

基于最优非线性扩散的快速相干斑抑制算法研究

郑世超¹, 冯文森², 牛建伟¹

(1. 北京航空航天大学计算机学院虚拟现实技术与系统国家重点实验室, 北京 100191;
2. 北京科技大学自动化学院, 北京 100083)

摘要: 合成孔径雷达(Synthetic Aperture Radar, SAR)图像相干斑去噪一直以来都是 SAR 图像处理的一项关键技术. 本文提出一种基于最优非线性扩散的快速相干斑抑制算法, 该算法使用最近提出的基于可训练非线性扩散的图像复原框架, 并针对合成孔径雷达强度图像, 结合相干斑噪声的统计特性, 训练非线性扩散过程中的滤波器参数和响应函数参数. 实验结果表明, 该算法性能与 PPBit, SAR-BM3D 等主流相干斑去噪算法性能相当甚至更优; 同时与这些算法相比, 该算法计算效率能够提高 75% 以上, 并且适于并行运算实现.

关键词: 合成孔径雷达强度图像; 相干斑去噪; 非线性扩散; 卷积神经网络

中图分类号: TP751.1 **文献标识码:** A **文章编号:** 0372-2112 (2017)12-2825-07

电子学报 URL: <http://www.ejournal.org.cn> **DOI:** 10.3969/j.issn.0372-2112.2017.12.001

A Fast and Accurate Despeckling Method with Optimized Nonlinear Diffusion

ZHENG Shi-chao¹, FENG Wen-sen², NIU Jian-wei¹

(1. State Key Laboratory of Virtual Reality Technology and Systems, School of Computer Science and Engineering, Beihang University, Beijing 100191, China; 2. School of Automation, University of Science and Technology Beijing, Beijing 100083, China)

Abstract: SAR (Synthetic Aperture Radar) despeckling is one of the key technologies in SAR image processing. This paper proposes an efficient despeckling algorithm based on optimized nonlinear diffusion model, which exploits the trainable nonlinear reaction diffusion framework. For the despeckling task, we train the parameters of linear filters and the influence functions, taking into account the speckle noise statistics of the intensity SAR image. Experimental results show that the proposed method provides comparable or even better results in comparison with PPBit and SAR-BM3D. Meanwhile, our proposed model is of high computation efficiency, and is well-suited for parallel computation.

Key words: SAR intensity image; despeckling; optimized nonlinear reaction diffusion model; convolutional neural networks

1 引言

合成孔径雷达(Synthetic Aperture Radar, SAR)图像相干斑去噪一直以来都是 SAR 图像处理的关键技术. 国内外专家对相干斑噪声抑制进行了大量的研究, 主要形成了四类方法: 空域算法、变换域算法(如小波域去噪算法)、非局部滤波和变分算法.

传统的空域滤波算法包括基于 LMMSE (Linear Minimum Mean Square Error) 准则^[1]的线性滤波器的

Lee、Frost 和 Kuan 等^[2-4]平稳滤波算法和基于滤波器窗内相干斑噪声局部非平稳假设的 MAP Gaussian 滤波和 Gamma MAP 滤波等^[5,6]非平稳滤波算法. 基于小波变换域的相干斑去噪算法主要有基于对数变换的小波变换域相干斑去噪算法^[7-10]以及近年来许多研究者^[11-15]提出的具有良好二维奇异性刻画能力和平移不变性质的新一代小波的相干斑去噪方法. 近年来非局部均值滤波已经广泛应用于 SAR 相干斑去噪中^[16,17], 贝叶斯非局部均值 (Bayesian NLM) 滤波算法^[18]、PPB 滤波滤波

算法 (Probabilistic Patch Based filter)^[19] 和 BM3D (Block-Matching 3D) 算法^[20] 等都是这类算法的代表. 另外, 变分模型在相干斑去噪领域中也得到越来越广泛的应用. 总变分 (Total Variation, TV)^[21-23] 和总广义变分 (Total Generalized Variation, TGV)^[24] 被引入到图像处理领域.

