

# 空间自适应正则化的图像超分重建算法

黄炜钦<sup>1,3</sup>, 黄德天<sup>1,2,3</sup>, 顾培婷<sup>1,3</sup>, 柳培忠<sup>4</sup>

<sup>1</sup>(华侨大学 工学院 福建 泉州 362021)

<sup>2</sup>(华侨大学 机电及自动化学院 福建 厦门 361021)

<sup>3</sup>(华侨大学 工业智能化技术与系统福建省高校工程研究中心 福建 泉州 362021)

<sup>4</sup>(厦门大学 信息科学与技术学院 福建 厦门 361005)

E-mail: huangdetian@hqu.edu.cn

**摘要:** 为提高稀疏表示系数的精度和图像的分辨率,提出一种基于稀疏表示和正则化技术的超分重建算法.首先引入自回归正则化项,通过样本图像来训练出描述图像局部结构的自回归模型,每个图像块自适应选择一个自回归模型用以调节解空间,实现图像局部的自适应控制.然后,引入非局部相似正则化项作为自回归正则化项的补充,用于保持图像边缘清晰度.从而,完整构造出一种基于自回归正则化和非局部相似正则化的稀疏编码目标函数.为了进一步恢复图像,实现图像去噪、去模糊,利用总变分正则化实现全局优化.实验结果表明,与L1SR、SISR、ANR、NE+LS、NE+NNLS、NE+LLE和A+(16 atoms)等算法相比,无论在主观视觉效果还是客观评价指标上,提出的算法都取得了更好的超分重建效果.

**关键词:** 超分辨率; 稀疏表示; 自回归模型; 非局部相似; 总变分正则化

中图分类号: TP391

文献标识码: A

文章编号: 1000-1220(2017)06-1398-06

## Image Super-resolution Reconstruction Algorithm Based on Spatial Adaptive Regularization

HUANG Wei-qin<sup>1,3</sup>, HUANG De-tian<sup>1,2,3</sup>, GU Pei-ting<sup>1,3</sup>, LIU Pei-zhong<sup>4</sup>

<sup>1</sup>(College of Engineering, Huaqiao University, Quanzhou 362021, China)

<sup>2</sup>(College of Mechanical Engineering and Automation, Huaqiao University, Xiamen 361021, China)

<sup>3</sup>(Universities Engineering Research Center of Fujian Province Industrial Intelligent Technology and Systems, Huaqiao University, Quanzhou 362021, China)

<sup>4</sup>(School of Information Science and Engineering, Xiamen University, Xiamen 361005, China)

**Abstract:** In order to improve the accuracy of sparse representation coefficients and the resolution of the image, a novel super reconstruction algorithm based on sparse representation and regularization technique is proposed. First, the auto-regressive (AR) regularization term is introduced in sparse coding objective function. The AR model which describes the local structure of the image can be trained by using the sample images. And each image patch adaptively selects an AR model to adjust the solution space and realize the image local adaptive control. Then, the non-local (NL) similarity regularization term is introduced as a complement to the AR regularization term, which is used to preserve the edge sharpness of the image. Therefore, the sparse coding objective function is constructed based on the AR regularization and NL similarity regularization. In order to restore the image and improve the performance of image denoising and deblurring further, the total-variation regularization is adopted to realize the global optimization. Experimental results validate that compared with L1SR, SISR, ANR, NE+LS, NE+NNLS, NE+LLE and A+(16 atoms) methods, the proposed approach achieves better super-resolution reconstruction effects in both subjective visual effects and objective evaluation criteria.

**Key words:** super resolution; sparse representation; auto-regressive model; non-local similarity; total-variation regularization

## 1 引言

图像超分辨率(Super Resolution, SR)重建技术<sup>[1]</sup>是从软件角度出发,通过相关算法对低分辨率(Low Resolution, LR)图像进行重建,从而获得清晰的高分辨率(High Resolution, HR)图像.该技术突破了现有成像器件的限制,是数字图像处理的研究热点之一. SR方法的关键是在重建过程中加入一定

的附加信息来弥补降质过程中损失的细节信息<sup>[2]</sup>.

在基于学习的图像SR方法中,Thomas Huang团队的Yang开创<sup>[3,4]</sup>的基于稀疏表示的图像SR算法最为突出. Yang等通过高分辨率图像样本库训练出具有相同稀疏表示的HR和LR字典对,并通过HR字典与输入LR图像的稀疏表示系数重建出对应HR图像.该算法获得的重建图像虽然具有较好的视觉效果,但具有一定的块效应.近年来,国内外

收稿日期: 2016-09-14 收修改稿日期: 2016-11-28 基金项目: 国家自然科学基金项目(61203242)资助; 泉州市科技计划项目(2014Z113, 2014Z103)资助; 华侨大学研究生科研创新能力培育计划项目(1511422002)资助. 作者简介: 黄炜钦,男,1991年生,硕士研究生,研究方向为数字图像处理; 黄德天(通信作者),男,1985年生,博士,讲师,研究方向为计算机视觉、机器学习和嵌入式系统; 顾培婷,女,1991年生,硕士研究生,研究方向为机器学习与目标跟踪; 柳培忠,男,1976年生,博士,副教授,研究方向为仿生图像处理与模式识别.

