

中图法分类号: TP391 文献标志码: A 文章编号: 1006-8961(2011)07-1289-08

论文索引信息: 王相海, 李放, 宋传鸣. 局部自适应混合模型的遥感图像去噪算法 [J]. 中国图象图形学报, 2011, 16(7): 1289-1296

# 局部自适应混合模型的遥感图像去噪算法

王相海<sup>1),3)</sup>, 李放<sup>1)</sup>, 宋传鸣<sup>1),2)</sup>

<sup>1)</sup> (辽宁师范大学计算机与信息技术学院, 大连 116029) <sup>2)</sup> (南京大学计算机科学与技术系, 南京 210093)

<sup>3)</sup> (南京大学计算机软件新技术国家重点实验室, 南京 210093)

**摘要:** 遥感图像的噪声分析和去除作为经典问题一直受到关注并成为遥感图像处理的一个重要研究领域。传统的去噪方法在一定程度上可以去除图像中的噪声,但往往在去噪的同时会使图像的边缘和细节信息模糊化。针对 P-M 模型在去除遥感图像高斯噪声时所存在的对图像强边缘和细节附近的噪声难以去除,以及 ROF 模型通常会导致平坦区域出现“假边缘”,甚至会产生块状效应等问题,提出一种基于局部自适应的混合模型。该模型针对图像局部区域所包含纹理信息的不同,自适应地调整约束权函数,使模型在平滑局部区域能更多地发挥 P-M 模型的特点,而在纹理丰富或边缘区域则更多地发挥 ROF 模型的特性,使模型在有效地去除高斯噪声的同时,很好地保护了遥感图像中的边缘特征和细节纹理信息。实验结果表明,对相同的高斯噪声所提出的混合模型去噪后图像的 SNR 较 P-M 和 ROF 模型分别提高了 3 dB 和 2 dB。

**关键词:** 遥感图像; 局部自适应混合模型; 去噪; P-M 模型; ROF 模型算法

## Remote sensing image de-noising based on local adaptive mixture model

Wang Xianghai<sup>1),3)</sup>, Li Fang<sup>1)</sup>, Song Chuanming<sup>1),2)</sup>

<sup>1)</sup> (College of Computer and Information Technology, Liaoning Normal University, Dalian 116029 China)

<sup>2)</sup> (Department of Computer Science and Technology, Nanjing University, Nanjing 210093 China)

<sup>3)</sup> (State Key Laboratory for Novel Software Technology, Nanjing University, Nanjing 210093 China)

**Abstract:** As a typical issue, the noise analysis and elimination of remote sensing images have attracted considerable attention, and become an important research field for remote sensing image processing. Although traditional de-noising methods can eliminate noises to some extent, the edges and details of image are usually blurred while eliminating noise. In addition, the classical P-M model cannot effectively remove the Gaussian noise near strong edges and details, while ROF model tends to produce fake edges even jaggies in smooth region. This paper proposes a local adaptive mixture model to address the issue. According to texture characteristics of an image's local region, our model can adaptively adjust a weighting function. By this way, our model exploits the advantages of the P-M model in smooth local region, and the advantages of the ROF model in the region with rich textures or edges. This facilitates our model to effectively eliminate Gaussian noise, and at the same time well protect the edge features and details of remote sensing image. Experimental results show that our model gains 3 dB and 2 dB higher SNR than the P-M model and the ROF model do separately.

**Keywords:** remote sensing image; local self-adapting mixture model; de-noise; P-M model; ROF model

## 0 引言

合成孔径雷达(SAR)因其自身的相干特性而使其成像包含一定的噪声<sup>[1]</sup>,这些噪声的存在会影响

遥感图像的解读,极大地降低诸如边缘检测、图像分割和目标分类等应用的效果。遥感图像的噪声主要由电噪声和光学噪声组成<sup>[2]</sup>。前者泛指热噪声、散粒噪声等;而后者则指因结构引起的空间随机不均匀噪声,它主要由周期性噪声和高斯噪声(加性噪

收稿日期:2010-07-12;修回日期:2011-01-21

基金项目:辽宁省自然科学基金项目(20102123);辽宁百千万人才工程项目(2008921036);南京邮电学院图像处理与图像通信江苏省重点实验室开放基金项目(LBEK2010003);江苏省普通高校研究生科研创新计划项目(CX07B-121z)。

