

基于多种正则化的改进超分辨率重建算法

黄吉庆, 王丽会, 秦 进, 程欣宇, 张 健, 李 智

HUANG Jiqing, WANG Lihui, QIN Jin, CHENG Xinyu, ZHANG Jian, LI Zhi

贵州省智能医学影像分析与精准诊断重点实验室, 贵州大学 计算机科学与技术学院, 贵阳 550025

Key Laboratory of Intelligent Medical Image Analysis and Precise Diagnosis of Guizhou Province, School of Computer Science and Technology, Guizhou University, Guiyang 550025, China

HUANG Jiqing, WANG Lihui, QIN Jin, et al. Improved image super resolution reconstruction method based on multiple regularizations. Computer Engineering and Applications, 2018, 54(15): 22-28.

Abstract: For better balancing the problems of noise-reducing and details-keeping in the process of the Super-Resolution (SR) image reconstruction, this paper proposes a novel multiple regularizations-based SR image reconstruction method, which combines an Amended Non-Local Total Variation (ANLTV) and Total Variation (TV) regularizations in the SR image reconstruction framework. Firstly, according to heavy-tailed distribution properties of the natural images, the ANLTV regularization is given by reformulating the weighting coefficients of the traditional Non-Local Total Variation (NLTV) with the combination of the Gaussian, Laplacian and Cauchy distributions. Accordingly, the initial SR image is then reconstructed using the split Bregman algorithm, from which, the final SR image is obtained by deblurring the initial reconstructed image with a TV regularization. In order to verify the performance of the proposed algorithm, the quantitative comparison between the proposed method and the traditional TV and NLTV based methods are carried out. The experimental results illustrate that the peak signal to noise ratio, signal to noise ratio and structural similarity obtained by the proposed method is obviously higher than the traditional ones, which is able to satisfy the requirement of reducing noise and preserving edge details in SR reconstruction simultaneously.

Key words: super resolution reconstruction; regularization method; Amended Non-Local Total Variation (ANLTV); split-Bregman algorithm

摘 要:为了解决超分辨率图像重建过程中无法同时降低平滑区域噪声和保持图像细节的问题,结合改进的非局部变分(NLTV)和全变分(TV)正则项方法提出一种新的超分辨率重建算法。首先,根据图像重尾分布特性,结合高斯分布、拉普拉斯分布及柯西分布改进了传统NLTV正则项系数,提出了改进的ANLTV正则项。然后利用ANLTV正则项基于分裂Bregman算法重建了初始的高分辨率图像。最后结合TV正则项对重建的高分辨率图像进行去模糊操作,进而得到最终的超分辨率图像重建结果。为验证所提算法的性能,分别利用该算法与传统的TV和NLTV算法进行超分辨率图像重建并对比。实验结果表明,所提出的方法相比于传统的TV和NLTV重建算法,其峰值信噪比、信噪比和结构相似度均有所提高,能够同时满足超分辨率图像重建过程中抑制噪声和保持边缘细节的需求。

关键词:超分辨率重建;正则化方法;改进的非局部变分;分裂Bregman算法

文献标志码:A **中图分类号:**TP751.1 **doi:**10.3778/j.issn.1002-8331.1805-0203

1 引言

由于成像设备分辨率的限制,外加噪声及运动等因素的影响,采集图像的分辨率通常较低,无法满足应用需求。为了解决这一问题,超分辨率(Super Resolution,

SR)重建技术应运而生,即在不改变硬件条件的情况下,利用图像的先验知识恢复出低分辨率图像(Low Resolution, LR)的细节信息,进而重建出高分辨率图像(High Resolution, HR)。

基金项目:国家自然科学基金(No.61661010, No.61562009);教育部留学人员归国启动基金;贵州省自然科学基金(No.20152044)。

作者简介:黄吉庆(1994—),男,硕士研究生,CCF学生会会员,研究领域为医学图像处理,超分辨率重建, E-mail: heaven_kong@163.com; 王丽会(1982—),女,博士,副教授,研究领域为医学图像处理,机器学习,医学成像;秦进(1978—),男,博士,副教授,研究领域为人工智能与模式识别、计算智能、机器学习。

收稿日期:2018-05-14 **修回日期:**2018-06-25 **文章编号:**1002-8331(2018)15-0022-07

目前,基于先验信息的超分辨率重建算法主要分为以下几类,即基于插值的算法、基于学习的算法和基于建模的算法^[1-6]。其中基于插值的算法是利用邻近像素点的灰度值对待插像素点的灰度值进行估计。较好的算法有基于边缘导向的插值算法(Edge-Directed Interpolation, NEDI)和基于自学习特征的交替插值算法(Self-learned Characteristics Based Switched Image Interpolation, SLCSI)^[7]。这两种方法在图像边缘和细节区域的重建效果有所提升,但仍无法完全克服图像插值算法的缺点,即基于局部信息的图像像素估计会引入图像的模糊,降低图像质量。

