

## 基于通道间相关性和非局部自相似性的彩色图像超分辨率算法

莫彩网<sup>1</sup> 常侃<sup>1,2,3</sup> 李恒鑫<sup>1</sup> 李明鸿<sup>1</sup> 覃团发<sup>1,2,3</sup>

1 广西大学计算机与电子信息学院 南宁 530004

2 广西大学广西多媒体通信与网络技术重点实验室 南宁 530004

3 广西大学广西高校多媒体通信与信息处理重点实验室 南宁 530004

(mcw525@yeah.net)

**摘要** 现有的大多数单图像超分辨率方法仅用于提高单个通道的分辨率。在处理彩色图像时,由于忽略了通道间的相关性,重建的高分辨率图像容易产生失真。针对这些问题,提出了一种综合考虑通道间相关性及非局部自相似性的彩色图像超分辨率算法。首先,为了充分利用彩色图像的通道间相关性,分别计算通道间残差信号和三通道平均信号的总变分范数;其次,为了进一步提升超分辨率的结果,基于图像内的非局部自相似性更新重建图像;最后,为了求解所建立的优化问题,提出了基于 split-Bregman 方法的快速迭代算法。将所提算法与一些主流算法进行了比较,在 3 倍上采样条件下,所提算法在 Set5 和 Set14 数据集上平均可获得的峰值信噪比(Peak Signal to Noise Ratio,PSNR)增益分别为 0.5 dB 及 0.36 dB。实验结果证明了联合应用通道间相关性及非局部自相似性能够有效提升彩色图像的超分辨重建质量。

**关键词:** 彩色图像超分辨率;通道间相关性;非局部自相似性;总变分;split-Bregman

**中图分类号** TP37

## Color Image Super-resolution Algorithm Based on Inter-channel Correlation and Nonlocal Self-similarity

MO Cai-wang<sup>1</sup>,CHANG Kan<sup>1,2,3</sup>,LI Heng-xin<sup>1</sup>,LI Ming-hong<sup>1</sup> and QIN Tuan-fa<sup>1,2,3</sup>

1 School of Computer and Electronic Information,Guangxi University,Nanning 530004,China

2 Guangxi Key Laboratory of Multimedia Communications and Network Technology,Guangxi University,Nanning 530004,China

3 Guangxi Colleges and Universities Key Laboratory of Multimedia Communications and Information Processing,Guangxi University,Nanning 530004,China

**Abstract** Most of the existing single image super-resolution (SR) algorithms are designed to improve the resolution of a single channel. When dealing with the color images,the inter-channel correlation is ignored,so the reconstructed high resolution (HR) image is prone to distortion. To solve the above problem,this paper proposes a SR algorithm for color images,which jointly takes the inter-channel correlation (ICC) and non-local self-similarity (NLSS) into consideration. First of all,in order to fully make use of the inter-channel correlation of color images,the total variation (TV)-norm of the residual signals and the TV-norm of the average signal of three color channels are respectively calculated. Secondly,to further improve the SR results,the reconstructed HR images are updated based on the non-local self-similarity of nature images. Finally,to solve the established optimization problem,a split-Bregman method-based iteration is proposed. The proposed algorithm is compared with several state-of-the-art methods. At a scale factor of 3,the average peak signal to noise ratio (PSNR) improvement achieved by the proposed algorithm reaches 0.5 dB on Set5,and 0.36 dB on Set14,respectively. The experimental results demonstrate that jointly utilizing ICC and NLSS is able to effectively improve the quality of the reconstructed HR color images.

**Keywords** Color image super-resolution,Inter-channel correlation,Non-local self-similarity,Total variation,Split-Bregman

## 1 引言

单图像超分辨率(Super-Resolution,SR)技术是目前图像处理中比较热门的研究领域。给定一个低分辨率(Low-Reso-

lution,LR)图像,该技术能够重建对应的高分辨率(High-Resolution,HR)图像。这种技术有望打破传感器固有的分辨率限制,因此具有广泛的应用前景。常见的单图像 SR 方法包括基于插值的方法、基于重建的方法和基于学习的方法 3

到稿日期:2019-05-09 返稿日期:2019-09-29 本文已加入开放科学计划(OSID),请扫描上方二维码获取补充信息。

基金项目:国家自然科学基金项目(61761005,61761007);广西自然科学基金项目(2016GXNSFAA380154)

This work was supported by the National Natural Science Foundation of China (61761005,61761007) and Natural Science Foundation of Guangxi Zhuang Autonomous Region(2016GXNSFAA380154).