目前, 效果较好的相干斑去噪算法主要是基于 NLM 的算法. 该类算法虽然能够取得较好的效果, 但算法计算效率较差. 针对这一问题, 本文提出了一种简便有效的降噪方法, 与当前主流的相干斑去噪方法相比, 该方法不仅具有很好的去噪性能而且其运算量较小. 我们采用最新提出的基于可训练非线性扩散^[25,26] 的图像复原框架进行相干斑噪声抑制, 这种模型可以理解成一种具有可训练激励函数的递归卷积神经网络.

本文首先对相干斑噪声和可训练非线性扩散过程进行简单介绍, 之后提出了基于可训练非线性扩散模型的 SAR 强度图像相干斑去噪方法. 在扩散过程中, 该模型使用的线性滤波器、影响函数等相关参数根据强度图像相干斑噪声的统计特性进行训练得到, 从而适用于相干斑去噪应用. 实验结果表明, 该算法性能与当前主流算法性能相当甚至更优, 同时具有很高的计算效率.

2 基本原理

本节我们首先对相干斑噪声和可训练非线性扩散过程^[25,26] 进行简单介绍.

2.1 相干斑噪声

假设 Y 是观测到 SAR 强度图像. 则 Y 可以表示为真实的图像强度 u 和相干斑噪声 η 之间的乘积:

$$Y = u\eta \quad (1)$$

注意到 L -视 SAR 强度图像的相干斑噪声 η 服从下面的 Gamma 分布

$$p(\eta) = \frac{1}{\Gamma(L)} L^L \eta^{L-1} e^{-L\eta} H(\eta) \quad (2)$$

其中, H 表示 Heaviside 函数, Γ 表示传统的 Gamma 函数.

2.2 可训练的非线性扩散过程

文献[25,26] 提出了一种基于非线性扩散的简便高效的图像复原框架. 这种框架在传统的非线性扩散模型基础上加入参数化的滤波器和非线性扩散函数, 称为时变非线性扩散模型, 如下所示

$$\begin{cases} \mathbf{u}_0 = \mathbf{f} \\ \mathbf{u}_{t+1} = \mathbf{u}_t - \sum_{i=1}^{N_k} \bar{\mathbf{k}}_i * \varphi_i^t(\mathbf{k}_i * \mathbf{u}_t) - \psi(\mathbf{u}_t, \mathbf{f}), 0 \leq t \leq T-1 \end{cases} \quad (3)$$

其中 \mathbf{u}_0 表示扩散过程的初始状态, \mathbf{k}_i^t 表示非线性滤波器, $\mathbf{k}_i * \mathbf{u}$ 表示图像 \mathbf{u} 与滤波器核 \mathbf{k}_i 的二维卷积, φ_i^t 表示非线性扩散函数, $\Psi(\mathbf{u}_t, \mathbf{f})$ 对应数据拟合项, N_k 表示滤波器个数, T 表示扩散步数. 假设模型的数据拟合项为 $D^t(\mathbf{u}, \mathbf{f})$, 则 $\Psi(\mathbf{u}_t, \mathbf{f})$ 一般选为 $\Psi(\mathbf{u}_t, \mathbf{f}) = \nabla_{\mathbf{u}} D^t(\mathbf{u}, \mathbf{f})$. 该模型中非线性扩散每一步中的参数都是不同的, 而且每一步的参数都需要通过一定的训练框架学习得到. 事实上, 文献[25,26] 所提出的非线性扩散过程和 FoE 模型关系^[27] 密切. FoE 模型一般求解的问题模型如下所示:

$$E(\mathbf{u}, \mathbf{f}) = \sum_{i=1}^{N_k} \sum_{p=1}^N \rho_i^t((\mathbf{k}_i^t * \mathbf{u})_p) + D(\mathbf{u}, \mathbf{f}) \quad (4)$$

其中 $\{\rho_i^t\}_{i=0}^{t=T-1}$ 为惩罚函数. 文献[25,26] 将上式改写成由若干个迭代步组成的梯度下降过程, 如式(3)所示, 同时优化每一步迭代中的参数.