学者在该方法基础上展开了广泛研究. Tikhonov 等<sup>[5]</sup>用正则化技术来求解反问题, 为图像重建提供了科学的理论基础. 自回归 (Auto-Regressive, AR) 模型正则化作为一个经典的方法, 成功地应用于图像压缩<sup>[6]</sup>和插值<sup>[7]</sup>. Wu 等<sup>[8]</sup>指出 AR 模型是从一个初始图像中局部计算得来, 他们在边缘结构的重建方面上取得很好的效果. 然而, 从初始图像中估计到的 AR 模型往往会产生视觉伪影. 除了 AR 模型正则化之外, 近年来非局部 (Non-local, NL) 相似正则化方法在各种图像复原中应用越来越广泛, 具有许多可喜的研究成果, 尤其在图像去噪<sup>[9]</sup>、去模糊<sup>[10]</sup>和超分辨率重建<sup>[11]</sup>方面. Mairal 等<sup>[12]</sup>将非局部相似先验知识与稀疏表示模型结合起来, 相似的图像块可以同时编码, 从而提高反向重构的鲁棒性.

结合上述文献的思路, 本文引入 AR 正则化和 NL 相似正则化对稀疏表示系数的求解进行约束, 并利用总变分 (Total-variation, TV) 正则化对重建后的高分辨率图像进行全局优化, 提高重建图像的质量.

## 2 基于稀疏表示和正则化理论的超分辨率重建模型

### 2.1 基于稀疏表示的超分辨率重建模型

HR 图像  $X \in R^N$  通过降质得到 LR 图像  $Y \in R^M$  的观测模型如下:

$$Y = DBX + n \quad (1)$$

其中  $D$  表示下采样矩阵,  $B$  表示模糊矩阵,  $n$  表示高斯白噪声.

上式表明, 图像的超分辨率重建是一个病态的反问题, 由给定的低分辨率图像  $Y$  可重建出很多个满足上述重建条件的高分辨率图像  $X$ . 为了保证式 (1) 得到唯一解, 需要通过加入一些稀疏先验知识来求解.

在稀疏表示模型中, 采用文献 [3] 的字典训练算法训练 HR 字典  $D_h$  和 LR 字典  $D_l$ , 通过  $D_l$  为每个 LR 图像块  $y$  找到对应的稀疏表示系数  $\alpha$ , 在 HR 与 LR 图像块具有相同稀疏表示的前提下, 通过  $\alpha$  与  $D_h$  可重建出 HR 图像块. 求解低分辨率图像块  $y$  的稀疏表示系数如式 (2) 所示:

$$\min \|\alpha\|_0 \text{ s.t. } \|FD_l\alpha - Fy\|_2^2 \leq \varepsilon \quad (2)$$

其中  $F$  是一个线性特征提取操作<sup>[3]</sup>.

通常, 式 (2) 的优化问题是一个 NP 难问题, 文献 [14] 的结果表明只要  $\alpha$  足够稀疏, 那么可以采用最小化  $l_1$ -范式来代替  $l_0$ -范式, 实现图像的高效重建, 如式 (3) 所示:

$$\min \|\alpha\|_1 \text{ s.t. } \|FD_l\alpha - Fy\|_2^2 \leq \varepsilon \quad (3)$$

采用拉格朗日乘数对式 (3) 进行等价转换, 可得如下表达式:

$$\min \lambda \|\alpha\|_1 + \frac{1}{2} \|FD_l\alpha - Fy\|_2^2 \quad (4)$$

其中  $\lambda$  是平衡解的稀疏度和图像块  $y$  保真度的参数.

### 2.2 图像超分辨率重建问题的正则化约束模型

由 2.1 所述的观测模型可知式 (1) 为病态方程. 在重建图像时, 当下采样矩阵  $D$ 、模糊矩阵  $B$  以及噪声  $n$  发生微小变化时, 图像重建结果将受到噪声和降质过程的干扰, 产生大的变化. 因此, 采用正则化可以实现稳定求解.

正则化方法利用解的先验知识构造附加约束, 以保证问

题解的存在、唯一及连续, 实现将不适定问题转化为适定问题. 该方法需要求解如下目标泛函的极小值以确定求解问题的近似解.

$$J(x, \mu) = \|y - Hx\|^2 + \mu p(x) \quad (5)$$

其中,  $\|y - Hx\|^2$  是数据拟合项,  $p(x)$  是正则化项, 对求解 HR 图像  $X$  进行约束以得到一个稳定解,  $\mu$  为约束强度. 超分辨率问题的本质是在满足充分拟合观测数据的条件下, 最小化某种奇异性度量值, 找到对应的最优解.