通信作者:常侃(pandack0619@163.com)

类。其中,基于插值的方法复杂度较低,但是效果不够理想,因此本文主要讨论后两类方法。

基于重建的方法将 LR 图像与 HR 图像间的某种先验信息构建为正则化约束项,用于约束逆向处理图像退化模型的过程,进而优化重建的 HR 图像质量。典型的先验信息有局部先验<sup>[1-2]</sup>、非局部先验<sup>[3]</sup>和稀疏先验<sup>[4]</sup>。为了取得更好的重建结果,研究者提出将多种不同的约束进行联合建模<sup>[5-6]</sup>。

基于学习的 SR 方法在测试环节具备较低的复杂度,并且能够更好地复原图像细节信息。该方法需要在训练环节学习从 LR 空间到 HR 空间的基本映射模型,并将该模型应用于测试环节。传统的基于学习的 SR 方法可以分为基于字典学习的方法<sup>[7-8]</sup>、基于协作表达的方法<sup>[9-10]</sup>、基于结构自相似的方法<sup>[11]</sup>等。随着并行计算技术的快速发展,人们提出了多种基于深度学习的方法<sup>[12-14]</sup>。该类方法在给定的 LR 和 HR 图像对上,基于卷积神经网络学习了从 LR 空间到 HR 空间的端到端映射。该类方法虽然取得了很好的效果,但是对计算资源的要求相对较高。

尽管单图像 SR 技术得到了较好的发展,但是大多数方法仅能处理单通道图像。当处理彩色图像时,一种简单的处理方式是将 SR 算法独立应用到每个彩色通道;另一种常见方法是将彩色图像从 RGB 空间转到 YCbCr 空间<sup>[15]</sup>,再将 SR 算法应用到 Y 通道,而对 Cb 和 Cr 通道只进行简单的插值处理。上述两种方法都没有考虑彩色图像通道间的相关性,因此影响了彩色图像的重建效果。

目前,一些研究人员提出了面向彩色图像的 SR 算法。例如,Zhang 等<sup>[16]</sup>采用 Y 通道作为引导图像,对色度图像进行引导滤波;Mairal 等<sup>[17]</sup>将灰度字典学习方法扩展到学习通道间的相关性上。Xu 等<sup>[18]</sup>提出了四元数稀疏表示模型,并将该模型应用于彩色图像 SR 问题。而 Mousavi 等<sup>[19]</sup>开发了一种捕获颜色信息量的方法,并利用它来平衡构建的正则化项。尽管文献<sup>[19]</sup>有效利用了彩色图像中所有颜色通道的信息,但是在这种方式下的稀疏编码很难给颜色通道间相关性的正则化项找到最稀疏解,从而增加了算法的复杂度。

本文提出了一种彩色图像 SR 算法。该算法在彩色图像 SR 模型上采用 TV 模型表征彩色图像通道间相关性,同时添加非局部自相似性约束来提升图像的重建质量。

## 2 相关背景知识

### 2.1 ScSR 算法

Yang 等<sup>[7]</sup>提出了基于稀疏表示的单图像 SR(Image Super-Resolution via sparse Representation, ScSR)算法,强调 HR 图像和 LR 图像可以使用相同的稀疏表示系数。根据算法流程可以将该算法分为字典训练和图像测试两部分。

在字典训练阶段,ScSR 算法<sup>[7]</sup>通过对训练图像库进行采样,得到 HR 图像块的样本集和 LR 图像块的样本集,学习这两个样本集之间的映射关系,可以得到对应的字典。进一步地,用相同的稀疏编码来表示 HR 图像块和 LR 图像块,即:

$$\begin{aligned} \{D_h, D_l, \alpha\} = \arg \min_{\{D_h, D_l, \alpha\}} & \frac{1}{N} \|X - D_h \alpha\|_2^2 + \frac{1}{M} \|Z - D_l \alpha\|_2^2 + \\ & \lambda \left( \frac{1}{N} + \frac{1}{M} \right) \|\alpha\|_1 \end{aligned} \quad (1)$$

其中,  $N$  和  $M$  分别是 HR 图像块和 LR 图像块向量形式的维

度;  $\alpha$  表示稀疏编码系数;参数  $\lambda$  用于平衡等式的稀疏性约束项;  $X$  表示 HR 图像,  $Z$  表示对应的 LR 图像;  $D_h$  表示 HR 字典,  $D_l$  表示 LR 字典。

在图像测试阶段,需要使 LR 图像  $Z$  和 HR 图像  $X$  的稀疏表示系数  $\alpha$  保持一致,因此  $X$  的图像块  $x$  可以通过训练阶段生成的 HR 字典  $D_h$  和稀疏系数  $\alpha$  来表示:

$$x \approx D_h \alpha \quad (2)$$

其中,稀疏系数  $\alpha$  可以通过输入的图像  $Z$  中的图像块  $z$  与训练阶段生成的 LR 字典  $D_l$  共同决定,即  $z \approx D_l \alpha$ 。

$Z$  的最稀疏表示的问题可以通过最小化 L1 范数进行有效恢复:

$$\alpha = \arg \min_{\alpha} \|FD\alpha - Fz\|_2^2 + \lambda \|\alpha\|_1 \quad (3)$$