随着深度学习和人工智能的快速发展,基于学习的方法进行超分辨率图像重建逐渐成为主流。其思想是利用多组低分辨率和高分辨率图像,通过算法学习到低分辨率和高分辨率图像的对应关系。常用的超分辨率重建模型包括卷积神经网络模型^[8]、残差神经网络模型^[9]、深度卷积对抗生成网络模型^[10]。但无论哪种学习模型,对低分辨率和高分辨率图像样本对的数目有很高的要求,并且训练的时间较长,不具有实时性和广泛应用性。

基于建模的方法是利用图像的降质模型对超分辨率图像重建提供约束,进而基于逆问题的求解方式获得超分辨率图像。在基于建模的方法中,通常加入正则项将病态问题转化为凸问题进行求解。目前常用的正则项包括 L_2 范数、 L_1 范数和 L_p 范数正则项^[11-20]。这些正则项通过对图像灰度梯度变化进行惩罚,进而实现降低平滑区域噪声并保持图像边缘和细节的效果。其中 L_2 范数主要包括吉洪诺夫(Tikhonov Regularization, TR)和马尔科夫随机场(Markov Random Field, MRF)的正则项,这类正则项通过惩罚图像的高频部分,能够很好地降低图像的噪声,但会过度平滑图像的边缘和细节信息。全变分正则项(Total Variation, TV)是典型的 L_1 范数正则项,这类正则项可以更好地保持边缘,但会在带有噪声的图像平滑区域产生阶梯效应。为了克服 L_1 和 L_2 范数正则项的缺点,研究学者们提出利用阈值算法优化 L_1 和 L_2 范数正则项,如Huber 马尔科夫随机场(Huber-MRF, HMRF)和BTV(Bilateral TV, BTV)等正则项。这种改进算法通过设置图像灰度梯度的阈值,以区分图像边缘和平滑区域,对边缘使用 L_1 范数正则项,而对平滑区域则使用 L_2 范数正则项,但这种方法的重建效果对阈值的选择很敏感。为了解决这一问题,非局部变分正则项(Non-Local Total Variation, NLTV)先验被提出^[21],即在TV的基础上引入非局部相似度权重系数,可在一定程度上解决TV在平滑区域引起的块效应问题。NLTV中的权重系数通常符合高斯分布,因此,从本质上讲,NLTV的权重系数是一种非局部的均匀滤波器,仍会引起图像边缘模糊现象。

鉴于TV和NLTV正则先验互补的优势,本文提出一种结合TV和改进NLTV的多种正则先验的超分辨率重建算法。首先根据图像灰度梯度满足重尾分布的特点,将原有NLTV正则项的权重系数由高斯分布更改为更满足重尾分布的多种分布的结合形式,提出ANLTV(Amended NLTV)正则先验;然后利用ANLTV正则先验对超分辨率图像进行初始估计,最后采用TV正则项对超分辨率图像的初始估计进行去模糊操作,从而得到最终的超分辨率重建结果。

目前,求解带有TV类正则先验的优化问题的方法有很多种,如共轭梯度法(Conjugate Gradient Algorithm, CG),快速组合分裂算法(Fast Composite Splitting Algorithm, FCSA),交替方向乘法(Alternating Direction Method of Multipliers, ADMM)以及分裂Bregman方法(Split Bregman Algorithm, SBA)等。其中CG方法利用目标函数的梯度信息,通过大量反复迭代,获得最优解,这种方法计算效率较低。FCSA是一种基于小波稀疏的凸优化的求解方法,求解效率相比CG方法有很大的提高,但这种方法求解时,会倾向于连续解,容易出现阶梯效应。ADMM和SBA方法是求解带有 L_1 范数正则先验问题的有效方法,其中Bregman方法是ADMM方法的一种特殊形式,在参数设置合理时,能比ADMM方法更快的收敛^[22]。因此,本文选择分裂Bregman算法对超分辨率图像进行求解。

2 基于多种正则化的改进超分辨率重建

2.1 图像降质模型

一般而言,低分辨率是由高分辨率图像经过模糊、下采样以及引入加性噪声等一系列降质过程获得的,因此按照降质模型,低分辨率与高分辨率图像之间的关系可以表示为:

$$y = D(h * x) + n \quad (1)$$

其中 y 为低分辨率图像, D 为下采样操作, h 为点扩散函数,表示图像模糊过程, x 为高分辨率图像, n 为加性噪声,本文采用均值为0方差可调节的高斯噪声。

