

# 基于广义高斯噪声分布模型的 迭代正则化图像复原

王光新 王正明 段晓君

(国防科技大学数学与系统科学系, 长沙 410073)

**摘要** 讨论了广义高斯分布加性噪声模型, 从对图像的最大似然估计出发, 结合正则化的复原方法, 提出了具有  $l_p$  范数数据逼近项的正则化目标泛函, 同时给出了自适应的正则化参数选择方法。对目标泛函使用迭代的方法求解, 分析了迭代式的收敛性。目标泛函中正则化参数的选择和图像复原的迭代运算同步进行并自动优化。实验结果表明, 对于加有广义高斯分布噪声的并被高斯型点扩展函数模糊的图像, 该方法可明显改善图像复原的效果, 尤其当广义高斯分布的形状参数  $p \leq 1$  时复原效果更好。

**关键词** 图像复原 广义高斯分布模型  $l_p$  范数 正则化

**中图分类号**: TP391.41 **文献标识码**: A **文章编号**: 1006-8961(2004)08-0978-06

## Iterative Regularized Image Restoration Based on a Generalized Gaussian Model for Noise

WANG Guang-xin, WANG Zheng-ming, DUAN Xiao-jun

(Department of Mathematics and System Science, National University of Defense Technology, Changsha 410073)

**Abstract** Based on the assumption of a generalized Gaussian model for the additive noise, this paper develops the regularized image restoration algorithm and proposes an  $l_p$ -norm data item to the regularization objective functional instead of the usual quadratic data item. Meanwhile, the paper applies an adaptive method for choosing the regularization parameter. An iterative algorithm is utilized for obtaining the restored image and the regularization parameter, which can be determined in terms of the partly restored image at each iteration step therefore allowing for the simultaneous determination of the restoration of the degraded image and the value of the regularization parameter. Numerical experiments demonstrate that our method results in high restoration performance when the image was blurred by a Gaussian PSF and an additive generalized Gaussian noise, especially when the shape parameter  $p \leq 1$ .

**Keywords** image restoration, generalized Gaussian model,  $l_p$  norm, regularization

### 1 引言

图像复原是图像处理的重要分支之一, 已经被深入研究并应用到许多领域中<sup>[1, 2]</sup>。图像退化有多种原因, 在成像过程中比较常见的两种退化是: (1) 由光学系统散焦、运动和大气扰动等原因造成的空间退化即图像模糊, 这种退化会引起分辨率的损失; (2) 由成像系统光电因素造成的点退化即噪声, 这种

退化会改变图像像素点的灰度值。针对不同的退化模型, 有不同的复原方法<sup>[2~4]</sup>。图像线性退化模型, 其矩阵形式为<sup>[1]</sup>

$$g = Hf + n \quad (1)$$

其中,  $g, f, n \in R^N$  ( $N$  是图像像素个数) 分别是由二维离散观测退化图像、原始图像和加性噪声按列拉长所得到的列向量。 $H$  是由空间退化的点扩展函数 (PSF) 生成的矩阵, 当点扩展函数是空间不变的而且对原始图像做卷积模糊时,  $H$  就是一个  $N \times N$  的

具有块结构的 Toeplitz 矩阵。

由于空间退化的低通特性,模型式(1)中  $H$  是一个病态矩阵,因而图像复原问题本质上是一个病态问题,甚至可能是一个奇异值问题<sup>[1]</sup>。这种问题的求解,通常使用正则化的方法来确定近似解。关于近似解在逼近真实数据的精确度方面,通常是要求均方误差最小,因而导致常见的二次数据逼近项<sup>[5,6]</sup>。文献[7]考虑使用不同分布的混合噪声,推导出具有二次和四次混合范数数据逼近项。文献[8]假设图像服从 Markov 随机场先验分布,并使用原始图像的最大后验估计作为正则化的数据逼近项。本文考虑使用服从广义高斯分布的噪声模型,提出使用最大似然估计的方法来逼近真实数据,因而导致了含有  $l_p$  范数的数据逼近项的正则化复原方法。