其中,  $F$  是线性特征提取算子,参数  $\lambda$  用于平衡等式的稀疏性约束项。

### 2.2 MCcSR 算法

Mousavi 等<sup>[19]</sup>在文献<sup>[7]</sup>的基础上,将基于稀疏表示的 SR 方法从单通道扩展到多通道,并利用边缘相似性作为通道间的相关性约束,提出了基于跨通道约束的彩色图像 SR 算法(Multi-Channel constrained Super Resolution method, MCcSR)。

MCcSR 算法<sup>[19]</sup>假设重构后的 HR 图像在 R,G,B 3 个颜色通道上具有相似的高频信息,同时各个通道存在一定的边缘差异,则:

$$\begin{cases} \|P_r x_r - P_g x_g\|_2 < \epsilon_{rg} \\ \|P_g x_g - P_b x_b\|_2 < \epsilon_{gb} \\ \|P_b x_b - P_r x_r\|_2 < \epsilon_{br} \end{cases} \quad (4)$$

其中,下标  $r, g, b$  分别表示 R,G,B 通道中的信号;矩阵  $P$  是高通边缘检测滤波器;  $\epsilon$  用于限制通道间相关性的边缘差异。

将上述颜色通道信息融入到 SR 框架中,以寻求融合了颜色信息之后的稀疏编码,即:

$$\begin{aligned} [\alpha_r, \alpha_g, \alpha_b] = \arg \min_{\{\alpha_r, \alpha_g, \alpha_b\}} & \sum_{c \in \{r, g, b\}} \frac{1}{2} \|z - D_{l_c} \alpha_c\|_2^2 + \\ & \lambda \|\alpha_c\|_1 + \tau [\|P_r D_{h_r} \alpha_r - P_g D_{h_g} \alpha_g\|_2^2 + \\ & \|P_g D_{h_g} \alpha_g - P_b D_{h_b} \alpha_b\|_2^2 + \|P_b D_{h_b} \alpha_b - \\ & P_r D_{h_r} \alpha_r\|_2^2] \end{aligned} \quad (5)$$

约束(4)强调了各个颜色通道的高频信息之间具有相似性。除了通道间约束,MCcSR 算法还包含各个通道的单独约束,如式(6)所示:

$$x_r = D_{h_r} \alpha_r, x_g = D_{h_g} \alpha_g, x_b = D_{h_b} \alpha_b \quad (6)$$

通过求解最优化问题(5)得到 3 个颜色通道的系数后,再结合式(6)得到各个颜色通道的重建结果。但是,针对每个图像块求解式(5)的复杂度较高。

## 3 基于通道间相关性和非局部自相似性的彩色图像超分辨率算法

由 2.2 节可知,文献<sup>[19]</sup>在文献<sup>[7]</sup>的基础上,将基于稀疏表示的 SR 方法从单通道扩展到多通道,并构建了考虑通道间相关性的正则化约束项。该算法的主要缺点在于:首先,算法对通道间相关性的建模不够准确;其次,算法并没有利用图像内的非局部相似性;最后,求解式(5)所采用的方法耗时过长,极大地限制了算法的应用场合。为解决上述问题,本文

提出了一种基于通道间相关性和非局部自相似性的彩色图像 SR 算法。

### 3.1 通道间相关性约束

本节提出了一种新的通道间相关性约束,如式(7)所示:

$$\Psi_C(\mathbf{X}) = \theta \|\mathbf{B}(\mathbf{x}_r + \mathbf{x}_g + \mathbf{x}_b)\|_1 + \delta [\|\mathbf{B}(\mathbf{x}_g - \mathbf{x}_b)\|_1 + \|\mathbf{B}(\mathbf{x}_b - \mathbf{x}_r)\|_1] \quad (7)$$

其中,  $\mathbf{B} = [\mathbf{B}_h^T, \mathbf{B}_v^T]$ ,  $\mathbf{B}_h^T \in \mathbb{R}^{N \times N}$  和  $\mathbf{B}_v^T \in \mathbb{R}^{N \times N}$  分别是水平方向和垂直方向上的梯度算子;  $N$  表示图像中的像素数; 而系数  $\theta$  和  $\delta$  是平衡不同正则化条件的参数。对式(7)取最小化, 相当于在梯度域下同时强调各通道信号残差的稀疏性以及色彩通道平均信号的稀疏性。

与 MCcSR 算法<sup>[19]</sup>的通道间相关性约束相比, 本文的约束主要有以下两点不同。一是在梯度域下对通道间相关性进行衡量。因为通道信号差值在梯度域具有稀疏性, 所以采用 L1 范数来衡量梯度域下的通道信号差值比 L2 范数更为合适。二是考虑了 3 个颜色通道的平均信息。因为在梯度域下, 3 个颜色通道的平均信息比通道间差值对图像边缘更敏感。因此, 考虑 3 个通道的平均信息可以使重建图像更具有鲁棒性。此外, 正因为加入了 3 个通道的平均信息, 在式(7)中仅需要考虑 G 通道和 B 通道、B 通道和 R 通道之间的残差, 即可涵盖各色彩通道的所有信息。

