

一种空间自适应正则化图象盲复原算法

薛梅 邹采荣 杨娟 杨绿溪

(东南大学无线电工程系信号与信息处理实验室, 南京 210096)

摘要 图象盲复原所面临的主要问题是可利用信息的不足, 所以必须充分利用图象本身及成像系统的先验信息. 为此, 结合模糊先验辨识的思想, 给出了一种新的空间自适应正则化算法, 该算法先用交替最小化的迭代方法对模糊进行先验辨识, 然后利用辨识结果, 用各向异性扩散进行图象复原. 算法充分利用了图象及成像系统(或点扩散函数 PSF)的分段平滑特性, 同时又利用各向异性扩散的概念, 使得正则化不仅在程度上, 而且在方向上都是空间自适应的, 从而能够有效地进行图象盲复原. 仿真结果表明, 该算法的复原效果优于空间自适应各向同性正则化(SAR)算法, 其收敛性能优于空间自适应各向异性正则化(SAAR)算法.

关键词 图象盲复原 模糊先验辨识 各向异性扩散

中图法分类号: TN911.73 文献标识码: A 文章编号: 1006-8961(2002)04-0356-07

A Space-Adaptive Regularization Approach for Blind Image Restoration

XUE Mei, ZOU Cai-rong, YANG Juan, YANG Lu-xi

(DSP Laboratory of Radio Engineering Department, Southeast University, Nanjing 210096)

Abstract A new space-adaptive regularization method for blind image restoration, which combines the idea of priori blur identification is presented. This new technique first identifies the point spread function(PSF) by using alternating minimization iterative algorithm. Then it restores the image based on the identified PSF using anisotropic regularization. The main difficulty in blind image restoration is insufficient information, which demands full utilization of priori knowledge of image itself and imaging system. This algorithm utilizes the piecewise smoothness of both the image and the PSF, and it simultaneously makes use of the concept of anisotropic diffusion, which carries out space-adaptive regularization according to the orientations of the image and the PSF. This new method's efficiency is demonstrated by numerically blurred images. It can get better restoration images than space-adaptive regularization (SAR) method, and converge faster than space-adaptive anisotropic regularization(SAAR) method.

Keywords Blind image restoration, Priori blur identification, Anisotropic diffusion

0 引言

图象生成和传输过程中, 各种不利因素, 均可引起图象质量退化, 如物体与相机之间的相对运动、散焦以及大气湍流等, 都可能使所得到的图象模糊, 同时噪声对图象质量也产生严重影响, 而这些都是难以避免的, 噪声主要是由测量误差、记录介质、传输介质

以及数字图象生成过程中的数字化引起的. 类似的退化过程在应用科学及工程等许多领域都能见到, 如可视化通信、智能控制、医学诊断、遥感、天文等.

上述退化过程的线性模型可描述如下:

$$g(x, y) = \int_D h(x, y; s, t) f(x - s, y - t) dsdt + n(x, y) \quad (x, y) \in \Omega \quad (1)$$

其中, $f(x, y)$ 表示原始图象, $g(x, y)$ 为观察到的退

化图象, $h(x, y; s, t)$ 为点扩散函数 PSF, s, t 为滤波器 h 的空间坐标, $n(x, y)$ 为加性噪声, Ω 为图象的支持域, D 为 PSF 的支持域。

图象复原的主要任务就是从观察到的退化图象中尽可能地恢复出原始图象的本来面目, 即在有噪声的情况下对退化图象去模糊。现有的许多复原方法都是在确切知道模糊算子的情况下进行的, 基本运算就是一个简单的反卷积过程, 但由于加性噪声的存在, 这一过程通常是病态的, 可通过引入正则化项来克服病态性。然而, 更常见的情况是模糊过程未知或不确知, 对这样的图象进行复原即盲复原, 才更有现实意义。盲复原存在的主要问题就是可利用信息太少。对式(1)进行数字化后, 观测图象 $g(x, y)$ 仅能提供与未知图象 $f(x, y)$ 相同数目的数据, 还有更多的数据需要估计。由于 $h(x, y; s, t)$ 对不同的象素 (x, y) 具有不同的值, 所以 $h(x, y; s, t)$ 包含比图象本身更多的未知信息, 但这样的复原几乎不可能实现, 为简化问题, 在盲复原中, 通常假定模糊系统移位不变, 即

