

基于 l_1/l_2 的高低阶全变差运动模糊图像盲复原方法

王灿^{1,2}, 杨帆^{1,2}, 李靖^{1,2}

¹河北工业大学电子信息工程学院, 天津 300401;

²天津市电子材料与器件重点实验室, 天津 300401

摘要 为了实现运动模糊图像的盲复原,提出了一种基于 l_1/l_2 的高低阶全变差图像盲复原方法。利用具有更强稀疏表达能力的 l_1/l_2 范式正则化先验项,加入高低阶混合全变差正则化模型。高阶全变差正则化模型可以抑制图像非边缘部分可能出现的阶梯及振铃效应,低阶全变差正则化模型可以保护自然图像的边缘稀疏特性。分别给出了清晰图像和模糊核的求解算法,两者的求解过程采用分裂 Bregman 迭代算法将目标函数分裂成多个子问题进行优化求解。实验结果表明,提出的方法能够很好地抑制振铃效应并保护图像的边缘细节,通过与其他盲复原方法进行比较,在视觉质量与客观质量评价上均说明本文算法具有更好的稳健性。

关键词 图像处理; 图像盲复原; 去模糊; l_1/l_2 范数; 高低阶全变差; 分裂 Bregman 迭代

中图分类号 TP391

文献标识码 A

doi: 10.3788/LOP55.041015

Blind Recovery Method of Motion Blurred Image Based on Combining l_1/l_2 Norm with High Order and Low Order Total Variation

Wang Can^{1,2}, Yang Fan^{1,2}, Li Jing^{1,2}

¹School of Electronic and Information Engineering, Hebei University of Technology, Tianjin 300401, China;

²Tianjin Key Laboratory of Electronic Materials and Devices, Tianjin 300401, China

Abstract In order to realize the blind recovery of motion blurred image, we present a blind recovery method based on combining l_1/l_2 norm with the high order and low order total variation. We adopt the ratio of l_1/l_2 norm regularization prior item which has high sparse expression ability, and add the high order and low order total variation regularization item. High order total variation regularization model can suppress the ladder effect and ringing effect that may occur in the region of non-edges. Low order total variation regularization model can protect the sparse feature of natural image edges. The solution of high-quality image and the solution of blurred kernel are given respectively, both of which employing Bregman iterative algorithms to split the objective function into multiple sub-problems. The experimental results show that the proposed method can restrain ringing effect and protect the image edge details. The robustness of proposed algorithm is better in the visual quality and objective quality evaluation comparing with other methods for blind recovery of motion blurred images.

Key words image processing; image blind recovery; deblurring; l_1/l_2 norm; combining high order and low order total variation; split Bregman iteration

OCIS codes 100.1455; 100.2000; 100.3020

收稿日期: 2017-09-13; 收到修改稿日期: 2017-10-29

基金项目: 河北省自然科学基金(E2016202341)、河北省高等学校科学技术研究项目(BJ2014013)、教育部人文社会科学研究规划基金(15YJA630108)

作者简介: 王灿(1990—),女,硕士研究生,主要从事数字图像处理方面的研究。E-mail: cwangele@163.com

导师简介: 杨帆(1966—),男,博士,教授,博士生导师,主要从事图像处理、模式识别及计算机视觉方面的研究。

E-mail: 563733948@qq.com(通信联系人)

1 引言

在采集图像时,成像装置与被拍摄物体之间产生复杂的相对位移,这一动态过程会使图像变模糊从而丢失部分有用信息,图像分辨率的下降加大了图像的辨识度。在图像实际应用中,如刑事侦查、临床诊断,以及监控系统等领域都需要使用高分辨率的图像,因此,模糊图像的复原工作意义重大。模糊图像可通过清晰图像与点扩展函数(PSF)卷积运算产生,清晰图像的求解问题关键在于建立退化模型,从而转化成反卷积问题。图像复原可分为模糊核未知时的盲反卷积^[1]和模糊核已知时的非盲去卷积^[2](如维纳滤波法^[3]、Richardson-Lucy(R-L)滤波法^[4]等)。当求得较精确的模糊核时,盲复原问题往往可以转化为非盲复原问题去求解。

近年来,许多学者采用图像先验条件作为约束条件,并取得了较大进展。2006年 Fergus 等^[5]为了去除相机抖动产生的图像模糊,利用贝叶斯方法以及结合零均值下的高斯混合先验模型描述自然图像梯度分布,利用指数混合先验模拟 PSF。相比较于 Fergus 等^[5]的研究算法,2008年 Shan 等^[6]利用局部先验对比约束来抑制振铃效应,利用稀疏先验条件交替迭代出模糊核和清晰图像。该方法虽然能较好地抑制图像的振铃效应,但是图像复原过于平滑,不利于细节的显示。随着正则化^[7]与稀疏表示方法^[8]在复原中的广泛应用,2011年 Krishnan 等^[9]提出一种基于规范化稀疏先验的盲去模糊算法,利用稀疏正则化效果更突出的 l_1/l_2 范式来求得更精确的清晰图像,该方法得出了较好的复原结果,且速度比较快,但是在模糊核优化过程中抑制了图像的细节,且复原的图像中存在较明显振铃效应。苏畅等^[10]提出了一种基于能量约束的自适应加权图像盲复原算法,该算法能有效恢复高斯类模糊图像,增强图像细节分辨能力。王民等^[11]提出了一种将粒子群优化(PSO)算法与超分辨率卷积神经网络(SRCNN)相结合的方法,利用 PSO 对网络权重进行初始化,同时结合梯度下降法(GD)对权值进行修正,使得 PSO 的全局搜索能力与 GD 的局部寻优能力相融合。唐佳林等^[12]提出一种结合主成分分析(PCA)和最大后验概率(MAP)的人脸超分辨复原算法,进一步提高了人脸图像的分辨率。全变差(TV)是 Rudin 等^[13]提出的图像去噪正则化模型,其低阶扩散特性使其能很好地保护图像的边缘特征。近年来高阶 TV 的平滑性也在图像复原领域作