第一作者简介:王相海(1965—),男,教授,博士生导师,中国计算机学会高级会员。2001年于南京大学计算机科学与技术博士后流动站出站,主要研究方向为多媒体信息处理、计算机图形学。E-mail:xhwang@lnnu.edu.cn。

声)构成。周期性噪声一般可以由频域变换滤波有效地消除;而对高斯噪声,传统的去噪方法有中值滤波、基于同态滤波,逆滤波等<sup>[3-6]</sup>。这些方法在一定程度上可以达到去除高斯噪声的目的,但具有一个共同的弱点是在去噪的同时,也会使图像的边缘模糊化,以及使图像的细节纹理信息丢失。近年来,偏微分方程(PDE)成为继小波之后的另一新型的图像处理工具,其中基于多尺度分析理论的公理性偏微分方程模型和基于变分模型的 Euler-Lagrange 方程在图像去噪中受到关注<sup>[7]</sup>。前者最为典型的代表是由 Perona 和 Malik 提出的非线性偏微分方程去噪模型(P-M 模型)<sup>[8]</sup>,该模型将图像的去噪与边缘检测统一起来考虑,实现了二者很好的平衡,然而文献<sup>[9]</sup>的研究表明该模型的方程具有“病态”特性,同时对图像中孤立强噪声(如椒盐噪声)和较强边缘噪声平滑不是很有效<sup>[10]</sup>。而基于变分模型最具代表性的模型是文献<sup>[11]</sup>所提出的非线性偏微分方程去噪模型(ROF 模型)。该方法将图像归类为变分有界函数空间,采用一次范数全变分作为其“平滑性”的度量,并沿着梯度垂直的方向进行约束,很好地保护了边缘信息,但是由于它并不完全符合图像处理形态学原则<sup>[12-13]</sup>,迭代多次后通常会产生阶梯效应。

本文首先对传统去噪模型 P-M 和 ROF 进行分析,并针对这两种模型的不足提出了一种新的混合 PDE 模型。该模型针对图像的局部区域所包含的纹理信息不同,自适应地调整约束权函数,使模型在平滑局部区域能更多地发挥 P-M 模型的作用,而在纹理丰富或边缘区域则更多地发挥 ROF 的作用,从而使模型在有效的去除高斯噪声的同时,很好地保护了遥感图像中的边缘特征和细节纹理信息。实验结果表明,与 P-M 模型和 ROF 模型相比,本文所提出的局部自适应混合模型具有更好的去噪效果。

## 1 P-M 模型与 ROF 模型及其分析

### 1.1 P-M 模型

P-M 模型的基本思想是采用非线性的各向异性扩散方程进行去噪,并构造一种与梯度成反比的扩散函数 $f(x) = k^2 / (x^2 + k^2)$ (其中  $k$  为阈值),使其在图像边缘处减慢扩散速度,在平滑处加快扩散速度,进而在去噪的同时,较好地保持边缘细节,是一种较为有效的去噪方法。

设  $u_0$  表示原始图像, $u$  为变化中的图像, $\nabla u$  是图像像素的梯度, $\zeta = \nabla u / |\nabla u|$  为梯度方向上的单位向量, $\eta$  为与  $\zeta$  垂直的切线向量,则有

$$\begin{aligned} \zeta &= \frac{1}{\sqrt{u_x^2 + u_y^2}} \begin{pmatrix} u_x \\ u_y \end{pmatrix} \\ \eta &= \frac{1}{\sqrt{u_x^2 + u_y^2}} \begin{pmatrix} -u_y \\ u_x \end{pmatrix} \end{aligned} \quad (1)$$

进一步地,令  $u_{\zeta\zeta}$  表示  $u$  沿着边缘梯度方向的方向导数, $u_{\eta\eta}$  表示  $u$  沿着边缘切线方向的方向导数,则

$$\begin{cases} u_{\zeta\zeta} = \frac{u_x^2 u_{xx} + 2u_x u_y u_{xy} + u_y^2 u_{yy}}{u_x^2 + u_y^2} \\ u_{\eta\eta} = \frac{u_x^2 u_{yy} - 2u_x u_y u_{xy} + u_y^2 u_{xx}}{u_x^2 + u_y^2} \end{cases} \quad (2)$$