## 3 基于空间自适应正则化的图像超分辨率

### 3.1 自回归正则化

在稀疏编码模型中, 通过加入 AR 模型来进一步约束求解, 实现图像局部区域的自适应控制. AR 正则化项的构造包括 AR 模型的训练和自适应选择:

AR 模型训练. 从高分辨率图像块的聚类结果中学习得到一组 AR 模型, 并自适应地为待重建图像块选择一个 AR 模型对图像块的重建进行约束. 首先将整个训练集划分为  $k$  个子图像训练集  $S_k$ , 对于每个  $S_k$  可以利用其本身包含的所有样本图像块来训练出一个 AR 模型. AR 模型的阶数非常重要, 若一个 AR 模型阶数太高可能会导致数据过拟合<sup>[15]</sup>. 在实验中, 窗口大小设置为  $3 \times 3$  (即, AR 模型的阶数设为 8). 令第  $k$  个子图像数据集  $S_k$  的 AR 模型的参数向量为  $a_k$ , 则  $a_k$  可以通过最小二乘法简单地计算出来, 公式如下:

$$a_k = \arg \min_a \sum_{s_i \in S_k} (s_i - a^T q_i)^2 \quad (6)$$

其中  $s_i$  是图像块  $S_k$  的中间像素,  $q_i$  是包含  $s_i$  的相邻像素的向量. 通过将 AR 模型的训练过程应用于每一个子图像数据集, 就可以获得一组 AR 模型  $\{a_1, a_2, \dots, a_k\}$ , 再将这些 AR 模型用于图像块的自适应选择.

AR 模型的自适应选择. 对于每个子图像数据集中的每个图像块  $x_i$  的 AR 模型的自适应选择, 通过  $x_i$  的一个估计值  $\hat{x}_i$ , 计算出其通过高通滤波器后得出的结果  $\hat{x}_i^h$ .  $\mu_k$  表示的是与  $S_k$  相关的每个聚类  $C_k$  的中心. 令  $k_i = \arg \min_k \|\hat{x}_i^h - \mu_k\|_2$ , 然后将第  $k_i$  个 AR 模型  $a_{k_i}$  分配给图像块  $x_i$ , 设  $\chi_i$  表示图像块  $x_i$  的中间像素,  $\chi_i$  是包含了  $x_i$  的所有相邻像素的向量, 通过  $a_{k_i}$  和  $\chi_i$  实现将  $x_i$  的预测误差最小化, 即最小化  $\|x_i - a_{k_i}^T \chi_i\|_2^2$ . 最后将该约束条件加入到稀疏编码的过程中, 即加入式 (4) 中, 从而得到如下目标函数:

$$\min \lambda \|\alpha\|_1 + \frac{1}{2} \|FD_l\alpha - Fy\|_2^2 + \gamma \cdot \sum_{x_i \in X} \|x_i - a_{k_i}^T \chi_i\|_2^2 \quad (7)$$

其中  $\gamma$  为常数, 用于调节 AR 模型正则化项对稀疏编码的影响. 如果将第三项  $\sum_{x_i \in X} \|x_i - a_{k_i}^T \chi_i\|_2^2$  写成  $\|(\mathbf{I} - \mathbf{A})\mathbf{x}\|_2^2$ , 则式 (7) 可以改写为:

$$\min \lambda \|\alpha\|_1 + \frac{1}{2} \|FD_l\alpha - Fy\|_2^2 + \gamma \cdot \|(\mathbf{I} - \mathbf{A})\mathbf{x}\|_2^2 \quad (8)$$

其中  $\mathbf{I}$  是单位矩阵,

$$\mathbf{A}(i, j) = \begin{cases} a_i, & \text{当 } x_j \in \chi_i, \text{ 其中 } a_i \in a_{k_i} \\ 0, & \text{当 } x_j \notin \chi_i \end{cases}$$

### 3.2 非局部相似正则化

AR模型主要利用了每个图像块的局部数据,缺乏在非局部上优化.为了对基于AR模型的自适应正则化项进行补充,在稀疏编码阶段引入了一个NL相似正则化项,非局部相似可以将非局部冗余贯穿在图像中,从而改善重建图像的质量<sup>[15]</sup>.

