

# 基于空间自适应非凸正则项全变差 相干斑噪声抑制\*

李金才<sup>1)†</sup> 彭宇行<sup>1)</sup> 朱敏<sup>1)</sup> 陈鹏<sup>2)</sup>

1) (国防科学技术大学计算机学院, 长沙 410073)

2) (周口职业技术学院信息工程系, 周口 466000)

(2014年3月31日收到; 2014年5月6日收到修改稿)

全变差正则化方法是相干斑噪声抑制研究的热点. 非凸正则项能够更好地保持图像的边缘、纹理细节信息; 空间自适应正则化参数可以根据像素点所在的区域, 合理地控制噪声抑制程度, 从而提高噪声抑制效果. 本文结合非凸正则项和空间自适应正则化参数提出了一种新的全变差相干斑噪声抑制模型, 并且给出了一种模型求解的数值算法. 数值试验结果表明该模型能够获得更好的相干斑噪声抑制效果.

**关键词:** 非凸正则项, 全变差, 相干斑噪声抑制, 空间自适应正则化参数

**PACS:** 95.75.Mn, 42.30.Va, 42.30.Sy

**DOI:** 10.7498/aps.63.189501

## 1 引言

相干斑噪声广泛存在于合成孔径雷达 (synthetic aperture radar, SAR)、医学超声、激光和声学等相干成像系统<sup>[1-6]</sup>. 由于相干斑噪声的存在, 严重影响了图像的解释和应用. 相干斑噪声抑制成为相干成像系统图像进一步应用的基础和关键<sup>[7-9]</sup>.

相干斑噪声抑制方法主要包括基于局部统计特性的滤波方法<sup>[10-13]</sup>、基于变换域的滤波方法<sup>[14,15]</sup>和基于偏微分方程和全变差的滤波方法<sup>[16-34]</sup>. 其中, 基于全变差的相干斑噪声抑制方法是近10年来研究的热点. 2003年, Rudin、Lions和Osher提出的RLO模型<sup>[20]</sup>是第一个用于去除相干斑噪声的全变差模型, 该模型包含两项: 保真项和正则项. 其中, 保真项基于噪声分布的假设推导而来; 全变差被用作正则项, 用于光滑同质区域和保持图像的边缘、纹理细节信息. 一般认为相干斑噪声服从Gamma分布, 然而RLO模型

是基于Gaussian分布的. 2008年, Aubert和Aujol<sup>[21]</sup>针对Gamma分布的相干斑噪声, 基于最大后验概率, 提出了著名的AA模型, 取得了较好的噪声抑制效果. 然而, RLO模型和AA模型的保真项都是非凸的, 这使得模型的数值求解变得困难. 近年来, 基于log变换构造凸的保真项, 先后提出了Shi-Osher模型<sup>[22]</sup>、Bioucas Dias-Figueiredo (BF)模型<sup>[23,24]</sup>、Huang-Ng-Wen模型<sup>[25]</sup>和Steidl-Teuber模型<sup>[26]</sup>等; 基于 $m$ 次方根变换, 提出了 $m$ -V模型<sup>[27,28]</sup>. 这些模型具有一个共同点, 就是正则项都是凸的, 从而可以保证有全局最优解. 然而, 一些应用研究<sup>[35-39]</sup>显示非凸正则项能够更好地保持甚至增强图像的边缘、纹理细节信息. Han等<sup>[29]</sup>基于非凸稀疏正则项提出了一种新的相干斑噪声抑制模型 (nonconvex regularizer based speckle noise removal, NRSNR), 该模型利用了非凸正则项的优点, 获得了比使用凸正则项的AA、BF等模型更好的噪声抑制效果.

基于全变差的相干斑噪声抑制模型中, 正则

\* 国家重点基础研究发展计划 (批准号: 2014CB340303) 和国家高技术研究发展计划 (批准号: 2013AA01A213) 资助的课题.

† 通讯作者. E-mail: lijincal@nudt.edu.cn

项本质上是一种局部滤波器<sup>[40]</sup>, 正则化参数控制着噪声抑制的程度. 直观上, 正则化参数应该随着像素点所在位置不同而变化, 然而, 上面提到的所有模型中的正则化参数使用的都是常量. 这使得模型无法准确地对噪声抑制程度进行控制, 容易出现同质区域噪声抑制不足, 或者边缘、纹理细节过度光滑的情况. 针对乘性噪声模型, Chen 和 Cheng<sup>[30]</sup> 基于一些随机变量的统计特性, 提出了一个具有约束条件的全变差模型 (spatially adapted total variation model, SATVM), 该模型能够空间自适应地选择正则化参数, 更加合理地控制噪声抑制程度, 从而提高模型的噪声抑制效果; 王旭东等<sup>[31]</sup> 基于由最大期望 (expectation maximization, EM) 得到的自适应权函数, 提出了去除相干斑噪声的重加权各向异性全变差模型, 获得了较好的噪声抑制效果.

但是, 目前使用自适应正则化参数的全变差模型中, 为了方便模型求解, 确保模型有全局最优解, 正则项都是凸的. 然而, 凸正则项全变差模型相比非凸正则项全变差模型, 不能更好地保持图像边缘、纹理细节. 另外, 在使用非凸正则项的全变差模型中, 正则化参数采用的是常量, 在整个噪声抑制过程中其值保持不变, 不能根据像素点所在图像的位置合理地控制噪声抑制程度. 所以, 本文针对以上问题, 提出了一种基于空间自适应正则化参数的非凸正则项全变差相干斑噪声抑制模型 (spatially adapted total variation model with nonconvex regularizer, SATVMNR). 该模型使用自适应正则化参数合理地控制不同区域噪声抑制程度, 利用非凸正则项更好地保持图像边缘、纹理细节信息, 从而获得了更好的相干斑噪声抑制效果. 并且, 基于 Newton 迭代法 (Newton's Method, NM)、增广拉格朗日乘子法 (augmented lagrange multiplier, ALM)、交替方法乘子法 (alternating direction method of multipliers, ADMM) 和迭代重加权法 (iteratively reweighted method, IRM), 给出了模型的一种数值求解算法.

## 2 相关研究

对于一副  $m \times n$  的图像, 本文考虑如下乘性噪声模型:

$$f_i = u_i n_i \quad i = 1, \dots, m \times n, \quad (1)$$

其中  $f$  是观测图像,  $u$  是待恢复的图像,  $n$  是噪声.  $f, u, n$  分别是随机图像  $F, U, N$  的采样. 其中  $N$  是独立同分布噪声图像, 并且服从均值为 1、方差为  $1/L$  的 Gamma 分布, 其概率密度函数为

$$P_N(n) = \frac{L^L}{\Gamma(L)} n^{L-1} e^{-Ln} \quad \{n \geq 0\}, \quad (2)$$

其中  $L$  是等效视数. 为了文章的完整性, 下面简要介绍非凸正则项全变差模型和空间自适应全变差模型.

