

基于随机扰动梯度近似的图像复原与重构算法*

刘传才, 傅清祥

(福州大学 计算机科学与技术系, 福建 福州 350002)

E-mail: liucc@fzu.edu.cn

http://www.fzu.edu.cn

摘要: 为了复原缺乏先验知识的降质图像以及探索层析 X 射线图像重构的新途径, 借鉴 Spall 和 Cristion 的随机扰动近似 (SPSA) 方法, 将其扩展到高阶和多元的情形, 进而提出了一种新的随机扰动梯度近似算法. 此算法无须先验知识或后验概率, 具有良好的稳定收敛性. 对比实验表明, 将此算法用于图像的复原和重构可获得良好的效果, 而且性能稳定.

关键词: 图像重构; 层析 X 射线摄影法; L 混合过程; 图像复原; 随机扰动梯度

中图分类号: TP391 **文献标识码:** A

在降质图像的复原中, 常存在两种情况: (1) 缺乏原始图像的先验知识; (2) 不清楚图像上叠加噪声的先验信息或统计特征. 为此, 需建立模型来描述退化过程, 并寻找消除或减弱降质影响的复原方法. 然而, 就叠加了噪声的图像而言, 其图像的复原涉及到噪声的统计特性及噪声与图像信号的相关情况, 这一问题非常复杂. 在实际应用中, 常假定噪声是白噪声, 即它的频谱密度为常数, 而且与图像不相关. 这种假设是理想的, 因为白噪声的概念是一个数学上的抽象, 与实际情况有一定的出入. 另一方面, 不同的复原技术需要不同的有关噪声的先验信息. 此外, 在层析 X 射线的图像重构中, 现有的多数方法以扰动的有限假设和 X 射线所穿透介质的光学特性的先验知识^[1]为基础, 或依据后验概率^[2], 或将噪声数据函数分别投影到它的一致性区域和不一致性区域中去^[3]. 然而, 在实际工作中, 无论是先验知识还是后验概率都不容易确定. 此外, 通常这些算法还需对大的、满的以及病态的 Jacobi 矩阵求逆.

鉴于上述原因, 本文将随机场理论引入到图像的复原和重构中, 并借鉴 Spall 和 Cristion 提出的用于函数最小化的一类随机扰动近似 (simultaneous perturbation stochastic approximation, 简称 SPSA) 方法^[4], 提出了一种随机扰动梯度近似算法 (stochastic perturbation gradient approximation, 简称 SPGA). 在图像的复原和重构中, 此算法能克服上述缺陷.

1 图像的复原与重构

1.1 图像的复原与重构方式

在成像过程中, 由于成像系统的内在因素和(或)外在环境的影响, 原始图像 $f(x, y)$ 经过一个退化算子 $H(x, y)$ 的作用, 与噪声 $n(x, y)$ 叠加形成退化的图像 $g(x, y)$, 其降质退化可用数学模型描述为

$$g(x, y) = H[f(x, y)] + n(x, y). \quad (1)$$

式(1)中的 $H[f(x, y)]$ 可理解为综合所有退化因素的函数. 图像复原即是借助退化图像 $g(x, y)$ 与退化算子 $D(x, y)$ 逆向地寻找原始图像的最佳近似估计. 若将连续函数离散化, 则退化模型可写为 $g = Df + n$. 同样, 对于在

* 收稿日期: 2000-11-18; 修改日期: 2001-03-19

基金项目: 国家重点基础研究发展规划 973 资助项目 (G1998030600); 福建省自然科学基金资助项目 (F00013)

作者简介: 刘传才 (1963 -), 男, 湖南常德人, 博士, 副教授, 主要研究领域为模式识别与智能系统, 网络信息安全; 傅清祥 (1941 -), 男, 福建泉州人, 教授, 主要研究领域为算法与数据结构, 计算几何.

噪声背景下的图像重构,通常可将目标物或它的图像、目标物的投影和噪声用一个形如 $g = Df + n$ 的线性方程 $p = \exists f + \varepsilon$ 来描述^[2].对于后者, p 为测量向量, f 为图像向量, ε 是附加的测量噪声,它是某个概率空间上的一个随机变量.由此可见,无论是图像复原,还是图像重构,都可用同样形式的数学模型来描述.那么不妨将 $g = Df + n$ 和 $p = \exists f + \varepsilon$ 记为

$$L = \Re f + n. \tag{2}$$

以数学角度来看,图像的复原与重构实质上是求 L 的最小值.本文将采用改进的 SPGA 算法求 L 的最小值,并在第 2 节中详细论述此算法.