$$h(x, y; s, t) = h(s, t) \quad (x, y) \in \Omega \quad (2)$$

即便如此, $h(s, t)$ 中的元素仍然是未知的, 需要进行估计。

早期的一些图象盲复原方法, 或者对噪声敏感, 或者需要对图象或成像系统施加很多特定的约束, 甚至还有因为计算量太大而无法实现。之所以如此, 一个重要的原因还是: 已知信息太少, 结果可能有很多解, 甚至无穷多解, 因此算法极易陷入局部极小。很明显, 非负性及支持域的限制将有利于减少解的个数, 但仅有这些还是远远不够的。若能找到更多的先验信息, 则可大大降低问题的难度, 提高算法的性能, 为此, 根据图象及成像系统的分段平滑性以及边缘的方向性, 提出了各向异性扩散的图象盲复原方法, 即 SAAR 算法^[1-3]。所谓分段平滑, 就是指除边缘以外的区域是平滑的, 这一要求并不苛刻, 绝大部分图象都满足这一要求; 而且常见的几种模糊, 如运动模糊、散焦模糊等都是分段平滑的。同时, 各向异性扩散使得平滑仅沿着边缘的切线方向进行, 从而很好地保存了边缘, 减弱了振铃效应。但经研究发现, SAAR 算法尽管在理论上比较完美, 但实现起来并不容易, 一是算法收敛速度慢, 二是对参数的选择敏感, 极易陷入局部极小。针对这些问题, 提出了空间自适应正则化图象盲复原算法。

1 算法的原理

通过对 SAAR 算法的深入研究发现, 其收敛速度之所以慢, 主要是由于各向异性扩散实现起来比较费时; 而算法的病态性则是由于各向异性扩散所构筑的代价函数中的正则化项是非二次的, 即代价函数不是凸函数, 存在多个局部极小点。考虑到大部分情况下, 对 PSF 并没必要进行各项异性平滑; 另外, 辨识和复原并非两个不可分割的过程, 于是, 结合模糊先验辨识的思想, 给出了解决问题的思路, 即寻找一种有效的盲辨识方法, 对模糊进行先验辨识; 利用辨识结果, 用各向异性扩散进行图象复原。

1.1 利用正则化方法进行模糊过程的先验盲辨识

由于所要处理的问题是“盲”的, 无法建立其模糊过程的模型, 因此几种传统的模糊先验辨识方法均不可用。而正则化方法是近年来处理“盲”问题的一种比较流行且有效的方法, 结合其在图象盲复原中的应用, 提出了空间自适应正则化的模糊过程辨识方法, 即在

$$\hat{h}(x, y) \geq 0 \quad (x, y) \in D \quad (3)$$

$$\sum_{(x, y) \in D} \hat{h}(x, y) = 1 \quad (4)$$

条件下, 最小化如下代价函数

$$L(\hat{f}, \hat{h}) = \frac{1}{2} \int_{\Omega} w_1(x, y) e^2(x, y) dx dy + \frac{\gamma}{2} \int_D w_3(s, t) \left| \int_{D_a} a(k, l) \hat{h}(s-k, t-l) dk dl \right|^2 ds dt \quad (5)$$

其中, $w_1(x, y)$ 、 $w_3(s, t)$ 为权系数矩阵, $a(k, l)$ 为正则化算子, D_a 为 $a(k, l)$ 的支持域。 $e(\cdot)$ 定义为辨识残差

$$e(x, y) = g(x, y) - \int_D \hat{h}(s, t) f(x-s, y-t) ds dt \quad (6)$$

但上式中, 在盲的情况下, 无法得到 $f(x, y)$, 若只是简单地用 $g(x, y)$ 来近似, 显然无法得到合理的 PSF 估计。为此, 采用自适应的方法, 即辨识过程中, $f(x, y)$ 随 $\hat{h}(x, y)$ 的变化而作相应的变化, 以便 $f(x, y)$ 尽可能与真实图象逼近, 从而辨识结果也更为准确, 即在

$$0 \leq \min \leq \hat{f}(x, y) \leq \max \leq \infty \quad (x, y) \in \Omega \quad (7)$$