出了很大贡献,如高阶偏微分方程(LLT)模型^[14],虽然高阶能根据图像平滑的近似规律抑制阶梯和振铃两大效应,但是过于平滑会使图像边缘信息变模糊。Papafitsoros 等^[15]在低阶全变差模型上增加了一个二阶全变差正则项,构造了低阶全变差和高阶全变差导数合并的凸函数,该模型在一定程度上可以避免阶梯效应且保持边缘信息。姜博宇等^[16]提出了基于全变差的双保真项去噪模型,此模型引入了自适应参数作为保真项的权重,使得模型能够根据不同的区域控制保真的强度,增加自适应去噪能力。

为了更有效地抑制盲复原过程中产生的振铃效应,保护图像的边缘特征,恢复图像的细节信息,本文结合 l_1/l_2 范式正则化先验项的稀疏表达能力与高低阶 TV 扩散模型的优点,提出了一种基于 l_1/l_2 的高低阶全变差的图像盲去模糊方法。首先采用超拉普拉斯分布模拟自然图像的重尾分布^[17],建立 l_1/l_2 拉普拉斯归一化稀疏先验模型,然后利用低阶 TV 在复原图像时能够保留纹理和轮廓等细节信息以及高阶 TV 能够使图像恢复更平滑并降低振铃的特点,组成高低阶混合全变差模型,既保护了图像边缘细节,又抑制了阶梯和振铃效应。在算法求解方面,利用算子分裂可以将目标函数分裂成多个子问题来进行最优化求解,结合分裂 Bregman 迭代算法^[18]收敛速度快的特点,简化算法的求解方式。

2 基于 l_1/l_2 的高低阶全变差正则化图像复原模型的提出

由于模糊核是未知的,图像盲反卷积是一个病态的逆问题。病态问题是指方程不存在唯一解,且求解过程对观测数据具有连续依赖性,图像的模糊退化过程可以看成是原始清晰图像与 PSF 进行卷积的结果,即

$$\mathbf{f} = \mathbf{H} \otimes \mathbf{L} + \mathbf{n}, \quad (1)$$

式中 \mathbf{L} 为原始高分辨率图像, \mathbf{f} 为模糊后的低分辨率图像, \mathbf{n} 为随机噪声, \mathbf{H} 为模糊图像的模糊核, \otimes 为卷积算子符号。使用传统的复原方法如逆滤波时,即使 \mathbf{f} 中存在微小的错误也能导致复原图像相对于真实解产生巨大的差异。

2.1 复原算法来源

正则化方法通过对逆问题加入约束条件使得所求得的解更接近真实解或更有意义。由于图像复原问题具有不适定性,需要引入关于图像的先验知识,从而将图像复原转换成适定性问题进行求解。在图像处理中, l_1 范数正则项常常用于惩罚图像的高频

带。噪声位于图像的高频带,增加了图像的 l_1 范数,因此最小化 l_1 范数是图像去噪方式之一。但在图像模糊的模型中却是相反的,因为模糊减少了图像的高频带,也减少了图像的 l_1 范数。因此,在盲去卷积问题的设置中,在图像的高频处最小化 l_1 范数,会产生更模糊的图像。此时将 l_1 范数进行归一化,即除以 l_2 范数,相当于将 l_1 范数通过总能量进行了重塑,使得 l_1 范数尺度不变。基于图像先验的范数归一化 l_1/l_2 拉普拉斯先验正则化方法是解决图像复原问题的一种有效方法,该正则化方法具有更强的稀疏表达能力。其模型为

$$\operatorname{argmin}_{\mathbf{H}, \mathbf{L}} \left(\alpha \|\mathbf{H} \otimes \mathbf{L} - \mathbf{f}\|_2^2 + \lambda \frac{\|\mathbf{L}\|_1}{\|\mathbf{L}\|_2} + \theta \|\mathbf{H}\|_1 \right). \quad (2)$$

对于代价函数(2)式,模糊在减小 l_1 范数的同时也会减小 l_2 范数,但是 l_2 范数相对于 l_1 范数会减小得更快,因此模糊程度越大, l_1/l_2 的值越大。根据模糊与 l_1/l_2 的相互关系,即可得出通过减小 l_1/l_2 来调整复原后图像的清晰程度。

TV 正则化模型一般适用于超分辨率的图像重建工作中,能够恢复出模糊图像的边缘信息,正则化算子表示为

$$f_{\text{TV}}(\mathbf{X}) = \|\nabla \mathbf{X}\|_1, \quad (3)$$

式中 $\|\nabla \mathbf{x}\| = \sqrt{(D_x \mathbf{X})^2 + (D_y \mathbf{X})^2}$, ∇ 为梯度算子, $D_x \mathbf{X}$ 为 \mathbf{X} 在水平方向分量的梯度, $D_y \mathbf{X}$ 为 \mathbf{X} 在垂直方向分量的梯度。其矩阵差分形式为

$$f_{\text{TV}}(\mathbf{X}) = \sum_{i,j} \sqrt{(\mathbf{X}_{i+1,j} - \mathbf{X}_{i,j})^2 + (\mathbf{X}_{i,j+1} - \mathbf{X}_{i,j})^2}. \quad (4)$$

高阶 TV 形式,以二阶为例,表示为

$$\|\nabla^2 \mathbf{X}\|_1 = \sum_{i,j} \sqrt{(\nabla_{xx}^2 \mathbf{X})_{(i,j)}^2 + 2(\nabla_{xy}^2 \mathbf{X})_{(i,j)}^2 + (\nabla_{yy}^2 \mathbf{X})_{(i,j)}^2}. \quad (5)$$

虽然 TV 正则化模型在图像盲复原时能够恢复复原图像的边缘特征,但是由于低阶 TV 使复原图像的平滑部分存在分片常数现象,会导致图像出现阶梯效应。只对模糊图像进行低阶 TV 正则化约束,则会出现假边缘和振铃效应。高阶 TV 的引入则可以近似地描绘图像平滑区域的变化规律,由于数字图像复原过程不仅与该像素点水平和垂直两个方向像素有关,还与诸如正负对角线方向的像素有关。与利用一次平面函数逼近图像函数的一阶变差正则化方法不同,高阶变差正则化正是考虑了多个方向像素值的影响而建立的复原模型,其本质是在