非线性扩散过程的参数训练过程如下所述. 给定包含 S 组训练样本的训练数据集 $\{\mathbf{f}^s, \mathbf{u}_{gt}^s\}_{s=1}^S$, 其中 \mathbf{f}^s 为退化图像 (如噪声图像、低分辨率图像以及模糊图像等), \mathbf{u}_{gt}^s 对应真实图像. 训练框架采用某种损失函数 (本文采用 L_2 范数), 训练用于每一步扩散过程的模型参数集 Θ^t . 每一个扩散步的模型参数集 Θ^t 包含 λ 、线性滤波器参数和非线性扩散函数, 即 $\Theta^t = \{\lambda^t, \varphi_i^t, \mathbf{k}_i^t\}$. 训练框架可以描述为下面的优化问题:

$$\begin{cases} \min_{\Theta} L(\Theta) = \sum_{s=1}^S \mathcal{L}(\mathbf{u}_T^s, \mathbf{u}_{gt}^s) = \sum_{s=1}^S \frac{1}{2} \|\mathbf{u}_T^s - \mathbf{u}_{gt}^s\|_2^2 \\ \mathbf{u}_0^s = \mathbf{f}^s \\ \mathbf{u}_{t+1}^s = \mathbf{u}_t^s - \sum_{i=1}^{N_k} \sum_{j=1}^{N_k} \bar{\mathbf{k}}_i^t * \varphi_i^t(\mathbf{k}_j^t * \mathbf{u}_t^s) - \psi(\mathbf{u}_t^s, \mathbf{f}^s), \\ 0 \leq t \leq T-1 \end{cases} \quad (5)$$

其中, $\Theta = \{\Theta^t\}_{t=0}^{T-1}$. 这一优化问题可以使用 L-BFGS 算法或者随机梯度下降法来求解. 为了简便起见, 我们只用 Joint 训练框架同时训练扩散过程的模型参数. 相应的参数梯度 $\partial \mathbf{u}_t / \partial \Theta_t$ 可以表示为

$$\frac{\partial \mathcal{L}(\mathbf{u}_T, \mathbf{u}_{gt})}{\partial \Theta_t} = \frac{\partial \mathbf{u}_t}{\partial \Theta_t} \cdot \frac{\partial \mathbf{u}_{t+1}}{\partial \mathbf{u}_t} \dots \frac{\partial \mathcal{L}(\mathbf{u}_T, \mathbf{u}_{gt})}{\partial \mathbf{u}_T} \quad (6)$$

值得注意的是, 这一模型和卷积神经网络联系紧密. 非线性扩散过程的每一步迭代都包含与一组线性滤波器的卷积操作, 因此该扩散过程可以看作是一种特殊的卷积网络. 具体来说非线性扩散过程本质上是一种反馈卷积神经网络. 由于这种反馈操作, 该扩散过程应被归类为具有可训练激励函数的 Recurrent 网络^[28].

2.3 数据拟合项以及 Ipiano 优化算法

针对相干斑噪声, 我们采用 $D(\mathbf{u}) = \langle \mathbf{u} - \mathbf{Y} \cdot \log \mathbf{u}, 1 \rangle$ 作为式(5)中的数据拟合项. 然而, 如式(5)所示, 如

果我们取 $\Psi(\mathbf{u}, \mathbf{f}) = \nabla_{\mathbf{u}} D'(\mathbf{u}, \mathbf{f}) = 1 - \mathbf{f}/\mathbf{u}$, 则会存在以下问题: 在算法迭代中, 当 \mathbf{u} 非常接近零值时, $\Psi(\mathbf{u}, \mathbf{f})$ 的值可能会变得很大而导致梯度下降非常不稳定. 因此直接计算梯度下降 $1 - \mathbf{f}/\mathbf{u}$ 并不可行. 针对这一问题, 我们采用 Ipiano 算法对优化问题(式(5))进行求解, 该方法可以避免 $1 - \mathbf{f}/\mathbf{u}$ 的形式, 从而可以解决上述问题.