针对点扩散函数和下采样矩阵,本文采用了Antonio^[9]提出的卷积下采样模型,这种模型同时完成了图像模糊和下采样过程,并且可以较快地进行降质和上采样,其表达式为:

$$\begin{cases} D(x) = D^x \times x \times S^x \\ S(y) = S^x \times y \times D^x \end{cases} \quad (2)$$

式中 $D(x)$ 代表图像下采样和模糊过程, $S(y)$ 代表上采样过程,具体的采样矩阵由 D^x 和 S^x 表示:

$$D^x = \frac{1}{\sqrt{2}} \begin{bmatrix} 1 & 1 & 0 & 0 & \cdots & 0 & 0 \\ 0 & 0 & 1 & 1 & \cdots & 0 & 0 \\ \vdots & \vdots & \vdots & \vdots & & \vdots & \vdots \\ 0 & 0 & 0 & 0 & \cdots & 1 & 1 \end{bmatrix} \quad (3)$$

$$S^x = \frac{1}{\sqrt{2}} \begin{bmatrix} 1 & 0 & \cdots & 0 \\ 1 & 0 & \cdots & 0 \\ 0 & 1 & \cdots & 0 \\ 0 & 1 & \cdots & 0 \\ \vdots & \vdots & & \vdots \\ 0 & 0 & \cdots & 1 \\ 0 & 0 & \cdots & 1 \end{bmatrix} \quad (4)$$

若高分辨率图像 x 的大小为 $2m \times 2m$, 则 D^x 的维度为 $m \times 2m$, S^x 的维度为 $2m \times m$ 。通过下采样操作 $D(x)$, 可以得到 $m \times m$ 大小的下采样图像 y ; 通过上采样操作 $S(y)$, 可以得到 y 扩大两倍的上采样图像。

2.2 改进的超分辨率图像重建模型

根据图像的降质模型可知, 为恢复出高分辨率图像, 仅对低分辨率图像进行与降质模型对应的上采样操作即可。然而, 由于降质模型的低秩性, 使得这一逆过程的求解成为病态问题, 无法获得最优解。为解决这个问题, 需要在求解过程中引入正则项, 因此超分辨率图像的重建模型可表达为:

$$\hat{x} = \arg \min \left\{ \frac{\lambda}{2} \|y - D(h * x)\|_2^2 + R(x) \right\} \quad (5)$$

其中 $\|y - D(h * x)\|_2^2$ 是残差项, 代表重建图像和原始图像分别降质后得到的低分辨率图像的差异, 用以反应重建图像与原始图像的相似性; $R(x)$ 表示正则项, 代表了图像的先验信息。对公式(5)进行求解, 就可获得满足正则项约束的最优解。常见的正则项主要有 TV 和 NLTV 项, 其中 TV 正则项的表达式如下:

$$R_{TV}(x) = \left\| \frac{\partial x}{\partial h} \right\|_1 + \left\| \frac{\partial x}{\partial v} \right\|_1 \quad (6)$$

$\left\| \frac{\partial x}{\partial h} \right\|_1$ 和 $\left\| \frac{\partial x}{\partial v} \right\|_1$ 分别代表图像 x 在水平方向和竖直方向的一阶差分算子。由于 TV 正则项重建在图像平滑区域, 容易引起块效应, 因此, NLTV 正则项被提取, 其表达式为:

$$R_{NLTV}(x) = \nabla \sum_{i \in \Omega_i} \sum_{j \in \Pi_i} w(i, j) |x(i) - x(j)| \quad (7)$$

其中 i 表示图像 x 中的某一个像素点, Π_i 表示在图像 x 中以 $m_2 \times m_2$ 大小窗口搜索时获得的与像素点 i 相似的所有像素点的集合, $w(i, j)$ 为权重函数, 其定义为:

$$w(i, j) = \exp\left(-\frac{\|N_i(x) - N_j(x)\|_p^p}{\sigma^2}\right) \quad (8)$$

公式(8)中 $N_i(x) - N_j(x)$ 分别表示图像 x 在 i 和 j 点处的某固定大小邻域上对应的灰度差值, 邻域的窗口大小设置为 $m_1 \times m_1$, p 表示距离函数的范数, 通常取值为 2, 代表像素点 i 和 j 对应的邻域灰度的欧氏距离, σ 为权重系数的调节参数。