及式(3)、式(4)条件下, 最小化如下代价函数

$$L(\hat{f}, \hat{h}) = \frac{1}{2} \int_{\Omega} w_1(x, y) e^2(x, y) dx dy + \frac{\lambda}{2} \int_{\Omega} w_2(s, t) \left| \int_{D_c} c(m, n) \hat{f}(x-m, y-n) ds dt \right|^2 dx dy + \frac{\gamma}{2} \int_D w_3(s, t) \left| \int_{D_a} a(k, l) \hat{h}(s-k, t-l) dk dl \right|^2 ds dt \quad (8)$$

其中, $c(m, n)$ 为正则化算子, 通常为高通滤波器, 可选用拉普拉斯算子. D_c 为 $c(m, n)$ 的支持域. λ, ν 为正则化参数, 用来控制估计图象 $\hat{f}(x, y)$ 与观测图象 $g(x, y)$ 之间的逼近程度, 以及对 $\hat{f}(x, y)$ 、 $\hat{h}(x, y)$ 进行平滑的程度. 约束条件式(4)、式(7)陈述了这样的事实: 图象的灰度值为非负的; 成像系统是一个能量守恒系统. 约束条件式(7)还表明: 图象的灰度值通常限制在一定的范围 $[a, b]$, 这里取 $[0, 255]$.

理论上, 利用此算法可同时进行图象盲复原及系统的盲辨识, 但用拉普拉斯算子实现的正则化, 实际上是一种各向同性平滑操作, 这与图象自身的特性并不相符. 这种各向同性平滑, 必将导致图象边缘模糊, 严重的甚至产生振铃效应, 尤其是对模糊程度较大的图象, 复原结果的振铃效应十分明显, 而大量的仿真结果证明, 上述算法能够在先验信息很少的情况下, 经过简单的几次迭代(一般不超过 10 次), 即可有效地辨识出 PSF. 所以此处只取其辨识结果, 对于图象复原, 则采用下面的办法.

1.2 各向异性扩散图象复原方法

基于上述经验, 考虑到若能给出一种正则化算子, 使其能够对图象边缘进行有方向性的平滑, 即沿边缘方向进行平滑, 抑制与边缘垂直方向的平滑, 则可克服上述问题. 由于梯度算子是一种包含方向信息的正则化算子, 因此可以利用梯度算子进行正则化.

定义代价函数

$$L(\hat{f}, \hat{h}) = \frac{1}{2} \int_{\Omega} e^2(x, y) dx dy + \lambda \int_{\Omega} \kappa |\nabla \hat{f}(x, y)| dx dy \quad (9)$$

$|\nabla \hat{f}(x, y)|$ 表示图象在 (x, y) 点的梯度, κ 是关于梯度的函数. 最小化意味着图象梯度值的减小, 也就是对图象进行平滑. 文献[3]中给出了连续情况下对式(9)的求导过程. 在此导出式(9)第2项的离散形式的导数. 由于处理的是数字图象, 将式(9)第2项写成离散形式:

$$E = \sum_{v(x,y)} \kappa |\nabla \hat{f}(x, y)|$$

其中

$$|\nabla \hat{f}(x, y)| = \sqrt{|\hat{f}(x+1, y) - \hat{f}(x, y)|^2 + |\hat{f}(x, y+1) - \hat{f}(x, y)|^2}$$

所以

$$\frac{\partial E}{\partial \hat{f}(x, y)} = \frac{\partial \kappa |\nabla \hat{f}(x, y)|}{\partial \hat{f}(x, y)} + \frac{\partial \kappa |\nabla \hat{f}(x-1, y)|}{\partial \hat{f}(x, y)} +$$

$$\frac{\partial \kappa |\nabla \hat{f}(x, y-1)|}{\partial \hat{f}(x, y)} = \frac{\kappa' |\nabla \hat{f}(x, y)|}{|\nabla \hat{f}(x, y)|} |\hat{f}(x, y) - \hat{f}(x+1, y)| + |\hat{f}(x, y) - \hat{f}(x, y+1)| + \frac{\kappa' |\nabla \hat{f}(x-1, y)|}{|\nabla \hat{f}(x-1, y)|} |\hat{f}(x, y) - \hat{f}(x-1, y)| + \frac{\kappa' |\nabla \hat{f}(x, y-1)|}{|\nabla \hat{f}(x, y-1)|} |\hat{f}(x, y) - \hat{f}(x, y-1)|$$