Ipiano 算法求解的问题模型为

$$\arg \min_{\mathbf{u}} F(\mathbf{u}) + G(\mathbf{u}) \quad (7)$$

其中函数 $F(\mathbf{u})$ 要求是光滑函数(可能非凸), $G(\mathbf{u})$ 要求是凸函数(可能非光滑). Ipiano 算法的更新规则如下

$$\mathbf{u}^{n+1} = (\mathbf{I} + \tau \partial G)^{-1}(\mathbf{u}^n - \tau \nabla F(\mathbf{u}^n)) \quad (8)$$

其中 τ 为迭代步长. $(\mathbf{I} + \tau \partial G)^{-1}(\bar{\mathbf{u}})$ 可以通过下面的优化问题获得

$$(\mathbf{I} + \tau \partial G)^{-1}(\bar{\mathbf{u}}) = \arg \min_{\mathbf{u}} \frac{\|\mathbf{u} - \bar{\mathbf{u}}\|_2^2}{2} + \tau G(\mathbf{u}) \quad (9)$$

3 用于相干斑去噪的最优化非线性扩散过程

3.1 用于相干斑去噪的非线性扩散过程

在这一小节, 我们提出一种用于相干斑去噪的最优化非线性扩散过程. 首先, 如式(5)所示, 最优化非线性扩散过程可以看作是在求解式(5)时, 只优化少量几步迭代步中的参数. 因此, 我们结合数据拟合项 $D(\mathbf{u}) = \langle \mathbf{u} - \mathbf{Y} \cdot \log \mathbf{u}, \mathbf{1} \rangle$, 构建以下 FoE 优化模型:

$$\arg \min_{\mathbf{u} > 0} E(\mathbf{u}) = \sum_{i=1}^{N_i} \sum_{p=1}^N \rho_i((\mathbf{k}_i * \mathbf{u})_p) + \lambda \langle \mathbf{u} - \mathbf{f} \log \mathbf{u}, \mathbf{1} \rangle \quad (10)$$

对比式(7), 我们可以得到

$$F(\mathbf{u}) = \sum_{i=1}^{N_i} \sum_{p=1}^N \rho_i((\mathbf{k}_i * \mathbf{u})_p), G(\mathbf{u}) = \lambda \langle \mathbf{u} - \mathbf{f} \cdot \log \mathbf{u}, \mathbf{1} \rangle$$

通过计算, 容易得到

$$\nabla F(\mathbf{u}) = \sum_{i=1}^{N_i} \bar{\mathbf{K}}_i \varphi_i(\mathbf{K}_i \mathbf{u}) \quad (11)$$

其中 $\mathbf{K}_i \in R^{N \times N}$ 是一个高度稀疏的矩阵, 表示图像 \mathbf{u} 与滤波器核 \mathbf{k}_i 的二维卷积, 即 $\mathbf{K}_i \mathbf{u} \Leftrightarrow \mathbf{k}_i * \mathbf{u}$. 将式(11)以卷积形式重写, 可得:

$$\nabla F(\mathbf{u}) = \sum_{i=1}^{N_i} \bar{\mathbf{k}}_i * \varphi_i(\mathbf{k}_i * \mathbf{u}) \quad (12)$$

其中 $(\bar{\mathbf{k}}_i)$ 通过将二维滤波器 \mathbf{k}_i 旋转 180 度得到, 即 $(\bar{\mathbf{K}}_i \mathbf{u}) \Leftrightarrow \bar{\mathbf{k}}_i * \mathbf{u}$. 另一个子问题 $(\mathbf{I} + \tau \partial G)^{-1}(\bar{\mathbf{u}})$ 的形式为:

$$(\mathbf{I} + \tau \partial G)^{-1}(\bar{\mathbf{u}}) = \arg \min_{\mathbf{u}} \frac{\|\mathbf{u} - \bar{\mathbf{u}}\|_2^2}{2} + \tau \lambda \langle \mathbf{u} - \mathbf{f} \log \mathbf{u}, \mathbf{1} \rangle \quad (13)$$

直接对式(13)求导即可得解为:

$$\hat{\mathbf{u}} = (\mathbf{I} + \tau \partial G)^{-1}(\bar{\mathbf{u}}) = \frac{\bar{\mathbf{u}} - \tau \lambda + \sqrt{(\bar{\mathbf{u}} - \tau \lambda)^2 + 4\tau \lambda \mathbf{f}}}{2} \quad (14)$$