在一幅图像中, 图像灰度平滑区域占多数, 因此针对平滑区域, 相似块个数较多, 公式(8)则相当于针对多

个相似块实现一个高斯滤波, 进而可以有效地去除图像平滑区域的噪声, 解决 TV 正则先验引起的块效应问题。然而对于图像的边缘区域, 由公式(8)可知, 其权重系数很小并且快速衰减为 0, 如图 1 中的红色曲线所示, 当灰度梯度的绝对值大于 0.5 时, 权重系数趋近于 0, 若该灰度梯度出现的概率为 0, 则为 0 的高斯权重系数不会对结果有影响。然而自然图像的灰度梯度是符合重尾分布的, 即较大灰度梯度出现的概率不为 0, 则此时若仍然使用高斯分布的权重系数, 则会丢失图像的细节信息。因此, 本文对 NLTV 正则项的权重系数进行修改, 结合高斯分布、拉普拉斯分布及柯西分布提出 ANLTV 的权重系数, 其表达式如下:

$$w(i, j) = \alpha \times q(x) + \beta \times r(x) + \theta \times s(x) \quad (9)$$

式中 $q(x)$ 、 $r(x)$ 和 $s(x)$ 分别代表了高斯分布、柯西分布和拉普拉斯分布, α 、 β 和 θ 分别为各种分布的加权系数, 即:

$$\begin{cases} q(x) = \exp\left(-\frac{\|N_i(x) - N_j(x)\|^2}{\sigma^2}\right) \\ r(x) = \frac{1}{\pi (\|N_i(x) - N_j(x)\|^2 + 1)} \\ s(x) = \exp\left(-\frac{\|N_i(x) - N_j(x)\|}{\sigma}\right) \end{cases} \quad (10)$$




图1 权重系数与灰度梯度的关系示意图

图 1 中的黑色曲线为 ANLTV 的权重系数, 相比于高斯权重系数, 可以看出, 在图像的边缘区域, 改进的权重系数尾部较厚重, 更适合处理梯度满足重尾分布的图像。

虽然 ANLTV 的权重系数考虑了图像梯度变化的统计特性, 能够保持图像的细节信息, 但是不同相似块进行加权平均的过程中又不可避免地会引起图像边缘区域的模糊。为了解决这个问题, 根据 TV 正则项在保持图像边缘方面的优势, 在 ANLTV 正则化重建后, 再利用 TV 对重建图像进行去模糊操作。综上所述, 本文的超分辨率重建模型可以表示为:

$$\begin{cases} \hat{x}_0 = \arg \min_x \left\{ \frac{\lambda}{2} \|y - D(h^*x)\|_2^2 + |R_{\text{ANLTV}}(x)| \right\} \\ \hat{x} = \arg \min_x \left\{ \eta \| (h^*x - x_0) \|_2^2 + \gamma |R_{\text{TV}}(x)| \right\} \end{cases} \quad (11)$$

其中 $|\cdot|$ 代表着一范数, R_{ANLTV} 代表本文改进的 NLTV 正则项, R_{TV} 代表 TV 正则项, $\hat{x}_0$ 为基于 ANLTV 正则项初步重建的超分辨率图像, $\hat{x}$ 为利用 TV 正则项对初始重建超分辨率图像去模糊得到的结果。

为了求解公式(11)中的最小化问题,本文分别采用分裂 Bregman 方法对公式(11)中的两个优化问题进行迭代求解。

2.3 分裂 Bregman 算法求解

分裂 Bregman 方法是一种通过迭代,将正则项携带的先验信息传递到解之中的优化方法。它可以解决的问题形如:

$$\min_{x \in C} \{H(x) + J(x)\} \quad (12)$$

其中 C 是一个有界闭凸集, $H(x)$ 是可微凸函数, $J(x)$ 是凸正则项。

对于公式(9)所提出的超分辨率重建模型,满足分裂 Bregman 方法所能求解的问题。其中 $\|y - D(h^*x)\|_2^2$ 和 $\|(h^*x - x_0)\|_2^2$ 对应可微凸函数 $H(x)$, $|R_{\text{ANLTV}}(x)|$ 和 $|R_{\text{TV}}(x)|$ 是凸正则项,相当于 $J(x)$ 。故公式(11)可采用分裂 Bregman 方法进行求解。以公式(11)的第一个公式(11)为例,对其求解过程进行详细的描述。

首先令 $d = R_{\text{ANLTV}}(x)$, 可得:

$$\min_{x,d} \left\{ |d| + \frac{\lambda}{2} \|y - D(h^*x)\|_2^2 \right\} \quad (13)$$

然后,根据拉格朗日乘子法,将这个带有约束条件的问题转化为非限制性问题,即:

$$\min_{x,d} \left\{ |d| + \frac{\lambda}{2} \|y - D(h^*x)\|_2^2 + \frac{\mu}{2} \|d - R_{\text{ANLTV}}(x)\|_2^2 \right\} \quad (14)$$

令 $V(x, d) = |d| + \frac{\lambda}{2} \|y - D(h^*x)\|_2^2$, 代入公式(13)中可得:

$$\min_{x,d} \left\{ V(x, d) + \frac{\mu}{2} \|d - R_{\text{ANLTV}}(x)\|_2^2 \right\} \quad (15)$$