## 2 噪声的广义高斯分布模型

模型式(1)中,最常见的加性噪声为高斯白噪声。对于非高斯型的噪声,文献[9]详细讨论了广义高斯分布噪声模型参数的最大似然估计与检测,文献[4]基于广义高斯分布的噪声模型从图像的最大似然估计来考虑图像复原的问题,并给出了自适应的迭代复原算法。这里噪声模型为广义高斯分布的噪声,其概率密度函数为<sup>[4,9]</sup>

$$y(x; p, m, s) = \frac{p}{2s\Gamma\left(\frac{1}{p}\right)} \exp\left\{-\left(\frac{|x-m|}{s}\right)^p\right\}, p > 0 \quad (2)$$

其中,  $\Gamma(\cdot)$  是标准的 Gamma 函数即  $\Gamma(x) = \int_0^{\infty} t^{x-1} e^{-t} dt$ ,  $p$  是形状参数,  $m$  是均值,  $s$  是标准差。

当  $s = \sqrt{\Gamma(1/p)/\Gamma(3/p)}$  时,分布具有单位方差。广义高斯分布当  $p=1$  时是 Laplace 分布,当  $p=2$  时是高斯分布,当  $0 < p < 1$  时则得到重尾分布,而当  $p \rightarrow \infty$  时则可以近似逼近均匀随机分布。

假设噪声是独立同分布的且服从形状参数为  $p$  的零均值广义高斯分布,此时在分布函数中只有两个参数即形状参数  $p$  和标准差  $s$ ,在文献[4]、[9]中对于这两个参数的估计问题已经有很详尽的讨论。这里假定已经明确知道这两个参数。

考虑模型式(1)中广义高斯分布噪声(形状参数为  $p$ , 标准差为  $s$ )的情况下原始图像的估计问题。从最大似然估计的角度来看,原始图像的最大似然估计为

$$f_{ML} = \arg\{\max_{f,p,s} y_g(g|f;p,s)\} \quad (3)$$

其中,  $g$  的后验分布为<sup>[4]</sup>

$$y_g(g|f;p,s) = \left[ \frac{p}{2s\Gamma\left(\frac{1}{p}\right)} \right]^N \exp\left\{-\sum_{i=1}^N \left(\frac{|n_i|}{s}\right)^p\right\} \quad (4)$$

此处,  $N$  是图像像素个数。当  $p$  和  $s$  是已知参数时,则原始图像的最大似然估计的矩阵形式为

$$f_{ML} = \arg\{\min_f \|g - Hf\|_p^p\} \quad (5)$$

由上式求解得到的  $f_{ML}$  是从最大似然估计的角度来逼近原始图像,上式表明最大似然估计和参数  $s$  无关,只和参数  $p$  有关。 $p=2$  时即为最小二乘估计,和通常使用高斯白噪声所得的结果一致。

## 3 正则化图像复原算法

在模型式(1)中,已知观测图像和 PSF,确定原始图像的问题从数学的角度来说是个求逆的问题,也就是要确定式(1)逆变换的存在性和唯一性。当逆变换存在但不唯一时,图像复原就表现出它的病态性本质。对于此类病态性问题,可以使用正则化方法来确定问题的近似解,此时通常需要对如下表达形式的目标泛函(即平滑泛函)求最小化

$$M(\alpha, f) = \Phi_{\text{data}}(f; g) + \alpha \Phi_{\text{reg}}(f) \quad (6)$$

使上式最小化的向量  $\hat{f}$  即为原始图像的正则化复原图像,上式中数据逼近项  $\Phi_{\text{data}}(f; g)$  衡量了观测数据对真实数据的逼近程度,其具体形式决定于噪声的特点;  $\Phi_{\text{reg}}(f)$  为正则化项,它根据图像的先验信息对解进行约束,其具体形式决定于图像的先验信息;正则化参数  $\alpha$  用于平衡近似解的逼真度和平滑性。