### 2.1 非凸正则项全变差模型分析

非凸正则项全变差模型<sup>[29]</sup> 是基于 BF 模型<sup>[23,24]</sup> 演变而来. BF 模型首先使用 log 变换将乘性噪声模型 (1) 转换为加性噪声模型 (3):

$$g_i = v_i + w_i \quad i = 1, \dots, m \times n, \quad (3)$$

其中  $g_i = \log f_i, v_i = \log u_i, w_i = \log n_i$ . 则随机变量  $W = \log N$  满足:

$$\begin{aligned} P_W(w) &= P_N(e^w) e^w \\ &= \frac{L^L}{\Gamma(L)} e^{Lw} e^{-e^w L}, \end{aligned} \quad (4)$$

并且

$$P_{G|V}(g|v) = P_W(g - v). \quad (5)$$

文献<sup>[24]</sup> 假设变量  $v$  满足 Gibbs 先验, 则有

$$P_V(v) = \frac{1}{Z} \prod_{i=1}^{m \times n} \rho \exp(-\rho |\nabla_i v|), \quad (6)$$

其中  $Z$  是归一化常数,  $\rho > 0$  是一个常量参数,  $|\cdot|$  表示全变差. 然后根据条件独立假设和贝叶斯公式, 得到 BF 模型:

$$\min_v \left\{ L \sum_{i=1}^{m \times n} (v_i + e^{g_i - v_i}) + \lambda \sum_{i=1}^{m \times n} |\nabla_i v| \right\}. \quad (7)$$

文献<sup>[29]</sup> 用  $\rho_i$  代替 (6) 式中的  $\rho$ , 利用最大后验概率估计得到相应的最小化问题, 根据该最小化问题关于  $\rho_i$  的 Euler-Lagrange 方程可以得到

$$\rho_i = \frac{1}{|\nabla_i v|}. \quad (8)$$

根据 (8) 式, 得到了一个理想的正则项, 并且基于该正则项, 提出了一个非凸正则项的全变差模型:

$$\min_v \left\{ L \sum_{i=1}^{m \times n} (v_i + e^{g_i - v_i}) + \lambda \sum_{i=1}^{m \times n} \varphi(|\nabla_i v|) \right\}, \quad (9)$$

其中  $\varphi(|\nabla_i v|) = \alpha |\nabla_i v| / (1 + \alpha |\nabla_i v|)$ ,  $\alpha$  是一个足够大的辅助常数,  $\lambda$  是常量正则化参数.

模型 (9) 中  $\varphi(|\nabla_i v|)$  是 Weberied 全变差 [41,42] 的广义形式. Weberied 全变差在去除加性噪声时, 可以获得比传统的全变差更好的性能. 而模型 (9) 是基于乘性噪声模型 (1) 的 log 变化推导而来, 相当于针对加性噪声的抑制模型, 所以模型 (9) 能够利用非凸正则项的优点, 获得更好的相干斑噪声抑制效果.

### 2.2 空间自适应全变差模型分析

文献 [30] 首先研究了统计量  $\frac{f}{u} - \log \frac{f}{u}$  的统计特性, 给出了关于该统计量数学期望估计的定理.

**定理 [30]** 设  $n$  是满足 Gamma 分布的随机变量, 均值为 1, 方差为  $1/L$ . 考虑关于  $n$  的函数  $I(n) = n - \log n$ , 则关于  $I(n)$  的期望值有如下的估计结果:

$$E\{I(n)\} = 1 + \frac{1}{2L} + \frac{1}{12L^2} - \frac{5}{2L^3} + O\left(\frac{1}{L^3}\right). \quad (10)$$

作者将图像分解为两部分, 即:  $u = u_c + u_t$ . 其中,  $u_c$  表示图像的同质区域,  $u_t$  表示图像的边缘纹理区域. 假设模型的解为  $\tilde{u}$ , 对同质区域和边缘纹理区域分别研究随机变量  $\frac{f}{\tilde{u}} - \log \frac{f}{\tilde{u}}$  的期望值, 得到如下结果:

$$\begin{aligned} & \frac{1}{|\Omega_c|} \sum_{i \in \Omega_c} \left( \frac{f_i}{\tilde{u}_i} - \log \frac{f_i}{\tilde{u}_i} \right) \\ & \approx \frac{1}{|\Omega_c|} \sum_{i \in \Omega_c} (n_i - \log n_i) \\ & \approx 1 + \frac{1}{2L} + \frac{1}{12L^2}, \end{aligned} \quad (11)$$

$$\begin{aligned} & \frac{1}{|\Omega_t|} \sum_{i \in \Omega_t} \left( \frac{f_i}{\tilde{u}_i} - \log \frac{f_i}{\tilde{u}_i} \right) \\ & > \frac{1}{|\Omega_t|} \sum_{i \in \Omega_t} (n_i - \log n_i) \\ & \approx 1 + \frac{1}{2L} + \frac{1}{12L^2}, \end{aligned} \quad (12)$$

其中  $\Omega_c, \Omega_t$  分别表示同质区域和边缘纹理区域. 从上面的结论可以看出, 当像素点位于图像的纹理细节区域时, 经过全变差噪声抑制, 会造成该区域的过度光滑. 从而, 作者使用  $\frac{f}{u} - \log \frac{f}{u}$  的局部期望值来对图像噪声抑制过程进行约束, 提出了局部约

束的全变差模型:

$$\begin{aligned} & \min_v TV(v) \\ & \text{s.t. } S(v) \leq 1 + \frac{1}{2L} + \frac{1}{12L^2}, \end{aligned} \quad (13)$$

其中  $S(v)$  表示  $v$  的数学期望值, 并且

$$\begin{aligned} & S(v)(x) \\ & = \sum_{i \in \Omega_x^r} w(x, y_i) (f e^{-v} + v - \log f)(y_i), \end{aligned} \quad (14)$$

$w(x, y)$  表示以像素点  $x$  为中心的局部窗口的均值滤波器, 定义如下:

$$w(x, y) = \begin{cases} \frac{1}{|\Omega_x^r|} & \|y - x\|_\infty \leq \frac{r}{2} \\ 0 & \|y - x\|_\infty > \frac{r}{2} \end{cases}, \quad (15)$$

其中  $\Omega_x^r$  表示以  $x$  为中心,  $r$  为大小的滤波窗口.

然后, 通过分析模型 (13) 的性质, 提出了下面的空间自适应正则化参数全变差模型 SATVM:

$$\min_v \left\{ \sum_{i=1}^{m \times n} \lambda_i (v_i + e^{g_i - v_i}) + \sum_{i=1}^{m \times n} |\nabla_i v| \right\}. \quad (16)$$

该模型可以根据像素点所在图像区域自适应地调整正则化参数, 更加合理地控制图像噪声抑制的程度, 从而获得更好的噪声抑制效果.

## 3 基于空间自适应非凸正则项全变差模型

### 3.1 模型的提出

目前, 基于空间自适应正则化参数全变差模型中的正则项都是凸的, 凸正则项与非凸正则项相比, 不能更好地保持图像边缘、纹理等信息; 而采用非凸正则项全变差模型的正则化参数都采用常量, 这使得位于不同区域的像素点受到的噪声抑制程度相同, 导致同质区域的光滑程度不够, 或者边缘、纹理区域过度光滑, 从而影响噪声抑制效果. 本文针对以上问题, 结合空间自适应正则化参数和非凸正则项, 提出了一种新的相干斑噪声抑制模型.

针对相干斑噪声模型 (1), 采用 log 变换, 将其转换为模型 (3). 结合 (4) 和 (5) 式, 根据噪声独立同分布假设, 可以得到

$$\log P_{G|V}(g|v) = \sum_{i=1}^{m \times n} \log P_W(g_i - v_i)$$

$$= C - L \sum_{i=1}^{m \times n} (v_i + e^{g_i - v_i}), \quad (17)$$

其中

$$C = \sum_{i=1}^{m \times n} (L \log L - \log \Gamma(L) + Lg_i). \quad (18)$$

由于  $g$  是已知的观测图像  $f$  的  $\log$  变换, 所以  $g$  也是已知的, 从而  $C$  是常数.