### 3.2 联合通道间相关性及非局部自相似性的重建模型

图像统计表明, 任何一幅自然图像都会存在非局部结构或者纹理重复出现的现象。如果在进行图像 SR 的过程中能有效利用这些相似图像块提供的互补信息, 就可以更清晰地重构 HR 图像块。

Dabov 等<sup>[20]</sup>提出了彩色三维块匹配(Color Block-Matching 3D, CBM3D)算法, 它是一种有效利用彩色图像非局部相似性进行两步滤波的去噪算法。该算法的两大步骤都执行类似的操作: 首先利用图像的非局部相似性进行分组, 其次将分组图像块转成 3D 形式, 然后在 3D 形式下进行滤波, 最后将滤波后的图像块进行聚合。值得注意的是, 为了对彩色图像的色度通道进行有效去噪, CBM3D 算法<sup>[20]</sup>在色度通道上重复使用与亮度通道完全相同的分组, 即在色度通道上应用一个分组约束。

基于此, 本文提出下述联合考虑通道间相关性以及非局部自相似性的重建模型:

$$\hat{\mathbf{X}} = \arg \min_{\mathbf{X}} \frac{1}{2} \|\mathbf{Z} - \mathbf{H}\mathbf{X}\|_2^2 + \varphi \|\text{cbm3d}(\tilde{\mathbf{X}}) - \mathbf{X}\|_2^2 + \Psi_C(\mathbf{X}) \quad (8)$$

其中,  $\mathbf{X} = [\mathbf{X}_r, \mathbf{X}_g, \mathbf{X}_b]^T$ ,  $\hat{\mathbf{X}}$  表示最终重建的 HR 图像,  $\tilde{\mathbf{X}}$  表示目标 HR 图像的临时重建结果;  $\text{cbm3d}(\tilde{\mathbf{X}})$  表示利用 CBM3D<sup>[20]</sup>对  $\tilde{\mathbf{X}}$  进行去噪处理。  $\mathbf{Z}$  表示将 HR 图像  $\mathbf{X}$  经过模糊和下采样之后得到的 LR 图像,  $\mathbf{H}$  表示模糊和下采样降质过程。需要注意的是, 本文将  $\tilde{\mathbf{X}}$  与真实图像  $\mathbf{X}$  之间的误差视为噪声, 采用 CBM3D<sup>[20]</sup>的方法进行去除。

式(8)中的第一项是计算彩色图像的数据保真项, 强调 LR 测量值与 HR 重建值在 LR 空间的投影在数值上相近; 第二项表示待更新的重建图像要不断逼近经过 CBM3D<sup>[20]</sup>处理后的图像; 剩余项与 3.1 节构造的通道间相关性约束一致。

其中,  $\varphi, \theta$  和  $\delta$  表示等式中正则化项的权重系数, 本文通过大量的实验来获取这些系数的最佳值。本文提出的重建模型(8)联合应用了通道之间的相关性以及图像内部的非局部自相似性。由于有效利用了不同种类的先验信息, 该重建模型相比模型(5)更为准确。

### 3.3 算法最优化问题求解

为了便于计算, 将式(8)进行如下转换:

$$\hat{\mathbf{X}} = \arg \min_{\mathbf{X}} \frac{1}{2} \|\mathbf{Z} - \mathbf{H}\mathbf{X}\|_2^2 + \varphi \|\text{cbm3d}(\tilde{\mathbf{X}}) - \mathbf{X}\|_2^2 + \delta \|\tilde{\mathbf{B}}\mathbf{S}\mathbf{X}\|_1 \quad (9)$$

其中,  $\tilde{\mathbf{B}} = \text{diag}(\mathbf{B}, \mathbf{B}, \mathbf{B})$ ,  $\mathbf{I}$  是尺寸大小为  $N \times N$  的单位矩阵, 且  $\mathbf{S}$  矩阵的定义如下:

$$\mathbf{S} = \begin{bmatrix} \theta\mathbf{I}/\delta & \theta\mathbf{I}/\delta & \theta\mathbf{I}/\delta \\ 0 & \mathbf{I} & -\mathbf{I} \\ -\mathbf{I} & 0 & \mathbf{I} \end{bmatrix} \quad (10)$$

为了求解式(9)关于目标函数  $\mathbf{X}$  的 L1 项, 引进中间变量  $\mathbf{d}$ , 令  $\mathbf{d} = \tilde{\mathbf{B}}\mathbf{S}\mathbf{X}$ 。为了使等式可以加速收敛, 并且快速得到最优化结果, 为式(9)引入中间变量  $\mathbf{b}$ , 从而使等式可以根据 split-Bregman 迭代算法进行更新。转换的公式如下:

$$\{\tilde{\mathbf{X}}, \mathbf{d}\} = \arg \min_{\{\tilde{\mathbf{X}}, \mathbf{d}\}} \frac{1}{2} \|\mathbf{Z} - \mathbf{H}\mathbf{X}\|_2^2 + \varphi \|\text{cbm3d}(\tilde{\mathbf{X}}) - \mathbf{X}\|_2^2 + \delta \|\mathbf{d}\|_1 + \frac{\mu}{2} \|\mathbf{d} - \tilde{\mathbf{B}}\mathbf{S}\mathbf{X} - \mathbf{b}\|_2^2 \quad (11)$$