假定加性噪声服从形状参数为  $p$  的广义高斯分布,然后从对原始图像的最大似然估计的角度来定义数据的逼真度,根据上节分析可取  $\Phi_{\text{data}}(f; g) = \|g - Hf\|_p^p$ ,即得到  $l_p$  范数形式的数据逼近项。基于以上认识,正则化目标泛函为

$$M(\alpha(f), f) = \|g - Hf\|_p^p + \alpha(f) \|Cf\|_2^2 \quad (7)$$

其中,  $C$  为正则化算子,用来将有关图像的先验信息引入到复原过程之中,文献[6]详细讨论了正则化算子的选择及其性质,  $C$  的选择通常是基于原始图像的平滑性先验信息,这里  $C$  为由二维拉普拉斯算子<sup>[5~7]</sup>生成的大小与  $H$  相同的块结构 Toeplitz 矩阵。 $\alpha(f)$  是一个以图像为参数的泛函<sup>[5]</sup>,这种取法可以使得正则化参数具有一定的自适应性。如果  $p=2$  即噪声为高斯白噪声时,则正则化目标泛函与常见

的正则化目标泛函的形式相同<sup>[5~7]</sup>。

在正则化图像复原过程中,正则化参数的选择非常重要。文献[10]、[11]中已经总结并提出了许多确定正则化参数的方法,但这些方法都依赖于原始图像和噪声的先验信息。借鉴文献[7]的观点,则不需要知道原始图像的平滑度以及噪声的统计特征等有关的先验信息,而是根据复原过程中部分复原的图像数据来确定  $\alpha(f)$  的值。文献[7]认为正则化参数  $\alpha(f)$  应该是平滑泛函的函数,即

$$\alpha(f) = y(M(\alpha(f), f)) \quad (8)$$

其中,  $y(\cdot)$  是单调递增函数并满足一定的极值性质, 即当  $M(\alpha(f), f) = 0$  时  $\alpha(f) = 0$ , 当  $M(\alpha(f), f) = \infty$  时  $\alpha(f) = \infty$ 。为了使计算简单化,还附加要求平滑泛函  $M(\alpha(f), f)$  关于正则化参数  $\alpha(f)$  是一个凸函数。文献[7]证明了当  $y(\cdot)$  是线性函数时,可以满足以上要求。针对含有  $l_p$  范数的平滑泛函,提出如下形式的正则化参数

$$\alpha(f) = \tau M(f) = \tau (\|g - Hf\|_p^p + \alpha(f) \|Cf\|_2^2) \quad (9)$$

由上式立即可得

$$\alpha(f) = \frac{\|g - Hf\|_p^p}{1/\tau - \|Cf\|_2^2} \quad (10)$$

其中,  $\tau$  为线性函数的斜率常数, 满足  $1/\tau > \|g - Hf\|_p^p + \|Cf\|_2^2$ 。

### 4 迭代解及其收敛性分析

使用迭代的方法,运用最速下降法来求解正则化复原的目标函数的最小化问题。

在讨论问题的解法之前,必须注意到,当广义高斯分布的形状参数  $p \leq 1$  时,目标函数中  $l_p$  范数项是不可微的,而使用最速下降法来求解时必须用到目标函数的导数。为解决此矛盾,考虑对  $l_p$  范数项作如下形式的光滑逼近<sup>[12]</sup>

$$\|x\|_p^p \approx \sum_i ((|x^i|^2 + \epsilon)^{p/2} - \epsilon^{p/2}) \quad (11)$$

此处,  $\epsilon \geq 0$  是一个非常小的稳定性常数,实验中可以取  $\epsilon = 10^{-8}$ ,  $x^i$  表示向量  $x$  的第  $i$  个元素。在做了式(11)的光滑逼近之后,消除了目标函数中由于  $l_p$  范数而引起的不可导的难题,从而可以使用目标函数的近似的导数。