对于每一个局部图像块  $x_i$ ,在整个图像中寻找与其相似的图像块.在查找过程中,如果一个图像块  $x_i^l$  与当前图像块  $x_i$  满足  $e_i^l = \|\hat{x}_i - \hat{x}_i^l\|_2^2 \leq t$ ,那么  $x_i^l$  就是相似图像块,其中  $t$  是一个事先调整好的阈值,  $\hat{x}_i$  和  $\hat{x}_i^l$  分别是  $x_i$  和  $x_i^l$  的估计值.假设  $x_i$  是图像块  $x_i$  的中间像素,  $x_i^l$  是图像块  $x_i^l$  的中间像素,可以利用  $x_i^l$  的加权平均值,即  $\sum_{l=1}^L b_i^l x_i^l$  来预测  $x_i$ ,为  $x_i^l$  分配

的权重  $b_i^l$  可以表示为  $b_i^l = \exp\left(\frac{-e_i^l}{h}\right)$ ,其中  $h$  是一个权重的

调节因子,  $c_i = \sum_{l=1}^L \exp\left(\frac{-e_i^l}{h}\right)$  是归一化因子.为了使得加入的非局部信息更加准确,预测误差  $\|x_i - \sum_{l=1}^L b_i^l x_i^l\|_2^2$  应该尽可能小.设  $\mathbf{b}_i$  为包含所有权重  $b_i^l$  的列向量,  $\beta_i$  为包含所有  $x_i^l$  的列向量.最后,将非局部相似正则化项加入到稀疏编码阶段,即式(4)中,从而得到如下的目标函数.

$$\min \lambda \|\alpha\|_1 + \frac{1}{2} \|FD_l \alpha - Fy\|_2^2 + \eta \cdot \sum_{x_i \in x} \|x_i - \mathbf{b}_i^T \beta_i\|_2^2 \quad (9)$$

其中  $\eta$  是一个用于调整非局部正则化项的常数.式(9)可以改写为

$$\min \lambda \|\alpha\|_1 + \frac{1}{2} \|FD_l \alpha - Fy\|_2^2 + \eta \cdot \|(\mathbf{I} - \mathbf{B}) \mathbf{x}\|_2^2 \quad (10)$$

其中  $\mathbf{I}$  是单位矩阵,

$$\mathbf{B}(i, l) = \begin{cases} b_i^l, & \text{当 } x_i^l \in \beta_i, \text{ 其中 } b_i^l \in \mathbf{b}_i \\ 0, & \text{当 } x_i^l \notin \beta_i \end{cases}$$

### 3.3 总变分正则化实现全局优化

由于待重建图像本身含有一些不明显的噪声,虽然数量少、强度较弱,但是这些噪声在一定程度上会因为超分辨率重建的病态性而变化,影响重建图像的质量.基于总变分正则化方法在去噪的同时能够较好地保持图像边缘细节的优点,本文采用Rudin等<sup>[13]</sup>提出的基于总变分正则化的复原算法对稀疏表示方法重建的图像进行去噪和全局优化.基于总变分正则化理论的图像去噪、去模糊的原理如下:

总变分模型需要满足的条件是找到一个图像  $u$ ,使得下式取得最小.

$$\min_{u \in BV(\Omega)} \int_{\Omega} |\nabla u(x)| dx + \int_{\Omega} \theta(x) T(Ku(x), f(x)) dx \quad (11)$$

其中,  $|\nabla u(x)|$  为图像  $u$  在积分区域  $\Omega$  内的梯度幅值,在此积分区域是一个二维有界集,即  $\Omega \subset R^2$ ,  $\theta(x)$  为表示正则化强度的非负函数,  $K$  为模糊操作,  $f$  为由基于稀疏表示重建得到的图像,  $T$  确定了如下数据保真度的类型:

$$T(Ku(x), f(x)) = \begin{cases} \frac{1}{2} (Ku(x) - f(x))^2 & \text{Gaussiannoise} \\ |Ku(x) - f(x)| & \text{Laplacenoise} \\ |Ku(x) - f(x)| \log Ku(x) & \text{Poissonnoise} \end{cases} \quad (12)$$

为了简单起见,通常将  $\theta(x)$  指定为一个正的常数,即  $\theta(x) = \theta$ .对于图像的修复问题,假设  $f$  在  $M \subset \Omega$  上未知,则  $\theta(x)$  表示如下:

$$\theta(x) = \begin{cases} 0 & \text{if } x = M \\ C & \text{otherwise} \end{cases} \quad (13)$$

其中,  $C > 0$  是一个固定参数.

本文采用 Split-Bregman 算法求解式(11)的最小化问题,对重建后的图像进行优化,得到图像  $u$ .该算法不仅可以快速解决  $l_1$  范数正则化问题<sup>[16]</sup>,而且适用于多种 TV 正则化问题,求解效率高、具有较强的可靠性,能够充分保证图像的去噪和优化效果.

### 3.4 本文算法的整体流程

本文算法的具体步骤如下:

输入:待重建 LR 图像  $y$ 、训练字典用的样本图像  $X$  以及训练 AR 模型和 NL 相似先验知识的样本图像  $X'$ .

步骤 1.对 HR 图像  $X$  进行降质操作,获得 LR 图像  $Y$ .

步骤 2.对上述  $X$  和  $Y$  分块,获得 HR 图像子块  $Q_h$  和 LR 图像子块  $Q_l$ .

步骤 3.对  $Q_h$  和  $Q_l$  进行字典训练,获得 HR 字典  $D_h$  和 LR 字典  $D_l$ .