1.2 图像的后(置)滤波(postfiltering)

在采用 SPGA 算法实施图像的复原和重构时,我们借鉴了 Llacer 等人的研究经验*.当迭代过程超越可行点以致使复原和重构图像品质下降时,就采用后(置)滤波的补救措施.就后(置)滤波器而言,只要能选择合适宽度的高斯核,就能过滤掉噪声.此外,后(置)滤波图像还有良好的视觉效果.事实上,这与 Snyder 等人表述的思想是一致的^[5].

2 SPGA 算法

记 p 维欧基里德空间为 \Re^p , 向量 x 的欧基里德范数为 $|\bar{x}|$, 矩阵 Π 的算子范数记为 $\|\Pi\|$, 即 $\|\Pi\| = \sup_{x \neq 0} |\Pi \bar{x}| / |\bar{x}|, \forall u \in D$, 在 $D \subset \Re^p$ 是开域的情况下,求函数 $L(u)$ 的最小值.对混有噪声的测量值,可用 $L(u) + \varepsilon_n(\omega)$ 的数学形式描述,其中 $\varepsilon_n(\omega)$ 是概率空间 (Ω, F, P) 上的随机变量.对每个 n 和 ω ,假定可通过物理实验获得 $L(u) + \varepsilon_n(\omega)$ 的测量值.如果有必要的话,可重复物理实验.由于测量噪声 $\varepsilon_n(\omega)$ 与 u 无关,因此它是一种与状态无关的噪声.借鉴文献[6]的研究经验,可将这种与状态无关的噪声拓展为与状态有关的噪声.为求 $L(u)$ 的最小值,则需要它的梯度估计器 $G(u)$,即 $G(u) = L_u(u)$.

SPSA 方法^[4]. 令 a_k 是一个固定的正数序列,且 a_k 为时刻 k 的步长.那么,采用 Spall 方法的原始形式,从初始估计 \hat{u}_0 着手,借助式(3)获得参数估计的序列 $\hat{u}_{k+1}(\omega + \omega')$,

$$\hat{u}_{k+1} = \hat{u}_k - a_{k+1} H(k+1, \hat{u}_k), k = 0, 1, \dots \tag{3}$$

式(3)中, $a_k = a / k^\delta, 0 < \delta \leq 1, k = 1, 2, \dots$

高阶方法. 将 SPSA 的思想加以推广,进而导出高阶的梯度近似.依据文献[7],假定 $f(z)$ 为实变量 z 的实值函数,并且 $h > 0$.由 $(S_h f)(z) = f(z+h)$ 定义位移算子 S_h ,而中心差分算子 δ_h 定义为 $(\delta_h f)(z) = f(z+h/2) - f(z-h/2)$.很明显,可将 δ_h 表述为 $\delta_h = (S_h)^{1/2} - (S_h)^{-1/2}$.另一方面, z 附近的 Taylor 级数展开式为

$$f(z+h) = e^{hD} f(z), \tag{4}$$

式(4)的 D 是微分算子.因 $f(z+h) = (S_h f)(z)$,那么 S_h 可写为 $S_h = e^{hD}$.与式(4)结合, δ_h 可写为 $\delta_h = e^{hD/2} - e^{-hD/2} = 2\sinh(hD/2)$.依据这一表达式,可获得 D 的表达式为