用向量  $\rho_i$  代替 (6) 式中标量  $\rho$ , 则有:

$$P_V(v) = \frac{1}{Z} \prod_{i=1}^{m \times n} \rho_i \exp(-\rho_i |\nabla_i v|). \quad (19)$$

根据贝叶斯公式可以得到

$$P_{V|G}(v|g) \propto P_{G|V}(g|v)P_V(v). \quad (20)$$

则可以得到下面的无约束最小化问题:

$$\min_v \left\{ L \sum_{i=1}^{m \times n} (v_i + e^{g_i - v_i}) + \sum_{i=1}^{m \times n} \rho_i |\nabla_i v| - \sum_{i=1}^{m \times n} \log \rho_i \right\}. \quad (21)$$

根据 (21) 式关于  $\rho_i$  的 Euler-Lagrange 方程, 便可得到 (8) 式. 为了避免分母为 0, (8) 式可以进一步改写为

$$\rho_i = \frac{1}{|\nabla_i v| + \alpha^{-1}}, \quad (22)$$

其中,  $\alpha$  是一个足够大的辅助常数. 则理想的正则项为  $\sum_{i=1}^{m \times n} \alpha |\nabla_i v| / (1 + \alpha |\nabla_i v|)$ . 从而, 结合空间自适应正则化参数, 提出了下面的相干斑噪声抑制模型:

$$\min_v \left\{ L \sum_{i=1}^{m \times n} (v_i + e^{g_i - v_i}) + \sum_{i=1}^{m \times n} \lambda_i \varphi(|\nabla_i v|) \right\}$$

s.t.  $S(v) \leq \gamma,$  (23)

其中  $\varphi(s) = \alpha s / (1 + \alpha s), \gamma = 1 + \frac{1}{2L} + \frac{1}{12L^2} - \frac{5}{2L^3}$ .

根据文献 [30] 的分析可知, 模型 (13) 的解  $\tilde{v}$  满足模型 (23) 的一阶最优条件. 设:

$$\lambda_\mu^0 = \mu \max(S(v_\mu) - \gamma, 0), \quad (24)$$

$$\lambda_\mu = \sum_{i=1}^{m \times n} w(x_i, y) \lambda_\mu^0(x_i), \quad (25)$$

其中  $\mu$  是惩罚参数, 则可以得到:

$$\tilde{\lambda}^0 = (S(\tilde{v}) - \gamma) = 0, \quad \text{a.e. in } \Omega, \quad (26)$$

其中 a.e. 表示“几乎处处”. 从 (26) 式可以看出  $\tilde{\lambda}^0$  是模型 (13) 对应的拉格朗日函数的拉格朗日乘子. 所以, 可以使用拉格朗日乘子迭代更新的方式自适应地调整正则化参数.

正则化参数  $\lambda_i$  的大小决定着噪声抑制的程度. 不同于模型 (16) 的正则化参数作用于保真项, 模型 (23) 的正则化参数作用于正则项. 所以针对模型 (23), 对于同质区域,  $\lambda_i$  的取值应该偏大, 但是较大的  $\lambda_i$  会使得噪声抑制过度, 从而造成边缘、纹理细节信息的丢失; 对于边缘、纹理细节区域,  $\lambda_i$  的取值应该偏小, 但是较小的  $\lambda_i$  又会造成同质区域噪声抑制不足. 所以,  $\lambda_i$  的取值采取迭代更新策略. 首先选择一个较大的  $\lambda_i$ , 可以得到一幅噪声过度抑制的图像, 对于包含边缘、纹理细节区域, 会使得  $S(v) > \gamma$ , 此时需要减小正则化参数  $\lambda_i$ . 基于  $v^k$  更新  $\lambda^k$  的公式如下:

$$\tilde{\lambda}_i^{k+1} = \lambda_i^k - \delta \max(S(v_i^k) - \gamma, 0), \quad (27)$$

$$\lambda_i^{k+1} = \frac{1}{r^2} \sum_{j \in \Omega_r^i} (\tilde{\lambda}_i^{k+1}), \quad (28)$$

其中  $\delta > 0$  是迭代步长,  $\Omega_r^i$  是以像素点  $(i)$  为中心、 $r$  为大小的局部窗口.

### 3.2 模型分析

SATVMNR 模型与 NRSNR 模型的主要区别在于, 该模型的正则化参数  $\lambda_i$  会根据像素点所在的区域不同而自适应地进行调整, 这样能够更加准确、合理地控制噪声的抑制程度, 从而获得更好的噪声抑制效果. 与 SATVM 模型的主要区别在于, 该模型的正则项是非凸的, 更加确切地讲, 该正则项是稀疏非凸的, 此处的稀疏是指图像梯度模的稀疏. 一般可以认为图像是分片常值的, 在此意义下, 图像各区域的边缘、纹理细节相对于整幅图像而言可以说是稀疏的. 从而, SATVMNR 模型可以利用非凸正则项能够更好地保持图像边缘、纹理细节的特点来提高图像噪声的抑制效果.

从 (23) 式可以看出, 正则化参数  $\lambda_i$  如果在噪声抑制过程中始终取值为常数, 并且没有局部期望值大小的约束, 则该模型就转化为 NRSNR 模型. 如果正则项函数  $\varphi(|\nabla_i v|) = |\nabla_i v|$ , 则该模型就转化为 SATVM 模型. 由此可见, 本文提出的模型比 NRSNR 模型和 SATVM 模型更具一般性.

通常全变差  $TV(v)$  有两种选择: 一种是各向同性全变差, 另一种为各向异性全变差, 两种全变差的定义分别为 (29) 和 (30) 式. 由于各向异性全变差极小化的可行域严格包含各向同性全变差解的可行域, 并且各向异性全变差便于采用更加灵活的方法减小全变差 [31]. 所以, 本文的全变差采用各向异性公式.

各向同性全变差定义为

$$TV(v) = \sum_{i=1}^{m \times n} \sqrt{(\nabla_i^1 v)^2 + (\nabla_i^2 v)^2}; \quad (29)$$

各向异性全变差定义为

$$TV(v) = \sum_{i=1}^{m \times n} |\nabla_i^1 v| + |\nabla_i^2 v|; \quad (30)$$

其中  $\nabla_i^1 v$  和  $\nabla_i^2 v$  分别表示在  $(i)$  位置的像素点水平和垂直方向的一阶差分算子.