根据 Bregman 算法^[20]的思想,公式(15)中 $V(x, d)$ 可由 Bregman 距离 $D_V^P(x, x^k, d, d^k)$ 来代替,其定义为:

$$\begin{aligned} D_V^P(x, x^k, d, d^k) &= V(x, d) - V(x^k, d^k) - \\ &< P_x^k, x - x^k > - < P_d^k, d - d^k > \end{aligned} \quad (16)$$

式中 x^k, d^k 为第 k 次迭代时获得的解, P_x^k 和 P_d^k 分别表示函数 $V(x, d)$ 在 x^k, d^k 上的次梯度,即 $(P_x^k, P_d^k) \in \partial V(x^k, d^k)$, $< \cdot >$ 代表点乘操作。

将公式(16)代入到公式(15)可得第 $k+1$ 次迭代获得的优化解为:

$$\begin{aligned} (x^{k+1}, d^{k+1}) &= \min_{x,d} \{ D_V^P(x, x^k, d, d^k) + \\ &\frac{\mu}{2} \|d - R_{\text{ANLTV}}(x)\|_2^2 \} = \min_{x,d} \{ V(x, d) - \end{aligned}$$

$$\begin{aligned} &V(x^k, d^k) - < P_x^k, x - x^k > - < P_d^k, d - d^k > + \\ &\frac{\mu}{2} \|d - R_{\text{ANLTV}}(x)\|_2^2 \} \end{aligned} \quad (17)$$

根据次梯度的定义,将公式(13)分别对 x 和 d 求导,可得到次梯度的迭代如下:

$$\begin{cases} P_x^{k+1} = P_x^k - \mu (\nabla R_{\text{ANLTV}}(x))^T (R_{\text{ANLTV}}(x^{k+1}) - d^{k+1}) \\ P_d^{k+1} = P_d^k - \mu (d^{k+1} - R_{\text{ANLTV}}(x^{k+1})) \end{cases} \quad (18)$$

令 $P_x^0 = 0, P_d^0 = 0$, 并将公式(16)迭代展开相加可得:

$$\begin{cases} P_x^{k+1} = -\mu \sum_{i=1}^{k+1} (\nabla R_{\text{ANLTV}}(x))^T (R_{\text{ANLTV}}(x^i) - d^i) \\ P_d^{k+1} = -\mu \sum_{i=1}^{k+1} (d^i - R_{\text{ANLTV}}(x^i)) \end{cases} \quad (19)$$

令 $b^{k+1} = b^k + (R_{\text{ANLTV}}(x^{k+1}) - d^{k+1}), b^0 = 0$, 迭代相加则得:

$$b^{k+1} = -\sum_{i=1}^{k+1} (d^i - R_{\text{ANLTV}}(x^i)) \quad (20)$$

将公式(18)代入公式(17)中可得:

$$\begin{cases} P_x^k = -\mu (\nabla R_{\text{ANLTV}}(x^k))^T b^k \\ P_d^k = \mu b^k \end{cases} \quad (21)$$

再将公式(21)代入到公式(17)中则有:

$$\begin{aligned} (x^{k+1}, d^{k+1}) &= \min_{x,d} \{ V(x, d) - V(x^k, d^k) + \\ &\mu < b^k, R_{\text{ANLTV}}(x) - R_{\text{ANLTV}}(x^k) > - \\ &\mu < b^k, d - d^k > + \frac{\mu}{2} \|d - R_{\text{ANLTV}}(x)\|_2^2 \} = \\ &\min_{x,d} \{ V(x, d) - V(x^k, d^k) - \\ &\mu < b^k, d - R_{\text{ANLTV}}(x) > - \mu < b^k, R_{\text{ANLTV}}(x^k) - \\ &d^k > + \frac{\mu}{2} \|d - R_{\text{ANLTV}}(x)\|_2^2 \} = \\ &\min_{x,d} \{ V(x, d) - V(x^k, d^k) - \\ &\mu < b^k, d - R_{\text{ANLTV}}(x) > + \\ &\frac{\mu}{2} \|d - R_{\text{ANLTV}}(x)\|_2^2 + C_1 \} = \\ &\min_{x,d} \left\{ |d| + \frac{\lambda}{2} \|y - D(h^*x)\|_2^2 + \right. \\ &\left. \frac{\mu}{2} \|d - R_{\text{ANLTV}}(x) - b^k\|_2^2 + C_2 \right\} \end{aligned} \quad (22)$$