$$hD = 2 \sin h^{-1}(\delta_h / 2). \tag{5}$$

用 $P_{2m}(\delta_h)$ 表示式(5)右边的第 $2m$ 阶形式的 Taylor 级数展开式.通常,对一个有 $2m+1$ 阶连续导数的函数 f ,存在表达式 $hf'(z) = P_{2m}(\delta_h) + h^{2m+1}(-1)^m(m!)^2 f^{(2m+1)}(\xi)/(2m+1)!$,此式最后一项中的 ξ 落在区间 $[z-mh, z+mh]$ 上.由于导数近似有良好的收敛特性,即式(5)右边展开式的系数比其他展开式的系数能更快地衰减为 0,因此导数的近似有助于数值分析.对多变量的函数 $L(u)$,可对其偏导数作近似.对此,固定 $h > 0$,在 v 方向上,通过将算子 δ_h 应用于标量 z 的函数 $f(z) = L(u+zv)$ 的方式,定义中心差分算子 $\delta_{v,h}$.那么,若函数 L 是 $2m+1$ 阶连续可微的,且当 u 只限于稠密域时,则有 $hf'(0) = hv^T (\partial L(u) / \partial u) = P_{2m}(\delta_{v,h})L(u) + O(h^{2m+1})$,其中 $P_{2m}(\delta_{v,h})$ 为函数 $f(z)$ 的 $2m$ 阶形式的 Taylor 展开式.随机取 $v = A_k$,并使 $0 < c_k \leq 1$ 为一个正的固定序列.在 $u \pm (i-1/2)c_k A_k, i = 1, \dots, m$ 上,梯度估计器是

* Llacer, J., Veklerov, E., Nunez, J. The concept of causality (feasibility) in tomographic image reconstruction. In: Proceedings of the NATO Adv. Study Inst., Povoia, Portugal, Sept. 1988.

以测量值为基础的.单个测量值具有 $L(u \pm (i-1/2)c_k A_k) + \varepsilon_k^{\pm(i-1/2)}$ 的形式(式中的 $\varepsilon_k^{\pm(i-1/2)}$ 是测量误差).注意到,对于 $m=1$,量读测量值的位置处于 u 和标准的SPSA量读位置的中间.对于 $i=1, \dots, m$,假定 $u \pm (i-1/2)c_k \in D_0$.令 $M(u)$ 为在 u 位置上量读的测量值,即 $M(u)=L(u)+\varepsilon$.那么在 $u \in D_0$ 位置上,定义梯度估计器为

$$H(k, u) = P_{2m}(\delta_{A_k, c_k})M(u)/(c_k A_k). \tag{6}$$

依据上式确定的梯度估计器,并采用与式(3)相同的重新设定规则,就像在式(3)中那样替换 $H(k,u)$ 来定义估计器序列.更高阶的SPSA的分析方法与上面二阶的SPSA的分析方法类似.

定理. 令 $h=\min(4m\gamma, 1-2\gamma)>0$.假定在 $u=u^*$ 上,函数 L 的 Hessian 矩阵的最小特征值记为 λ ,并且满足 $a\lambda>h/2$.此外,假定存在4个条件:(1) 函数 $L(u)$ 关于 $u \in D$ 是三阶连续可微的.令 $K<\infty$ 为多达三阶导数的算子范数的上界.假定在 D 内, $L(u)$ 的最小值 u^* 是惟一的.(2) 假定测量的噪声过程 $\varepsilon_n(\omega)$ 是关于一对 σ 场 (F_n, F_n^+) 簇^[6]的零平均的 L 混合过程.(3) 对任何 $m \geq 1$ 和 $E_p A_{kl}^{-m} < \infty, A_{ki} = A_{ki}(\omega') = (A_{k1}, A_{k2}, \dots, A_{kp})^T$ 是一个 i.i.d.的、对称分布的有界随机变量的双序列.(4) 假设 $D_0 \subset \text{int } D$ 表示一个稠密的凸域,并且 $u^* \in \text{int } D_0$.此外,半径 $c>0$ 的 D_0 的邻域闭包为 $D(c)$,并且 $D(c)$ 在 D 内.对每个 $\zeta \in D_0$ 及 $1 \leq s \leq t$,定义 $\bar{x}(t, s, \zeta) \in D$,当 $C_0, \lambda>0$ 时,存在不等式 $\|\partial \bar{y}(t, s, \zeta)/\partial \zeta\| \leq C_0 (s/t)^{a\lambda}$ ($\|\cdot\|$ 表示一个矩阵的算子范数).而这4个条件满足:在 D 上,函数 L 是 $2m+1$ 阶连续可微的.此外,在条件(4)中, D_0 的邻域(半径为 $(m+1)c/2$)在 D 内.那么,式(3)定义的估计器序列 \hat{u}_k 与式(6)定义的具有重新设定机制的 H 结合,则有下面的式(7)成立:

$$\hat{u}_k - u^* = O_M(k^{-h/2}). \tag{7}$$

定理的证明见附录.