### 3.3 模型求解

为了求解模型 (23), 给定一个较大的正则化参数  $\lambda$  的初值. 首先通过引入辅助变量  $k$  将最小化问题 (23) 转换为如下约束最小化问题:

$$\min_{v,k} \left\{ L \sum_{i=1}^{m \times n} (v_i + e^{g_i - v_i}) + \sum_{i=1}^{m \times n} \lambda_i \varphi(|\nabla_i k|) \right\}, \quad (31)$$

$$\text{s.t. } v = k. \quad (32)$$

使用 ALM 方法, 上面的最小化问题可以转化为

$$\min_{v,k} \left\{ L \sum_{i=1}^{m \times n} (v_i + e^{g_i - v_i}) + \sum_{i=1}^{m \times n} \lambda_i \varphi(|\nabla_i k|) + \frac{\tau}{2} \sum_{i=1}^{m \times n} (v_i - k_i)^2 \right\}, \quad (33)$$

其中  $\tau$  是正的惩罚参数. 此处  $\tau$  的取值应该足够大, 因为我们的目的是求能量泛函的极小值, 并且强制  $k$  和  $v$  近似相等, 如果  $\tau$  的取值过小, 即使  $v-k$  的值较大, 泛函的总能量也可以很小, 这就无法实现  $k$  和  $v$  近似相等的要求. 类似地, 当  $\tau$  的取值足够大时, 要想使得泛函的总能量达到极小,  $v-k$  的值就只能非常小, 这样就满足了  $k$  和  $v$  近似相等的要求. 但是, 如果  $\tau$  的取值过大, 又会使得最小化问题 (33) 变成病态的. 为了克服该问题, 采用文献 [29]

中的方法, 引入一个调节变量  $t$ , 则最小化问题 (33) 可以转换为

$$\min_{v,k} \left\{ L \sum_{i=1}^{m \times n} (v_i + e^{g_i - v_i}) + \sum_{i=1}^{m \times n} \lambda_i \varphi(|\nabla_i k|) + \frac{\tau}{2} \sum_{i=1}^{m \times n} (v_i - k_i + t_i)^2 \right\}, \quad (34)$$

这将使得惩罚参数  $\tau$  的取值更加灵活.

然后, 使用经典的 ADMM 方法 [43] 来求解问题 (34). 首先给定  $k$  求解  $v$ , 则有

$$v^{k+1} = \arg \min_v \left\{ L \sum_{i=1}^{m \times n} (v_i + e^{g_i - v_i}) + \frac{\tau}{2} \sum_{i=1}^{m \times n} (v_i - k_i^k + t_i^k)^2 \right\}; \quad (35)$$

然后, 给定  $v$  求解  $k$ , 则有

$$k^{k+1} = \arg \min_k \left\{ \sum_{i=1}^{m \times n} \lambda_i^k \varphi(|\nabla_i k|) + \frac{\tau}{2} \sum_{i=1}^{m \times n} (v_i^{k+1} - k_i + t_i^k)^2 \right\}; \quad (36)$$

其中上标表示迭代次数. 最小化问题 (35) 可以通过 NM 方法进行求解. 由于最小化问题 (36) 是非凸的, 所以采用 IRM 方法进行求解. 引入权重变量  $q$ , 令

$$q_i = \frac{\alpha \lambda_i^k}{1 + \alpha |\nabla_i k|}, \quad (37)$$

则最小化问题 (36) 可转换为下面的形式:

$$\min_{k,q} \left\{ \sum_{i=1}^{m \times n} q_i |\nabla_i k| + \frac{\tau}{2} \sum_{i=1}^{m \times n} (v_i^{k+1} - k_i + t_i^k)^2 \right\}, \quad (38)$$

对于最小化问题 (38), 可以使用关于  $k$  和  $q$  的 ADMM 方法进行求解. 其中  $q^k$  的更新可以在已知  $k^k$  的情况下, 通过 (37) 式来实现.  $k^k$  的更新可以通过求解下面的最小化问题进行实现:

$$\min_k \left\{ \sum_{i=1}^{m \times n} q_i^k |\nabla_i k| + \frac{\tau}{2} \sum_{i=1}^{m \times n} (v_i^{k+1} - k_i + t_i^k)^2 \right\}. \quad (39)$$

最小化问题(39)可以通过Chambolle投影算法[44]进行求解,这样便可得到更新后的 $(v^{k+1}, k^{k+1})$ .然后,根据(27)和(28)式更新 $\lambda^k$ .迭代终止条件一般为使得两次迭代结果满足条件(40)或者达到最大迭代次数.

$$\frac{\|u^{k+1} - u^k\|_2}{\|u^k\|_2} < \varepsilon, \quad (40)$$

其中 $\varepsilon$ 是一个正的小量,表示容许误差.

根据上面的分析,求解该模型的详细数值算法如下.

**算法 1** 基于空间自适应非凸正则项全变差相干斑噪声抑制算法

输入: 观测图像  $f$ , 最大迭代次数  $K$ , 迭代步长  $\delta$ , 正则化参数  $\lambda$ , 等效视数  $L$ , 滤波窗口大小  $r$ , 惩罚参数  $\tau$ , 误差  $\varepsilon$ , 时间步长  $\delta t$ ;

输出: 待恢复图像  $u$ ;

- 1: 初始化  $k = 0, v^k = k^k = \log f, t^k = 0$ ;
- 2: 初始化权重函数  $q^k = \frac{\alpha \lambda^k}{1 + \alpha |\nabla k^k|}$ ;
- 3: for  $k = 1 : K$  {
- 4: for iterNewton=1:maxNewton {
- 5:
 
$$v^k = v^{k-1} - \frac{L(1 - e^{(g^{k-1} - v^{k-1})}) + \tau(v^{k-1} - k^{k-1} + t^{k-1})}{Le^{(g^{k-1} - v^{k-1})} + \tau};$$
- 6: }
- 7:  $u^k = e^{v^k}$ ;
- 8: if  $\left(\frac{\|u^k - u^{k-1}\|_2}{\|u^{k-1}\|_2} < \varepsilon\right)$  {
- 9: return  $u^k$ ;
- 10: }
- 11: else {
- 12: 更新调节变量  $t^k = v^k + t^{k-1}$ ;
- 13: 初始化变量  $p^k = 0$ ;
- 14: for iterChambolle=1:maxChambolle {
- 15: 计算变量  $p^k$  的散度  $\text{div} p^k$ ;
- 16: 更新变量  $p^k = \frac{p^k + \delta t \nabla(\text{div} p^k - \tau t^k)}{1 + \delta t / q^{k-1} |\text{div} p^k - \tau t^k|}$ ,  $\delta t$  为时间步长;
- 17: }
- 18: 计算  $k^k = t^k - \frac{\text{div} p^k}{\tau}$ ;

- 19: 更新权重函数  $q^k = \frac{\alpha \lambda^k}{1 + \alpha |\nabla k^k|}$ ;
- 20: 更新调节变量  $t^k = t^k + v^k - k^k$ ;
- 21: if  $(S(v^k) \leq \gamma)$  {
- 22:  $\lambda^k = \lambda^{k-1}$ ;
- 23: }
- 24: else {
- 25:  $\tilde{\lambda}^k = \lambda^{k-1} - \delta(S(v^k) - \gamma)$ ;
- 26:  $\lambda^k = \frac{1}{r^2} \sum_{j \in \Omega_r}(\tilde{\lambda}^k)$ ;
- 27: }
- 28: }
- 29: }

### 3.4 评价指标

为了评价不同模型的噪声抑制效果,对于有原始图像的测试图像,采用信噪比(signal-to-noise ratio, SNR)和峰值信噪比(peak signal-to-noise ratio, PSNR)作为质量评价指标;对于真实SAR图像,由于没有原始图像,所以采用结构相似度(structural similarity, SSIM)[45,46]作为质量评价指标.为了说明不同模型的边缘保持能力,采用边缘保持指数(edge preserving index, EPI)[47]作为评价指标,EPI越大说明算法边缘保持能力越强.