由式(2)可得

$$u_{\eta\eta} + u_{\zeta\zeta} = u_{xx} + u_{yy} \quad (3)$$

下面给出 P-M 的扩散模型<sup>[8]</sup>:

$$\begin{aligned} \frac{\partial u}{\partial t} &= \operatorname{div}[f(|\nabla u|) \nabla u] = \\ &= \frac{\partial}{\partial x}[f(|\nabla u|) u_x] + \frac{\partial}{\partial y}[f(|\nabla u|) u_y] = \\ &= \frac{\partial f(|\nabla u|)}{\partial(|\nabla u|)} \cdot \frac{\partial(|\nabla u|)}{\partial x} u_x + \frac{\partial f(|\nabla u|)}{\partial(|\nabla u|)} \cdot \\ &= \frac{\partial(|\nabla u|)}{\partial y} u_y + f(|\nabla u|) (u_{xx} + u_{yy}) \end{aligned} \quad (4)$$

令  $\frac{\partial f(|\nabla u|)}{\partial(|\nabla u|)} = f'(|\nabla u|)$ , 则

$$\begin{aligned} \frac{\partial u}{\partial t} &= f'(|\nabla u|) [(\sqrt{u_x^2 + u_y^2})_x u_x + (\sqrt{u_x^2 + u_y^2})_y u_y] + \\ &= f(|\nabla u|) (u_{xx} + u_{yy}) = |\nabla u| f'(|\nabla u|) u_{\zeta\zeta} + \\ &= f(|\nabla u|) (u_{xx} + u_{yy}) \end{aligned} \quad (5)$$

由式(3)得

$$\frac{\partial u}{\partial t} = |\nabla u| f'(|\nabla u|) u_{\zeta\zeta} + f(|\nabla u|) (u_{\zeta\zeta} + u_{\eta\eta}) \quad (6)$$

最后将扩散函数  $f(|\nabla u|) = \frac{k^2}{k^2 + |\nabla u|^2}$  代入上式,有

$$\frac{\partial u}{\partial t} = \frac{k^2}{k^2 + |\nabla u|^2} u_{\eta\eta} + \frac{k^2}{k^2 + |\nabla u|^2} \frac{k^2 - |\nabla u|^2}{k^2 + |\nabla u|^2} u_{\zeta\zeta} \quad (7)$$

由式(7)可知,P-M 模型的扩散是沿着边缘的梯度方向和沿着边缘的切线方向同时进行的,因此具有较强的去噪能力<sup>[14]</sup>。另一方面,尽管扩散函数的值是随着梯度值的变大而逐渐变小的,可是在  $u_{\zeta\zeta}$  前仍存在系数。这意味着 P-M 模型在图像去噪过程中,不可避免地也会在梯度方向进行光滑作用,以致于会破坏图像的一些局部特征。

### 1.2 ROF 模型

ROF 模型是另一种经典的去噪方法,其基本思想是含噪声图像的总变分应大于无噪声图像的总变分,据此构造一个能量泛函并将其转化为偏微分方程来求解。设  $I_0$  是原始灰度图像,  $I$  为变化中的灰度图像,  $\nabla I$  是图像像素的梯度,  $\lambda$  为拉格朗日乘子,则能得到一个图像复原的能量泛函公式<sup>[11]</sup>

$$E(I) = \int |\nabla I| \, d\Omega + \lambda \int [I - I_0]^2 \, d\Omega \quad (8)$$

其 Euler-Lagrange 方程为

$$\lambda(I - I_0) - \operatorname{div}\left(\frac{\nabla I}{|\nabla I|}\right) = 0 \quad (9)$$

式(9)为 ROF 的基本模型,也叫做非线性去卷积模型。

采用梯度下降法进行离散化,可得

$$\frac{dI}{dt} = \operatorname{div}\left(\frac{\nabla I}{|\nabla I|}\right) - \lambda(I - I_0) \quad (10)$$

进一步,令

$$g = \frac{1}{|\nabla I|} = \frac{1}{\sqrt{I_x^2 + I_y^2}} \quad (11)$$

则有

$$\operatorname{div}\left(\frac{\nabla I}{|\nabla I|}\right) = \frac{1}{|\nabla I|} \nabla(\nabla I) + \nabla I \nabla\left(\frac{1}{|\nabla I|}\right) = \frac{I_{xx} + I_{yy}}{|\nabla I|} + \left(\frac{\partial g}{\partial x} I_x + \frac{\partial g}{\partial y} I_y\right) \quad (12)$$

$$\text{而 } \frac{\partial g}{\partial x} = -\frac{I_{xx} I_x + I_{yx} I_y}{|\nabla I|^3}, \frac{\partial g}{\partial y} = -\frac{I_{xy} I_x + I_{yy} I_y}{|\nabla I|^3}, \text{ 则}$$

$$\frac{\partial g}{\partial x} I_x + \frac{\partial g}{\partial y} I_y = -\frac{I_{xx} I_x^2 + 2I_{xy} I_x I_y + I_{yy} I_y^2}{|\nabla I|^3} \quad (13)$$

