式实现块组模型中三维曲面的平滑, 从而达到图像去噪、边缘平滑和有效保持边缘等目的, 在重建图的非光滑区域中, 细节更丰富、边缘更清晰且噪声被有效的抑制. 同时使用分区域融合的方法, 补偿了自适应块组割先验在平滑区域弱约束度所造成的影响. 实验表明, 本文方法取得了较好的 PSNR 和 SSIM 客观评价值, 也呈现了较好的主观视觉效果.

References

1 Li Y P, Huttenlocher D P. Sparse long-range random field and its application to image denoising. In: Proceeding of the

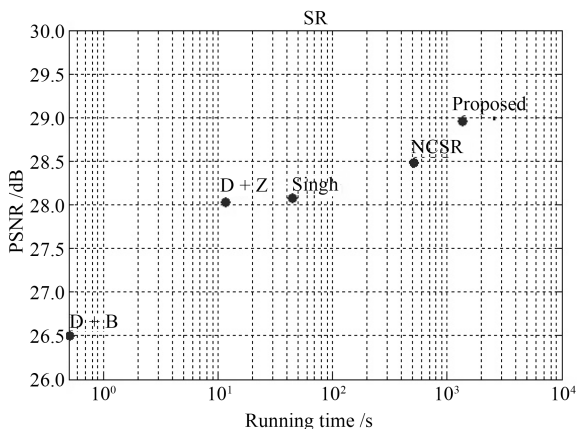


图 9 噪声图像超分辨率重建的性能与运行时间综合比较图
 ($\sigma = 20, o = 2$)

Fig. 9 PSNR versus running time for different SR methods on noisy LR images ($\sigma = 20, o = 2$)