SNR, PSNR的定义分别如下:

$$\text{SNR}(X, Y) = 10 \log_{10} \left( \frac{\|X - \bar{X}\|_2^2}{\|X - Y\|_2^2} \right), \quad (41)$$

$$\text{PSNR}(X, Y) = 10 \log_{10} \left( \frac{|\max X|^2}{\|X - Y\|_2^2} \right), \quad (42)$$

其中  $X$  和  $Y$  分别表示原始图像和去噪后的图像,  $\bar{X}$  表示图像  $X$  的均值. SNR 和 PSNR 的取值越大,说明噪声抑制效果越好.

SSIM 的定义 [45] 如下:

$$\text{SSIM}(X, Y) = [l(X, Y)]^\alpha \cdot [c(X, Y)]^\beta \cdot [s(X, Y)]^\gamma, \quad (43)$$

其中  $X$  和  $Y$  是参与比较的图像,  $l(\cdot)$ ,  $c(\cdot)$  和  $s(\cdot)$  分别是亮度、对比度和结构比较函数. SSIM 的取值范围为 0—1, SSIM 值越接近 1 表示噪声抑制效果越好.

EPI 的定义如下:

$$\text{EPI} = \frac{\sum \sqrt{[p_o(i, j) - p_o(i + 1, j)]^2 + p_o(i, j) - p_o(i, j + 1)^2}}{\sum \sqrt{[p_i(i, j) - p_i(i + 1, j)]^2 + p_i(i, j) - p_i(i, j + 1)^2}}, \quad (44)$$

其中  $p_i(i, j)$  为输入图像在点  $(i, j)$  的灰度值,  $p_o(i, j)$  为输出图像在点  $(i, j)$  的灰度值.

## 4 数值试验

### 4.1 参数设置

首先给出用于数值试验的原始图像, 如图 1 所示, 其中第一行为仿真图像, 第二行为真实 SAR 图像 [48]. 本节使用 Lena 作为测试图像, 分别添加等效视数  $L = 6, 13, 20$  的 Gamma 噪声, 误差  $\varepsilon = 0.0001$ , 时间步长  $\delta t = 1/5$ , Newton 迭代次数为 5, Chambolle 迭代次数为 10, 并用 SNR 作为评

价指标. 以下所有实验均是基于 Matlab 2010 a, 并且在同一台机器上完成.

#### 4.1.1 迭代步长 $\delta$

测试迭代步长  $\delta$  对最终噪声抑制结果的影响. 设置初始化  $\lambda = L$ , 滤波窗口  $r = 17$ , 惩罚参数  $\tau = 2$ , 辅助常量  $\alpha = 2.5$ . 迭代步长  $\delta$  从 1 变化到 40, 噪声抑制图像的 SNR 随  $\delta$  的变化趋势如图 2 所示. 从图 2 可以看出, 当  $L = 6$  时, SNR 几乎没有变化; 当  $L = 13, 20$  时, SNR 虽然有所增加, 但是增加幅度不大. 所以迭代步长对最终滤波结果影响不大.

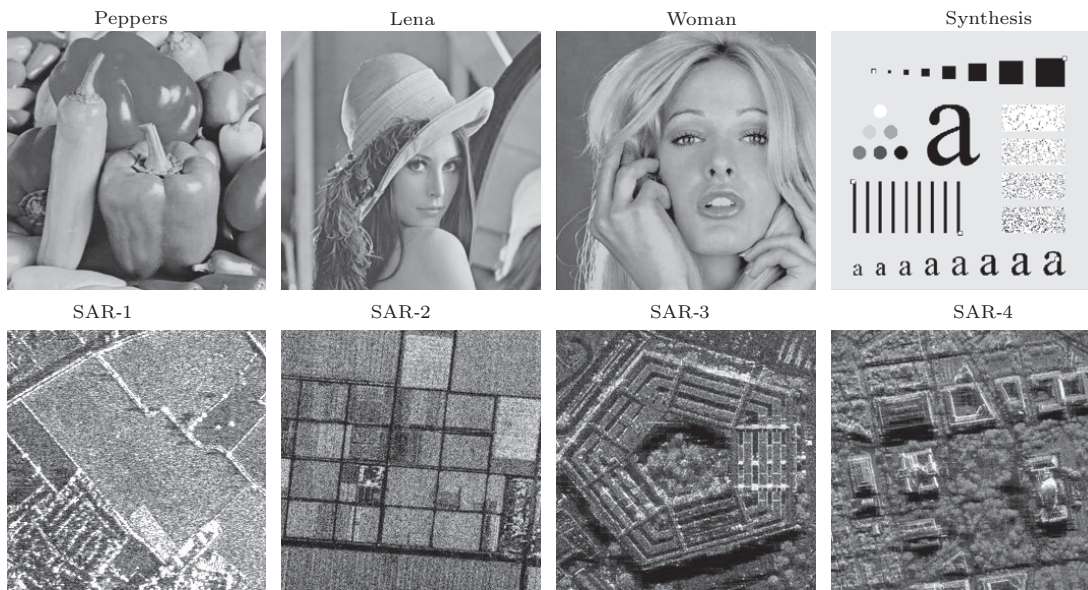


图 1 用于试验的原始图像




图 2 SNR 随迭代步长  $\delta$  的变化趋势

#### 4.1.2 初始正则化参数 $\lambda$

为了设置最优的初始正则化参数  $\lambda$ , 固定  $\delta = 5, r = 17, \tau = 2, \alpha = 2.5$ , 让初始化  $\lambda$  的取值在区间  $[1, 3]$ , SNR 随  $\lambda$  的变化如图 3 所示. 从

图 3 可以看到, 随着  $\lambda$  的增加, SNR 出现了先增大后减少的趋势, 对于不同的  $L$ , SNR 的最大值都出现在  $\lambda$  的大小在 1.5 到 2 之间. 为了测试的方便, 在后面的测试过程中, 初始正则化参数  $\lambda$  的大小都设置为 1.7.

#### 4.1.3 滤波窗口大小 $r$

测试滤波窗口大小  $r$  对噪声抑制效果的影响. 首先设置  $\delta = 5, \lambda = 1.7, \tau = 2, \alpha = 2.5$ , 滤波窗口大小  $r \in \{9, 11, 13, 15, 17, 19, 21, 23, 25\}$ , SNR 随  $r$  变化的趋势如图 4 所示. 从图 4 可以看出, 随着滤波窗口  $r$  的增加, SNR 也不断增加, 但是增加的幅度不断减少. 这是因为随着滤波窗口不断增大, 窗口内所含的像素点个数增加, 能够更加准确地调整正则化参数, 从而更好地控制噪声抑制程度. 但

是,随着滤波窗口不断增加,所含像素点个数越来越多,正则化参数的局部特征变得弱化,所以SNR增加幅度不断减少.由于过大的滤波窗口不仅增加计算量,而且使得正则化参数的局部性趋于全局性,所以在后面的试验过程中,滤波窗口大小都设置为17.




图3 SNR随初始 $\lambda$ 的变化趋势




图4 SNR随滤波窗口大小 $r$ 的变化趋势

#### 4.1.4 辅助常量 $\alpha$

考察辅助常量 $\alpha$ 对噪声抑制效果的影响.首先设置 $\delta = 5$ ,  $\lambda = 1.7$ ,  $\tau = 2$ ,  $r = 17$ ,  $\alpha$ 从1变到5, SNR随 $\alpha$ 的变化趋势如图5所示.从图5可以看出,随着 $\alpha$ 的增加,SNR能够快速达到其最大值,对于不同的等效视数 $L$ , $\alpha$ 的取值略有不同,对于 $L$ 的取值为6, 13和20时, $\alpha$ 相应的值分别为2, 2.5和3.