综上并由式(2)(3)可得

$$\operatorname{div}\left(\frac{\nabla I}{|\nabla I|}\right) = \frac{I_{\zeta\zeta} + I_{\eta\eta}}{|\nabla I|} + \left(-\frac{|\nabla I|^2 I_{\zeta\zeta}}{|\nabla I|^3}\right) = \frac{1}{|\nabla I|} I_{\eta\eta} \quad (14)$$

由式(14)可知,ROF 模型是沿着边缘方向进行扩散的,因而能很好地保持边缘信息。然而,对于图像的平坦区域,沿着边缘方向进行扩散则会导致平坦区域出现“假边缘”,甚至会产生块状效应。此外,由于在图像中包含有  $|\nabla I| = 0$  的点,式(9)是一个带有病态条件的 PDE 方程。

## 2 基于局部自适应的混合模型

### 2.1 模型的提出

无论是 P-M 模型还是 ROF 模型,在进行图像去

噪时都是针对整幅图像进行的。而对于一幅图像来说,纹理、边界区域与平滑区域的分布通常不是均匀的。这样,如果能根据图像局部区域的特征,选取合适的模型进行处理,势必会提高图像的去噪效果。基于这种思路,本文针对 ROF 模型和 P-M 模型的特点,提出具有局部自适应特点的混合偏微分去噪模型

$$E(w) = \int [\delta\rho(|\nabla w|) + (1 - \delta)|\nabla w|] \, d\Omega + \lambda \int (w - w^0)^2 \, d\Omega \quad (15)$$

式中,  $\delta \in [0, 1]$  为权函数,  $\lambda$  为拉格朗日乘子,  $\nabla w$  为图像像素的梯度,  $w^0$  为初始图像。

由式(15),当  $\delta = 0$  时,该模型退化为 ROF 模型;而当  $\delta = 1$  时,该模型退化为 P-M 模型。根据第 1 节的分析可知,在图像边缘及纹理信息较丰富的区域,应加强 ROF 模型的作用,这时  $\delta$  趋近于 0;而在图像的平坦区域,则应加强 P-M 模型的作用,这时  $\delta$  应趋近于 1。为此,针对不同的图像块区域特性,构造了不同的权函数  $\delta_1, \delta_2, \delta_3$  (图 1):




图 1 3 种权函数的曲线图

Fig. 1 Curves of three functions

1) 当图像块区域表现为平坦区域特征时,权函数为

$$\delta_1 = \ln\left(\frac{e - 1}{255/2} |\nabla w| + 1\right) \quad (16)$$

$\delta_1$  随着  $|\nabla w|$  的增大迅速趋近于 1,此时混合模型趋于 P-M 模型。

2) 当图像块区域表现为边缘或纹理区域特征

时,权函数为

$$\delta_2 = e^{\frac{\ln 2}{255\sqrt{2}}|\nabla w|} - 1 \quad (17)$$

$\delta_2$  随着  $|\nabla w|$  值的增大缓慢趋近于 1, 此时混合模型趋于 ROF 模型。

3) 当图像块区域特征表现为不明显倾向于前两种情况的一种时,权函数为

$$\delta_3 = \frac{|\nabla w|}{255\sqrt{2}} \quad (18)$$

$\delta_3$  随着  $|\nabla w|$  值的增大逐渐趋近于 1, 此时混合模型趋于 ROF 模型与 P-M 模型的折中。

## 2.2 图像块区域特征的判定

图像中某一方向灰度级的变化率直接影响到梯度的变化, 本文用平均梯度来度量图像块区域的特性。对大小为  $m \times n$  的图像, 其某一块区域  $A$  的平均梯度定义为

$$ave = \frac{1}{(m-1)(n-1)} \sum_{(x,y) \in A} \sqrt{w_x^2 + w_y^2} \quad (19)$$