基于上面的分析,利用最速下降法,提出逐次逼近的迭代形式为

$$f^{(k+1)} = f^{(k)} - \frac{\beta}{p} \nabla_f M(f) |_{f^{(k)}}$$

$$= f^{(k)} + \beta \left\{ H^T U(f^{(k)}) (g - Hf^{(k)}) - \frac{2}{p} \alpha(f^{(k)}) C^T C f^{(k)} \right\} \quad (12)$$

其中,  $f^{(k)}$  表示第  $k$  次迭代的结果,松弛参数  $\beta$  用于控制迭代的步长进而控制迭代算法的收敛速度,  $U(f^{(k)})$  是大小和  $H$  相同的对角矩阵,其对角线上的元素

$$U(f^{(k)})_{i,i} = \begin{cases} \frac{1}{(|g_i - (h_i^T f^{(k)})_i|^2 + \epsilon)^{1-p/2}} & p \leq 1 \\ |g_i - (h_i^T f^{(k)})_i|^{p-2} & p > 1 \end{cases} \quad (13)$$

其中,  $g_i$  是向量  $g$  第  $i$  个元素,  $h_i$  是由  $H$  的第  $i$  列所组成的列向量。从上式可以看出,虽然在  $p \leq 1$  和  $p > 1$  时  $U(f^{(k)})$  的元素表达形式不同,但是由于稳定性常数  $\epsilon$  的取值特点,当  $p = 1$  时,式(13)中的两种表达式实际上是近似等价的。

正则化参数也在每步迭代中自行修正,其形式由式(10)可得

$$\alpha(f^{(k)}) = \frac{\|g - Hf^{(k)}\|_p^p}{1/\tau - \|Cf^{(k)}\|_2^2} \quad (14)$$

迭代算法的初始值取为  $f_0 = H^T g$ , 迭代算法的终止准则为

$$\frac{\|f^{(k+1)} - f^{(k)}\|_2^2}{\|f^{(k)}\|_2^2} \leq 10^{-7} \quad (15)$$

在式(14)中近似地取  $1/\tau = \|g\|_p^p + \|g\|_2^2$ 。

如果直接使用上面的迭代式来计算,就必须面对大型的矩阵,例如对于一个  $256 \times 256$  像素的灰度图像,矩阵  $H$  和  $C$  就将是一个大小为  $65\,536 \times 65\,536$  的矩阵,这为计算带来了很大的麻烦。由于  $H$  是块结构的 Toeplitz 矩阵的特殊形式,那么与矩阵  $H$  和  $H^T$  相乘可以分别用二维卷积和相关运算来近似代替<sup>[1,9]</sup>, 对于  $C$  和  $C^T$  也做同样的处理,因而式(12)可以改写为如下形式

$$F^{(k+1)} = F^{(k)} + \beta (\overline{H} \otimes G - \overline{H} * F^{(k)})^{p-1} \cdot \text{sign}(G - \overline{H} * F^{(k)}) - \frac{2}{p} \alpha(F^{(k)}) \overline{C} \otimes \overline{C} * F^{(k)} \quad (16)$$

其中,  $F, G$  分别是对应于  $f, g$  的二维矩阵,  $\overline{H}$  和  $\overline{C}$  分别是构造  $H$  的点扩展函数和构造  $C$  的大小为  $3 \times 3$  的拉普拉斯算子,  $\otimes$  和  $*$  分别表示矩阵的相关和卷积运算,  $\cdot$  表示矩阵按元素对应相乘,  $|A|^{p-1}$  和  $\text{sign}(\cdot)$  分别表示矩阵按元素取绝对值的指数和按元素取符号。这样处理之后,由于减小了问题的规模并使用了卷积代替大尺度矩阵相乘,从而提高了计算速度。