#### 4.1.5 惩罚参数 $\tau$

考察惩罚参数 $\tau$ 对噪声抑制效果的影响.首先设置 $\delta = 5$ ,  $\lambda = 1.7$ ,  $r = 17$ ,对于 $L$ 分别为6, 13和20时, $\alpha$ 相应的值分别为2, 2.5和3, $\tau$ 从1变到10, SNR随 $\tau$ 的变化趋势如图6所示.从图6可以看出,

惩罚参数 $\tau$ 对最终噪声抑制结果影响不大,从而不会出现由于惩罚参数 $\tau$ 选择不当造成噪声抑制结果不稳定的现象.




图5 SNR随辅助常量 $\alpha$ 的变化趋势




图6 SNR随惩罚参数 $\tau$ 的变化趋势

## 4.2 噪声抑制效果比较

针对图1中的仿真图像,分别添加等效视数 $L \in \{6, 13, 20\}$ 的Gamma噪声,然后分别使用SATVM, NRSNR和SATVMNR三种模型进行相干斑噪声抑制试验. SATVM模型的参数设置为:初值正则化参数为0.1,迭代步长为40,滤波窗口为17; NRSNR模型的参数设置为:正则化参数为1,对于 $L$ 分别为6, 13和20时,惩罚参数 $\tau$ 和辅助常量 $\alpha$ 的设置分别为10, 3, 2和3, 3.5, 5. SATVMNR模型的参数设置为:初始正则化参数为1.7,迭代步长为5,滤波窗口大小为17,对于 $L$ 分别为6, 13和20时,惩罚参数 $\tau$ 和辅助常量 $\alpha$ 的设置分别为10, 10, 9和2, 2.5, 3.图1中4幅仿真图像在不同等效视数情况下的噪声抑制评价指标的结果如表1所示.图7显示了在 $L = 13$ 时,三个模型相干斑噪声抑制结果的可视效果.模型的运行时间是基于

Matlab 自带 tic, toc 命令测量得到, 为了避免由于系统自身造成的误差, 运行时间均采用分别运行 10 次, 然后取平均值获得.

针对图 1 中的真实 SAR 图像, 使用和仿真图像相同的参数设置, 三种模型的相干斑噪声抑制评价指标结果如表 2 所示, 可视效果如图 8 所示.

从表 1 和表 2 可以看出, SATVMNR 模型不论是仿真图像还是真实 SAR 图像的噪声抑制效果和边缘保持能力都优于 SATVM 模型和 NRSNR 模型. 相比于 NRSNR 模型, SATVMNR 模型除了利用了非凸正则项保持图像的边缘、纹理, 而且能够根据像素点所在的区域自适应地调整噪声的抑制程度, 对于同质区域进行更多的光滑操作, 而对于边缘、纹理区域少做甚至不做光滑操作, 从而能够更好地保持边缘、纹理信息; 相比于 SATVM 模型, SATVMNR 模型不仅能够根据图像的区域自适应地控制噪声的抑制程度, 而且利用了非凸正则项更好地保持边缘、纹理的优点, 从而获得了比 SATVM

模型更好的噪声抑制效果. 从表 1 和表 2 还可以看出, 算法的运行效率受到图像噪声强度和图像自身的影响. 总体而言, 本文提出的算法具有更高的运行效率. 从图 7 和图 8 可以看出, SATVM 模型的噪声抑制结果不同程度地出现了“阶梯”现象, 在噪声强度较大的情况下, 一些边缘、纹理附近的噪声抑制程度不足, 主要是因为强噪声情况下, 容易引起边缘、纹理判断失准, 将噪声作为边缘进行处理, 从而造成噪声抑制不足的情况; 相比于 SATVM 模型, NRSNR 模型获得了更好的可视效果, 但是会出现整体噪声抑制不足的情况, 主要是因为噪声抑制过程中正则化参数为常量, 不能根据像素点所在位置进行自适应调整; SATVMNR 模型的可视效果要优于 NRSNR 模型和 SATVM 模型, 主要是由于 SATVMNR 模型充分利用了非凸正则项和空间自适应正则化参数的优点, 从而提高了相干斑噪声抑制的整体效果.

表 1 三种模型针对仿真图像噪声抑制的评价指标

评价指标	模型	等效视数											
		Peppers			Lena			Woman			Synthesis		
		6	13	20	6	13	20	6	13	20	6	13	20
SNR	噪声图像	0.15	3.45	5.34	0.31	3.62	5.51	-3.45	-0.14	1.73	-3.71	-0.40	1.50
	SATVM	9.46	12.90	14.83	9.11	12.07	14.08	6.83	9.15	11.05	3.80	6.94	9.61
	NRSNR	11.01	13.34	15.00	10.75	13.35	14.05	7.98	9.24	10.33	7.88	9.23	11.45
	SATVMNR	<b>11.67</b>	<b>13.98</b>	<b>15.10</b>	<b>11.20</b>	<b>13.45</b>	<b>14.59</b>	<b>8.52</b>	<b>10.65</b>	<b>11.73</b>	<b>8.46</b>	<b>10.92</b>	<b>12.12</b>
PSNR	噪声图像	12.63	15.93	17.82	13.55	16.86	18.75	11.00	14.31	16.18	9.80	13.11	15.02
	SATVM	21.93	25.37	27.31	22.35	25.31	27.32	21.29	23.60	25.51	17.31	20.45	23.13
	NRSNR	23.48	25.82	27.47	23.99	26.59	27.29	22.43	23.69	24.78	21.39	22.74	24.96
	SATVMNR	<b>24.14</b>	<b>26.46</b>	<b>27.58</b>	<b>24.44</b>	<b>26.69</b>	<b>27.83</b>	<b>22.98</b>	<b>25.10</b>	<b>26.19</b>	<b>21.97</b>	<b>24.43</b>	<b>25.63</b>
EPI	SATVM	0.54	0.60	0.65	0.10	0.26	0.36	0.21	0.44	0.54	0.3	0.47	0.68
	NRSNR	0.61	0.67	0.72	0.26	0.43	0.63	0.29	0.66	0.74	0.35	0.65	0.72
	SATVMNR	<b>0.65</b>	<b>0.68</b>	<b>0.76</b>	<b>0.36</b>	<b>0.50</b>	<b>0.68</b>	<b>0.40</b>	<b>0.67</b>	<b>0.79</b>	<b>0.35</b>	<b>0.67</b>	<b>0.74</b>
时间/s	SATVM	10.05	7.17	5.73	11.00	7.08	6.10	10.12	7.50	6.25	10.78	9.26	<b>7.03</b>
	NRSNR	1.97	2.23	4.62	2.95	4.42	<b>6.03</b>	2.16	3.54	12.14	10.51	<b>6.44</b>	9.81
	SATVMNR	<b>0.65</b>	<b>1.08</b>	<b>4.54</b>	<b>0.73</b>	<b>1.20</b>	6.10	<b>0.58</b>	<b>0.94</b>	<b>4.97</b>	<b>0.77</b>	9.96	12.20