图 9 进一步给出了放大因子为 2 时, 算法性能与运行时间的综合比较. 可以发现, NCSR^[20] 方法

- 10th European Conference on Computer Vision. Marseille, France: Springer, 2008. 344–357
- 2 Roth S, Black M J. Fields of experts: a framework for learning image priors. In: Proceedings of the 2005 IEEE Computer Society Conference on Computer Vision and Pattern Recognition. San Diego, USA: IEEE, 2005. 860–867
 - 3 Tappen M F. Utilizing variational optimization to learn Markov random fields. In: Proceedings of the 2007 IEEE Conference on Computer Vision and Pattern Recognition. Minneapolis, USA: IEEE, 2007. 1–8
 - 4 Nasri M, Nezamabadi-pour H. Image denoising in the wavelet domain using a new adaptive thresholding function. *Neurocomputing*, 2009, **72**(4): 1012–1025
 - 5 Mihcak M K, Kozintsev I, Ramchandran K, Moulin P. Low-complexity image denoising based on statistical modeling of wavelet coefficients. *IEEE Signal Processing Letters*, 1999, **6**(12): 300–303
 - 6 Buades A, Coll B, Morel J-M. A non-local algorithm for image denoising. In: Proceedings of the 2005 IEEE Computer Society Conference on Computer Vision and Pattern Recognition. San Diego, USA: IEEE, 2005. 60–65
 - 7 Dabov K, Foi A, Katkovnik V, Egiazarian K. Color image denoising via sparse 3D collaborative filtering with grouping constraint in luminance-chrominance space. In: Proceedings of the 2007 IEEE International Conference on Image Processing. San Antonio, USA: IEEE, 2007. I-313–I-316
 - 8 Dabov K, Foi A, Katkovnik V, Egiazarian K. Image denoising by sparse 3-D transform-domain collaborative filtering. *IEEE Transactions on Image Processing*, 2007, **16**(8): 2080–2095
 - 9 Zhang Rui, Feng Xiang-Chu, Wang Si-Qi, Chang Li-Hong. A sparse gradients field based image denoising algorithm via non-local means. *Acta Automatica Sinica*, 2015, **41**(9): 1542–1552
(张瑞, 冯象初, 王斯琪, 常莉红. 基于稀疏梯度场的非局部图像去噪算法. *自动化学报*, 2015, **41**(9): 1542–1552)
 - 10 Zhang X J, Wu X L. Image interpolation by adaptive 2-D autoregressive modeling and soft-decision estimation. *IEEE Transactions on Image Processing*, 2008, **17**(6): 887–896
 - 11 Hung K-W, Siu W-C. Fast image interpolation using the bilateral filter. *IET Image Processing*, 2012, **6**(7): 877–890
 - 12 Zhang K B, Gao X B, Tao D C, Li X L. Single image super-resolution with non-local means and steering kernel regression. *IEEE Transactions on Image Processing*, 2012, **21**(11): 4544–4556
 - 13 Yan Q, Xu Y, Yang X K, Nguyen T Q. Single image super-resolution based on gradient profile sharpness. *IEEE Transactions on Image Processing*, 2015, **24**(10): 3187–3202
 - 14 Dai S Y, Han M, Xu W, Wu Y, Gong Y H, Katsaggelos A K. Softcuts: a soft edge smoothness prior for color image super-resolution. *IEEE Transactions on Image Processing*, 2009, **18**(5): 969–981
 - 15 Zeyde R, Elad M, Protter M. On single image scale-up using sparse-representations. In: Proceedings of the 7th International Conference on Curves and Surfaces. Avignon, France: Springer, 2012. 711–730
 - 16 Peleg T, Elad M. A statistical prediction model based on sparse representations for single image super-resolution. *IEEE Transactions on Image Processing*, 2014, **23**(6): 2569–2582
 - 17 Jia K, Wang X G, Tang X O. Image transformation based on learning dictionaries across image spaces. *IEEE transactions on Pattern Analysis and Machine Intelligence*, 2013, **35**(2): 367–380
 - 18 Li Min, Cheng Jian, Le Xiang, Li Xiao-Wen. Super-resolution reconstruction for color images based on simultaneous sparse approximation. *Journal of Optoelectronics · Laser*, 2011, **22**(8): 1241–1245
(李民, 程建, 乐翔, 李小文. 基于联合稀疏近似的彩色图像超分辨率重建. *光电子·激光*, 2011, **22**(8): 1241–1245)
 - 19 Singh A, Porikli F, Ahuja N. Super-resolving noisy images. In: Proceedings of the 2014 IEEE Conference on Computer Vision and Pattern Recognition. Columbus, USA: IEEE, 2014. 2846–2853
 - 20 Dong W S, Zhang L, Shi G M, Li X. Nonlocally centralized sparse representation for image restoration. *IEEE Transactions on Image Processing*, 2013, **22**(4): 1620–1630
 - 21 Zhang Y Q, Liu J Y, Yang W H, Guo Z M. Image super-resolution based on structure-modulated sparse representation. *IEEE Transactions on Image Processing*, 2015, **24**(9): 2797–2810
 - 22 Li T, He X H, Teng Q Z, Wang Z Y, Ren C. Space-time super-resolution with patch group cuts prior. *Signal Processing: Image Communication*, 2015, **30**: 147–165
 - 23 Boykov Y, Kolmogorov V. Computing geodesics and minimal surfaces via graph cuts. In: Proceedings of the 2003 IEEE International Conference on Computer Vision. Nice, France: IEEE, 2003. 26–33
 - 24 Boykov Y, Veksler O, Zabih R. Fast approximate energy minimization via graph cuts. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2001, **23**(11): 1222–1239
 - 25 Candés E J, Wakin M B, Boyd S P. Enhancing sparsity by reweighted l_1 minimization. *Journal of Fourier Analysis and Applications*, 2008, **14**(5–6): 877–905
 - 26 Han Yu, Wang Wei-Wei, Feng Xiang-Chu. Iteratively reweighted method based nonrigid image registration. *Acta Automatica Sinica*, 2011, **37**(9): 1059–1066
(韩雨, 王卫卫, 冯象初. 基于迭代重加权的非刚性图像配准. *自动化学报*, 2011, **37**(9): 1059–1066)
 - 27 Daubechies I, Defrise M, De Mol C. An iterative thresholding algorithm for linear inverse problems with a sparsity constraint. *Communications on Pure and Applied Mathematics*, 2004, **57**(11): 1413–1457
 - 28 Fan Wen-Ru, Wang Hua-Xiang, Hao Kui-Hong. Two-step iterative TV regularization algorithm for image reconstruction of electrical impedance tomography. *Chinese Journal of Scientific Instrument*, 2012, **33**(3): 625–630
(范文茹, 王化祥, 郝魁红. 基于两步迭代 TV 正则化的电阻抗图像重建算法. *仪器仪表学报*, 2012, **33**(3): 625–630)
 - 29 Irani M, Peleg S. Motion analysis for image enhancement: resolution, occlusion, and transparency. *Journal of Visual Communication and Image Representation*, 1993, **4**(4): 324–335
 - 30 Dai S Y, Han M, Xu W, Wu Y, Gong Y H. Soft edge smoothness prior for alpha channel super resolution. In: Proceedings of the 2007 IEEE Conference on Computer Vision and Pattern Recognition. Minneapolis, USA: IEEE, 2007.



李滔 四川大学电子信息学院博士研究生. 主要研究方向为图像超分辨率重建, 图像复原.

E-mail: lucia634@163.com

(**LI Tao** Ph.D. candidate at the College of Electronics and Information Engineering, Sichuan University. Her research interest covers image super-

resolution reconstruction and image restoration.)



何小海 四川大学电子信息学院教授. 主要研究方向为图像处理, 模式识别, 图像通信. 本文通信作者.

E-mail: hxh@scu.edu.cn

(**HE Xiao-Hai** Professor at the College of Electronics and Information Engineering, Sichuan University. His research interest covers image processing,

pattern recognition, and image communication. Corresponding author of this paper.)



卿琳波 四川大学电子信息学院副教授. 主要研究方向为图像压缩, 视频编码与传输, 信息理论.

E-mail: qing_lb@scu.edu.cn

(**QING Lin-Bo** Associate professor at the College of Electronics and Information Engineering, Sichuan University. His research interest covers image

compression, video coding and transmission, and information theory.)



滕奇志 四川大学电子信息学院教授. 主要研究方向为图像处理, 图像通信, 模式识别, 软件工程.

E-mail: qzteng@scu.edu.cn

(**TENG Qi-Zhi** Professor at the College of Electronics and Information Engineering, Sichuan University. Her research interest covers image process-

ing, image communication, pattern recognition, and software engineering.)