对于函数  $f(x) = x + \beta (H^T U y - H^T U H x - \frac{2}{p} \alpha C^T C x)$ , 考虑如下范数不等式

$$\|f(x_1) - f(x_2)\| = \left\| (x_1 - x_2) \left[ 1 - \beta(H^T U H + \frac{2}{p} \alpha C^T C) \right] \right\| \leq \|x_1 - x_2\| \left\| 1 - \beta(H^T U H + \frac{2}{p} \alpha C^T C) \right\| \quad (17)$$

根据压缩映射原理, 为使式(12)中的算法收敛则要求

$$0 < \left\| 1 - \beta(H^T U H + \frac{2}{p} \alpha C^T C) \right\| < 1 \quad (18)$$

易证  $(H^T U H + \frac{2}{p} \alpha C^T C)$  是正定矩阵(与  $H$  和  $C$  的选取有关)。使用矩阵“2”范数, 并利用矩阵“2”范数与最大奇异值之间的关系, 式(18)可重写为

$$0 < \left| 1 - \beta \sigma_{\max}(H^T U H + \frac{2}{p} \alpha C^T C) \right| < 1 \quad (19)$$

从而得到

$$0 < \beta \sigma_{\max}(H^T U H + \frac{2}{p} \alpha C^T C) < 2 \quad (20)$$

其中,  $\sigma_{\max}(Q)$  表示  $Q$  的最大奇异值。由三角不等式可得

$$0 < \beta(\sigma_{\max}(H^T U H) + \frac{2}{p} \alpha \sigma_{\max}(C^T C)) < 2 \quad (21)$$

因此关于松弛参数有

$$0 < \beta < \frac{2}{\sigma_{\max}(H^T U H) + \frac{2}{p} \alpha \sigma_{\max}(C^T C)} \quad (22)$$

在实际应用中, 由于矩阵奇异值的计算比较困难, 因而在迭代算法中, 对奇异值求解问题作相应的处理。利用  $U$  是对角矩阵这一性质, 考虑对  $H$  和  $C$  作规范化, 使得  $\sigma_{\max}(H^T) = \sigma_{\max}(H) = \sigma_{\max}(C^T C) = 1$ 。因而在规范化处理之后, 由于  $U$  是对角矩阵, 并考虑到正则化参数为迭代的形式, 由式(18)可得松弛参数为

$$0 < \beta < \frac{2}{\max_i |u_i^{(k)}| + \frac{2}{p} \alpha(f^{(k)})} \quad (23)$$

其中,  $u_i^{(k)}$  为第  $k$  次迭代时对角矩阵  $U$  对角线上的元素。上式对松弛参数的选取只是给出了一个范围, 在实际计算中通过试错的方式可逐步修正松弛参数。实验结果表明, 适当的松弛参数不仅可以加快迭代算法的收敛速度, 而且由于对正则化参数也有一定

的调节作用, 因而也在一定程度上提高了复原的效果。松弛参数的快速选取方法尚有待进一步研究。

### 5 实验结果

实验中所用到评估图像复原性能的参数为改进信噪比( $ISNR$ ), 其定义形式为

$$ISNR = 10 \log_{10} \frac{\|g - f\|_2^2}{\|\hat{f} - f\|_2^2} \quad (24)$$

为了便于将本文方法的复原性能与其他方法做比较, 同时给出迭代正则化图像复原算法<sup>[7]</sup>(IRIR)的复原结果。这种方法和本文方法(IRPN)的共同点是: 都用迭代方法求解正则化目标泛函而且用同样的方法确定正则化参数; 不同点是: IRIR 方法基于均方误差最小化, 在目标泛函中使用二次数据逼近项, 本文则针对广义高斯分布噪声使用  $l_p$  范数数据逼近项。实验使用尺寸为  $11 \times 11$ 、标准差为 1 的(其中对图像 B 时使用的标准差为 2)高斯型点扩展函数对原图像进行卷积模糊, 然后分别加入不同形状参数的单位方差的广义分布高斯噪声。实验处理的图像是 0~255 灰度级的图像, 包括图像 A ( $128 \times 128$  分辨率为 1m 的遥感图像), 图像 B ( $256 \times 256$  分辨率为 5m 的遥感图像)和图像 C ( $256 \times 256$  的 cameraman 图像)。对退化图像分别使用上述两种方法进行复原, 将迭代次数限制在 150 次以内, 统计 200 次复原结果得到平均  $ISNR$ , 结果比较如表 1 所示, 其中,  $p$  为广义高斯噪声的形状参数,  $SNR$  为退化图像的信噪比。图 1~图 3 为实验结果。