定义扩散系数: $d |\nabla f| = \frac{\kappa' |\nabla f|}{|\nabla f|}$, 则

$$\frac{\partial E}{\partial \hat{f}(x, y)} = - |d |\nabla \hat{f}(x, y)| |\hat{f}(x+1, y) - \hat{f}(x, y)| - |d |\nabla \hat{f}(x-1, y)| |\hat{f}(x, y) - \hat{f}(x-1, y)| - |d |\nabla \hat{f}(x, y)| |\hat{f}(x, y+1) - \hat{f}(x, y)| - |d |\nabla \hat{f}(x, y-1)| |\hat{f}(x, y) - \hat{f}(x, y-1)|$$

所以

$$\frac{\partial E}{\partial \hat{f}(x, y)} = - \operatorname{div} |d |\nabla \hat{f}(x, y)| |\nabla \hat{f}(x, y)|$$

将上式改写为

$$\frac{\partial \hat{f}(x, y)}{\partial a} = - \frac{\partial E}{\partial \hat{f}(x, y)} = \operatorname{div} |d |\nabla \hat{f}(x, y)| |\nabla \hat{f}(x, y)| \quad (10)$$

式(10)称为各向异性扩散方程.

2 算法的细节及实现

2.1 各向异性扩散问题

图象复原过程中, 扩散系数的正确选择, 对算法的成功起着至关重要的作用. 文献[3]证明, 式(9)仍可能导致各向同性扩散, 即会在各个方向上进行同等程度的平滑, 如前面所述, 这样的复原仍会使复原图象边缘模糊, 并产生振铃效应. 但若合理地设计函数 $\kappa(\cdot)$, 使得扩散过程仅沿边缘的切线方向进行, 这样, 沿着边缘方向的图象部分将得到平滑, 而与边缘垂直方向的图象部分则得以保存; 即对平滑区进行平滑, 而灰度变化剧烈的区域平滑受到抑制. 函数 $\kappa |\nabla f(x, y)|$ 的 Hessian 矩阵的第 1 特征值为

$$\lambda_1 |\nabla f| = \frac{\kappa' |\nabla f|}{|\nabla f|} = d |\nabla f| \quad (11)$$

其第 2 特征值为

$$\lambda_1 \|\nabla f\| = \kappa^1 \|\nabla f\| \quad (12)$$

则各向异性扩散方程式(10)可分解为

$$\frac{\partial f}{\partial t} = \lambda_1 D_o + \lambda_2 D_g \quad (13)$$

其中

$$\begin{aligned} D_o &= \frac{f_x^2 f_{yy} - 2f_x f_y f_{xy} + f_y^2 f_{xx}}{f_x^2 + f_y^2} \\ D_g &= \frac{f_x^2 f_{xx} + 2f_x f_y f_{xy} + f_y^2 f_{yy}}{f_x^2 + f_y^2} \end{aligned} \quad (14)$$

分别为图象 $f(x, y)$ 沿与局部梯度垂直和平行方向的二阶方向导数. 由于扩散系数 $c(\cdot)$ 总是正的, 所以式(13)的第 1 项表示一种沿与梯度垂直方向的退化前向扩散(即平滑), 这种扩散有助于保护边缘. 式(13)的第 2 项表示一种沿梯度方向的退化扩散, 当 $\lambda_2 \|\nabla f\| > 0$ 时, 为前向扩散, 将会模糊边界或引起振铃效应, 因此在边缘附近区域应禁止这种扩散; 当 $\lambda_2 \|\nabla f\| < 0$ 时, 表示后向扩散, 将会锐化边缘, 但由于这种后向扩散是病态的, 为了尽可能减少图象盲复原问题的病态性, 最佳选择为 $\lambda_2 \|\nabla f\| = \kappa^2 \|\nabla f\| = 0$.