局部小范围内利用二次曲面函数逼近图像函数,可以有效降低振铃效应。但是高阶 TV 在处理图像边缘部分又存在自身缺陷,其特点为图像复原过程会使得图像过于光滑,造成边缘信息缺失,进而出现边缘模糊现象,此时低阶 TV 正则化模型则能够更好地处理图像的边缘特征。

2.2 基于 l_1/l_2 的高低阶全变差正则化图像复原模型

为了同时解决边缘模糊和阶梯效应的产生问题,本文模型结合了范数比值正则化模型,以及低阶 TV 和高阶 TV 的混合全变差正则化模型的优势,既能满足复原的稀疏性要求,又能在保护边缘特性的同时根据像素的变化规律抑制振铃效应,保留更多的细节特征。本文提出的图像盲去模糊的总函数模型为

$$\operatorname{argmin}_{\mathbf{H}, \mathbf{L}} \left(\alpha \|\mathbf{H} \otimes \mathbf{L} - \mathbf{f}\|_2^2 + \lambda \frac{\|\nabla \mathbf{L}\|_1}{\|\nabla \mathbf{L}\|_2} + \gamma \|\nabla^2 \mathbf{L}\|_1 + \beta \|\nabla \mathbf{L}\|_2^2 + \theta \|\mathbf{H}\|_1 \right), \quad (6)$$

式中 $\alpha, \beta, \gamma, \lambda, \theta$ 为各项的正则化调节参数,

$\|\nabla \mathbf{L}\|_1 = \sum_{i,j} \sqrt{(\nabla_x \mathbf{L})_{(i,j)}^2 + (\nabla_y \mathbf{L})_{(i,j)}^2}$, $\nabla_x \mathbf{L}$ 为 \mathbf{L} 在水平方向的偏导数, $\nabla_y \mathbf{L}$ 为 \mathbf{L} 在垂直方向的偏导数, $\nabla^2 \mathbf{L}$ 为 \mathbf{L} 的二阶求导, $\|\nabla^2 \mathbf{L}\|_1 = \sum_{i,j} \sqrt{(\nabla_{xx}^2 \mathbf{L})_{(i,j)}^2 + 2(\nabla_{xy}^2 \mathbf{L})_{(i,j)}^2 + (\nabla_{yy}^2 \mathbf{L})_{(i,j)}^2}$ 。

(6) 式中第一项为保真项,可以使复原图像尽可能保留原始图像的细节特征;第二项为广义拉普拉斯规范化稀疏先验;第三项为高阶 TV 正则项,可以有效抑制 TV 扩散带来的分片常数现象,减少图像非边缘部分可能出现的阶梯及振铃效应,使复原图像趋于平滑;第四项对应的 l_2 范数可以更好地处理图像的边缘特征。两者相结合可以有效提升反卷积复原图像的视觉质量。本文提出的去模糊模型为多变量求解函数,通过引入分裂 Bregman 迭代的思想将目标函数分裂成多个子问题来求解,既能简化运算过程,又能提高求解速度和准确度。

3 算法模型的优化求解

对于模糊核与清晰图像的求解分两部分交替更新迭代来实现,第一部分更新原始模糊图像的梯度变换,逐步更新迭代出清晰图像,第二部分更新模糊核 \mathbf{H} 。将自然图像梯度的重尾分布作为先验子引入第一个代价函数中,即采用范数 l_1/l_2 比值作为先验项。在求解清晰图像和模糊核过程中利用分裂 Bregman 迭代算法的思想将目标函数分裂成多个子问题来进行最优化求解。对于模糊核采用由小尺寸到大尺寸

进行逐步估计,模糊图像尺寸为 $s \text{ pixel} \times s \text{ pixel}$, 其中 $3 \leq s \leq S$, 且 s 以 $\sqrt{2}$ 的增量由大尺寸向小尺寸增大。

3.1 清晰图像 L 的求解

模糊核与清晰图像的求解采用交替迭代方法,因此求解 L 时模糊核已知,可忽略模糊核正则项,保留清晰图像 L 的正则项,得到清晰图像 L 的函数模型:

$$\operatorname{argmin}_L \left(\alpha \| \mathbf{H} \otimes L - f \|_2^2 + \lambda \frac{\| \nabla L \|_1}{\| \nabla L \|_2} + \gamma \| \nabla^2 L \|_1 + \beta \| \nabla L \|_2 \right). \quad (7)$$

设定 L_i, H_i 为当前状态下的清晰图像和模糊核。利用分裂 Bregman 算法,引入辅助变量 \mathbf{g}, \mathbf{b} 。产生两个约束项 $\mathbf{g} = \nabla L, \mathbf{g} = (g_x; g_y)$ 和 $\mathbf{b} = \nabla^2 L, \mathbf{b} = (b_{xx}; b_{xy}; b_{yx}; b_{yy})$ 。通过约束项将上述约束问题转化为 L 的无约束问题来求最优化解

$$(L_i^{n+1}, \mathbf{g}_i^{n+1}, \mathbf{b}_i^{n+1}) = \operatorname{argmin}_{L, \mathbf{g}, \mathbf{b}} \left(\alpha \| H_i \otimes L - f \|_2^2 + \lambda \frac{\| \mathbf{g} \|_1}{\| \nabla L_i \|_2} + \gamma \| \mathbf{b} \|_1 + \beta \| \nabla L \|_2 + \frac{\mu_1}{2} \| \mathbf{g} - \nabla L - \mathbf{d}_i^n \|_2^2 + \frac{\mu_2}{2} \| \mathbf{b} - \nabla^2 L - \mathbf{e}_i^n \|_2^2 \right), \quad (8)$$