实验结果表明: 对于被大气扰动而模糊的遥感图像, 本文方法(IRPN)的复原效果比通常的迭代正则化复原算法(IRIR)更好, 当  $p \leq 2$  时效果改进更多; 对于同样信噪比的退化图像, 两种方法的复原效果都会随着广义高斯分布噪声形状参数的改变而改变; 本文方法可以有效地抑制在复原过程中反卷积对附加噪声的放大作用。

表 1 两种方法的  $ISNR$  比较

单位: dB

$p$	图像 A			图像 B			图像 C		
	$SNR$	IRIR	IRPN	$SNR$	IRIR	IRPN	$SNR$	IRIR	IRPN
0.4	15.069 2	6.845 8	8.908	12.302	7.996 3	9.619 8	19.745 6	5.046 6	7.081 6
0.7	15.069 2	6.833 3	8.812 3	12.301	7.987	9.6	19.745 5	5.038 8	7.005 6
1	15.068	6.818 3	8.507 5	12.301 1	7.972 7	9.539 9	19.743 2	5.001 7	6.664 4
2	15.058 1	6.497 9	6.955 5	12.296	7.941 6	9.137 6	19.730 1	4.800 6	5.088 5
4	15.016 1	4.762 3	4.798 1	12.277 5	7.572 6	7.845 8	19.655 8	3.593 6	3.832
8	14.919 6	3.367 3	3.420 2	12.209 9	6.333 6	6.548 9	19.478 1	2.581 4	2.904 5




图1 图像A加入形状参数 $\rho=0.4$ 的广义高斯噪声时的图像复原结果

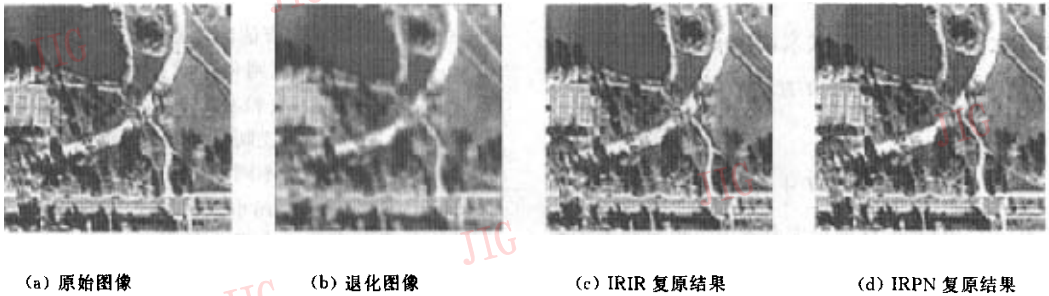


图2 图像B加入形状参数 $\rho=2$ 的广义高斯噪声时的图像复原结果




图3 图像C加入形状参数 $\rho=4$ 的广义高斯噪声时的图像复原结果

## 6 结论

本文基于广义高斯分布噪声模型,从最大似然估计的角度来逼近真实数据,提出了含有 $l_p$ 范数数据逼近项的正则化图像复原方法。

该算法有如下特点:

(1)对于附加有服从广义高斯分布噪声的退化图像,由于正则化图像复原算法在模型上更加符合噪声的分布,因而复原效果比较好;

(2)使用正则化方法,有效地抑制了复原过程中对噪声的放大,对于广义高斯分布的噪声而言,形状参数越小(尤其当 $\rho \leq 1$ )对噪声的抑制效果就越好,这主要是由于形状参数越小则噪声的分布越表现出重尾性,即稀疏性越好,从而降低了对图像的污染