公式(20)中, C_1 和 C_2 是常数项。为了加快公式(20)的迭代求解速度,利用分裂 Bregman 的思想,分别对 x 和 d 进行迭代求解,即:

$$\begin{cases} x^{k+1} = \arg \min_x \left\{ |d| + \frac{\lambda}{2} \|y - D(h^*x)\|_2^2 + \right. \\ \left. \frac{\mu}{2} \|d - R_{\text{ANLTV}}(x) - b^k\|_2^2 \right\} \\ d^k = \arg \min_d \left\{ |d| + \frac{\mu}{2} \|d - R_{\text{ANLTV}}(x^{k+1}) - b^k\|_2^2 \right\} \end{cases} \quad (23)$$

公式(21)对 x 进行求导等于零可得:

$$\begin{aligned} &\lambda \{ h^T * S(y) - h^T * (S \circ D(h^T * x)) \} - \\ &\mu \nabla R_{\text{ANLTV}}(x) (d^k - R_{\text{ANLTV}}(x) - b^k) = 0 \end{aligned} \quad (24)$$

其中 $S \circ D$ 表示对图像依次进行下采样 S 和上采样 D 操作。根据高斯赛德尔方法^[23]对公式(22)进行求解,可得第 $k+1$ 步迭代 x 的解:

$$\begin{cases} x_i^{k+1,n+1} = \frac{1}{\lambda + \mu \sum_j w_{ij}} (\mu \sum_j w_{ij} x_j^{k+1,n} + \lambda y_i^{k+1} - \\ \mu \sum_j \sqrt{w_{ij}} (d_{ij}^{k+1,n} - d_{ji}^{k+1,n} - b_{ij}^{k+1,n} + b_{ji}^{k+1,n})) \end{cases} \quad (25)$$

$$x^{k+1,0} = h^T(S \circ D(h * x^k))$$

公式(21)对 d 进行求导等于零,并利用收缩算子可得第 $k+1$ 步迭代 d 的解:

$$d^{k+1} = \text{shrink}(R_{\text{ANLTV}}(x^{k+1}) + b^k, \frac{1}{\mu}) \quad (26)$$

经过多次迭代,可以得到初步重建的高分辨率图像 $\hat{x}_0$ 。对初步获得的高分辨率图像 $\hat{x}_0$ 根据公式(11)的第二个公式进行去模糊处理,其求解过程与上述过程相同。

具体的算法求解流程图如下所示:

算法 1 ANLTV 超分辨率重建 Bregman 正则化

输入:低分辨率图像 y , 参数设置

输出:高分辨率图像 $\hat{x}_0$

初始化图像 x^0 (使用双三次插值算法), 初始化 $d^0 = b^0 = 0$

外层循环:

$x^{k+1,0} = h^T(S \circ D(h * x^k))$, $y^{k+1} = h^T * S(y^k)$;

内层循环:

$$x_i^{k+1,n+1} = \frac{1}{\lambda + \mu \sum_j w_{ij}} (\mu \sum_j w_{ij} x_j^{k+1,n} + \lambda y_i^{k+1} - \mu \sum_j \sqrt{w_{ij}} (d_{ij}^{k+1,n} - d_{ji}^{k+1,n} - b_{ij}^{k+1,n} + b_{ji}^{k+1,n}))$$

$$d^{k+1,n+1} = \text{shrink}(R_{\text{ANLTV}}(x^{k+1,n+1}) + b^{k,n+1}, \frac{1}{\mu})$$

$$b^{k+1,n+1} = b^k + (R_{\text{ANLTV}}(x^{k+1,n+1}) - d^{k+1,n+1})$$


$$d^{k+1} = \text{shrink}(R_{\text{ANLTV}}(x^{k+1}) + b^k, \frac{1}{\mu})$$

$$b^{k+1} = b^k + (R_{\text{ANLTV}}(x^{k+1}) - d^{k+1})$$



(a)原始图像及选择的ROI (b)原始HR图像 (c)下采样图像 (d)ITV重建结果 (e)ATV重建结果 (f)NLTV重建结果 (g)ANLTV+TV重建结果

图2 Lena图像超分辨率重建结果



(a)原始图像及选择的ROI (b)原始HR图像 (c)下采样图像 (d)ITV重建结果 (e)ATV重建结果 (f)NLTV重建结果 (g)ANLTV+TV重建结果

图3 Airfield图像超分辨率重建结果

3 实验结果与分析

为了验证本文所提算法的性能,实验分别选取大小为 512×512 的 Lena、Airfield、Baboon 和 Phantom 图像为 HR 图像,利用 2.1 节阐述的图像降质模型,对图像进行模糊和下采样并添加加性噪声,得到对应的 LR 图像。再根据超分辨率图像重建的原理,分别利用基于 ITV、ATV、NLTV 以及本文改进的 ANLTV+TV 正则项的超分辨率重建算法进行重构。重建过程中不同方法所使用的参数如表 1 所示。