当 $a\lambda<h/2$,依据上式可导出 $\hat{u}_k - u^* = O_M(k^{-a\lambda})$.最终,对 $a\lambda = h/2, \forall \varepsilon>0$,有 $\hat{u}_k - u^* = O_M(k^{-a\lambda+\varepsilon})$.在 $4m\gamma=1-2\gamma$ 的情形下,求 $h=\min(4m\gamma, 1-2\gamma)$ 的最大值.由此可得 $\gamma=1/(4m+2), h=2m/(2m+1)$.所获得的最好估计为

$$\hat{u}_k - u^* = O_M(k^{-m/(2m+1)}), \tag{8}$$

如果 m 足够大,这个估计能任意接近 $1/2$.

重新设定. 假定初始估计 \hat{u}_0 在 D_0 中,定义一个遵循式(3)的试探性的值 $\hat{u}_{k+1}^+ = \hat{u}_k - a_{k+1}H(k+1, \hat{u}_k)$, 然后进行设置.

$$\hat{u}_{k+1} = \hat{u}_{k+1}^+ \quad \text{when } \hat{u}_{k+1}^+ \in D_0, \tag{9}$$

$$\hat{u}_{k+1} = \hat{u}_0 \quad \text{when } \hat{u}_{k+1}^+ \notin D_0. \tag{10}$$

3 实验与讨论

为验证 SPGA 算法的有效性,我们选择了几个比较典型的例子对图像的复原与重构进行实验.由于不了解噪声的先验信息或统计特征,那么在图像的复原中,分别采用 SPGA 算法和反向滤波器对图像做复原对比实验.在 Hoffman 脑剖视图的重构中,对在不同迭代次数下获得的重构结果作比较.此外,在利用(3)式进行迭代时,取参数 $a=0.5, \delta=1, k=1, 2, \dots$

奔跑中的 Collie 图像.对奔跑中的 Collie 进行拍摄所获得的图像是模糊的,其大小为 256×256 的黑白图像.在 Collie 图像的复原中,迭代 35 次后,反向滤波和 SPGA 算法所获得的结果分别如图 1(b)和图 1(c)所示.



Fig.1 Reconstruction of the degraded Collie image

图 1 Collie 降质图像的复原

航拍的军用机场图像.由于机载的摄像机与机场之间存在着相对运动,并且在大气中或多或少地存在一定的扰动因素,因而拍摄所获得的图像变得模糊,其黑白图像的大小为 512×512 .在迭代 45 次后,反向滤波和 SPGA 算法对其所作的复原获得的结果分别如图 2(b)和图 2(c)所示.



Fig.2 Reconstruction of the military airport aerial photo

图 2 航拍的军用机场图像的复原

模特图像.模特图像为 256×256 的黑白图像.在迭代 35 次后,反向滤波和 SPGA 算法对其所作的复原分别如图 3(b)和图 3(c)所示.



Fig.3 Reconstruction of the model image

图 3 模特图像的复原

上述 3 种情形下的图像复原,从视觉上来说,SPGA 算法比反向滤波获得的图像滤波效果要好,特别在 Photoshop 上可明显地看出来.

此外,在 Hoffman 脑剖视图的重构中,对一个有 3 亿个尖顶脉冲的数据集来说,图 4 展示了 SPGA 算法对其实施重构而获得的效果.实际上,在尖顶脉冲数很大的情形下,SPGA 算法的图像重构效果类似 Shepp-Logan 滤波器获得的效果,即 Shepp-Logan 滤波器在它的最大值附近有频率截断时所获得的一个过滤性后向投影结果.值得一提的是,此时的重构图像表现出较高的清晰度,并且有低的、可接受的噪声轮廓.鉴于重构图像(即图 4)的视觉优点,以及考虑到应设法使数据集有 1 百万个尖顶脉冲的要求,因此图 4 可充当一个可能的重构标准,即充当由一个有 1 百万个尖顶脉冲的数据集重构 Hoffman 脑剖视图的标准.此外,热区活动范围与冷区活动范围的比值近似设为 4.5:1.重构实验中所使用的数据取自 UCLA(University of California, Los Angeles) ECAT-III 层析 X 射线摄影机的一个环形存储器^[8].对于有 1 百万个尖顶脉冲的数据集,就一个像素而言,由其他重构方法获得的最大尖顶脉冲数接近 3000.对于实际数据,在重构之前,必须对其施加两类不同的修正(修正的细节可参见文献[9]):