接下来将式(11)分解为“ $\mathbf{X}$ ”和“ $\mathbf{d}$ ”两个子问题, 并迭代求解。则“ $\mathbf{X}$ ”和“ $\mathbf{d}$ ”两个子问题的具体计算公式分解如下:

$$\begin{cases} \mathbf{X}^{k+1} = \arg \min_{\mathbf{X}} \|\mathbf{Z} - \mathbf{H}\mathbf{X}\|_2^2 + 2\varphi \|\text{cbm3d}(\tilde{\mathbf{X}}) - \mathbf{X}\|_2^2 + \mu \|\mathbf{d}^k - \tilde{\mathbf{B}}\mathbf{S}\mathbf{X} - \mathbf{b}^k\|_2^2 \\ \mathbf{d}^{k+1} = \arg \min_{\mathbf{d}} \delta \|\mathbf{d}\|_1 + \frac{\mu}{2} \|\mathbf{d}^k - \tilde{\mathbf{B}}\mathbf{S}\mathbf{X}^{k+1} - \mathbf{b}^k\|_2^2 \\ \mathbf{b}^{k+1} = \mathbf{b}^k + \tilde{\mathbf{B}}\mathbf{S}\mathbf{X}^{k+1} - \mathbf{d}^{k+1} \end{cases} \quad (12)$$

其中,  $\mu$  是公式变换过程中引入的用于平衡约束项的加权参数。应该注意的是, 因为 CBM3D 迭代的复杂度较高, 为了平衡算法的复杂度和准确度, 本文算法每循环 3 次, 使用 CBM3D 更新一次  $\tilde{\mathbf{X}}$ , 更新后的输出结果用  $\hat{\mathbf{X}}_{Temp}$  表示。

在式(11)中, 对于“ $\mathbf{X}$ ”子问题, 可以通过对代价函数求导, 并令求导结果等于 0 来得到第  $(k+1)$  次迭代时  $\mathbf{X}$  的表达式:

$$\mathbf{X}^{k+1} = \frac{[\mathbf{H}^T \mathbf{Z} + 2\varphi \hat{\mathbf{X}}_{Temp} + \mu(\tilde{\mathbf{B}}\mathbf{S})^T(\mathbf{d}^k - \mathbf{b}^k)]}{[\mathbf{H}^T \mathbf{H} + 2\varphi + \mu(\tilde{\mathbf{B}}\mathbf{S})^T(\tilde{\mathbf{B}}\mathbf{S})]} \quad (13)$$

直接计算式(13)的复杂度依然很高, 因此本文采用共轭梯度法<sup>[21]</sup>计算第  $(k+1)$  次迭代时  $\mathbf{X}$  的数值。

对于“ $\mathbf{d}$ ”子问题, 可以进行如下求解:

$$\mathbf{d}^{k+1} = \text{shrink}(\tilde{\mathbf{B}}\mathbf{S}\mathbf{X}^{k+1} + \mathbf{b}^k, \delta/\mu) \quad (14)$$

$\text{shrink}(x, \tau)$  为收缩函数, 其公式如下:

$$\text{shrink}(x, \tau) = \frac{x}{|x|} \max(|x| - \tau, 0) \quad (15)$$

由此, 完成了式(9)最优化问题的求解推导。CISR 算法的流程如算法 1 所示, 其中  $K$  表示迭代次数的上限。

#### 算法 1 CISR

输入:  $\tilde{\mathbf{X}}, \mathbf{Z}, \delta, \theta, \mu, \varphi$

```

输出: $\hat{\mathbf{X}}$ 
初始化: $\mathbf{d}^0 = \mathbf{BSX}, b^0 = 0$ .
For  $k=0, 1, 2, \dots, K$ 
If  $\text{mod}(k, 3) = 0$ 
 $\hat{\mathbf{X}}_{\text{Temp}} = \text{cbm3d}(\tilde{\mathbf{X}}_k)$ 
end
根据式(13)计算  $\mathbf{X}^{k+1}$ ;
根据式(14)计算  $\mathbf{d}^{k+1}$ ;
根据式(12)计算  $\mathbf{b}^{k+1}$ ;
End For
输出  $\hat{\mathbf{X}} = \mathbf{X}^K$ 

