

优化重加权 L1 范数的图像盲复原算法

王 凯¹, 肖 亮^{1,2}, 黄丽丽³, 韦志辉¹

(1. 南京理工大学计算机科学与工程学院, 江苏南京 210094; 2. 江苏省光谱成像与智能感知重点实验室, 江苏南京 210094;
3. 广西科技大学理学院, 广西柳州 545006)

摘 要: 在单幅运动模糊图像的盲复原问题中, 图像中强边缘部分的利用成为模糊核估计的关键所在. 为此, 本文提出了一种优化重加权 L1 范数的图像盲复原算法. 首先, 建立了基于加权 L1 范数的模糊核盲估计模型, 并引入了一种图像平滑模型对权重进行优化估计, 从而减少计算权重时受细小结构以及噪声的影响, 其次, 设计了模糊核盲估计模型求解的迭代收缩阈值数值算法, 最后采用了一种基于超拉普拉斯先验的快速图像非盲复原算法对模糊图像进行复原. 仿真和实际数据实验结果验证了本文算法的有效性.

关键词: 图像盲复原; 加权 L1 范数; 迭代收缩阈值

中图分类号: TP317.4

文献标识码: A

文章编号: 0372-2112 (2016)09-2175-06

电子学报 URL: <http://www.ejournal.org.cn>

DOI: 10.3969/j.issn.0372-2112.2016.09.023

Blind Image Deblurring Based on Optimal Reweighted L1 Norm

WANG Kai¹, XIAO Liang^{1,2}, HUANG Li-li³, WEI Zhi-hui¹

(1. School of Computer Science and Engineering, Nanjing University of Science and Technology, Nanjing, Jiangsu 210094, China;
2. Jiangsu Key Lab of Spectral Imaging and Intelligent Sensing, Nanjing, Jiangsu 210094, China;
3. School of Science, Guangxi University of Science and Technology, Liuzhou, Guangxi 545006, China)

Abstract: In single blind motion deblurring, salient edges have been the key to success of kernel estimation. To this end, a new blind motion deblurring algorithm is proposed based on optimal reweighted L1 norm. Firstly, the weighted L1 based blind kernel estimation model is constructed. Then, for reducing the influence of noise and tiny structures, an image smoothing model is introduced into the optimal estimation of weights. A numerical algorithm based on iterative shrinkage-thresholding is also proposed to solve the blind kernel estimation model. At last, a fast non-blind deconvolution method using Hyper-Laplacian priors is utilized to restore the final image. Experimental results on simulated and real-world data demonstrate the superiority of the proposed method.

Key words: blind image deblurring; weighted L1 norm; iterative shrinkage-thresholding

1 引言

图像在采集、传输的过程中, 不可避免地会产生噪声污染、模糊等退化现象, 而在诸如光学、天文、医学以及遥感等众多应用领域中, 往往需要清晰的、高质量的图像. 通过系统硬件修正固然可以有效提高图像质量, 但往往因为成本较高、应用范围狭窄使得研究软件上的图像复原技术成为迫切需求.

运动模糊作为成像中一种普遍存在的退化现象, 其产生的原因通常是由于图像采集设备在曝光时间内

与目标场景间的相对运动, 例如在飞机、快速行驶的汽车或航天器上拍摄图像, 拍摄对象相对速度过快或相机抖动等. 从数学角度来看, 图像模糊的过程通常表示为原始清晰图像与点扩散函数(Point Spread Function, PSF, 又称为模糊核)的卷积. 因此, 图像复原的过程即为一种解卷积的过程. 而图像盲复原问题就是指在模糊核未知的情况下恢复出清晰的图像, 该问题已经成为视频监控、军事目标识别以及消费型摄影、摄像等众多应用领域的一个有趣研究课题.

目前, 国内外报道了大量关于图像盲复原技术的

收稿日期: 2014-12-04; 修回日期: 2015-11-02; 责任编辑: 梅志强

基金项目: 国家自然科学基金(No. 61171165, No. 11431015, No. 61302178); 江苏省六大人才高峰项目(No. 2012DZXX-036); 中央高校基本科研业务费专项资金(No. 30915012204); 广西省自然科学基金(No. 2014GXNSFAA118360)

研究工作^[1-16]. 特别是从 Fergus 等人^[1]开创性的工作开始, 相关方面的研究已经从早期的参数化模糊核^[2,3]转而关注更为一般的无法参数化表示的模糊核. 其中目前备受关注的方法主要有两类: 基于最大后验概率 (Maximum a Posteriori, MAP) 的方法^[4-13]和基于变分贝叶斯 (Variational Bayesian, VB) 框架的方法^[1,14-16]. 这两种方法的不同点在于: 前者属于经典的点估计范畴, 而后者是将变分法引入了贝叶斯统计推断过程中. 基于 VB 框架的方法实质上是图像与模糊核的联合后验概率在图像空间进行边缘化, 转而求解关于模糊核的边缘分布, 这种策略的好处在于避免了在高维图像空间中进行参数估计. 但是, 基于 VB 框架的方法也有其局限性, 特别是如何推导出边缘分布的形式以及边缘分布的推断成为了该类方法的难点.