Fig.4

图 4

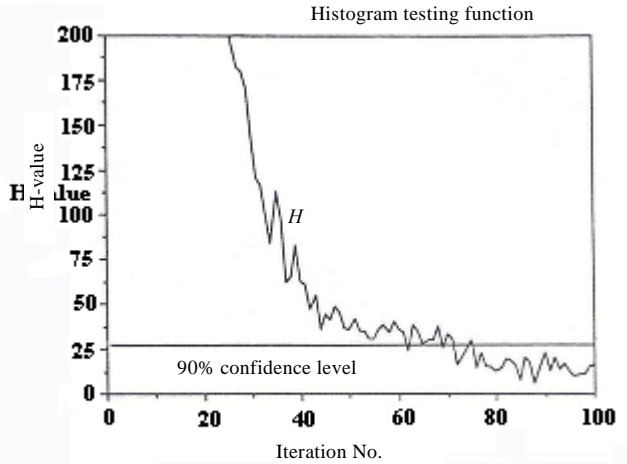
(1) 必须扣除随机重合(random coincidences).对于 Hoffman 脑剖视图的数据集,仅有约 6.5%的随机重合,由这两种修正方法获得的图像相互之间是难以区分的.此外,在测试范围内,SPGA 算法对非 Poisson 的投影数据表现出鲁棒性.

(2) 必须在数据处理中考虑 γ 射线的吸收与探测器增益的修正问题.同时还要考虑沿探测器重合路径的吸收系数与成对探测器的相对增益的积.

在实施图像重构的过程中,有必要确定重构的可行性.在此,我们采用 VL 判别标准^[10]来实现这一功能.文献[11]的研究表明,已知矩阵 \mathcal{R} 的精度差是重构失败的原因.对此, Llacer 和 Veklerov 提出了一个更宽松的判别准则,此准则有一个可调节的参数 λ ,它对应于已知矩阵元素 \mathcal{R}_{ji} 的不确定性.一旦经验性地确定了 λ 之后,在最大似然估计 MLE(maximum likelihood estimate)的迭代过程中,虽然它对迭代步长不敏感,但重构图像肯定会落入可行区域.对于本文的可行性检验,我们取 $\lambda=6.5\%$.

在 Hoffman 脑剖视图的重构中,图 5 是对一个有 1 百万个尖顶脉冲的 Hoffman 脑剖视图数据集,在其重构期间,对应迭代次数的测试函数 H 的值.可以看出,重构图像落入可行区域的可接受阈值为一条直线.

Hoffman 脑剖视图的重构图像的大小为 128×128 .图 6(a)显示了 SPGA 算法在迭代 25 次后的重构结果.图 6(b)是迭代 45 次后的结果,并在此过程中获得了近似的可行性判据.图 6(c)展示了迭代 110 次后具有更高对比度的图像.图 6(d)显示了迭代 300 次后的重构结果.图 6(e)是图 6(d)的后滤波结果,在后滤波中,滤波器的核是高斯的,并且 $\sigma=0.55$.



直方图测试函数, 90%置信度, 迭代次数.

Fig.5

图 5




Fig. 6

图 6

4 结 语

SPGA 算法的图像复原和 Hoffman 脑剖视图的重构结果表明,在停止点上,SPGA 的重构过程与 MLE 和 FMAPE (the fast maximum a posteriori with entropy)类似,但 SPGA 算法无须先验知识或者后验概率,这是它的优点之一.SPGA 的另一个特别吸引人之处是它具有很好的稳定收敛特性.在最小点上,如果代价函数的 Hessian 矩阵的所有本征值都在 $1/2$ 的右面,则误差指数可任意地接近 $1/2$,而且代价函数足够光滑,还可使用导数的高阶近似.实验研究表明,在 SPGA 的收敛点上,图像的视觉效果好,且具有良好的稳定性.此外,通过选择合适的对照参数(如文中把图 4 作为标准),就能确保最后获得的重构图像是可行的.

致谢 本文的研究工作得到了李志博士的帮助,他为本工作提供了 UCLA ECAT-III层析 X 射线的 Hoffman 脑剖视图资料和后(置)滤波器的源程序.在此表示诚挚的感谢!