式中 μ_1, μ_2 为两个惩罚项的系数, \mathbf{d}, \mathbf{e} 为两个惩罚项变量, 其中 $\mathbf{d} = [(d_x)_i^n; (d_y)_i^n]$, $\mathbf{e} = [(e_{xx})_i^n; (e_{xy})_i^n; (e_{yx})_i^n; (e_{yy})_i^n]$ 。函数分内外两层循环迭代, i 为外部循环, 其中 $0 \leq i \leq I = 8$, 而内循环 $0 \leq n \leq N = 8, n, i$ 均为整数, H_i 为对应的模糊核估计中第 i 次估计出的模糊核。外循环为 i , 内循环为 $n = N$ 时, 估计图像 $L_{i+1} = L_i^n$ 。对于(7)式直接求解难度较大, 因为数据项跟正则项对变量的依赖不同, 所以可以利用分裂 Bregman 算法将(7)式分成几个子问题来求解:

$$L_i^{n+1} = \operatorname{argmin}_L \left(\alpha \| H_i \otimes L - f \|_2^2 + \lambda \frac{\| \mathbf{g} \|_1}{\| \nabla L_i \|_2} + \right.$$

$$\left. \beta \| \nabla L \|_2 + \frac{\mu_1}{2} \| \mathbf{g} - \nabla L - \mathbf{d}_i^n \|_2^2 + \frac{\mu_2}{2} \| \mathbf{b} - \nabla^2 L - \mathbf{e}_i^n \|_2^2 \right), \quad (9)$$

$$\mathbf{b}_i^{n+1} = \operatorname{argmin}_b \left(\gamma \| \mathbf{b} \|_1 + \frac{\mu_2}{2} \| \mathbf{b} - \nabla^2 L_i^{n+1} - \mathbf{e}_i^n \|_2^2 \right), \quad (10)$$

$$\mathbf{g}_i^{n+1} = \operatorname{argmin}_g \left(\lambda \frac{\| \mathbf{g} \|_1}{\| \nabla L_i^{n+1} \|_2} + \frac{\mu_1}{2} \| \mathbf{g} - \nabla L_i^{n+1} - \mathbf{d}_i^n \|_2^2 \right), \quad (11)$$

$$\mathbf{d}_i^{n+1} = \mathbf{d}_i^n + \nabla L_i^{n+1} - \mathbf{g}_i^{n+1}, \quad (12)$$

$$\mathbf{e}_i^{n+1} = \mathbf{e}_i^n + \nabla^2 L_i^{n+1} - \mathbf{b}_i^{n+1}. \quad (13)$$

1) 固定 $\mathbf{g}, \mathbf{b}, \mathbf{d}, \mathbf{e}$, 求解(9)式 L 的子问题。因为正则项 $\| \mathbf{g} \|_1 / \| \nabla L_i \|_2$ 的存在, L 的更新求解问题是一个非凸优化问题, $\| \nabla L_i \|_2$ 在迭代过程中不会产生突变, 因此可以采用文献[9]中提到的将第 i 次迭代得到的 $\| \nabla L_i \|_2$ 作为一个常量代入第 $i+1$ 次迭代中, 在 L 子问题求解中可以将 $\| \nabla L_i \|_2$ 作为常量。对(9)式求梯度并使其梯度为 0, 则有

$$\begin{aligned} & \left[\alpha \mathbf{H}_i^T \mathbf{H} + \left(\beta + \frac{\mu_1}{2} \right) (\nabla_x^T \nabla_x + \nabla_y^T \nabla_y) + \right. \\ & \left. \frac{\mu_2}{2} (\nabla_{xx}^T \nabla_{xx} + \nabla_{xy}^T \nabla_{xy} + \nabla_{yx}^T \nabla_{yx} + \nabla_{yy}^T \nabla_{yy}) \right] u_i^{n+1} = \\ & \alpha \mathbf{H}_i^T f + \frac{\mu_1}{2} \nabla_x^T [(g_x)_i^n - (d_x)_i^n] + \\ & \frac{\mu_1}{2} \nabla_y^T [(g_y)_i^n - (d_y)_i^n] + \\ & \frac{\mu_2}{2} \{ \nabla_{xx}^T [(b_{xx})_i^n - (e_{xx})_i^n] + \\ & \nabla_{xy}^T [(b_{xy})_i^n - (e_{xy})_i^n] + \\ & \nabla_{yx}^T [(b_{yx})_i^n - (e_{yx})_i^n] + \\ & \nabla_{yy}^T [(b_{yy})_i^n - (e_{yy})_i^n] \}, \quad (14) \end{aligned}$$

对(14)式通过快速傅里叶变换(FFT)解得 L_i^{n+1} :

$$\left\{ \begin{aligned} L_i^{n+1} = \mathcal{F}^{-1} & \left\{ \frac{\alpha \mathcal{F} \mathbf{H}_i^T \cdot * \mathcal{F} f + \frac{\mu_1}{2} \mathcal{F} \nabla_x^T \cdot * [(g_x)_i^n - (d_x)_i^n] + \frac{\mu_1}{2} \mathcal{F} \nabla_y^T \cdot * [(g_y)_i^n - (d_y)_i^n] + \frac{\mu_2}{2} A}{\alpha \mathcal{F} \mathbf{H}_i^T \cdot * \mathcal{F} \mathbf{H} + (\beta + \frac{\mu_1}{2}) (\mathcal{F} \nabla_x^T \cdot * \mathcal{F} \nabla_x + \mathcal{F} \nabla_y^T \cdot * \mathcal{F} \nabla_y) + \frac{\mu_2}{2} B} \right\}, \quad (15) \\ A = \mathcal{F} \nabla_{xx}^T \cdot * [(b_{xx})_i^n - (e_{xx})_i^n] + \mathcal{F} \nabla_{xy}^T \cdot * [(b_{xy})_i^n - (e_{xy})_i^n] + \\ \mathcal{F} \nabla_{yx}^T \cdot * [(b_{yx})_i^n - (e_{yx})_i^n] + \mathcal{F} \nabla_{yy}^T \cdot * [(b_{yy})_i^n - (e_{yy})_i^n] \\ B = \mathcal{F} \nabla_{xx}^T \cdot * \mathcal{F} \nabla_{xx} + \mathcal{F} \nabla_{xy}^T \cdot * \mathcal{F} \nabla_{xy} + \mathcal{F} \nabla_{yx}^T \cdot * \mathcal{F} \nabla_{yx} + \mathcal{F} \nabla_{yy}^T \cdot * \mathcal{F} \nabla_{yy} \end{aligned} \right.$$