表 1 超分辨率图像重建参数

参数	方法			
	ITV	ATV	NLTV	ANLTV+TV
λ	300	300	300	300
μ	100	100	100	100
m_1	—	—	3	3
m_2	—	—	13	13
σ	—	—	0.25	0.25
α	—	—	—	0.30
β	—	—	—	0.30
θ	—	—	—	0.60

为了提高不同算法重建图像的视觉对比效果,本文在几种图像中分别选择一个感兴趣区域,进行局部放大显示,如图 2 至图 5 所示,其中(a)显示了感兴趣区域,(b)为原始 HR 图像;(c)为下采样图像;(d)为 ITV 正则化重建结果;(e)为 ATV 正则化重建结果;(f)为 NLTV 正则化重建结果;(g)为本文所提出的 ANLTV+TV 正则化重建结果。

从 Lena 图(图 2)和 Airfield 图(图 3)的重建视觉效果上看,利用本文所提出的方法重建获得的超分辨率图像,在平滑区域噪声减少,并且在边缘区域对比度明显增加。这是由于 ANLTV 相比于原始的 NLTV 正则先验,满足重尾分布的权重系数没有屏蔽掉图像的细节信




图4 Baboon图像超分辨率重建结果




图5 Phantom图像超分辨率重建结果

息,因此在边缘处理效果比NLTV要好很多。同时,经过ANLTV在图像平滑区域的均值滤波处理,可以很好地去除噪声的影响,进而再利用TV正则先验进行图像去模糊时,无块效应产生。

图2和图3是图像细节和图像平滑区域分布较均衡的图像,为了进一步验证本文算法,又分别对图像细节较多的Baboon图像和图像平滑区域较多的Phantom图像进行重建,其结果如图4和图5所示。从Baboon图像的重建结果可以看出,改进后算法很好地保证了边缘的对比度,展示出更多的细节信息。而针对平滑区域较多的Phantom图像,ATV和ITV算法在平滑区域仍存在着一些噪声;NLTV可以去除平滑区域的块效应,但是会模糊图像边缘;而ANLTV+TV在平滑区域几乎无噪声影响,并且边缘对比度较明显。

为了定量地分析4种不同正则项对于超分辨率图像重建效果的影响,本文采用峰值信噪比(Peak Signal-to-Noise Ratio,PSNR)、平均结构相似度(Structural Similarity Index,SSIM)和信噪比(Signal-to-Noise Ratio,SNR))3种评价指标对重建结果进行对比,如表2所示。

可以看出在两组图像中,本文所提出的方法在3种评价指标上都有一定的提升。针对Lena图像PSNR至少提高了6%,SNR至少提高了5%,SSIM提高了3%;对Airfield图像PSNR则至少提高10%,SNR提高了10%,SSIM提高了10%;对Baboon图像PSNR至少提高了3%,SNR提高了5%,SSIM提高了19%;而对于Phantom图像PSNR提高了8%,SNR提高了至少14%,SSIM至少提高了3%。可以看出针对不同特点的图像,各种评价指标的提升效果均不同,其原因可由图像灰度梯度的分布特点来解释,如图6所示。

从图6中可以看出,Baboon和Airfield图像的重尾分布最为明显,因此其在边缘的重建视觉效果最好,结

表2 4种不同正则项定量评价指标

图像	正则项	PSNR	SNR	SSIM
Lena	ITV	28.3	22.8	0.88
	ATV	28.4	22.9	0.88
	NLTV	28.2	22.6	0.89
	ANLTV+TV	30.1	24.0	0.91
Airfield	ITV	22.6	19.7	0.75
	ATV	24.2	21.3	0.75
	NLTV	22.7	19.8	0.77
	ANLTV+TV	26.4	23.5	0.85
Baboon	ITV	20.4	14.9	0.58
	ATV	20.5	15.0	0.58
	NLTV	20.6	15.1	0.59
	ANLTV+TV	21.1	15.6	0.69
Phantom	ITV	25.9	13.8	0.87
	ATV	26.1	13.9	0.86
	NLTV	26.2	14.0	0.89
	ANLTV+TV	27.9	15.8	0.90




图6 不同图像灰度梯度分布与高斯分布的区别

构相似度提升较高。针对Lena图像,其灰度梯度分布尾部较高斯分布而言,不是很厚,但是在图像平滑区域,下降速度却比高斯分布快很多,说明在图像平滑区域相

似性很大,所以处理加权均匀滤波时处理平滑区域效果很好,进而SNR得到很大的改善。尤其针对Phantom图像,其梯度分布曲线下降速度最快,所以利用本文方法,其SNR提升的最多,但由于尾部分布概率几乎为0,其SSIM并未提高很多。可以看出,利用本文所提方法,不管针对平滑图像,还是细节较多的图像,都能得到很好的重建效果。