下面给出两种良态的扩散系数

$$c(s) = \begin{cases} \frac{1}{T} & s < T \\ \frac{1}{s} & s \geq T \end{cases} \quad \text{或} \quad c(s) = \begin{cases} \frac{\rho(T+\epsilon)^{p-1}}{T} & s < T \\ \frac{\rho(s+\epsilon)^{p-1}}{s} & s \geq T \end{cases} \quad (15)$$

其中, T 称为扩散系数阈值. T 的选择应考虑如下因素: 在图象梯度小的地方进行均匀扩散, 以有效地消除噪声, 同时又能保护边缘. 第 2 种良态扩散系数中, $\epsilon > 0, 0 < p < 1$, 仿真结果表明, 此种形式的扩散不仅能够有效去除图象噪声, 而且在一定程度上可避免“方块效应”. 需要指出的是, 在算法实现过程中, 改变扩散系数, 可能会使算法的性能有所改善.

2.2 参数的选择问题

算法中一些参数的选择也是一个不可忽视的问题. 若参数选择不合适, 轻则使算法收敛速度变慢, 重则可能导致算法不收敛, 算法无法实现. 本算法中有较多的参数, 如正则化参数、正则化权系数、正则化算子、扩散系数阈值, 内迭代次数等需要考虑.

(1) 正则化参数 λ, γ

关于复原问题中最优正则化参数的估计问题, 曾有文章进行过讨论, 也有的给出了估计方法. 尽管

这些方法也可用于图象复原中, 但都很复杂. 文献 [1] 给出了一种新的比较简单的方法. 该方法基于这样一种思想: 当算法收敛时, 代价函数式(8)对图象估计及 PSF 估计的偏导数为零. 由于盲辨识过程中, 这两个参数仅用来控制对图象及 PSF 的正则化程度, 所以只要知道它们之间的数量级关系即可. 同时考虑算法中的尺度问题, 给出如下关系

$$\frac{\gamma}{\lambda} \approx \sum_{(x,y) \in \Omega} \hat{f}(x,y) \max_{(x,y) \in \Omega} \hat{f}(x,y) \quad (16)$$

至于 λ 与 γ 的实际大小, 则与退化图象的噪声水平及模糊程度有关.

(2) 正则化算子

一般情况下, 图象的正则化算子为高通滤波器, 需要注意的是, 图象正则化算子的支持域太大通常会导致边缘模糊, 并引起振铃效应, 所以应选用较小的支持域. 在盲辨识过程中, 对图象选用 3×3 的拉普拉斯算子. 对于 PSF, 由于模糊算子本身的支持域很小, 所以对应的正则化算子的支持域也应很小. 对应于一维和二维 PSF 的正则化算子可分别取为

$$\text{一维: } \mathbf{A} = \begin{bmatrix} 1 & -1 \\ -1 & 1 \end{bmatrix} \quad \text{或} \quad \mathbf{A} = \begin{bmatrix} 1 \\ -1 \end{bmatrix} \quad (17)$$

$$\text{二维: } \mathbf{A} = \begin{bmatrix} 2 & -1 \\ -1 & 0 \end{bmatrix} \quad (18)$$

(3) 正则化权系数

$$w_1(x, y) = \begin{cases} 1 & \text{可靠数据} \\ 0 & \text{其他} \end{cases} \quad (x, y) \in \Omega \quad (19)$$

由于通常情况下, 都认为当前的数据是可靠的, 所以权系数 w_1 一般为全 1 阵.

$$w_2(x, y) = \frac{1}{1 + \alpha \sigma_{\text{local}}(g)} \quad (x, y) \in \Omega \quad (20)$$

其中, $\sigma_{\text{local}}(g)$ 为观测图象 g 在点 (x, y) 的局部方差, 该方差是针对以 (x, y) 为中心的 $P \times Q$ 窗口内的数据求得的. α 的取值应满足:

$$\alpha \max_{(x,y) \in \Omega} \sigma_{\text{local}}(g) \approx 1000 \quad (21)$$

算法性能对此参数的取值并不敏感.

对于 PSF 的权系数 $w_3(x, y)$, 由于事先并不知道 PSF 的其他特性, 只是将它初始化为单位阵, 而后在迭代过程中, 根据所估计的 PSF 来获得:

$$w_3^n(x, y) = \frac{1}{1 + \alpha_3 \sigma_{\text{local}}^n(h)} \quad (x, y) \in D \quad (22)$$

其中, $\sigma_{\text{local}}^n(\hat{h})$ 表示 PSF 第 n 次迭代的估计值 \hat{h} 的局部方差. α_3 的取值满足

$$\alpha_3 \max_{(x, y) \in D} \sigma_{\text{local}}^n(\hat{h}) \approx 1000 \quad (23)$$

需要说明的是, 在共轭梯度算法中, 权系数 $w_3(x, y)$ 的估计应在迭代的外循环中进行, 以免破坏共轭梯度算法的性能.