在图像盲复原问题中, 相较于基于 VB 框架的方法而言, 基于 MAP 估计的方法有着模型简单、先验选择灵活、数值算法简单高效等优点而被广泛采用. 例如, Almeida 等人^[4]根据自然图像边缘的稀疏性原理, 利用超拉普拉斯 (Hyper-Laplacian) 先验对图像进行建模. Krishnan 等人^[5]发现 L1/L2 范数能够在能量泛函的最优化过程中有效地区分模糊图像与清晰图像. Kotera 等人^[6]采用了与文献[4]中类似的这类超拉普拉斯先验, 并且针对模糊核采用了 L1 范数约束, 保证了模糊核的稀疏性. 但是这几种方法存在一个共同的问题, 即这些图像的先验模型对自然图像边缘的稀疏性刻画并不充分, 容易导致错误地模糊核. 最近, 文献[7]中 Krishnan 等人提出基于 VB 框架的方法和基于 MAP 估计的方法有其相似之处, 并提出了一种加权的 L2 范数约束图像的梯度, 由于加权的 L2 范数从理论上来说是对 L0 范数的一种逼近, 从而满足自然图像边缘的稀疏性原理. 但是该方法在迭代过程中重新计算权重时很容易受到图像中奇异点的影响, 导致权重的估计并不鲁棒.

针对上述算法所出现的问题, 并结合 MAP 框架的优点, 提出了一种优化重加权 L1 范数的运动模糊图像盲复原算法. 本文贡献主要有以下三点: (1) 首先, 考虑到在盲复原问题中图像的边缘区域包含了大部分的模糊信息, 因此本文采用了一种加权的 L1 范数对图像进行建模, 并且加权 L1 范数作为一种稀疏性先验, 突出对图像显著边缘部分的利用, 从而减小图像中微小结构对模糊核估计的不利影响; (2) 实际中, 权重的计算往往会受到噪声的影响, 因此本文采用了一种图像平滑算法对权重进行优化, 削弱噪声对权重计算的影响, 以期获得更好的复原结果; (3) 针对所提出的优化重加权 L1 范数的图像盲复原模型, 利用优化中的半二次分裂技巧, 结合交替最小化方法进行有效求解. 实验结果表明, 优化加权 L1 范数的运动模糊图像盲复原算法能

够有效地估计模糊核并取得较好的复原效果.

2 基于 MAP 估计的图像盲复原模型

图像的运动模糊降质过程通常可以用如下的数学模型来描述:

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

其中 \mathbf{x} 表示原始清晰图像, \mathbf{k} 为未知的模糊核, \mathbf{y} 表示模糊降质图像, \mathbf{n} 为加性高斯白噪声, \otimes 表示卷积算子.

图像盲复原的目标在于仅仅已知观测图像 \mathbf{y} 的情况下, 估计出理想的清晰图像 \mathbf{x} 和模糊核 \mathbf{k} . 众所周知, 即使是在模糊核 \mathbf{k} 已知的情况下, 上述问题依然是一个不适定的反问题, 这使得盲复原问题的求解变得更加困难. 一般的, 在 Bayesian 统计框架下充分利用理想图像的先验知识有利于改善问题的性质. 因此, 利用 Bayesian 公式, \mathbf{x} 和 \mathbf{k} 的后验概率可以写成如下形式:

$$p(\mathbf{x}, \mathbf{k} | \mathbf{y}) \propto p(\mathbf{y} | \mathbf{x}, \mathbf{k}) p(\mathbf{x}) p(\mathbf{k}) \quad (2)$$

盲复原问题的解即为使得该联合后验概率最大化的解. 根据贝叶斯-最大后验概率估计 (Bayesian-MAP) 理论, 将式(2)经过 $-2\log$ 变换后可建立如下的盲复原问题的变分模型:

$$(\hat{\mathbf{x}}, \hat{\mathbf{k}}) = \underset{\mathbf{x}, \mathbf{k}}{\operatorname{argmin}} \|\mathbf{x} \otimes \mathbf{k} - \mathbf{y}\|_2^2 + \lambda \varphi(\mathbf{x}) + \eta \psi(\mathbf{k}) \quad (3)$$

第 1 项为数据保真项, 第 2、3 项的 $\varphi(\mathbf{x})$ 和 $\psi(\mathbf{k})$ 分别对应了式(2)中先验概率 $p(\mathbf{x})$ 和 $p(\mathbf{k})$ 的势函数, λ 和 η 为对应的正则化参数.