4 结论

本文针对超分辨率图像重建过程中,无法同时满足平滑噪声和保持图像边缘的问题,提出一种基于多个正则项的改进的超分辨率重建算法。首先利用自然图像灰度梯度满足重尾分布的特性,结合高斯、拉普拉斯和柯西分布改进了传统NLTV正则项的加权系数,进而提出一种新的ANLTV正则项,并利用该正则项对超分辨率图像进行初始重建。然后结合TV正则项在保持图像边缘方面的优势,利用TV正则项对初始重建图像进行去模糊操作,进而获得最终的超分辨率图像重建结果。实验结果表明,本文所提的超分辨率图像重建算法,相比于传统的基于TV和NLTV的超分辨率图像重建算法,无论针对平滑图像还是细节较多的图像,其峰值信噪比,信噪比以及结构相似性均有提升,在一定程度上解决了超分辨率重建过程中同时抑制噪声和保持边缘的矛盾。

参考文献:

- [1] Yeganli F, Nazzal M, Ozkaramanli H. Super-resolution using multiple structured dictionaries based on the gradient operator and bicubic interpolation[C]//Signal Processing and Communication Application Conference, 2016: 941-944.
- [2] Hu Changsheng, Zhan S, Wu Congzhong. Image super-resolution based on deep learning features[J]. Acta Automatica Sinica, 2017, 43(5): 814-821.
- [3] 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.
- [4] 曾凯, 丁世飞. 图像超分辨率重建的研究进展[J]. 计算机工程与应用, 2017, 53(16): 29-35.
- [5] 杨靖, 彭国华. 低帧率周期运动视频超分辨率重建方法[J]. 计算机工程与应用, 2017, 53(8): 174-179.
- [6] Mourabit I El, Rhabi M El, Hakim A, et al. A new denoising model for multi-frame super-resolution image reconstruction[J]. Signal Processing, 2017, 132(C): 51-65.
- [7] Jaiswal S P, Jakhetiya V, Tiwari A K, et al. An efficient image interpolation algorithm based upon the switching and self learned characteristics for natural images[C]//IEEE International Symposium on Circuits and System, 2011: 861-864.
- [8] 肖进胜, 刘恩雨, 朱力, 等. 改进的基于卷积神经网络的图像超分辨率算法[J]. 光学学报, 2017, 37(3): 96-104.
- [9] 王一宁, 秦品乐, 李传朋, 等. 基于残差神经网络的图像超分辨率改进算法[J]. 计算机应用, 2018(1): 246-254.
- [10] 李方彪, 何昕, 魏仲慧, 等. 生成式对抗神经网络的多帧红外图像超分辨率重建[J]. 红外与激光工程, 2018, 47(2).
- [11] Marquina A, Osher S J. Image super-resolution by Tv-regularization and bregman iteration[J]. Journal of Scientific Computing, 2008, 37(3): 367-382.
- [12] Shen H, Peng L, Yue L, et al. Adaptive norm selection for regularized image restoration and super-resolution[J]. IEEE Transactions on Cybernetics, 2016, 46(6): 1388-1399.
- [13] Goldstein T, Osher S. The split bregman method for l1-regularized problems[J]. SIAM Journal on Imaging Sciences, 2009, 2(2): 323-343.
- [14] 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.
- [15] Li L, Xie Y, Hu W, et al. Neurocomputing single image super-resolution using combined total variation regularization by split Bregman iteration[J]. Neurocomputing, 2014, 142: 551-560.
- [16] Yue L, Shen H, Li J, et al. Image super-resolution: The techniques, applications, and future[J]. Signal Processing, 2016, 128: 389-408.
- [17] 李欣, 崔子冠, 孙林慧, 等. 基于局部回归模型的图像超分辨率重建[J]. 计算机应用, 2016, 36(6): 1654-1658.
- [18] 邵文泽, 韦志辉. 基于广义Huber—MRF图像建模的超分辨率复原算法[J]. 软件学报, 2007, 18(10): 2434-2444.
- [19] Chen J, Nunez-Yanez J, Achim A. Video super-resolution using generalized gaussian Markov random fields[J]. IEEE Signal Processing Letters, 2012, 19(2): 63-66.
- [20] Zhang X, 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.
- [21] Gilboa G, Osher S. Nonlocal linear image regularization and supervised segmentation[J]. SIAM Journal on Multiscale Modeling & Simulation, 2007, 6(2): 595-630.
- [22] Nien H, Fessler J A. A convergence proof of the split Bregman method for regularized least-squares problems[J]. Mathematics, 2014.
- [23] Bush J. Bregman algorithms[D]. Santa Barbara: University of California, 2011.