```

## 4 实验结果与分析

为了验证本文提出的彩色图像 SR 算法的有效性,将所

提算法与 Bicubic 上采样、文献[7]的算法、文献[8]的算法、文献[9]的算法以及文献[19]的算法进行比较。所采用的测试数据库为 Set5<sup>[22]</sup> 和 Set14<sup>[8]</sup>。需要注意的是,Set14 图像库中有两幅黑白图像,在本次实验中已将其排除。通过大量实验,本文将输入参数设置为如下经验值: $\delta = 32.0, \theta = 80.0, \mu = 0.4, \varphi = 30.0, K = 15$ 。采用文献[10]中的算法的重建图像作为  $\mathbf{X}$  的初始值  $\tilde{\mathbf{X}}$ 。

本文实验与文献[7-9, 19]一致,对测试图像进行 3 倍的 Bicubic 下采样得到 LR 图像,再在 LR 图像上进行处理。文献[7]的算法、文献[8]的算法和文献[9]的算法分别在 LR 图像的 3 个通道上独立进行 SR 处理,而文献[19]的算法和本文算法则将 LR 图像的 3 个通道作为一个整体进行 SR 处理。表 1 和表 2 分别列出了各种算法在相同实验条件下进行 SR 处理的 PSNR 值和 SSIM 值。

表 1 Set5 图像库下的 PSNR(dB)和 SSIM 对比( $\times 3$ )

Table 1 Comparison of PSNR (dB) and SSIM results for testing images in Set5 ( $\times 3$ )

图像	评估值	Bicubic	文献[7]算法	文献[8]算法	文献[9]算法	文献[19]算法	本文算法
baby	PSNR/dB	38.39	39.27	39.29	39.41	39.36	<b>39.52</b>
	SSIM	0.8839	0.9028	0.8981	0.9023	0.9040	<b>0.9054</b>
bird	PSNR/dB	36.35	37.71	37.80	38.09	38.01	<b>38.75</b>
	SSIM	0.9101	0.928	0.9276	0.9315	0.9313	<b>0.9409</b>
butterfly	PSNR/dB	28.73	29.97	29.80	30.06	30.58	<b>31.66</b>
	SSIM	0.7932	0.8265	0.8252	0.8294	0.8478	<b>0.8855</b>
head	PSNR/dB	36.00	36.36	36.41	<b>36.50</b>	36.46	36.36
	SSIM	0.7259	0.7518	0.7408	0.7495	0.7531	<b>0.7532</b>
woman	PSNR/dB	33.29	34.39	34.48	34.69	34.82	<b>35.47</b>
	SSIM	0.8783	0.8985	0.8985	0.9017	0.9041	<b>0.9171</b>
平均	PSNR/dB	34.55	35.55	35.55	35.75	35.85	<b>36.35</b>
	SSIM	0.8383	0.8580	0.8616	0.8630	0.8681	<b>0.8804</b>

表 2 Set14 图像库下的 PSNR(dB)和 SSIM 对比( $\times 3$ )

Table 2 Comparison of PSNR (dB) and SSIM results for testing images in Set14 ( $\times 3$ )

图像	评估值	Bicubic	文献[7]算法	文献[8]算法	文献[9]算法	文献[19]算法	本文算法
baby	PSNR/dB	26.71	26.91	26.99	27.01	27.00	<b>27.08</b>
	SSIM	0.4812	0.5100	0.5383	0.5280	0.5396	<b>0.5425</b>
barbara	PSNR/dB	30.75	31.16	31.24	31.19	<b>31.27</b>	31.12
	SSIM	0.7221	0.7442	0.7542	0.7489	<b>0.7559</b>	0.7540
coastguard	PSNR/dB	31.31	31.71	31.78	31.75	31.79	<b>31.95</b>
	SSIM	0.5801	0.6109	0.6333	0.6212	<b>0.6333</b>	0.6325
comic	PSNR/dB	27.50	28.07	28.24	28.28	28.40	<b>28.73</b>
	SSIM	0.6856	0.7209	0.7411	0.7349	0.7483	<b>0.7629</b>
face	PSNR/dB	35.95	36.33	36.35	36.47	<b>36.41</b>	36.36
	SSIM	0.7238	0.7393	0.7498	0.7479	0.7513	<b>0.7520</b>
flowers	PSNR/dB	30.92	31.68	31.85	31.91	32.07	<b>32.71</b>
	SSIM	0.7797	0.8034	0.8143	0.8122	0.8193	<b>0.8335</b>
foreman	PSNR/dB	35.75	36.93	36.87	37.22	37.54	<b>37.83</b>
	SSIM	0.8906	0.9067	0.9062	0.9106	0.9134	<b>0.9266</b>
lenna	PSNR/dB	35.25	36.02	36.05	36.23	36.26	<b>36.43</b>
	SSIM	0.7874	0.8018	0.8079	0.8079	0.8104	<b>0.8126</b>
monarch	PSNR/dB	34.06	35.04	35.18	35.33	35.66	<b>36.51</b>
	SSIM	0.9064	0.9181	0.9189	0.9206	0.9236	<b>0.9346</b>
pepper	PSNR/dB	35.23	36.13	35.93	36.10	36.30	<b>36.51</b>
	SSIM	0.7899	0.8014	0.8031	0.8031	0.8060	<b>0.8101</b>
ppt3	PSNR/dB	28.02	29.04	29.16	29.09	29.32	<b>30.61</b>
	SSIM	0.8623	0.8836	0.8844	0.8784	0.8899	<b>0.9234</b>
zebra	PSNR/dB	31.33	32.65	32.81	32.89	33.16	<b>33.67</b>
	SSIM	0.7787	0.8131	0.8295	0.8241	0.8340	<b>0.8418</b>
平均	PSNR/dB	31.90	32.64	32.70	32.79	32.93	<b>33.29</b>
	SSIM	0.7490	0.7711	0.7818	0.7781	0.7854	<b>0.7942</b>