(4) 扩散系数阈值

关于图象复原过程中扩散系数阈值 T 的选择, 需考虑以下因素: 退化图象的噪声大小; 图象的细节需保留的程度. 算法对此参数的选取并不敏感, 一般取 0.1 数量级即可.

(5) 内迭代次数的选择

对于一幅 $M \times N$ 的图象, 用共轭梯度法最优化时, 需要迭代 $M \times N$ 步, 才能收敛到 $L(\hat{f}^n, \hat{h}^n | \hat{h}^n)$ 的最小值. 为了简化问题, 通常迭代 m 次后就让算法中止, 此处的 $m \ll M \times N$, 这就是通常所说的部分共轭梯度法. 为保证算法的快速收敛, m 的正确选择至关重要, 通常取一个大于代价函数 $L(\hat{f}^n, \hat{h}^n | \hat{h}^n)$ 对应的 Hessian 矩阵的主特征值数目的整数. 由于线性运动模糊及散焦模糊通常是低通的, 其对应的代价函数的 Hessian 矩阵的主特征值数目也很少, 因此较小的 m 即可满足要求, 本算法中, 取 $m = 10$.

需要指出的是, 在盲辨识过程中, 要分别对 PSF 和图象使代价函数最小化, 若交换两者最小化的顺序, 有时会使得算法收敛所需的迭代次数减少.

2.3 算法的实现过程

算法首先用交替最小化法来实现图象退化系统的盲辨识, 而后用各向异性正则化法复原出图象. 在优化代价函数时, 采用共轭梯度法^[1, 2].

(1) 系统的盲辨识

由于共轭梯度法是通过迭代实现的, 而盲辨识过程中采用的交替最小化算法也是通过迭代实现的, 所以此处采用嵌套形式, 即内循环用来完成共轭梯度算法, 外循环用来实现交替最小化. 迭代终止后, 取 PSF 的辨识结果.

(2) 图象的复原

利用系统盲辨识得到的 PSF, 用各向异性正则化方法对图象进行复原, 过程与上述交替最小化方法几乎相同, 只有两点区别: 第一, 在外循环过程中

不需要再对 PSF 进行估计, 第二, 用各向异性扩散代替各向同性扩散.

上述算法中, 还需进一步说明 PSF 的支持域问题. 由于盲复原算法中不得不对 PSF 进行估计, 因此若对其支持域估计得过小, 将无法正确地辨识 PSF, 甚至可能导致算法失败. 为能正确辨识出 PSF, 需要将其支持域估计得比较大, 但这样会增加计算量, 为此, 提出如下的“修剪”方法: 判断是否某一边的所有点都小于设定的阈值, 若是, 则删去整条边.

另外, 在图象复原过程中, 由于各向异性扩散趋于使图象分布变成一个分段常函数, 因此, 当正则化参数选得比较大时, 会使复原图象中出现“块效应”.

2.4 实验结果及分析

(1) 一维 PSF 情况

从图 1 可以清楚地看出, 与以前比较成功的算法 SAR 相比, 本文算法不仅使得复原出的图象边界更加清晰, 而且也大大消除了振铃效应. 从一些客观的指标也可以看出本文算法的有效性. 图 1(c) 的改善信噪比 $ISNR = 7.2546 \text{ dB}$; 而图 1(d) 的 $ISNR = 9.6064 \text{ dB}$. 从计算量来看, 要得到图 1(c), 仅需迭代 15 次左右; 而要得到图 1(d), 需要迭代 150 次左右, 尽管后者所需迭代次数远远多于前者, 但效果却有很大改善, 并且较之纯粹的 SAR 算法所需的数千次迭代仍未必能够收敛来说, 本算法的有效性是较明显的.