步骤 4.通过  $y$  与  $D_l$  确定求解  $y$  对应的稀疏表示系数  $\alpha$  的目标函数:

$$\min \|\alpha\|_0 \text{ s.t. } \|FD_l \alpha - Fy\|_2^2 \leq \varepsilon.$$

步骤 5.从样本图像  $X'$  学习得到自适应 AR 模型和非局部相似先验知识.

步骤 6.将训练好的 AR 正则化项加入到稀疏编码阶段,即在步骤 4 中的目标函数加入  $\gamma \cdot \|(\mathbf{I} - \mathbf{A}) \mathbf{x}\|_2^2$  一项.

步骤 7.在稀疏编码阶段加入 NL 相似正则化项,即在步骤 4 中的目标函数加入  $\eta \cdot \|(\mathbf{I} - \mathbf{B}) \mathbf{x}\|_2^2$  一项.

步骤 8.由步骤 5、6、7 确定出本文稀疏编码的目标函数,求解该目标函数得到稀疏表示系数矩阵,目标函数为:

$$\min \lambda \|\alpha\|_1 + \frac{1}{2} \|FD_l \alpha - Fy\|_2^2 + \gamma \cdot \|(\mathbf{I} - \mathbf{A}) \mathbf{x}\|_2^2 + \eta \cdot \|(\mathbf{I} - \mathbf{B}) \mathbf{x}\|_2^2 \quad (14)$$

步骤 9.通过将  $D_h$  与  $\alpha$  线性组合,重建出 HR 图像  $x$ :

$$x = D_h * \alpha$$

步骤 10.利用总变分正则化对图像  $x$  进行去噪和全局优化,得到优化的 HR 图像  $u$ .

输出: HR 图像  $u$ .

## 4 实验与分析

### 4.1 实验环境与数据准备

本文采用 MATLAB2014a 作为仿真实验平台;计算机的配置如下,CPU: Inter ( R ) Celeron ( R ) CPU G550 @ 2.60GHz,内存:8GB 操作系统:Windows 64 位.

对于字典训练的图像训练集,采用文献[3,4,17,18]均使用的含有91张高分辨率图像的训练集.为了保证实验的客观性,采用的测试图像库有 Set5<sup>[19]</sup> 和 Set14<sup>[20]</sup> 以及 BSDS300<sup>[21]</sup> 中取100张,这些测试图像专门用于评价超分辨率重建算法.

本文算法基于 Yang 等人提出的 LISR<sup>[3]</sup> 方法改进, 在稀疏编码阶段加入 AR 正则化项实现局部结构自适应性控制, 并加入 NL 相似正则化项作为 AR 模型的补充, 提高重建质量, 最后引入 TV 正则化技术来实现全局优化. 在改进过程中的 SR 重建方法有 LISR + AR、LISR + AR + NL、LISR + AR + NL + TV 三种算法. 与本文实验进行对比的其他 SR 重建方法主要包括双三次插值法 (Bicubic)、LISR、Zeyde 等人提出的单帧图像重建 SISR<sup>[20]</sup>、Timofte 等人提出 ANR 和 A + (16 atoms)<sup>[17, 18]</sup>、NE + LS<sup>[19]</sup>、NE + NNLS<sup>[19]</sup>、NE + LLE<sup>[22]</sup>.

仿真实验中采用客观和主观两种评价方法来评价重建图像. 在客观评价方面采用峰值信噪比 (PSNR) 和结构相似性度量 (SSIM) 两种指标. 若 PSNR 值越高, 则重建效果越好. 若 SSIM 值越接近 1, 表示重建图像与原始图像在结构、亮度和对比度上相似度越高, 重建效果越好. 其中:

$$PSNR = 10 \cdot \log_{10} \frac{(255)^2 \cdot MN}{\|x - \hat{x}\|^2} \quad (15)$$

$$SSIM = \frac{(2\mu_x\mu_{\hat{x}} + C_1)(2\sigma_{x\hat{x}} + C_2)}{(\mu_x^2 + \mu_{\hat{x}}^2 + C_1)(\sigma_x^2 + \sigma_{\hat{x}}^2 + C_2)} \quad (16)$$

式中:  $\hat{x}$  为重建高分辨率图像,  $x$  为原始高分辨率图像,  $M$ 、 $N$  是维数,  $\mu_x$ 、 $\mu_{\hat{x}}$  和  $\sigma_x^2$ 、 $\sigma_{\hat{x}}^2$  是与之对应的均值和方差,  $\sigma_{x\hat{x}}$  是协方差,  $C_1$  和  $C_2$  是常数.

#### 4.2 图像超分辨率重建实验

为更好地定量评价图像的重建质量, 本文实验的待重建 LR 图像通过对原始 HR 图像进行高斯模糊和降采样得到, 并将原始 HR 图像作为 HR 参考图像. 对于待重建 LR 图像的分块, 分为  $3 \times 3$  的 LR 图像块, 在邻近块之间的重叠区为 1 个像素. 若将 LR 图像进行 3 倍放大后重建, 就可以得到  $9 \times 9$  的 HR 图像块, 邻近块之间的重叠区为 3 个像素. 实验分为以下 2 组.