图7 三种模型对仿真图像相干斑噪声抑制的可视效果

表2 三种模型对真实 SAR 图像抑制的评价指标

评价指标	模式	SAR-1	SAR-2	SAR-3	SAR-4
SSIM	SATVM	0.44866	0.53393	0.69649	0.75474
	NRSNR	0.50343	0.52124	0.70754	0.7386
	SATVMNR	<b>0.56124</b>	<b>0.57498</b>	<b>0.72322</b>	<b>0.7654</b>
EPI	SATVM	0.2980	0.3013	0.3817	0.4291
	NRSNR	0.3107	0.3035	0.3819	0.4389
	SATVMNR	<b>0.3127</b>	<b>0.3310</b>	<b>0.3827</b>	<b>0.4942</b>
时间/s	SATVM	0.3125	0.2752	0.3274	0.2617
	NRSNR	0.3265	0.2882	0.3141	0.2582
	SATVMNR	<b>0.2791</b>	<b>0.2356</b>	<b>0.2306</b>	<b>0.2369</b>

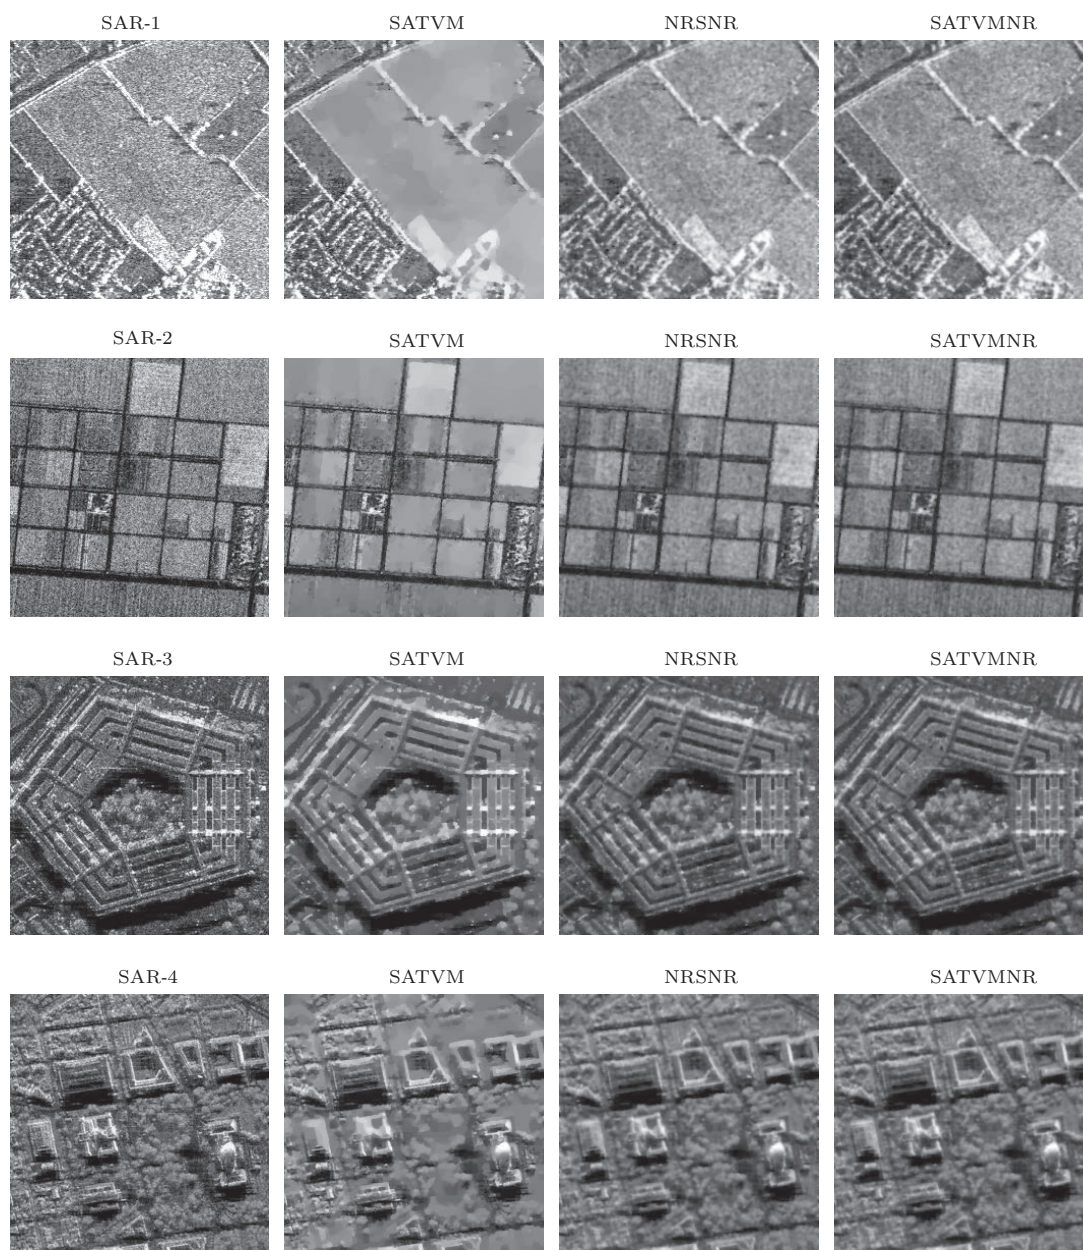


图8 三种模型对真实 SAR 图像相干斑噪声抑制的可视效果

## 5 结 论

本文结合非凸正则项和空间自适应正则化参数提出了一种新的全变差相干斑噪声抑制模型. 该模型利用非凸正则项能够更好地保持边缘、纹理细节的特点, 同时可以根据像素点所在的区域, 自适应地调整正则化参数, 合理地控制噪声抑制的程度, 从而获得更好的相干斑噪声抑制效果. 对仿真图像和真实 SAR 图像的数值试验结果表明, 该模型的噪声抑制效果要优于仅使用非凸正则项或者空间自适应正则化参数的模型. 该模型的提出对相

干成像系统图像的解释和应用具有重要意义.

感谢西安电子科技大学韩雨博士和解放军第三军医大学陈代强博士在论文完成过程中的有益讨论, 并提供代码用于测试比较; 感谢 Zhou Zhang 博士提供代码用于模型性能检测比较; 感谢美国 Sandia 国家实验室提供样本图像.

## 参考文献

- [1] Wu Y L, Wu Z S 2014 *Chin. Phys. B* **23** 037801
- [2] Basak K, Manjunatha M, Dutta P K 2012 *Med. Biol. Eng. Comput.* **50** 547
- [3] Ji W J, Tong C M 2013 *Chin. Phys. B* **22** 020301