观察式(3)可知, 基于 MAP 估计的图像盲复原算法的关键之一在于, 如何选择合适的图像和模糊核的先验模型.

3 优化重加权 L1 范数的图像盲复原

3.1 图像的先验模型

在图像的模糊过程中, 相比较平坦部分而言, 边缘部分受到的影响更为明显. 因此, 图像的边缘部分往往包含了大部分模糊信息, 从而使得对图像边缘的建模成为盲复原问题的关键. 作为自然图像共有的一种特性, 即自然图像的边缘是稀疏的, 可以利用下面的先验模型对图像进行建模:

$$\varphi(\mathbf{x}) = \|\Omega \mathbf{x}\|_p, p \in (0, 1] \quad (4)$$

式中, Ω 是边缘特征提取算子. 出于计算方便以及建模简单方面的考虑, 这里定义 Ω 为一阶梯度算子 $\nabla = (\nabla_h, \nabla_v)$, 而 h 和 v 分别表示垂直方向与水平方向. 另一方面, 这里将式(4)中的 p 取为 1, 满足了稀疏性要求, 并且同时也保证了求解的问题是一个凸变分问题.

考虑到盲复原算法通常是先估计出模糊核, 再利用图像非盲恢复算法估计清晰图像, 因此, 在估计模糊核的过程中, 可以在图像梯度域进行处理, 从而充分利用图像的边缘信息. 令 $\nabla \mathbf{x}$ 和 $\nabla \mathbf{y}$ 分别表示原始清晰图

像和观测图像的梯度,并且由于卷积算子是线性的,故式(1)可转换为

$$\nabla \mathbf{y} = \nabla \mathbf{x} \otimes \mathbf{k} + \mathbf{n}' \quad (5)$$

于是,基于 L1 范数的模糊核盲估计模型可以写成如下形式:

$$(\nabla \hat{\mathbf{x}}, \hat{\mathbf{k}}) = \underset{\nabla \mathbf{x}, \mathbf{k}}{\operatorname{argmin}} \|\nabla \mathbf{x} \otimes \mathbf{k} - \nabla \mathbf{y}\|_2^2 + \lambda \|\nabla \mathbf{x}\|_1 + \eta \|\mathbf{k}\|_2^2 \quad (6)$$

这里,选择 L2 范数作为模糊核的先验模型,使得在约束模糊核光滑性的同时保证了子问题存在闭合解.

基于 L1 范数的模糊核盲估计模型存在一个缺点:文献[14]指出,对于上述的图像稀疏性先验而言,式(6)估计的模糊核往往是 delta 函数,而不是正确的模糊核.这是由于当估计的模糊核 $\hat{\mathbf{k}}$ 为 delta 函数时, $\hat{\mathbf{x}}$ 为观测的模糊图像,此时式(6)的能量值要小于当 $\hat{\mathbf{k}}$ 取真实模糊核时的能量值.为了克服这种缺点,现有方法中主要分为两种途径:一种是提升图像先验的稀疏性,典型的是选取 L0 范数作为图像的稀疏性先验^[11-12],但由于这是一个 NP-hard 问题,问题求解困难成为了该途径的主要难点;另一种途径则是显式或隐式地提取图像的强边缘^[7-10],本文引入的加权 L1 范数^[17]作为一种稀疏性先验,通过动态地控制当前图像不同成份的权重,以达到提取图像强边缘的目的.在式(6)中引入权重 \mathbf{w} ,得到基于加权 L1 范数的模糊核盲估计模型如下:

$$(\nabla \hat{\mathbf{x}}, \hat{\mathbf{k}}) = \underset{\nabla \mathbf{x}, \mathbf{k}}{\operatorname{argmin}} \|\nabla \mathbf{x} \otimes \mathbf{k} - \nabla \mathbf{y}\|_2^2 + \lambda \|\mathbf{w} \cdot \nabla \mathbf{x}\|_1 + \eta \|\mathbf{k}\|_2^2 \quad (7)$$

从上式可以看出,为了提取图像的强边缘,要求边缘部分的权重尽可能小,而平坦区域部分的权重尽可能的大.再者,从本质上来说,加权 L1 范数可以作为 L0 范数的一种逼近,因此同样具有提升稀疏性的作用.