第 1 组实验: 该组实验主要是将在改进过程中出现的 LISR + AR、LISR + AR + NL 和 LISR + AR + NL + TV 三种算法与 LISR 进行重建比较. 10 张测试图像来源于 Set5 与 Set14. 表 1 列出了上述的四种算法下的峰值信噪比 (PSNR), 表中可以看出, 改进的三种算法的 PSNR 都优于 LISR 算法, 并且 PSNR 值越来越高. 图 1 是对测试图像 baby 分别采用 LISR、LISR + AR、LISR + AR + NL 和 LISR + AR + NL + TV 四种算法的重建结果以及原始 HR 参考图像 Reference 的效果比较.

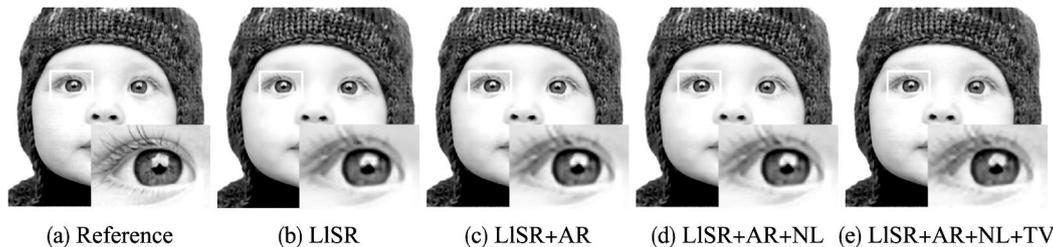


图 1 baby 四种 SR 算法重建图像的比较

Fig. 1 Comparison of the reconstructed images of four SR algorithms for baby

PSNR 和 SSIM 的平均值比较, 从中可以看出, 本文算法在两个评价指标下平均值都是最高的.

## 5 结论

本文结合稀疏表示和正则化技术, 提出了一种空间自适

通过比较在同一区域的细节放大图像可以看出, LISR 算法重建图像仍然比较模糊, LISR + AR 和 LISR + AR + NL 算法在边缘和纹理上具有明显的增强, LISR + AR + NL + TV 算法不仅边缘锐化效果明显, 而且重建图像更加清晰. 由此可见, 基于 LISR 算法改进的原理在实验中具有显著的效果.

第 2 组实验: 该组实验是将本文算法与 3.1 提到的 Bicubic、LISR、SISR、ANR、NE + LS、NE + NNLS、NE + LLE 和 A + (16 atoms) 等 8 种 SR 算法在 PSNR 和 SSIM 两个方面进行比较, 10 张测试图像来源于 Set5 与 Set14. 下页表 2 列出了本文算法和其他 8 种 SR 算法所对应的重建图像的 PSNR 和 SSIM 值. 在上述两个指标下的最优值均用粗体标出. 表 2 表明, 与其他 8 种 SR 算法相比, 本文算法在两个评价指标下均达到最优.

表 1 四种 SR 算法的 PSNR 值的比较

Table 1 Comparison of PSNR for four SR algorithms

images	LISR	LISR + AR	LISR + AR + NL	LISR + AR + NL + TV
baby	34.29	34.42	34.45	<b>35.19</b>
bird	34.11	34.31	34.39	<b>34.98</b>
butterfly	25.59	25.72	25.80	<b>26.98</b>
woman	29.94	30.10	30.17	<b>30.81</b>
comic	23.90	23.95	23.98	<b>24.27</b>
bridge	24.82	24.88	24.91	<b>25.15</b>
flowers	28.25	28.31	28.34	<b>28.84</b>
lena	32.64	32.84	32.88	<b>33.29</b>
monarch	30.71	30.88	30.96	<b>31.92</b>
zebra	27.95	27.97	28.05	<b>29.03</b>
Average	29.22	29.34	29.39	<b>30.05</b>

下页图 2 从主观方面展示了上述提及的几种重建方法的重建效果, 依次分别为原始高分辨参考图像 Reference、Bicubic、LISR、SISR、ANR、NE + LS、NE + NNLS、NE + LLE 和 A + (16 atoms) 以及本文算法重建的高分辨率图像. 通过比较同一区域的细节放大图像, 可以看出本文算法恢复了更多的边缘和纹理的细节且没有引入过多的虚假细节, 重建图像更加清晰. 本文算法结合 AR、NL 和 TV 三种正则化技术进行重建, 在图像局部、非局部以及全局三个方面进行优化, 因此具有更好的超分辨率重建效果.