References:

[1] Hielscher, A.H., Klose, A.D., Hanson, K.M. Gradient-Based iterative image reconstruction scheme for time-resolved optical tomography. IEEE Transactions on Medical Imaging, 1999,18(3):262~271.
 [2] Hanson, K.M. Object detection and amplitude estimation based on maximum a posteriori reconstruction. SPIE, Medical Imaging IV on Image Formation, 1990,MI-1231(4):164~175.
 [3] Pan, Xiao-chuan. Consistency condition and linear reconstruction methods in diffraction tomography. IEEE Transactions on Medical Imaging, 2000,19(1):51~54.
 [4] Spall, J.C., Cristion, J.A. Model-Free control of nonlinear stochastic systems with discrete-time measurements. IEEE Transactions on Automatic Control, 1998,43(9):1198~1210.
 [5] Snyder, D.L., Miller, M.I., Thomas, L.J., et al. Noise and edge artifacts in maximum-likelihood reconstructions for emission tomography. IEEE Transactions on Medical Imaging, 1987,MI-6(3):228~238.
 [6] Gerencsér, L. Convergence rate of moments in stochastic approximation with simultaneous perturbation gradient approximation and resetting. IEEE Transactions on Automatic Control, 1999,44(5):894~905.
 [7] Fox, L. Two-Point Boundary Problems in Ordinary Differential Equations. Oxford: Clarendons, 1957.
 [8] Hoffman, E.J., Ricci, A.R., van der Stee, L.M.A.M., et al. ECAT-III-Basic design considerations. IEEE Transactions on Nuclear Science, 1983,30(1):729~733.
 [9] Nunez, J., Llacer, J. A fast Bayesian reconstruction algorithm for emission tomography with entropy prior converging to feasible images. IEEE Transactions on Medical Imaging, 1990,9(2):159~171.
 [10] Veklerov, E., Llacer, J. Stopping rule for the MLE algorithm based on statistical hypothesis testing. IEEE Transactions on Medical Imaging, 1987,6(4):313~319.
 [11] Llacer, J., Veklerov, E. Feasible images and practical stopping rules in iterative image reconstruction. IEEE Transactions on Medical Imaging, 1989,8(2):186~193.
 [12] Gerencsér, L. On a class of mixing processes. Stochastics, 1989,26(1):165~191.
 [13] Gerencsér, L. Rate of convergence of recursive estimator. SIAM Journal on Control and Optimization, 1992,30(5):1200~1227.

附录

证明:重新考虑 $\delta_s^*(J^\varepsilon)$ 的估计问题:在概率空间 (Ω, F, P) 上,对任意固定的 $\omega, \varepsilon_{1r}(\omega)$, 其有界性意味着过程 $(\varepsilon_{1r}(\omega)A_r^{-1}(\omega'))$ 是一个关于 σ 场 (F_r^-, F_r^+) 的零平均的 L 混合过程,并且在 ω 上均匀^[12],故可将 $\delta_s^*(J^\varepsilon)$ 写为 $\delta_s^*(J^\varepsilon) = \delta_s^*(J^\varepsilon(\omega, \omega'))$. 对于所有的 $m > 1$, 根据上式,则有 $(E_{P_r})^{1/(2m)} |\delta_s^*(J^\varepsilon(\omega, \omega'))|^{2m} \leq C s^{-1/2+\gamma}$, 在该式中, C 与 ω 无关. 在 Ω 上, 关于 (ω, dP) , 对这个不等式求积就可获得如下不等式

$$\delta_s^*(J^\varepsilon) = \delta_{e^\omega}^*(J^\varepsilon) \leq e^{(-1/2+\gamma)\omega} \rho_\omega^*(J^\varepsilon) = O_M(e^{(-1/2+\gamma)\omega}) = O_M(s^{-1/2+\gamma}). \tag{i}$$