式中,  $w_x$  和  $w_y$  分别为图像中像素点的  $x$  方向导数和  $y$  方向导数。采用中心差分法对其进行离散化, 形式为

$$\begin{cases} w_x = (w(i+1, j) - w(i-1, j))/2 \\ w_y = (w(i, j+1) - w(i, j-1))/2 \end{cases} \quad (20)$$

图像区域块的平均梯度值越大, 说明该图像块的纹理越丰富; 反之, 则表现为图像块越平滑。

## 2.3 混合模型的数值解

为了避免当  $|\nabla w| = 0$  时模型出现病态特性, 对  $|\nabla w|$  进行了修正, 即用  $|\nabla w|_\alpha = \sqrt{I_x^2 + I_y^2 + \alpha}$  来替代  $|\nabla w|$ , 其中  $\alpha$  为一小正数 (本文选取  $\alpha = 10^{-16}$ ), 这样所提出的混合模型为

$$E(w) = \int [\delta \rho(|\nabla w|_\alpha) + (1-\delta)|\nabla w|_\alpha] d\Omega + \lambda \int (w - w^0)^2 d\Omega \quad (21)$$

**定理** 式(21)收敛并存在极小解。

**证明:** 设存在一个极小序列  $\{w_n\} \in W^{1,2}$ , 其中  $W^{1,2}$  为 Sobolev 空间, 则由 Sobolev 空间的性质可得

$$\lim_{n \rightarrow \infty} E(w_n) = \inf_{w \in W^{1,2}} E(w) \quad (22)$$

下面证明存在一个收敛的子序列  $w_n$  收敛到  $w$ , 即  $w_n \rightarrow w$ 。由函数  $\int [\delta \rho(|\nabla w|_\alpha) + (1-\delta)|\nabla w|_\alpha] d\Omega$

的强制性可知  $|\nabla w_n|_2 < M$ , 其中  $M$  为一常数。所以,  $|\nabla w_n|_2$  是有界的。又由  $|w_n - w_0|$  与 1 的关系, 可以将图像区域分成  $\Omega_1$  和  $\Omega_2$ , 其中  $\Omega_1 := \{(x, y) : |w_n - w_0| < 1\}$ ,

$\Omega_2 := \{(x, y) : |w_n - w_0| \geq 1\}$ 。在  $\Omega_1$  中,  $\int_{\Omega_1} |w_n - w_0| d\Omega_1 < M_1$ , 在  $\Omega_2$  中,  $\int_{\Omega_2} |w_n - w_0| d\Omega_2 < M_2$ , 从而有  $|w_n - w_0|_2 = \int_{\Omega_1} |w_n - w_0| d\Omega_1 + \int_{\Omega_2} |w_n - w_0| d\Omega_2 < M_1 + M_2 = N$ , 即  $|w_n - w_0|_2$  是有界的。

再由  $|w_n|_2 \leq |w_n - w_0|_2 + |w_0|_2$ , 其中  $|w_0|_2$  为一常数, 则  $|w_n|_2$  是有界的。又  $|\nabla w_n|_2$  有界, 所以  $w_n$  在 Sobolev 空间有界并且收敛, 则必存在  $w$  为  $E(w)$  的一个极小解。证毕。

下面给出求式(21)数值解的过程: 混合模型的 Euler-Lagrange 方程为

$$\lambda(w - w^0) - \operatorname{div} \left( \frac{(1-\delta)\nabla w}{|\nabla w|_\alpha} + \delta f(|\nabla w|_\alpha) \nabla w \right) = 0 \quad (23)$$

采用梯度下降法对其进行求解可得

$$\frac{\partial w}{\partial t} = \operatorname{div} \left( (1-\delta) \frac{\nabla w}{|\nabla w|_\alpha} + \delta f(|\nabla w|_\alpha) \nabla w \right) - \lambda(w - w^0) \quad (24)$$

$$\begin{aligned} \text{对于 } |\nabla w|^2, \text{ 其梯度离散化公式为} \\ |\nabla w|^2 = (w(i-1, j) - w(i, j))^2 + \\ (w(i+1, j) - w(i, j))^2 + (w(i, j-1) - \\ w(i, j))^2 + (w(i, j+1) - w(i, j))^2 \end{aligned} \quad (25)$$