下页表 3 列出了 B100 中 100 张图像在不同 SR 算法下

应正则化的图像超分辨率重建算法. 该算法利用一组自回归模型来对图像的局部结构进行自适应调整, 通过非局部相似正则化获得的图像非局部冗余以保持图像边缘信息, 并提出了一种基于自回归正则化和非局部相似正则化的稀疏编码目标函数. 此外, 通过总变分正则化对重建后的图像进行全局优

化. 实验结果表明, 与多种超分辨率算法相比, 本文算法具有更好的重建效果, 可显著改善分辨率提升能力.

表2 不同SR算法的PSNR和SSIM值的比较

Table 2 Comparison of PSNR and SSIM for different SR algorithms

images	PSNR/ SSIM	Bicubic	LISR	SISR	ANR	NE + LS	NE + NNLS	NE + LLE A + (16atoms)	本文 算法	
baby	PSNR	33.91	34.29	35.08	35.13	34.96	34.77	35.06	35.13	<b>35.19</b>
	SSIM	0.9244	0.9225	0.9402	0.9415	0.9390	0.9370	0.9401	0.9409	<b>0.9423</b>
bird	PSNR	32.58	34.11	34.57	34.60	34.36	34.26	34.56	34.83	<b>34.98</b>
	SSIM	0.9422	0.9530	0.9615	0.9623	0.9602	0.9581	0.9615	0.9629	<b>0.9639</b>
butterfly	PSNR	24.04	25.59	25.94	25.90	25.83	25.61	25.75	26.17	<b>26.98</b>
	SSIM	0.8592	0.8926	0.9052	0.9019	0.9047	0.8971	0.9007	0.9063	<b>0.9212</b>
woman	PSNR	28.56	29.94	30.37	30.33	30.20	29.89	30.22	30.57	30.81
	SSIM	0.9123	0.9235	0.9374	0.9368	0.9363	0.9321	0.9360	0.9387	<b>0.9410</b>
flowers	PSNR	27.23	28.25	28.43	28.49	28.35	28.21	28.38	28.52	28.84
	SSIM	0.8385	0.8635	0.8713	0.8739	0.8697	0.8673	0.8718	0.8745	<b>0.8802</b>
Lena	PSNR	31.68	32.64	33.00	33.08	32.98	32.82	33.01	33.17	<b>33.29</b>
	SSIM	0.8820	0.8852	0.9002	0.9022	0.9000	0.8981	0.9009	0.9027	<b>0.9039</b>
monarch	PSNR	29.43	30.71	31.10	31.09	30.94	30.76	30.95	31.31	<b>31.92</b>
	SSIM	0.9350	0.9421	0.9510	0.9508	0.9499	0.9478	0.9495	0.9518	<b>0.9556</b>
Pepper	PSNR	32.39	33.32	34.07	33.82	33.91	33.56	33.80	34.01	<b>34.35</b>
	SSIM	0.8907	0.8851	0.9060	0.9045	0.9046	0.9017	0.9041	0.9052	<b>0.9086</b>
ppt3	PSNR	23.71	24.98	25.23	25.03	25.15	24.81	24.94	25.22	25.67
	SSIM	0.8874	0.9024	0.9204	0.9123	0.9193	0.9077	0.9111	0.9146	<b>0.9302</b>
Zebra	PSNR	26.63	27.95	28.49	28.43	28.26	28.12	28.31	28.64	<b>29.03</b>
	SSIM	0.8361	0.8647	0.8775	0.8794	0.8748	0.8719	0.8777	0.8809	<b>0.8871</b>
Average	PSNR	29.01	30.18	30.63	30.67	30.49	30.28	30.50	30.76	<b>31.10</b>
	SSIM	0.8908	0.9035	0.9171	0.9166	0.9159	0.9119	0.9153	0.9179	<b>0.9234</b>