在实际的盲复原问题中,由于是在图像的梯度域进行处理,因此,关键步骤是如何找到合适的权重,能够反映梯度图像自身特征并增强其稀疏性.文献[17]给出了一种简单的权重计算方式,即在交替迭代求解的过程中,依据上次的估计结果获得 $\mathbf{w}_q^{(n)} = 1/(|(\nabla \mathbf{x}^{(n-1)})_q| + \varepsilon)$.但是这种权重计算方式容易受到噪声以及异常点的影响,鲁棒性较差.因此,进一步地,本文将给出权重优化估计模型,提高权重估计的准确性.

3.2 权重的优化估计

在对加权 L1 问题进行求解的过程中,每一次迭代时权重的计算都与上次估计的梯度图像有关.由于噪声的影响,会使得估计的权重图同样出现噪声,本文采用了一种边缘保持的图像平滑算法^[18]对其进行优化,令 $\mathbf{w}' = \mathbf{w}^{(n)}$ 即

$$\min_{\mathbf{w}} \|\mathbf{w} - \mathbf{w}'\|_2^2 + \kappa \|\nabla \mathbf{w}\|_0 \quad (8)$$

这里,第一项是数据保真项,第二项为正则项,通过约束权重图梯度的 L0 范数最小,从而达到保留优化权重图中的边缘部分,对图像进行平滑处理的目的.

同时,由于在盲复原问题中,图像中的纹理部分对模糊核估计的影响很大,因此在计算权重 \mathbf{w}' 时,要使得纹理区域的权重尽可能的大.文献[10]给出了一种提取纹理的指标,可以区别纹理部分和强边缘部分,该指标为

$$\mathbf{r} = \left\| \sum_{q \in N_h(p)} (\nabla \mathbf{x})_q \right\| / \left(\sum_{q \in N_h(p)} \|(\nabla \mathbf{x})_q\| + 0.5 \right) \quad (9)$$

式中, $N_h(p)$ 表示以 p 为中心点半径为 h 的邻域.从式中可以看出,平坦区域与纹理部分的 \mathbf{r} 值小,而强边缘部分的 \mathbf{r} 值则大.根据该指标,给出权重的计算形式为

$$\mathbf{w}' = 1/(\mathbf{r} + \varepsilon) \quad (10)$$

如图 1(a) 和图 1(b) 所示,分别给出原图的权重映射图以及权重优化估计后的映射图.由于在计算权重时,首先要计算的图像梯度受噪声影响明显,使得权重计算误差较大,进而影响后续的模糊核估计.而图 1(b) 显示了优化后的权重映射图,可以看出部分消除了噪声的影响,说明了优化估计的有效性.相比较文献[17]的权重估计,提出的优化权重估计,不但可以有效减缓噪声的影响,同时由于考虑了图像的结构性,使得在计算权重时避免了纹理部分对模糊核估计的不利影响.




图1 权重映射图及残差图

3.3 优化重加权 L1 范数的模糊核盲估计模型与算法

结合加权 L1 范数的模糊核盲估计模型式(7),权重优化式(8)以及权重计算式(10),给出迭代的模糊核盲估计优化模型如下

$$\begin{cases} \mathbf{w}' = \frac{1}{\mathbf{r}(\nabla \mathbf{x}^{(n-1)}) + \varepsilon} \\ \mathbf{w}^{(n)} = \underset{\mathbf{w}}{\operatorname{argmin}} \|\mathbf{w} - \mathbf{w}'\|_2^2 + \kappa \|\nabla \mathbf{w}\|_0 \\ (\nabla \mathbf{x}^{(n)}, \mathbf{k}^{(n)}) = \underset{\nabla \mathbf{x}, \mathbf{k}}{\operatorname{argmin}} \|\nabla \mathbf{x} \otimes \mathbf{k} - \nabla \mathbf{y}\|_2^2 \\ \quad + \lambda \|\mathbf{w}^{(n)} \cdot \nabla \mathbf{x}\|_1 + \eta \|\mathbf{k}\|_2^2 \end{cases} \quad (11)$$

式中, $\mathbf{r}(\nabla \mathbf{x}^{(n-1)})$ 表示指标 \mathbf{r} 值的计算与上一次迭代的梯度图像有关,而参数 $\varepsilon > 0$ 则是为了防止出现权重计算时分母为零的情况,从而保证了权重计算的鲁棒性.

显然地,可以分别对上述优化问题的两个子问题交替求解,子问题

$$\mathbf{w}^{(n)} = \arg \min_{\mathbf{w}} \|\mathbf{w} - \mathbf{w}'\|_2^2 + \kappa \|\nabla \mathbf{w}\|_0 \quad (12)$$

可以引入辅助变量,利用半二次分裂法进行求解^[19],详细过程不再赘述.