将式(25)应用于式(24)可得迭代公式为

$$w^{n+1} = w^n + \Delta t (\delta \sum (f(|\nabla w|_\alpha) \nabla w) + (1-\delta)(k - \lambda(w^n - w^0))) \quad (26)$$

式中,  $k = \frac{(w_{xx}w_y^2 - 2w_xw_yw_{xy} + w_{yy}w_x^2)}{(\nabla w_x^2 + \nabla w_y^2 + \alpha)^3}$ ,  $\Delta t$  为离散化时间步长。

## 2.4 混合模型的算法实现

所提出混合模型的算法步骤如下:

1) 初始化

(1) 记  $w^0$  为初始含噪声的图像, 根据式(19)计算整体图像的平均梯度  $ave$ ;

(2) 将图像  $w^0$  分成互不重叠的块。本文实验中, 将块大小设置为  $16 \times 16$  像素。

2) 进行基于分块的迭代计算

(1) 用  $p$  和  $r$  分别表示图像分块的序号及对每块的迭代次数, 并赋初值:  $p = 1, r = 0$ ;

(2) 设  $\varepsilon$  为一小正常数阈值, 用以辅助界定图像分块的属性。该阈值可通过实验统计获得, 本文

实验中取其为 0.001;

(3) 选取拉格朗日乘子  $\lambda$  为 1.5, 离散化时间步长  $\Delta t$  为 0.1;

(4) 用式(19)计算第  $p$  块的平均梯度值  $avge_r$ , 并将其与  $avge$  进行比较。如果  $avge_r < avge + \varepsilon$ , 则令

$$\delta = \ln\left(\frac{e - 1}{255 \sqrt{2}} |\nabla \mathbf{w}|_{\alpha} + 1\right)$$

如果  $avge_r > avge + \varepsilon$ , 则令

$$\delta = e^{\frac{\ln 2}{255 \sqrt{2}} |\nabla \mathbf{w}|_{\alpha}} - 1$$

否则, 令

$$\delta = \frac{|\nabla \mathbf{w}|_{\alpha}}{255 \sqrt{2}}$$

(5) 根据式(27)计算

$$\mathbf{w}^{n+1} = \mathbf{w}^n + \Delta t (\delta \sum (f(|\nabla \mathbf{w}|_{\alpha}) \nabla \mathbf{w}) + (1 - \delta)(k - \lambda(\mathbf{w}^n - \mathbf{w}^0)));$$

(6) 如果  $|\mathbf{w}_p^{r+1} - \mathbf{w}_p^r| > 0.01$ , 令  $r = r + 1$ , 并转向步骤(5); 否则, 如果  $p = m$ , 则转向步骤(3), 否则, 令  $p = p + 1$ , 转向步骤(4)。

3) 算法结束。

### 3 实验与分析

为了验证本文模型的有效性, 首先选取大小为  $256 \times 256$  像素的 3 幅遥感图像作为测试图像, 在多种强度的高斯噪音下, 将所提出的混合模型与 P-M 模型和 ROF 模型的去噪效果进行了比较, 并采用信噪比 (SNR) 来度量去噪后的图像质量; 其次, 分析 3 种模型的计算量。实验平台的硬件环境为双核处理器 (单核主频是 1.73 GHz), 1 G 内存, 操作系统为 Window XP, 编程环境采用 Matlab 7.3.0.267 (R2006b)。

#### 3.1 去噪结果的比较

表 1—3 分别给出了遥感图像 band、river 和 pan 在分别加入均值为 0、方差为 10、15、20 和 30 的高斯噪声后, 采用 P-M 模型、ROF 模型和本文自适应混合模型进行去噪的结果, 图 2 是其相应的 SNR 曲线图。从图中可以看出, 相对于 P-M 模型算法和 ROF 模型算法, 本文算法具有更好的去噪效果, 并且在有效去除图像中噪音的同时, 能够很好地保持图像的纹理信息。而且由图 2 可知, 当图像添加的噪音越

表 1 3 种方法对包含不同噪声 band 图像的去噪结果比较

Tab. 1 The de-noising results of three models for "band" image with different noises

















	方差 10 高斯噪声	方差 15 高斯噪声	方差 20 高斯噪声	方差 30 高斯噪声
含噪声图像				
P-M 模型				
ROF 模型				
本文自适应混合模型				

表 2 3 种方法对包含不同噪声 river 图像的去噪结果

Tab.2 The de-noising results of three models for "river" image with different noises