式中 \mathbf{H}^T 与 ∇^T 分别为 \mathbf{H} 与 ∇ 的复共轭变换, \mathcal{F}^{-1} 为二维傅里叶逆变换运算, \mathcal{F} 为二维傅里叶变换。

2) 固定 $\mathbf{g}, L, \mathbf{d}, \mathbf{e}$, 求解(10)式 \mathbf{b} 的子问题。对于 l_b 范数的优化求解问题, 采用收缩阈值法求解, 对 l_1

范数用软阈值法求解,软阈值函数用 S_{soft} 符号表示:

$$\mathbf{f} = \operatorname{argmin}_f \left(\omega \|\mathbf{f}\|_1 + \frac{1}{2} \|\mathbf{f} - \mathbf{q}\|_2^2 \right), \quad (16)$$

$$S_{\text{soft}}(\mathbf{q}, \omega) = \max(|\mathbf{q}| - \omega, 0) \operatorname{sgn}(\mathbf{q}), \quad (17)$$

(17)式为软阈值函数(16)式的解。

则有

$$\mathbf{b}_i^{n+1} = S_{\text{soft}} \left[\left(\nabla^2 \mathbf{L}_i^{n+1} + \mathbf{e}_i^n \right), \frac{\gamma}{\mu_2} \right]. \quad (18)$$

3) 固定 $\mathbf{b}, \mathbf{L}, \mathbf{d}, \mathbf{e}$, 求解 \mathbf{g} 的子问题。对(11)式整理变换得

$$\mathbf{g}_i^{n+1} = \operatorname{argmin}_g \left(\|\mathbf{g}\|_1 + \frac{\mu_1}{2} \frac{\|\nabla \mathbf{L}_i^{n+1}\|_2}{\lambda} \|\mathbf{g} - \nabla \mathbf{L}_i^{n+1} - \mathbf{d}_i^n\|_2^2 \right), \quad (19)$$

同理 \mathbf{b} 的子问题中, l_1 范数的求解原理, 可得

$$\mathbf{g}_i^{n+1} = S_{\text{soft}} \left[\left(\nabla \mathbf{L}_i^{n+1} + \mathbf{d}_i^n \right), \frac{\lambda}{\mu_1 \|\nabla \mathbf{L}_i^{n+1}\|_2} \right]. \quad (20)$$

3.2 模糊核 \mathbf{H} 的求解

综上所述, 忽略清晰图像 \mathbf{L} 的正则项, 保留模糊核 \mathbf{H} 的正则项, 得到以下求解模糊核的函数模型

$$\operatorname{argmin}_H (\alpha \|\mathbf{H} \otimes \mathbf{L} - \mathbf{f}\|_2^2 + \theta \|\mathbf{H}\|_1). \quad (21)$$

利用分裂 Bregman 迭代算法, 将模糊核的求解转变成多个子问题的最优化求解。并选择 BCCB 矩阵作为预处理算子来降低计算复杂度, 因其可以通过快速傅里叶变换来实现对角化。引入一个辅助变量 \mathbf{d} 来替代 \mathbf{H} , $\mathbf{d} = (d_x; d_y)$, 将(21)式转换为约束的优化问题来求解

$$\begin{cases} \operatorname{argmin}_H (\alpha \|\mathbf{H} \otimes \mathbf{L} - \mathbf{f}\|_2^2 + \theta \|\mathbf{H}\|_1) \\ \text{s.t. } \mathbf{d} = \mathbf{H} \end{cases}. \quad (22)$$

引入二次惩罚函数项使 \mathbf{d} 无限逼近于 \mathbf{H} , 从而将(22)式的约束问题转化为无约束最优化求解问题

$$(\mathbf{H}_i, \mathbf{d}_i) = \operatorname{argmin}_{\mathbf{H}, \mathbf{d}} \left(\alpha \|\mathbf{H} \otimes \mathbf{L}_{i+1} - \mathbf{f}\|_2^2 + \theta \|\mathbf{d}\|_1 + \frac{\epsilon}{2} \|\mathbf{d} - \mathbf{H} - \mathbf{k}_i\|_2^2 \right), \quad (23)$$

$$\mathbf{k}_{i+1} = \mathbf{k}_i + \mathbf{H}_i - \mathbf{d}_i, \quad (24)$$

式中 \mathbf{L}_{i+1} 为对应的原图像估计中第 i 次估计出的清晰图像, ϵ 为惩罚项系数, \mathbf{k} 为惩罚项变量, $\mathbf{k} = [(k_x)_i; (k_y)_i]$ 。利用分裂 Bregman 算法将(23)式分成如下两个子问题来求解

$$\mathbf{H}_{i+1} = \operatorname{argmin}_H \left(\alpha \|\mathbf{H} \otimes \mathbf{L}_{i+1} - \mathbf{f}\|_2^2 + \frac{\epsilon}{2} \|\mathbf{d} - \mathbf{H} - \mathbf{k}_i\|_2^2 \right), \quad (25)$$

$$\mathbf{d}_{i+1} = \operatorname{argmin}_d \left(\theta \|\mathbf{d}\|_1 + \frac{\epsilon}{2} \|\mathbf{d} - \mathbf{H} - \mathbf{k}_i\|_2^2 \right). \quad (26)$$

1) 固定 \mathbf{d}, \mathbf{k} , 求解 \mathbf{H} 的子问题。令 \mathbf{I} 为单位矩阵, 对(25)式求导, 并使其导数为零, 再经过快速傅里叶变换得

$$\mathbf{H}_{i+1} = \mathcal{F}^{-1} \left[\frac{\alpha \mathcal{F} \mathbf{L}_{i+1}^T * \mathcal{F} \mathbf{f} + \frac{\epsilon}{2} \mathcal{F}(\mathbf{H}_i - \mathbf{d}_i)}{\alpha \mathcal{F} \mathbf{L}_{i+1}^T * \mathcal{F} \mathbf{L}_{i+1} - \frac{\epsilon}{2} \mathcal{F} \mathbf{I}} \right]. \quad (27)$$