从表 1、表 2 中可以看出,文献[19]的算法比较优秀,因

此将本文算法与文献[19]的算法做详细的数值对比。相比文

献[19]的算法,本文算法在 Set5 图像库上的平均 PSNR 提升了 0.5dB,平均 SSIM 提升了 0.0123;在 Set14 图像库上平均 PSNR 提升了 0.36dB,平均 SSIM 提升了 0.0088。

为了从主观质量上评价各算法性能的优劣,图 1 和图 2 分别展示了除 Bicubic 上采样以外的各种算法在彩色图像 woman 和 pepper 上的重建结果。从 SR 重建效果图及其放大区域可以清楚地看到,相比其他几种算法,本文算法得到的重建图像失真较小,物体边缘更为清晰,结构特征得到了更好的保持。

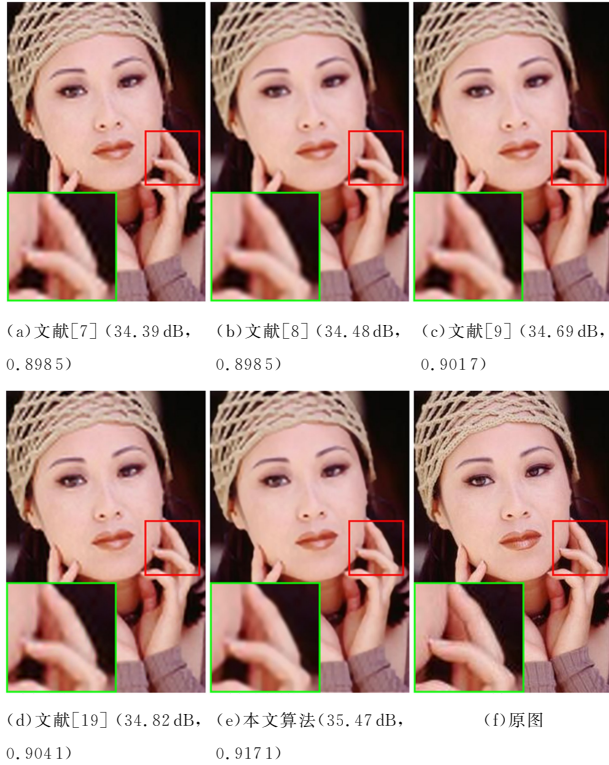


图 1 彩色图像 woman 的 SR 结果对比

Fig. 1 Comparison of SR results of color image woman



图 2 彩色图像 pepper 的 SR 结果对比

Fig. 2 Comparison of SR results of color image pepper

价算法性能的一个重要指标。表 3 列出了在同一实验条件下各种算法在 Set5 和 Set14 图像库上的平均运行时间。从表中可以看出,文献[19]的运行速度最慢,主要原因在于文献[19]针对每个图像块都需要求解问题(5),而在采用过完备字典的情况下,问题(5)的求解复杂度很高。相比文献[19],本文算法的运行速度具有明显优势,主要原因在于:首先,本文所建立的核心问题(9)考虑的是梯度域下的稀疏性,未知变量的维度不高;其次,本文算法采用了 split-Bregman 方法计算问题(9),算法的收敛速度得到了明显提升。本文算法与文献[8]、文献[9]中的算法的速度接近,但是获得了明显优于文献[8]、文献[9]中的算法的重建结果。

表 3 各算法在两个图像库上的平均运行时间

Table 3 Comparison of average running time on two image sets (单位:s)

图像库	文献[7]	文献[8]	文献[9]	文献[19]	本文算法
Set5	214.66	3.95	2.34	37597.40	2.23
Set14	119.39	2.10	1.29	2068.08	1.24

**结束语** 本文提出了一种基于通道间相关性和非局部自相似性的彩色图像 SR 算法。首先,将 TV 模型应用到图像 SR 结构上,使其可以有效利用彩色图像的通道间相关性;其次,利用彩色图像的非局部自相似性更新重建的图像;最后,为了求解优化问题,提出了一种基于 split-Bregman 方法的快速迭代算法。从实验结果可以看出,在同等实验条件下,本文算法相比文献[7]、文献[8]、文献[9]和文献[19]中的算法来说,在主客观质量上都有较为明显的提升,同时具有较低的算法复杂度。尽管本文已经验证所提模型的有效性,但是在其他应用上(如图像去噪、去模糊等),本文模型的效果未知。我们将在未来的工作中进一步对上述应用进行研究和探讨。