- [4] Ma C, Gu H, Su W M, Li C Z 2014 *Acta Phys. Sin.* **63** 028403 (in Chinese) [马超, 顾红, 苏卫民, 李传中 2014 物理学报 **63** 028403]
- [5] Argenti F, Lapini A, Bianchi T, Alparone L 2013 *IEEE Geosci. Remote Sens. Magaz.* **1** 6
- [6] Abbott J G, Thurstone F L 1979 *Ultrasonic Imaging* **1** 303
- [7] Chen S, Zhao H C, Zhang S N, Chen Y 2013 *Acta Phys. Sin.* **62** 218405 (in Chinese) [陈思, 赵慧昌, 张淑宁, 陈勇 2013 物理学报 **62** 218405]
- [8] Jiang Z H, Huang S X, You X B, Xiao Y G 2014 *Chin. Phys. B* **23** 050302
- [9] Jiang Z H, Huang S X, Shi H Q, Zhang W, Wang B 2011 *Acta Phys. Sin.* **60** 108402 (in Chinese) [姜祝辉, 黄思训, 石汉青, 张伟, 王彪 2011 物理学报 **60** 108402]
- [10] Lee J S 1980 *IEEE Trans. Pattern Anal. Mach. Intell.* **PAMI-2** 165
- [11] Frost V S, Stiles J A, Shanmugan K S, Holtzman J C 1982 *IEEE Trans. Pattern Anal. Mach. Intell.* **PAMI-4** 157
- [12] Kuan D T, Sawchuk A A, Strand T C, Chavel P 1985 *IEEE Trans. Pattern Anal. Mach. Intell.* **PAMI-7** 165
- [13] Sun Z G, Han C Z 2010 *Acta Phys. Sin.* **59** 3210 (in Chinese) [孙增国, 韩崇昭 2010 物理学报 **59** 3210]
- [14] Donoho D L 1995 *IEEE Trans. Inform. Theory* **41** 613
- [15] Sveinsson J R, Benediktsson J A 2003 *IEEE Trans. Geosci. Remote Sens.* **41** 2404
- [16] Perona P, Malik J 1990 *IEEE Trans. Pattern Anal. Mach. Intell.* **12** 629
- [17] Yu Y J, Acton S T 2002 *IEEE Trans. Image Process.* **11** 1260
- [18] Aja-Fernández S, Alberola-López C 2006 *IEEE Trans. Image Process.* **15** 2694
- [19] Liu G J, Zeng X P, Tian F C, Li Z Z, Chaibou K 2009 *Signal Process.* **89** 2233
- [20] Rudin, L, Lions P L, Osher S 2003 *Geometric Level Set Methods in Imaging, Vision, and Graphics* (New York: Springer) pp103–119
- [21] Aubert G, Aujol J F 2008 *SIAM J Appl. Math.* **68** 925
- [22] Shi J, Osher S 2008 *SIAM J. Imaging Sci.* **1** 294
- [23] Bioucas-Dias J M, Figueiredo M A T 2009 *IEEE Int. Conf. Image Processing* Cairo, Egypt, November 7–10 2009 p3717
- [24] Bioucas-Dias J M, Figueiredo M A T 2010 *IEEE Trans. Image Process.* **19** 1720
- [25] Huang Y M, Ng M K, Wen Y W 2009 *SIAM J. Imaging Sci.* **2** 20
- [26] Steidl G, Teuber T 2010 *J. Math. Imaging Vis.* **36** 168
- [27] Yun S, Woo H 2012 *IEEE Trans. Image Process.* **21** 2523
- [28] Woo H, Yun S 2012 *IEEE Trans. Image Process.* **21** 1701
- [29] Han Y, Feng X C, Baciú G, Wang W W 2013 *Pattern Recognition* **46** 989
- [30] Chen D Q, Cheng L Z 2012 *IEEE Trans. Image Process.* **21** 1650
- [31] Wang X D, Feng X C, Huo L G 2012 *Acta Automat. Sin.* **38** 444 (in Chinese) [王旭东, 冯象初, 霍雷刚 2012 自动化学报 **38** 444]
- [32] Chen D Q, Cheng L Z 2014 *J. Comput. Appl. Math.* **257** 29
- [33] Li J C, Ma Z H, Peng Y X, Huang B 2013 *Acta Phys. Sin.* **62** 099501 (in Chinese) [李金才, 马自辉, 彭宇行, 黄斌 2013 物理学报 **62** 099501]
- [34] Sun Z G 2013 *Acta Phys. Sin.* **62** 180701 (in Chinese) [孙增国 2013 物理学报 **62** 180701]
- [35] Nikolova M, Ng M K, Tam C P 2010 *IEEE Trans. Image Process.* **19** 3073
- [36] Kreutz-Delgado K, Murray J F, Rao B D, Engan K, Ng M K, Zhang W K 2003 *Neural Comput.* **15** 349
- [37] Aubert G, Blanc-Féraud L, March R 2004 *SIAM J. Numer. Anal.* **42** 1128
- [38] Nikolova M, Ng M K, Zhang S, Ching W K 2008 *SIAM J. Imaging Sci.* **1** 2
- [39] Han Y, Wang W W, Feng X C 2012 *Pattern Recognition* **45** 363
- [40] Louchet C, Moisan L 2011 *SIAM J. Imaging Sci.* **4** 651
- [41] Shen J H, Jung Y M 2006 *Appl. Math. Opt.* **53** 331
- [42] Xiao L, Huang Z, Wei Z 2010 *EURASIP J. Adv. Signal Process.* **2010** 490384
- [43] Afonso M, Bioucas-Dias J, Figueiredo M 2010 *IEEE Trans. Image Process.* **19** 2345
- [44] Chambolle A 2004 *J. Math. Imaging Vis.* **20** 89
- [45] Wang Z <https://ece.uwaterloo.ca/~z70wang/research/ssim/> [May 15 2012]
- [46] Wang Z, Bovik A C, Sheikh H R, Simoncelli E P 2004 *IEEE Trans. Image Process.* **13** 600
- [47] Zhang H, Wang C, Zhang B, Wu F, Yan D M 2009 *High-Resolution SAR Image Target Recognition* (Beijing: Science Press) pp43–44 (in Chinese) [张红, 王超, 张波, 吴樊, 闫冬梅 2009 高分辨率 SAR 图像目标识别 (北京: 科学出版社) 第 43—44 页]
- [48] Sandia National Laboratories <http://www.sandia.gov/radar/imageryku.html> [August 5 2011]

# Spatially adapted total variation model with nonconvex regularizer based speckle reduction\*

Li Jin-Cai<sup>1)†</sup> Peng Yu-Xing<sup>1)</sup> Zhu Min<sup>1)</sup> Chen Peng<sup>2)</sup>

1) (School of Computer Science, National University of Defense Technology, Changsha 410073, China)

2) (Department of Information Engineering, Zhoukou Vocational and Technical College, Zhoukou 466000, China)

( Received 31 March 2014; revised manuscript received 6 May 2014 )

## Abstract

Total variation is a hot point of research on speckle reduction. The nonconvex regularizer can better preserve or even enhance the information about the edges of an image. Spatially adaptive regularization parameters can reasonably control the level of speckle reduction according to the region in which the pixels are, and improve the speckle reduction effect. In this paper, we present a new total variation model for speckle reduction by integrating nonconvex regularizer and spatially adaptive regularization parameters. In order to solve the model, a new algorithm is designed based on Newton's method, augmented Lagrange multiplier, alternating direction method of multipliers, and iteratively reweighted method. The numerical examples demonstrate that the proposed model can obtain the better speckle reduction effect.

**Keywords:** nonconvex regularizer, total variation, speckle reduction, spatially adaptive regularization parameters

**PACS:** 95.75.Mn, 42.30.Va, 42.30.Sy

**DOI:** [10.7498/aps.63.189501](https://doi.org/10.7498/aps.63.189501)

---

\* Project supported by the National Basic Research Program of China (Grant No. 2014CB340303) and the National High Technology Research and Development Program of China (Grant No. 2013AA01A213).

† Corresponding author. E-mail: [lijincai@nudt.edu.cn](mailto:lijincai@nudt.edu.cn)