2) 固定 \mathbf{H}, \mathbf{k} , 求解 \mathbf{d} 的子问题。对于(26)式的 l_1 范数利用求解 \mathbf{b} 的子问题中提到的二维收缩软阈值法(S_{soft})进行更新求解

$$\mathbf{d}_{i+1} = S_{\text{soft}} \left[(\mathbf{H} + \mathbf{k}_i), \frac{\theta}{\epsilon} \right]. \quad (28)$$

3.3 算法流程归纳

本文算法对于模糊图像 \mathbf{L} , 模糊核 \mathbf{H} 的估计是同时交替迭代进行的, 算法实现流程归纳如下。

输入: 模糊图像 \mathbf{L} , 模糊尺寸 s , 初始化各参数;

While $s < S$ do

 While $i < I$ do

 While $n < N$ do

 通过(15)式更新 \mathbf{L}_i^{n+1}

 通过(18)式更新 \mathbf{b}_i^{n+1}

 通过(20)式更新 \mathbf{g}_i^{n+1}

 End

 输出 $\mathbf{L}_{i+1} = \mathbf{L}_i^N$

 通过(27)式更新 \mathbf{H}_{i+1}

 通过(28)式更新 \mathbf{d}_{i+1}

 End

 输出 $\mathbf{L}_I, \mathbf{H}_I$

End

输出最终模糊核 \mathbf{H}_S , 清晰图像 \mathbf{L}_S 。

4 实验结果与分析

为验证本文所提出的基于 l_1/l_2 的高低阶全变差图像去模糊模型的有效性, 采用仿真模糊图像与真实模糊图像来进行大量实验测试对比, 测试集图像为彩色图像。对比模型采用了近年来模糊图像复原效果较好的 Krishnan 等^[9]算法与 Xu 等^[19]的算法。模型中的几个重要参数设置如下。

参数 γ 控制高阶 TV 扩散的速度, 若其值太大, 复原图像的边缘会因为过度的高阶扩散而被平滑掉。在本文的实验中, 参数 γ 的取值为 $[0.1, 1]$ 。实

验过程分别取 0.1、0.5、1 时对同一模糊核下相同图像进行复原, 并比较峰值信噪比 (PSNR), 实验表明在此范围内已经达到平衡, PSNR 相差很小, 但当 γ 取 0.5 时, PSNR 值最大, 因此取 $\gamma=0.5$ 。参数 β 为低阶 TV 正则化项, 控制图像边缘细节锐化程度, 该参数的设定通过取值范围由大到小, 逐次逼近的方式优化得到, 最终取为固定值, $\beta=0.2$ 时得到复原图像质量最好。参数 μ_1, μ_2 分别影响着变量 \mathbf{g} 和 \mathbf{b} 的更新速度, 取值越大, 更新速度越慢。在不影响算法性能的前提下经过反复实验, 对惩罚参数 μ_1, μ_2 统一设置为: $\mu_1=11\lambda, \mu_2=10^{-3}\gamma$ 。 θ 的取值根据模糊核的大小设定, 经过验证当 $\theta=0.25$ s 时算法的稳健性达到最佳。其余参数根据实际输入图像进行调节得到最佳复原结果。本课题的实验在配置为 Intel Core-i5-2410 M CPU 2.3 GHz RAM 4.00 GB 的 Lenovo 笔记本上完成。系统为 Windows7, 仿真软件为 MATLAB 2014a。

4.1 仿真模糊图像复原实验

选择两幅清晰图像 Lena 和 peppers, 分别通过与两种模糊核做卷积运算以及添加噪声得到测试模糊图像。图 1(a) 为模糊核 $K1$, 方向是 135° , 长度为 21; 图 1(b) 为自定义不规则运动模糊核 $K2$, 大小为 $13 \text{ pixel} \times 13 \text{ pixel}$ 。图 2(b) 为 Lena 与模糊核 $K1$ 做卷积运算, 添加信噪比水平为 30 dB 的高斯噪声得到的模糊图像。图 3(b) 为 peppers 与模糊核 $K2$ 做卷积运算, 添加信噪比水平为 30 dB 的高斯噪声得到的模糊图像。图 2 和图 3 分别展示出文献[9]方法、文献[19]方法以及本文算法针对人工模糊图像的复原图像, 可以发现, 利用文献[9]方法得到的复原图像存在明显的振铃效应, 采用文献[19]方法得到的复原图像虽然振铃效应有所减弱, 但边缘细节保持较差, 而本文算法得到的图像可达到同时消除阶梯效应且边缘细节保持清晰的效果。




图 1 自定义模糊核。(a) $K1$; (b) $K2$

Fig. 1 Customized blurred kernel. (a) $K1$; (b) $K2$



图 2 模糊图像 Lena($K1$)的盲复原对比结果。(a)清晰图像;(b)模糊图像($K1$);(c)文献[9]方法;(d)文献[19]方法;(e)本文方法;(f)本文方法估计的模糊核

Fig. 2 Comparison results of the blind recovery of blurred images for Lena with kernel $K1$. (a) Original image; (b) blurred image with kernel $K1$; (c) method of Ref. [9]; (d) method of Ref. [19]; (e) proposed method; (f) blurred kernel estimated by proposed method



图3 模糊图像 peppers(K2)的盲复原对比结果。(a)清晰图像;(b)模糊图像(K2);
(c)文献[9]方法;(d)文献[19]方法;(e)本文方法;(f)本文方法估计模糊核

Fig. 3 Comparison results of the blind recovery of blurred images for peppers with kernel K2. (a) Original image;
(b) blurred image with kernel K2; (c) method of Ref. [9]; (d) method of Ref. [19]; (e) proposed method;
(f) blurred kernel estimated by proposed method

在客观质量评价上,采用 PSNR 以及结构相似度(SSIM)来作为客观评价不同图像复原方法的标准,PSNR 的值越大,SSIM 的值越接近 1,说明复原图像与清晰图像越接近。表 1 和表 2 分别为文献[9]方法、文献[19]以及本文复原算法的 PSNR 值比较与 SSIM 值比较,并给出了清晰图像 Lena 和 peppers,用于盲复原实验的模糊图像由 Lena 和 peppers 分别于模糊核 K1、K2 做卷积得到。由表 1 和表 2 实验数据可知,本文复原算法的 PSNR 值、SSIM 值相比较于其他两种算法均有所提高,复原结果失真更少。