关于 $\delta_s^*(J^C)$ 的估计, 采用下式^[6]:

$$\delta H^C(t) = O_M(k^{-1+\gamma}). \tag{ii}$$

由式(ii)可导出不等式 $\delta_s^*(J^C) \leq \sup_{\sigma \leq q \leq \sigma \wedge \tau(\sigma), s \leq \sigma \leq qs} \int_\sigma^1 |(a/r)\delta H^C(r)| dr \leq \int_s^{q^2s} (a/r)Cr^{-1+\gamma} dr \leq C s^{-1+\gamma}$. 如果测量噪声为 0, 那么 $\forall \gamma$, 则有 $\delta_s^*(J^C) = O_M(s^{-1})$. 关于 $\delta_s^*(J^{A1})$ 的估计, 对于固定的 σ 和 u , 过程可用式(iii)来描述^[6]:

$$J^{A1}(r, y(r, \sigma, u)) = -(A_r^{-1}(\omega')A_r^T(\omega') - I)G(y(r, \sigma, u)). \tag{iii}$$

在式(iii)中, $r \geq \sigma$, 前两项是关于 u 的偏导数, 并且它们是在概率空间 (Ω, F, P) 上零平均的 L 混合过程. 由文献[13]的引理 3.1 可得 $\delta_s^*(J^{A1}) = O_M(s^{-1/2})$. 关于 $\delta_s^*(J^{A, 2m+1})$ 的估计, 可由下面的不等式

$$\delta_s^*(J^{A, 2m+1}) \leq \int_s^{q^2s} (a/r)C C_r^{2m} dr \leq \int_s^{q^2s} aC(c^{2m}/r^{1+2m\gamma})dr \leq C_1 s^{-2m\gamma}, C_1 > 0 \tag{iv}$$

导出 $\delta_s^*(J^{A, 2m+1}) = O_M(s^{-2m\gamma})$. 因此 $h = \min(4m\gamma, 1-2\gamma)$, $\delta_s^* = O_M(s^{-h/2})$ 成立. □

An Image Restoration and Reconstruction Algorithm Based on Stochastic Perturbation Gradient Approximation*

LIU Chuan-cai, FU Qing-xiang

(Department of Computer Science and Technology, Fuzhou University, Fuzhou 350002, China)

E-mail: liucc@fzu.edu.cn

http://www.fzu.edu.cn

Abstract: In order to restore degenerative images, which are go short of priori knowledge about original images, and explore new ways of x-ray tomographic image reconstruction, the experience of Spall and Cristion's simultaneous perturbation stochastic approximation (SPSA) method is drawn on, and this algorithm is extended to the high order and multivariate case, then a new gradient approximation algorithm with stochastic perturbation is presented. This algorithm does not need either a priori knowledge or a posteriori probability, and has convergence with excellent stability. Comparative experiments show that this algorithm converges to visually good images with excellent stability for restoration and reconstruction of images.

Key words: image reconstruction; x-ray tomography; L-mixing processe; image restoration; stochastic perturbation gradient

* Received November 18, 2000; accepted March 19, 2001

Supported by the National Grand Fundamental Research 973 Program of China under Grant No.G1998030600; the Natural Science Foundation of Fujian Province of China under Grant No.F00013

全国办公自动化技术及应用学术会议

征文通知

中国计算机学会办公自动化专业委员会拟于 2003 年春在扬州召开办公自动化(OA)技术及应用学术会议,同时召开全体委员会会议。现将有关事项通知如下:

一、征文范围

所有涉及 OA 技术和应用的动向、研究、开发和应用成果的论文,主要包括:(1) OA 现状及技术发展趋势;(2) 网络技术与分布式系统;(3) OA 中的信息安全技术;(4) OA 开发工具和 OA 语言;(5) workflow/数据库、数据仓库和数据挖掘技术;(6) OA 中的多媒体技术;(7) 电子商务/电子政务;(8) 人工智能与决策分析在 OA 中的应用;(9) 其他。

二、来稿要求

1. 理论联系实际,具有学术和应用推广价值。未被其他会议、期刊录用或发表。
2. 来稿一般不得超过 6000 字(含图表),为了便于正式出版论文集,来稿必须附中、英文摘要、关键词及主要参考文献,注明作者姓名、工作单位、详细通讯地址(包括电子邮件地址)与作者简介。
3. 欢迎电子投稿,来稿一般不退,请自留底稿。

三、来稿地址

南京 东南大学计算机科学与工程系 胡苏宁 邮编:210096

电话:(025)3793044 E-mail: yangming@seu.edu.cn

四、重要日期

征文截止日期: 2002 年 10 月 15 日

录用通知发出日期: 2002 年 11 月 20 日