而子问题

$$(\nabla \mathbf{x}^{(n)}, \mathbf{k}^{(n)}) = \arg \min_{\nabla \mathbf{x}, \mathbf{k}} \|\nabla \mathbf{x} \otimes \mathbf{k} - \nabla \mathbf{y}\|_2^2 + \lambda \|\mathbf{w}^{(n)} \cdot \nabla \mathbf{x}\|_1 + \eta \|\mathbf{k}\|_2^2 \quad (13)$$

是包含两个未知变量的凸优化问题.进一步地,可分别固定其中某个变量,对另一个变量进行求解,得到如下两个子问题

$$\begin{cases} \nabla \mathbf{x}^{(n)} = \arg \min_{\nabla \mathbf{x}} \|\nabla \mathbf{x} \otimes \mathbf{k}^{(n-1)} - \nabla \mathbf{y}\|_2^2 + \lambda \|\mathbf{w}^{(n)} \cdot \nabla \mathbf{x}\|_1 \\ \mathbf{k}^{(n)} = \arg \min_{\mathbf{k}} \|\nabla \mathbf{x}^{(n-1)} \otimes \mathbf{k} - \nabla \mathbf{y}\|_2^2 + \eta \|\mathbf{k}\|_2^2 \end{cases} \quad (14)$$

其中子问题:

$$\nabla \mathbf{x}^{(n)} = \arg \min_{\nabla \mathbf{x}} \|\nabla \mathbf{x} \otimes \mathbf{k}^{(n-1)} - \nabla \mathbf{y}\|_2^2 + \lambda \|\mathbf{w}^{(n)} \cdot \nabla \mathbf{x}\|_1 \quad (15)$$

是一个典型加权 L1 正则化问题,考虑使用迭代收缩阈值算法 (Iterative Shrinkage-Thresholding Algorithm, ISTA)^[20]进行求解,具体解的格式为

$$\mathbf{x}_i^{(n)} = \text{soft}(v_i^{(n)}, \alpha_i^{(n)}) \quad (16)$$

其中 $\text{soft}(z, u) = \max(|z| - u, 0) \text{sgn}(z)$. 具体地,

$$\begin{cases} v^{(n)} = \nabla \mathbf{x}^{(n-1)} - \delta \cdot \mathbf{k}^T \otimes (\mathbf{k} \otimes \nabla \mathbf{x}^{(n-1)} - \nabla \mathbf{y}) \\ \alpha^{(n)} = \lambda \delta \mathbf{w}^{(n)} \end{cases} \quad (17)$$

式(16)中的 $v_i^{(n)}$ 和 $\alpha_i^{(n)}$ 分别为向量 $\mathbf{v}^{(n)}$ 和 $\alpha^{(n)}$ 的分量.

子问题

$$\mathbf{k}^{(n)} = \arg \min_{\mathbf{k}} \|\nabla \mathbf{x}^{(n-1)} \otimes \mathbf{k} - \nabla \mathbf{y}\|_2^2 + \eta \|\mathbf{k}\|_2^2 \quad (18)$$

是一个关于 \mathbf{k} 二次能量泛函,因此存在闭合解,这里采用快速傅立叶变换进行求解.其解的形式如下

$$\mathbf{k}^{(n)} = F^{-1} \left(\frac{F(\nabla \mathbf{x}^{(n-1)}) \cdot F(\nabla \mathbf{y})}{F(\nabla \mathbf{x}^{(n-1)}) \cdot F(\nabla \mathbf{x}^{(n-1)}) + \eta} \right) \quad (19)$$

式中 $F(\cdot)$ 表示快速傅立叶变换, $F(\cdot)$ 和 $F^{-1}(\cdot)$ 分别为其复共轭和逆变换.

3.4 图像非盲复原算法及其他实现细节

由于图像盲复原算法包含了模糊核的盲估计和图像非盲恢复两个步骤,因此估计出模糊核之后,需要进一步采用非盲复原算法得到最终的清晰图像.本文采用现有的一种基于超拉普拉斯先验的快速图像非盲复原算法^[21]对模糊图像进行复原.

为了避免在估计较大模糊核时算法陷入局部极小值,本文采用了一种多尺度迭代框架^[1]用于模糊核盲估计.具体地将模糊图像降采样为 S 个尺度,记为 $\{\mathbf{y}_1, \dots, \mathbf{y}_S\}$. 在每一个尺度 $s \in \{1, \dots, S-1\}$ 下估计出当前尺度的模糊核 \mathbf{k}_s ,对其上采样后作为下一个更精细尺度模糊核估计的初始值 $\mathbf{k}_{s+1}^{(0)}$,而当前尺度估计的梯度图像

$\nabla \mathbf{x}_s$ 同样通过上采样后作为下一个更精细尺度梯度图像的初始值 $\nabla \mathbf{x}_{s+1}^{(0)}$. 特别的,在最粗的尺度 $s=1$ 时,取 delta 函数为模糊核 $\mathbf{k}_1^{(0)}$ 的初始值,而梯度图像的初始值则设定为 $\nabla \mathbf{x}_1^{(0)} = \nabla \mathbf{y}_1$.