表 1 各复原方法的 PSNR 值比较

Table 1 PSNR comparison with different methods dB

Blur image	Blur kernel	Method of Ref.[9]	Method of Ref.[19]	Proposed method
Lena	K1	26.36	27.54	28.83
	K2	26.31	25.24	26.84
Peppers	K1	27.63	26.85	28.33
	K2	28.39	27.92	29.04

表 2 各复原方法的 SSIM 值比较

Table 2 SSIM comparison with different methods

Blur image	Blur kernel	Method of Ref.[9]	Method of Ref.[19]	Proposed method
Lena	K1	0.7155	0.8887	0.9372
	K2	0.8296	0.7426	0.9128
Peppers	K1	0.9167	0.8701	0.9434
	K2	0.9042	0.8864	0.9544

4.2 真实模糊图像复原实验

为更好地验证本文算法在实际彩色模糊图像复

原中的效果,选取两组彩色模糊图像 Roma 和 fishes 进行复原实验,使其与文献[9]方法和文献[19]方法的复原效果进行对比。

图 4 表示模糊图像 Roma 用本文算法、文献[9]方法,以及文献[19]方法复原后的效果图。第一行从左到右依次为原始模糊图像、文献[9]方法的复原图像及其模糊核,文献[19]方法的复原图像及其模糊核、本文方法复原图像及其模糊核。为了更清晰地表现各种复原方法对图像细节的处理,第二行为从对应的每幅复原图像的相同位置取一定区域的细节图进行放大。从视觉质量上不难看出,文献[19]方法虽然振铃效应较弱,但图像过于平滑使得边缘细节保持不突出,使图像整体看起来较为模糊。从局部细节放大图可看出,文献[9]方法的复原效果不太理想,其对振铃效应的抑制比较弱,导致图像中存在大量假边缘,掩盖了图像的细节特点。而本文方法的复原图像细节明显,轮廓比较清晰,同时也大大抑制了振铃效应,有很好的视觉效果。

图 5 所示为采用文献[9]模糊图像 fishes 来进行复原对比。第一行从左到右中依次为原始模糊图像、文献[9]方法的复原图像及其模糊核,文献[19]方法的复原图像及其模糊核、本文方法复原图像及其模糊核,第二行为对应的细节放大图。文献[9]方法与文献[19]方法对于模糊核的估计均有一部分噪声,这使得图像的复原没有精确的模糊核支撑。而且文献[19]方法去模糊后的图像过于平滑,fishes 的部分纹路细节被平滑掉了。从细节放大图可以看出文献[9]方法和文献[19]方法的复原结果在




图4 模糊图像 Roma 的复原对比结果。(a)模糊图像;(b)文献[9]方法;(c)文献[19]方法;(d)本文方法
Fig. 4 Comparison results of the blind recovery of blurred images for Roma. (a) Blurred image;
(b) method of Ref. [9]; (c) method of Ref. [19]; (d) proposed method

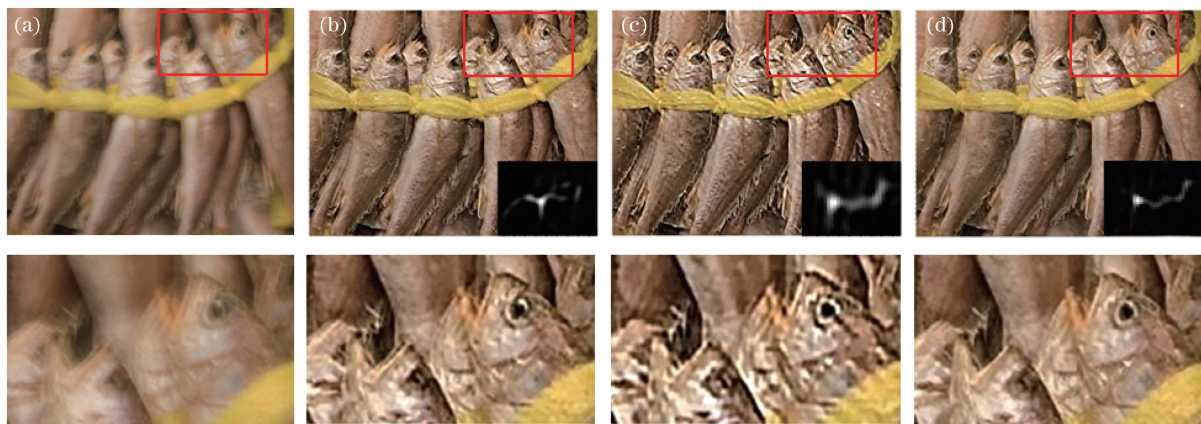


图5 模糊图像 fishes 的复原对比结果。(a)模糊图像;(b)文献[9]方法;(c)文献[19]方法;(d)本文方法
Fig. 5 Comparison results of the blind recovery of blurred images for fishes. (a) Blurred image;
(b) method of Ref. [9]; (c) method of Ref. [19]; (d) proposed method

fishes 的眼、嘴等部位存在振铃效应,轮廓较为模糊,细节特点不清晰,没有很好地把握到像素的变化规律。本文方法复原的图像 fishes 的眼部、鱼鳞,以及鱼尾处的纹路和轮廓都是比较清晰。

通过增加信息熵值的比较进一步说明本文算法的有益性,其中熵值越高代表图像信息量越大,图像越清晰。表3分别为文献[9]方法、文献[19]方法,以及本文复原算法的信息熵值比较,由表3的数据可以看出本文算法得到图像的信息熵值最大,因此利用本文复原算法可最大程度地恢复原始图像,保留更多有效信息。

表3 各复原方法的信息熵值比较

Table 3 Comentropy comparison with different methods

Blurred image	Method of Ref.[9]	Method of Ref.[19]	Proposed method
Roma	5.32	6.63	7.03
Fishes	6.46	5.97	6.98