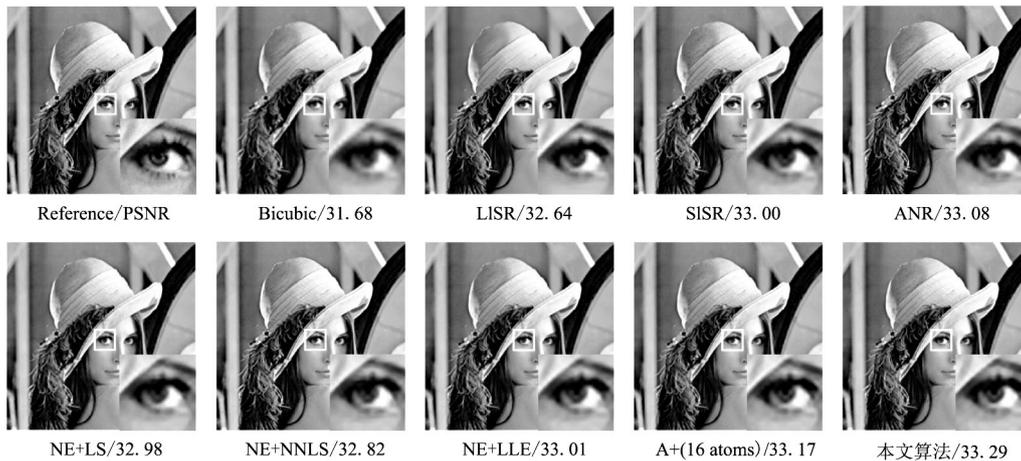


图2 不同SR算法重建图像的比较

Fig. 2 Comparison of the reconstructed images of different SR algorithms

表3 B100在不同SR算法下的PSNR和SSIM值的比较

Table 3 Comparison of PSNR and SSIM for different SR algorithms for B100

images	PSNR/ SSIM	Bicubic	LISR	SISR	ANR	NE + LS	NE + NNLS	NE + LLE A + (16atoms)	本文 算法	
Average	PSNR	27.15	27.72	27.87	27.89	27.83	27.73	27.85	27.94	<b>28.08</b>
	SSIM	0.7775	0.7996	0.8091	0.8122	0.8085	0.8061	0.8110	0.8137	<b>0.8177</b>

References:

[1] Kang M G ,Chaudhuri S. Super-resolution image reconstruction [J]. IEEE Signal Processing Magazine 2003 20(3) : 19-20.

[2] An Yao-zhu ,Lu Yao ,Zhao Hong. An adaptive-regularized image super-resolution [J]. Acta Automatica Sinica 2012 38(4) : 601-608.

[3] Yang J ,Wright J ,Huang T ,et al. Image super-resolution as sparse

- representation of raw image patches [C]. IEEE Conference on Computer Vision and Pattern Recognition (CVPR) 2008: 1-8.
- [4] 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.
- [5] Tikhonov A N, Arsenin V Y. Solutions of ill-posed problems [M]. V. H. Winston and Sons, 1977.
- [6] Wu X, Barthel K U, Zhang W. Piecewise 2D autoregression for predictive image coding [C]. International Conference on Image Processing (ICIP), 1998: 901-904.
- [7] Zhang X, Wu X. Image interpolation by adaptive 2-D autoregressive modeling and soft-decision estimation [J]. IEEE Transactions on Image Processing, 2008, 17(6): 887-896.
- [8] Wu X, Zhang X, Wang J. Model-guided adaptive recovery of compressive sensing [C]. Data Compression Conference (DCC), 2009: 123-132.
- [9] Zhang L, Dong W, Zhang D, et al. Two-stage image denoising by principal component analysis with local pixel grouping [J]. Pattern Recognition, 2010, 43(4): 1531-1549.
- [10] Zhang X, Burger M, Bresson X, et al. Bregmanized nonlocal regularization for deconvolution and sparse reconstruction [J]. Siam Journal on Imaging Sciences (SIIMS), 2010, 3(3): 253-276.
- [11] Protter M, Elad M, Takeda H, et al. Generalizing the nonlocal-means to super-resolution reconstruction [J]. IEEE Transactions on Image Processing, 2009, 18(1): 36-51.
- [12] Mairal J, Bach F, Ponce J, et al. Non-local sparse models for image restoration [C]. IEEE International Conference on Computer Vision (ICCV), 2009: 2272-2279.
- [13] Rudin L I, Osher S, Fatemi E. Nonlinear total variation based noise removal algorithms [J]. Physica D Nonlinear Phenomena (PHYSICA D), 1992, 60(1-4): 259-268.
- [14] Donoho D L. For most large underdetermined systems of equations the minimal  $l_1$ -norm near-solution approximates the sparsest near-solution [J]. Communications on Pure and Applied Mathematics, 2006, 59(7): 907-934.
- [15] 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.
- [16] Goldstein T, Osher S. The split bregman method for  $L_1$ -regularized problems [J]. Siam Journal on Imaging Sciences (SIIMS), 2009, 2(2): 323-343.
- [17] Timofte R, De V, Van Gool L. Anchored neighborhood regression for fast example-based super-resolution [C]. IEEE International Conference on Computer Vision (ICCV), 2013: 1920-1927.
- [18] Timofte R, Smet V D, Gool L V. A+: adjusted anchored neighborhood regression for fast super-resolution [C]. Computer Vision — Asian Conference on Computer Vision (ACCV), 2014, 2015: 111-126.
- [19] Bevilacqua M, Roumy A, Guillemot C, et al. Low-complexity single-image super-resolution based on nonnegative neighbor embedding [C]. The British Machine Vision Conference (BMVC), 2012: 1-10.
- [20] Zeyde R, Elad M, Protter M. On single image scale-up using sparse-representations [C]. International Conference on Curves and Surfaces, 2010, 6920: 711-730.
- [21] Martin B D, Charless F, Doron T, et al. A database of human segmented natural images and its application to evaluating segmentation algorithms and measuring ecological statistics [C]. IEEE International Conference on Computer Vision (ICCV), 2014, 2(2): 416-423.
- [22] Chang H, Yeung D Y, Xiong Y. Super-resolution through neighbor embedding [C]. IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR), 2004: 275-282.