因此,本文的优化重加权 L1 范数的图像盲复原算法具体步骤如下:

步骤 1 初始化参数 λ, η, κ 和 ε , 模糊核初始值 $\mathbf{k}_1^{(0)}$, 梯度图像初始值 $\nabla \mathbf{x}_1^{(0)}$, 模糊核支撑集大小 $N \times N$, 尺度数 S 以及单尺度内最大迭代次数 N_{\max} .

步骤 2 在当前尺度 s 下,输入模糊核初值 $\mathbf{k}_s^{(0)}$ 以及梯度图像初值 $\nabla \mathbf{x}_s^{(0)}$.

步骤 3 利用式(10)计算权重,再针对子问题式(12)的权重优化,采用半二次分裂算法求解得到权重 $\mathbf{w}_s^{(n)}$.

步骤 4 针对子问题式(15)的梯度图像更新,采用 ISTA 算法求解得到当前梯度图像 $\nabla \mathbf{x}_s^{(n)}$.

步骤 5 针对子问题式(18)的模糊核更新,在傅立叶变换域进行求解得到模糊核 $\mathbf{k}_s^{(n)}$.

步骤 6 单尺度内迭代终止条件. 即,如果 $n \geq N_{\max}$, 令 $\nabla \mathbf{x}_s = \nabla \mathbf{x}_s^{(n)}, \mathbf{k}_s = \mathbf{k}_s^{(n)}$, 此时单尺度内迭代终止; 否则,令 $n = n + 1$, 并转至步骤 3.

步骤 7 多尺度迭代终止条件. 即,如果 $s \geq S$, 令 $\mathbf{k} = \mathbf{k}_s$, 此时多尺度迭代终止; 否则,令 $s = s + 1$, 并转至步骤 2.

步骤 8 采用上述图像非盲复原算法估计清晰图像 \mathbf{x} .

4 实验结果与分析

4.1 仿真数据实验

采用文献[14]中的数据集测试算法的性能,将本文的方法分别与基于 MAP 估计框架的五种方法进行对比,包括基于 L1/L2 范数的盲去卷积算法^[5],基于超拉普拉斯稀疏性先验的盲去卷积算法^[6],Shan 等人的基于分段函数逼近重尾分布的盲去模糊方法^[9]以及两种显式提取图像边缘的方法^[8,10]. 该测试数据集包含了 32 幅 255×255 模糊图像,分别由 4 幅清晰图像和 8 种模糊核生成. 为了量化地说明各种算法的盲复原效果,本节采用 SSD (Sum of Squared Difference) 错误率^[14]来对各个算法的复原结果进行度量,具体形式如下

$$\text{ratio} = \|\mathbf{x}_{\text{est}} - \mathbf{x}_{\text{sharp}}\|_2^2 / \|\mathbf{x}_{\text{gt}} - \mathbf{x}_{\text{sharp}}\|_2^2 \quad (20)$$

其中, $\mathbf{x}_{\text{sharp}}$ 表示清晰图像, \mathbf{x}_{est} 和 \mathbf{x}_{gt} 则表示分别对估计的模糊核和真实模糊核采用相同的非盲复原算法得到的结果. 需要特别说明的是,为了保证实验的公平性,这里我们针对上述各种方法估计出的模糊核均采用文献[21]的非盲复原方法,并使用与文献[21]相同的默认参数. 关于实验中模糊核盲估计部分的参数选取,设置 $\lambda = 0.01, \eta = 0.002, \kappa = \varepsilon = 0.02, N_{\max} =$

21,而模糊核支撑集大小通常人为给定,从而进一步确定尺度数 S . 其他对比算法的参数均按照原文或原程序中的默认设置.

图 2 给出了各算法 SSD 错误率百分比的折线图. 以图中第三组数据为例,它表示在 32 幅测试图像中,SSD 错误率小于 3 的百分比. 对每一组数据而言,百分比越大的算法表示模糊核的估计越准确,从而复原的效果越好. 在进行对比的几种算法中,通过比较各个算法达到不同精度的百分比可以看出,本文的算法对模糊核的估计最为准确.