(2) 二维 PSF 情况

从视觉效果及改善信噪比 $ISNR$ 两方面进行比较. 从视觉效果上看(图 2), 与 PSF 为一维情况下相同, 利用本文算法复原出的图象不仅边界更加清晰, 而且比较有效地消除了“振铃”效应. 从 $ISNR$ 来看, 图 2(c) 的 $ISNR = 7.3617 \text{ dB}$, 而图 2(d) 的 $ISNR = 9.2579 \text{ dB}$.

可见, 在 PSF 为二维时, 本文算法仍不失为一种十分有效的盲复原算法. 这就使得本算法的应用面进一步得到拓宽, 因为工程实际中常见的模糊(如散焦模糊等), 通常是二维的, 即便是运动模糊, 常常由于镜头与物体的相对位置, 也决定了这种模糊很少是严格意义上的一维模糊, 再者, 即使是严格的一维模糊, 也完全可以看作是二维情况的特例. 需要说明的是, 该算法收敛所需迭代次数较大, 在二维情况下, 即使在较小的 3×3 模糊时, 仍需 600 到 800 次左右的迭代. 尽管如此, 从上面所示的盲复原效果来看, 这种较大次数的迭代仍是值得的.



(a) 原始图象



(b) 退化图象

1× 10 均匀运动模糊, 加上 PSNR 为 40dB 的高斯白噪声)



(c) SAR 算法的盲复原结果



(d) 本文算法的盲复原结果

图 1 PF 为一维时的图象盲复原结果



(a) 原始图象



(b) 退化图象

(3× 3 均匀运动模糊加上 PSNR 为 40dB 的高斯白噪声)



(c) SAR 算法的盲复原结果



(d) 本文算法的盲复原结果

图 2 PF 为二维时的图象盲复原结果

3 结 论

结合模糊先验辨识的思想,给出了一种新的适用于空间移不变模糊的图象盲复原方法.该方法克服了SAAR算法收敛速度慢,极易陷入局部极小的问题;通过利用各向异性扩散,也克服了SAR盲复原算法中,复原结果有严重振铃效应的问题.大量仿真结果表明,即使在模糊程度较大的情况下,算法仍能取得较为理想的复原结果.但是,噪声对图象盲复原算法有着严重的影响,噪声不仅使得图象质量退化,掩盖图象细节,还可能加剧图象盲复原的病态性,这主要由于噪声的存在会掩盖图象的频域零点,因此若在盲复原之前,能对图象进行一些除噪运算,或将除噪算法结合入盲复原的迭代过程中,必将有助于图象盲复原的实现,这也是下一步的研究重点.

参 考 文 献

- 1 You Y L, Kaveh M. A regularization approach to joint blur identification and image restoration[J]. IEEE Trans. On Image Processing, 1996, 5(3): 416~ 428.
- 2 You Y L, Kaveh M. Blind image restoration by anisotropic regularization[J]. IEEE Trans. On Image Processing, 1999, 8(3): 396~ 407.
- 3 You Y L, Xu W-Y, Tannenbaum A *et al.* Behavioral analysis of anisotropic diffusion in image processing[J]. IEEE Trans. On Image Processing, 1996, 5(11): 1539~ 1552.
- 4 KundurD, Hatzinakos D. Blind image deconvolution[J]. IEEE Signal Processing Magazine, 1996, 13(5): 43~ 64.
- 5 Banham Mark M, Katsaggelos A K. Digital image restoration [J]. IEEE Signal Processing Magazine, 1997, 14(3): 24~ 41.

- 6 Michael K Ng, Robert J. Plemmons, Sanzheng Qian. Regularization of RIF blind image deconvolution[J]. IEEE Trans On Image Processing, 2000, 9(6): 1130~ 1134.
- 7 Kang M G, Katsaggelos A K. Simultaneous multi-channel image restoration and estimation of the regularization parameters[J]. IEEE Trans. On Image Processing, 1997, 6(5): 774~ 778.



薛梅 1976年生,东南大学无线电系硕士研究生.主要研究方向为图象复原、盲复原等图象处理.



邹采荣 1965年生,教授.主要研究方向为人工神经网络、盲信号处理和图象处理.



杨娟 1972年生,2001年获东南大学无线电系硕士学位.主要研究方向为图象复原、盲复原等图象处理.



杨绿溪 1965年生,教授.主要研究方向为人工神经网络、盲信号处理和图象处理.