通过对以上各种算法处理效果的对比,总结出本文算法的优点:1)极大地提升了规范化稀疏先验方法的估计准确度;2)改善了原有方法的稳健性;3)结合了高阶全变差对阶梯效应的抑制与低阶全变差保护边缘特征的两大优点;4)恢复图像中的振铃效应明显降低,图像细节更为清晰,物体轮廓信息更加明显。

5 结论

为了更好地进行运动模糊图像的盲复原工作,采用了基于 l_1/l_2 范式的高低阶 TV 混合的全变差盲复原方法实现对模糊图像的清晰处理。 l_1/l_2 正则化模型作为广义规范化稀疏先验具有更强稀疏表达能力,保证了图像的稀疏性要求。高低阶混合全变差正则化模型是非凸的,相比较于凸优化正则模型具有更好的边缘保持性,不仅可以恢复图像边缘

的细节,还可以有效避免平滑区域出现的假边缘现象。在算法的求解过程中引入了分裂 Bregman 迭代算法以及收缩阈值法来降低求解难度。实验结果表明,本文提出的复原模型不仅具有更好的视觉质量,而且对 PSNR,SSIM 均有所提高。

参 考 文 献

- [1] Liu R W, Wu D, Wu C S, *et al.* Hybrid regularized blur kernel estimation for single-image blind deconvolution[C]. IEEE International Conference on Systems, Man, and Cybernetics, 2015: 1815-1820.
- [2] Li Z M, Zheng Y, Jing W F, *et al.* Hyper-Laplacian non-blind deblurring model based on regional division [C]. International Conference on Network and Information Systems for Computers, 2015: 223-226.
- [3] Yang Y M, Gao M T, He J. Wiener filtering image restoration technology research and improvement[J]. Science Technology and Engineering, 2012, 12(29): 7611-7615.
杨艳美, 高满屯, 贺剑. 维纳滤波图像复原技术的研究与改进[J]. 科学技术与工程, 2012, 12(29): 7611-7615.
- [4] Zhao B, Zhang W S, Ding H. Novel image deblurring algorithm based on Richardson-Lucy[J]. Computer Engineering and Applications, 2011, 47(34): 1-4.
赵博, 张文生, 丁欢. 基于 Richardson-Lucy 的图像去模糊新算法[J]. 计算机工程与应用, 2011, 47(34): 1-4.
- [5] Fergus R, Singh B, Hertzmann A, *et al.* Removing camera shake from a single photograph[J]. ACM Transactions on Graphics, 2006, 25(3): 787-794.
- [6] Shan Q, Jia J Y, Agarwala A. High-quality motion deblurring from a single image [J]. ACM Transactions on Graphics, 2008, 27(3): 73.
- [7] Yan J W, Xie T T, Peng H, *et al.* Motion image deblurring based on L_0 norms regularization term[J]. Laser & Optoelectronics Progress, 2017, 54(2): 021005.
闫敬文, 谢婷婷, 彭鸿, 等. 基于 L_0 范数正则项的运动图像去模糊[J]. 激光与光电子学进展, 2017, 54(2): 021005.
- [8] Perrone D, Favaro P. Alogarithmic image prior for blind deconvolution [J]. International Journal of Computer Vision, 2016, 117(2): 159-172.
- [9] Krishnan D, Tay T, Fergus R. Blind deconvolution using a normalized sparsity measure [C]. IEEE Conference on Computer Vision and Pattern Recognition, 2011: 233-240.
- [10] Su C, Fu T J, Zhang X X, *et al.* An adaptive weighted blind image restoration algorithm based on energy constraint[J]. Acta Optica Sinica, 2018, 38(2): 0210001.
苏畅, 付天骄, 张星祥, 等. 基于能量约束的自适应加权图像盲复原算法[J]. 光学学报, 2018, 38(2): 0210001.
- [11] Wang M, Liu K X, Liu L, *et al.* Super-resolution reconstruction of image based on optimized convolution neural network [J]. Laser & Optoelectronics Progress, 2017, 54(11): 111005.
王民, 刘可心, 刘利, 等. 基于优化卷积神经网络的图像超分辨率重建[J]. 激光与光电子学进展, 2017, 54(11): 111005.
- [12] Tang J L, Chen Z B, Su B H, *et al.* Super resolution restoration of low quality face images [J]. Laser & Optoelectronics Progress, 2018, 55(3): 031007.
唐佳林, 陈泽彬, 苏秉华, 等. 低质量人脸图像的超分辨率复原[J]. 激光与光电子学进展, 2018, 55(3): 031007.
- [13] Rudin L I, Osher S, Fatemi E. Nonlinear total variation based noise removal algorithms [C]. Proceedings of the eleventh annual international conference of the Center for Nonlinear Studies on Experimental mathematics, 1992, 60: 259-268.
- [14] Lysaker M, Lundervold A, Tai X C. Noise removal using fourth-order partial differential equation with applications to medical magnetic resonance images in space and time [J]. IEEE Transactions on Image Processing, 2003, 12(12): 1579-1590.
- [15] Papafitsoros K, Schönlieb C B. A combined first and second order variational approach for image reconstruction[J]. Journal of Mathematical Imaging and Vision, 2014, 48(2): 308-338.
- [16] Jiang B Y, Zhang J. Denosing model base on double-fidelity total variation[J]. Laser & Optoelectronics Progress, 2018, 55(2): 021004.
姜博宇, 张剑. 双保真全变差去噪模型[J]. 激光与光电子学进展, 2018, 55(2): 021004.
- [17] Krishnan D, Fergus R. Fast image deconvolution using hyper-Laplacian priors[C]. Proceedings of the 22nd International Conference on Neural Information Processing Systems, 2009: 1033-1041.
- [18] Tang S, Gong W G, Li W H, *et al.* Non-blind image deblurring method by local and nonlocal total variation models [J]. Signal Processing, 2014, 94: 339-349.
- [19] Xu L, Jia J Y. Two-phase kernel estimation for robust motion deblurring [C]. European Conference on Computer Vision, 2010: 157-170.