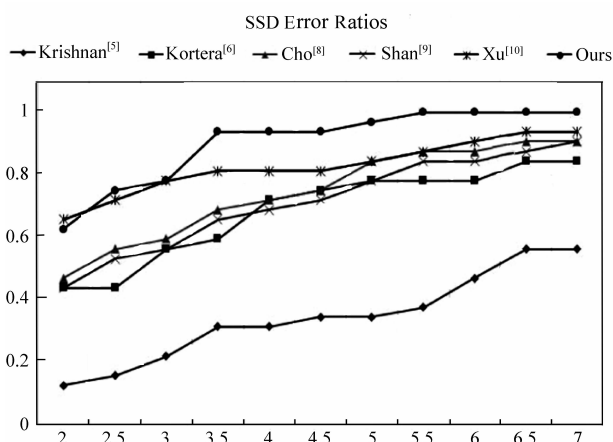


图 2 不同算法在测试数据集^[14]上的比较

4.2 实际数据实验

为了进一步验证本文算法的有效性,本节采用真实模糊图像作为测试数据,并与文献[5,6,8,10]中的方法进行比较. 图 3(a)为一幅大小为 640×480 的模糊图像 Kent,实验中估计的模糊核大小设置为 21×21 ;图 4(a)为一幅模糊更为严重的图像 Roma,其尺寸为 593×417 ,而实验中估计的模糊核大小则设置为 55×55 .

由图 3、图 4 可以看出,本文提出的方法同样可以用于真实模糊图像的盲复原. 相比较其他的对比算法,本文算法估计的模糊核连续性更强,包含的奇异点更少,即直观上更加准确,从而最终复原的图像有更加清晰的细节以及锐化的边缘. 图 3 中除本文算法以外,其他方法估计的模糊核都带有一定程度的拖尾,导致复原图像存在重影现象. 在模糊核较大的情况下,图 4(a)~4(d)都未能成功地估计模糊核,图 4(e)的效果则与本文比较接近,但其估计的模糊核中仍然存在少量的噪声. 由此可以看出,本文方法能够有效利用图像中的强边缘,提高模糊核估计的准确性以及复原质量.

5 结论

在基于 MAP 估计的图像盲复原框架下,本文提出了一种基于优化重加权 L1 范数的图像盲复原算法. 针对如何有效利用图像强边缘进行模糊核的盲估计,设

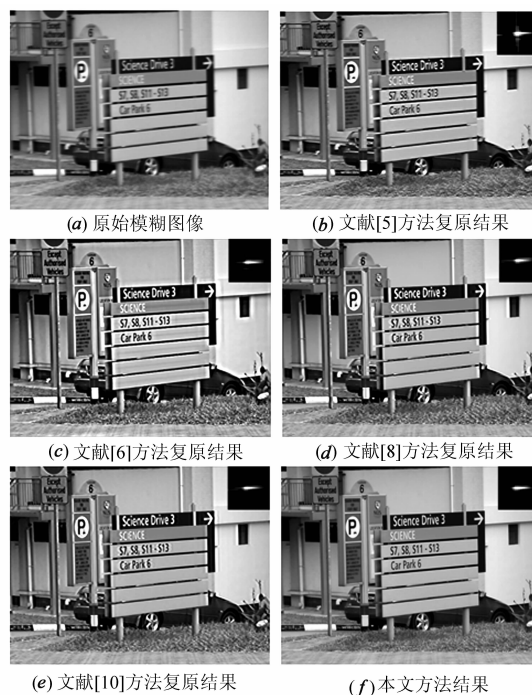


图 3 真实模糊图像 Kent 复原结果和对应的模糊核




图 4 真实模糊图像 Roma 复原结果和对应的模糊核

计了一种基于加权 L1 范数的模糊核盲估计模型,同时为了消除计算权重时因噪声造成的不利影响,提出了一种权重的优化估计方法,并给出了最终的优化模型及相应的数值求解算法. 在仿真实验中,本文提出的算法与其他算法相比,明显提高了性能. 进一步地,在实际数据实验中,本文方法不但估计的模糊核更加准确,在主观视觉效果上也有了明显的改善.