## 参考文献

- [1] RUDIN L I, OSHER S, FATEMI E. Nonlinear total variation based noise removal algorithms [J]. *Physica D: Nonlinear Phenomena*, 1992, 60(1/2/3/4): 259-268.
- [2] CHANG K, DING P L K, LI B. Single image super resolution using joint regularization [J]. *IEEE Signal Processing Letters*, 2018, 25(4): 596-600.
- [3] REN C, HE X, PU Y, et al. Enhanced non-local total variation model and multi-directional feature prediction prior for single image super resolution [J]. *IEEE Transactions on Image Processing*, 2019, 28(8): 3778-3793.
- [4] DONG W, ZHANG L, SHI G, et al. Image deblurring and super-resolution by adaptive sparse domain selection and adaptive regularization [J]. *IEEE Transactions on Image Processing*, 2011, 20(7): 1838-1857.
- [5] DONG W, ZHANG L, SHI G, et al. Nonlocally centralized sparse representation for image restoration [J]. *IEEE Transactions on Image Processing*, 2013, 22(4): 1620-1630.
- [6] CHANG K, ZHANG X, DING P L K, et al. Data-adaptive low-rank modeling and external gradient prior for single image super-resolution [J]. *Signal Processing*, 2019, 161: 36-49.

除了算法的主观质量和客观质量之外,运行时间也是评

- [7] YANG J, WRIGHT J, HUANG T S, et al. Image super-resolution via sparse representation [J]. *IEEE Transactions on Image Processing*, 2010, 19(11): 2861-2873.
- [8] ZEYDE R, ELAD M, PROTTER M. On single image scale-up using sparse-representations [C] // *International Conference on Curves and Surfaces*. 2010: 711-730.
- [9] TIMOFTE R, DE SMET V, VAN GOOL L. Anchored neighborhood regression for fast example-based super-resolution [C] // *Proceedings of the IEEE International Conference on Computer Vision (ICCV)*. 2013: 1920-1927.
- [10] TIMOFTE R, DE SMET V, VAN GOOL L. A+: Adjusted anchored neighborhood regression for fast super-resolution [C] // *Asian Conference on Computer Vision*. 2014: 111-126.
- [11] HUANG J B, SINGH A, AHUJA N. Single image super-resolution from transformed self-exemplars [C] // *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. 2015: 5197-5206.
- [12] DONG C, LOY C C, HE K, et al. Image super-resolution using deep convolutional networks [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*. 2016, 38(2): 295-307.
- [13] DONG C, LOY C C, TANG X. Accelerating the super-resolution convolutional neural network [C] // *European Conference on Computer Vision*. 2016: 391-407.
- [14] KIM J, KWON LEE J, MU LEE K. Accurate image super-resolution using very deep convolutional networks [C] // *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. 2016: 1646-1654.
- [15] ZHANG K, TAO D, GAO X, et al. Learning multiple linear mappings for efficient single image super-resolution [J]. *IEEE Transactions on Image Processing*, 2015, 24(3): 846-861.
- [16] ZHANG Q, CHEN B, LU X, et al. Super-resolution of single multi-color image with guided filter [J]. *Journal of Visual Communication and Image Representation*, 2019, 58: 277-284.
- [17] MAIRAL J, ELAD M, SAPIRO G. Sparse representation for color image restoration [J]. *IEEE Transactions on image processing*, 2008, 17(1): 53-69.
- [18] XU Y, YU L, XU H, et al. Vector sparse representation of color image using quaternion matrix analysis [J]. *IEEE Transactions on Image Processing*, 2015, 24(4): 1315-1329.
- [19] MOUSAVI H S, MONGA V. Sparsity-based color image super-resolution via exploiting cross channel constraints [J]. *IEEE Transactions on Image Processing*, 2017, 26(11): 5094-5106.
- [20] DABOV K, FOI A, KATKOVNIK V, et al. Color Image Denoising via Sparse 3D Collaborative Filtering with Grouping Constraint in Luminance-Chrominance Space [C] // *IEEE International Conference on Image Processing*. 2007: 313-316.
- [21] DAI Y H, YUAN Y. A nonlinear conjugate gradient method with a strong global convergence property [J]. *SIAM Journal on Optimization*, 1999, 10(1): 177-182.
- [22] BEVILACQUA M, ROUMY A, GUILLEMOT C, et al. Low-complexity single-image super-resolution based on nonnegative neighbor embedding [C] // *British Machine Vision Conference*. 2012: 135-1.



**MO Cai-wang**, born in 1993, postgraduate. Her main research interests include image super-resolution and denoising.



**CHANG KAN**, born in 1983, Ph.D, associate professor, master supervisor, is a member of China Computer Federation. His main research interests include image and video processing, compressive sensing, video coding, etc.