	方差 10 高斯噪声	方差 15 高斯噪声	方差 20 高斯噪声	方差 30 高斯噪声
含噪声图像				
P-M 模型				
ROF 模型				
本文自适应混合模型				

表 3 3 种模型对包含不同噪声 pan 图像的去噪结果

Tab.3 The de-noising results of three models for "pan" image with different noises

	方差 10 高斯噪声	方差 15 高斯噪声	方差 20 高斯噪声	方差 30 高斯噪声
含噪声图像				
P-M 模型				
ROF 模型				
本文自适应混合模型				

大时,本文算法较之 P-M 算法和 ROF 算法就越有效。特别是在图像的局部纹理区域,不但去噪效果更明显,而且可以最大程度地保护纹理边缘,不会引起块状效应,平均 SNR 较 P-M 模型与 ROF 模型能够提高 2~3 dB。为了更清晰地说明这一点,又选取了局部的 band 图像,并加入方差为 30 的高斯噪声进行实验,结果如表 2 所示。此局部图像的特点是既包含一定的平坦区域,又有纹理丰富的区域。

由图 3 可见,对于所选择的局部区域,P-M 模型的去噪效果较好,但是由于其在边缘的梯度和切线方向上均存在去噪系数,导致很多纹理信息的丢失。ROF 模型虽然保持了丰富的纹理信息,但是因为此模型在边缘的梯度方向上没有去噪系数,所以去噪效果不甚明显。由于本文的混合模型兼顾考虑了前面两个模型的优缺点,并引入局部自适应的权值在两个模型之间进行折中,尽可能地使模型作用达到最优化,最终获得了更高的去噪质量。




图 2 3 种模型去噪的 SNR 曲线图比较

Fig.2 SNR comparison among three models




图 3 局部 band 图像的去噪结果比较

Fig.3 De-noising result comparison for partial "band" image

### 3.2 计算量分析

计算量也是衡量算法有效性的指标之一,下面分析本文模型所需的计算量,并将其与 P-M 和 ROF 模型进行比较。需特别指出的是,假定加(减)、乘(除)、开平方和比较等操作具有相同的计算复杂度,仅以计算次数来评价计算量。由 2.4 节可知,本文模型包括以下 3 个主要步骤:

1) 计算整幅图像的平均梯度。根据式(19)(20),这一步需要  $T_1 = 9mn$  次运算。

2) 依次计算各分块的平均梯度值,将其与整幅图像的平均梯度进行比较,从而确定去噪系数  $\delta$ 。由于各个分块中的像素梯度已在第 1) 步计算得到,

此处只要计算一次平均梯度值即可,故需  $T_2 = mn/256$  次除法运算,另外,还要执行  $T_3 = mn/256$  次比较操作。

3) 根据相应的  $\delta$ ,并利用式(27)对每个分块进行  $r$  次迭代求解。由式(27)以及梯度、扩散函数的定义,每个分块的计算次数约为  $(54 \times 16 \times 16 \times r)$ ,则整幅图像的计算次数  $T_4 \in [54mnr_{\min}, 54mnr_{\max}]$  ( $r_{\min}$  和  $r_{\max}$  分别表示所有分块中迭代次数的最小值和最大值)。

综上,本文模型的计算量为  $T_1 + T_2 + T_3 + T_4 \approx 9mn + 54mn$ 。此外,P-M 模型由两个步骤组成,即计算梯度和热扩散,根据梯度定义和式(4),这个过程

共需  $21mn$  次运算;ROF 模型则包括梯度计算和能量最小化两个主要过程,由式(14)可知,该模型的计算次数约为  $8mn + 24mnq$ ,其中  $q$  表示迭代次数。由于本文模型能根据图像的局部区域特征自适应地在 P-M 和 ROF 模型之间折中,又 P-M 模型无需迭

代求解,故而本文模型的平均迭代次数必定明显少于 ROF 模型,即  $r < q$ ,尤其是较为平滑的图像。由此可知,本文模型的计算量介于 P-M 模型和 ROF 模型之间。表 1 给出了采用 3 种模型处理各测试图像的运行时间比较,其结果也证明了这一结论。