程度;

(3)在迭代算法中使用的松弛参数,提高了算法的收敛速度,同时对正则化参数也有一定的调节作用,因而也在一定程度上提高了复原的效果;

(4)正则化参数确定方法无需知道噪声的大小和图像的先验知识,而是在迭代过程中和复原图像的估计解同时趋于最优;

(5)在迭代算法中使用了卷积近似代替大尺度矩阵相乘,在一定程度上提高了计算速度。

由于图像的小波系数一般服从重尾性分布,本文的迭代复原算法对于小波域复原具方法的研究有一定的参考价值。文中松弛参数的选取只是给出了一个范围,在一定程度上影响了复原效果,因而松弛参数的自适应快速选取方法尚有待进一步研究。

## 参 考 文 献

- 1 Andrews H C, Hunt B R. Digital Image Restoration [M]. Prentice Hall, New York, 1977.
- 2 Banham M R, Katsaggelos A K. Digital image restoration [J]. IEEE Signal Processing Magazine, 1997, 14(3): 24~41.
- 3 Mesarovic V Z, Galatsanos N P, Katsaggelos A K. Regularized constrained total least squares image restoration [J]. IEEE Transactions on Image Processing, 1995, 4(8): 1096~1108.
- 4 Pun W H, Jeffs B D. Adaptive image restoration using a generalized Gaussian model for unknown noise [J]. IEEE Transactions on Image Processing, 1995, 4(10): 1451~1456.
- 5 Kang M G, Katsaggelos A K. General choice of the regularization functional in regularized image restoration [J]. IEEE Transactions on Image Processing, 1995, 4(5): 594~602.
- 6 Katsaggelos A K, Biemond J, Schafer R W, *et al.* A regularized iterative image restoration algorithm [J]. IEEE Transactions on Signal Processing, 1991, 39(4): 914~929.
- 7 Hong M C, Stathaki T, Katsaggelos A K. Iterative regularized least-mean mixed-norm image restoration [J]. Optical Engineering, 2002, 41(10): 2515~2524.
- 8 苏乘华, 金伟其. 基于 Poisson-Markov 场的超分辨率图像复原算法 [J]. 电子学报, 2003, 31(1): 41~44.
- 9 Pham T T, deFigueiredo R J P. Maximum likelihood estimation of a class of non-Gaussian densities with application to  $l_p$  deconvolution [J]. IEEE Transactions on Acoustics, Speech, and Signal Processing, 1989, 37(1): 73~82.
- 10 Van Kempen G M P, Van Vliet L J. The influence of the regularization parameter and the first estimate on the performance of Tikhonov regularized non-linear image restoration algorithms [J]. Journal of Microscopy, 2000, 198(1): 63~75.
- 11 Galatsanos N P, Katsaggelos A K. Methods for choosing the regularization parameter and estimating the noise variance in image restoration and their relation [J]. IEEE Transactions on Image Processing, 1992, 1(3): 322~336.
- 12 Belge M, Misha E K, Eric L M. Wavelet domain image restoration with adaptive edge-preserving regularization [J]. IEEE Transactions on Image Processing, 2000, 9(4): 597~608.

**王光新** 1976年生。2000年获国防科技大学应用数学专业理学学士学位,现为该校系统工程专业博士生。主要研究方向为数据融合、试验系统分析与评估。  
E-mail: wxgali@yahoo.com.cn



**王正明** 1962年生。教授、博士生导师。1986年于华中理工大学获数学专业理学硕士学位,1999年于国防科技大学获控制工程专业工学博士学位。主要研究方向为数据融合、试验系统分析与评估、时间序列分析等方面。



**段晓君** 1976年生。讲师。2000年于国防科技大学获应用数学专业理学硕士学位,2003年于国防科技大学获系统工程专业工学博士学位。现为国防科技大学主要研究方向为试验系统分析与评估、信息融合等。