参考文献

- [1] Fergus R, Singh B, Hertzmann A, Roweis S T, Freeman W T. Removing camera shake from a single photograph [J]. ACM Trans on Graphics, 2006, 25(3): 787 - 794.
- [2] Chan T F, Wong C K. Total variation blind deconvolution [J]. IEEE Transactions on Image Processing, 1998, 7(3): 370 - 375.
- [3] Yitzhaky Y, Mor I, Lantzman A, Kopeika N S. Direct method for restoration of motion-blurred images [J]. Journal of Opt Soc Am A, 1998, 15(6): 1512 - 1519.
- [4] Almeida M, Almeida L. Blind and semi-blind deblurring of natural images [J]. IEEE Transactions on Image Processing, 2010, 19(1): 36 - 52.
- [5] Krishnan D, et al. Blind deconvolution using a normalized sparsity measure [A]. Proceedings of International Conference on Computer Vision and Pattern Recognition [C]. Colorado Springs, CO, USA: IEEE, 2011. 233 - 240.
- [6] Kotera J, Sroubek F, Milanfar P. Blind deconvolution using alternating maximum a posteriori estimation with heavy-tailed priors [A]. Proceedings of International Conference on Computer Analysis of Image and Patterns, Part II [C]. Berlin, Germany: Springer, 2013. 59 - 66.
- [7] Krishnan D, Bruna J, Fergus R. Blind deconvolution with non-local sparsity reweighting [OL]. <http://arxiv.org/abs/1311.4029>, 2013.
- [8] Cho S, Lee S. Fast motion deblurring [A]. Proceedings of ACM SIGGRAPH Asia [C]. Yokobama, Japan: ACM, 2009. 145:1 - 145:8.
- [9] Shan Q, Jia J, Agarwala A. High-quality motion deblurring from a single image [J]. ACM Trans on Graphics, 2008. 27(3): 15 - 19.
- [10] Xu L, Jia J. Two-phase kernel estimation for robust motion deblurring [A]. Proceedings of European Conference on Computer Vision, Part I [C]. Berlin: Springer, 2010. 157 - 170.
- [11] Xu L, Zheng S, Jia J. Unnatural L0 sparse representation for natural image deblurring [A]. International Conference of Computer Vision and Pattern Recognition [C]. Portland, OR, USA: IEEE, 2013. 1107 - 1114.
- [12] Pan J, Su Z. Fast L0-regularized kernel estimation for robust motion deblurring [J]. IEEE Signal Processing Letters, 2013, 20(9): 841 - 844.
- [13] 张航, 罗大庸. 一种改进的全变差盲图像复原方法 [J]. 电子学报, 2005, 33(7): 1288 - 1290.
Zhang Hang, Luo Da-yong. A modified method for total variation blind image restoration [J]. Acta Electronica Sinica, 2005(7): 1288 - 1290. (in Chinese)
- [14] Levin A, Weiss Y, et al. Understanding and evaluating blind deconvolution algorithms [A]. International Conference of Computer Vision and Pattern Recognition [C]. Miami, FL, USA: IEEE, 2009. 1964 - 1971.
- [15] Levin A, Weiss Y, Durand F, Freeman W T. Efficient marginal likelihood optimization in blind deconvolution [A]. International Conference of Computer Vision and Pattern Recognition [C]. Colorado Springs, CO, USA: IEEE, 2011. 2657 - 2664.
- [16] Babacan S D, Molina R, Do M N, Katsaggelos. Bayesian blind deconvolution with general sparse image priors [A]. European Conference on Computer Vision, Part VI [C]. Berlin: Springer, 2012. 341 - 355.
- [17] Candes E J, Wakin M B, Boyd S P. Enhancing sparsity by re-weighted L1 minimization [J]. Journal of Fourier Analysis and Applications, 2008, 14(5 - 6): 877 - 905.
- [18] Xu L, Lu C, Xu Y, Jia J. Image smoothing via L0 gradient minimization [J]. ACM Trans on Graphics, 2011. 30(6): 61 - 64.
- [19] Wang Y, Yang J, et al. A new alternating minimization algorithm for total variation image reconstruction [J]. SIAM J Imaging Sciences, 2008, 1(3): 248 - 272.
- [20] Beck A, Teboulle M. A fast iterative shrinkage-thresholding algorithm For linear inverse problems [J]. SIAM Journal on Imaging Sciences, 2009, 2(1): 183 - 202.
- [21] Krishnan D, Fergus R. Fast image deconvolution using hyper-Laplacian priors [A]. Advances in Neural Information Processing Systems [C]. Vancouver B C, Canada: NIPS, 2009, 1033 - 1041.

作者简介



王 凯 (通信作者) 男, 1988 年出生于江苏扬州, 南京理工大学计算机系博士生, 研究方向为图像盲去模糊、图像建模理论。
E-mail: mfranciswong@163.com

肖 亮 男, 1976 年出生于湖南长沙, 南京理工大学计算机系教授, 博士生导师, 主要研究领域为图像处理反问题, 稀疏表示与压缩感知, 计算机视觉。

E-mail: xiaoliang@mail.njust.edu.cn

韦志辉 男, 1963 年生于江苏淮安, 南京理工大学计算机系教授, 博士生导师, 研究方向为基于变分偏微分方程理论及图像处理应用、基于视觉感知的稀疏编码理论及应用。

E-mail: gswei@mail.njust.edu.cn

黄丽丽 女, 1977 年出生于广西德保, 博士, 副教授, 主要研究领域为图像建模与算法。

E-mail: huang-lili@163.com