表 4 3 种模型处理各测试图像的运行时间比较

Tab. 4 Running time comparisons among three models for each test image

去噪模型	方差为 10			方差为 20			方差为 30			/s
	band	river	pan	band	river	pan	band	river	pan	
PM	5.22	4.40	4.45	4.72	4.50	4.45	4.53	4.50	4.48	
ROF	13.25	11.42	10.94	29.14	25.75	25.66	44.99	40.46	41.86	
本文	13.19	10.88	10.68	25.27	23.42	24.33	37.51	34.69	35.77	

## 4 结 论

在 P-M 模型和 ROF 模型的基础上提出一种新的基于局部自适应的混合模型。该模型考虑了图像的局部信息,针对分块图像的局部纹理特性,采用不同的约束系数,以充分利用 P-M 模型在平坦区域效果好和 ROF 模型能够最大化的保护边缘信息的特点,在很好的去除噪音的同时,能够最大限度的保护边缘信息。实验结果验证了所提出模型的有效性。

## 参考文献 (References)

- [1] Bo Yanchen, Wang Jinfeng. A wavelet-based filter for sar speckle reduction and the comparative evaluation on its performance [J]. Journal of Remote Sensing, 2003, 7(5): 393-399. [柏延臣, 王劲峰. 基于小波分析的 SAR 图像斑点滤波及其性能比较评价 [J]. 遥感学报, 2003, 7(5): 393-399.]
- [2] Gao Lianru, Zhang Bing. Study on the method for estimating the noise in remote sensing images based on local standard deviations [J]. Journal of Remote Sensing, 2007, 11(2): 201-208. [高连如, 张兵. 基于局部标准差的遥感图像噪声评估方法研究 [J]. 遥感学报, 2007, 11(2): 201-208.]
- [3] Sun T, Neuvo Y. Detail-preserving median based filters in image processing [J]. Pattern Recognition Letters, 1994, 15(4): 341-347.
- [4] Lin H, Willson A N. Median filters with adaptive length [J]. IEEE Trans. Circuits Syst., 1988, 35(6): 675-690.
- [5] Shih A C C, Liao H Y M, Lu C S. A new iterated two-band diffusion [J]. IEEE Trans. PAMI, 1990, 12(7): 629-639.
- [6] Alvarez L, Lions P L, Morel J M. Image selective smoothing and edge detection by nonlinear diffusion [J]. SIAM J. Numer. Anal., 1992, 29(3): 845-866.
- [7] Chen Zhengchao. A Research on the Technology of On-Orbit Calibration and Validation of China Dmc Microsatellite [D]. Beijing: Institute of Remote Sensing Applications Chinese Academy of Sciences, 2005. [陈正超. 中国 DMC 小卫星在轨测试技术研究 [D]. 北京: 中国科学院遥感应用研究所, 2005.]
- [8] Perona P, Malik J. Scale-space and edge detection using anisotropic diffusion [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 1990, 12: 629-639.
- [9] Catta F, Lion P L, Morel J M, et al. Image selective smoothing and edge detection by nonlinear diffusion [J]. SIAM Journal on Numerical Analysis, 1992, 29: 182-193.
- [10] Zhu Xuan, Zhou Mingquan, Zhu Chunxiang, et al. Image filtering by combination of the curvature-driven and edge-stopping nonlinear diffusion [J]. Acta Photonica Sinica, 2008, 37(3): 609-612. [祝轩, 周明全, 朱春香, 等. 曲率驱动与边缘停止相结合的非线性扩散及其在图像去噪中的应用 [J]. 光子学报, 2008, 37(3): 609-612.]
- [11] Rudin Li, Osher S, Fatemi E. Nonlinear total variation based noise removal algorithms [J]. Physic D, 1992, 60(1-4): 259-268.
- [12] Osher S, Fedikiw R. Level Set Methods and Dynamic Implicit Surfaces [M]. New York: Springer-Verlag New York, 2003: 23-90.
- [13] Marquina A, Osher S. Explicit algorithm for a new time dependent model based on level set motion for nonlinear deblurring and noise removal [J]. SIAM Journal on Scientific Computing, 2000, 22: 387-405.
- [14] Xie Huaying, Zhou Haiyin, Xie Meihua. Image denoising through combination of P-M diffusion and coherence enhancing diffusion [J]. Journal of Image and Graphic. 2005, 10(2): 57-60. [谢华英, 周海银, 谢美华. P-M 扩散与相干增强扩散相结合的抑制噪声方法 [J]. 中国图象图形学报, 2005, 10(2): 57-60.]