其中, 当 $\mathbf{f} > 0$ 时 $\hat{\mathbf{u}}$ 始终为正, 这一更新准则可以保证在扩散过程中 $\mathbf{u} > 0$, 即保证 $\log \mathbf{u}$ 有意义. 因此, 针对相干斑降噪的扩散过程可以表示为:

$$\mathbf{u}_{t+1} = \frac{\bar{\mathbf{u}}_{t+1} - \lambda^{t+1} + \sqrt{(\bar{\mathbf{u}}_{t+1} - \lambda^{t+1})^2 + 4\lambda^{t+1} \mathbf{f}}}{2} \quad (15)$$

其中 $\bar{\mathbf{u}}_{t+1} = \mathbf{u}_t - \sum_{i=1}^{N_i} \bar{\mathbf{k}}_i^{t+1} * \varphi_i^{t+1}(\mathbf{k}_i^{t+1} * \mathbf{u}_t)$, 这里我们设置 $\tau = 1$.

本算法的处理步骤如图 1 所示, 其中针对第 t 步迭代的训练参数为 $\Theta_t = \{\Gamma^t, \Omega^t\}$, $\Gamma^t = (\varphi_i^t, \mathbf{k}_i^t)_{i=1}^{N_i}$, $\Omega^t = \lambda^t$.

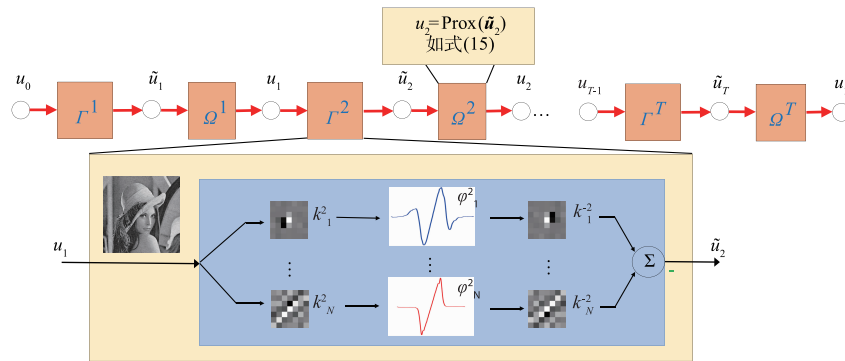


图1 本文算法流程图

3.2 参数梯度计算

在这一小节, 我们提出一种针对扩散过程的参数联合训练策略.

首先, 针对相干斑降噪的扩散函数, 我们需要计算损失函数 $\mathcal{L}(\mathbf{u}_T, \mathbf{u}_{gt}^s)$ 关于参数集 Θ_t 的梯度. 根据

$$\frac{\partial \mathcal{L}(\mathbf{u}_T, \mathbf{u}_{gt}^s)}{\partial \Theta_t} = \frac{\partial \mathbf{u}_T}{\partial \Theta_t} \cdot \frac{\partial \mathbf{u}_{t+1}}{\partial \mathbf{u}_t} \dots \frac{\partial \mathcal{L}(\mathbf{u}_T, \mathbf{u}_{gt}^s)}{\partial \mathbf{u}_T},$$

我们需要分别计算 $\frac{\partial \mathcal{L}(\mathbf{u}_T, \mathbf{u}_{gt}^s)}{\partial \Theta_t}$ 的各个组成部分, 即: $\frac{\partial \mathbf{u}_T}{\partial \Theta_t}$, $\frac{\partial \mathbf{u}_{t+1}}{\partial \mathbf{u}_t}$ 和 $\frac{\partial \mathcal{L}(\mathbf{u}_T, \mathbf{u}_{gt}^s)}{\partial \mathbf{u}_T}$. 基于式(5)使用的二次代价函数,

$\frac{\partial \mathcal{L}(\mathbf{u}_T, \mathbf{u}_{gt})}{\partial \mathbf{u}_T}$ 可以表示为

$$\frac{\partial \mathcal{L}(\mathbf{u}_T, \mathbf{u}_{gt})}{\partial \mathbf{u}_T} = \mathbf{u}_T - \mathbf{u}_{gt} \quad (16)$$

同时, $\frac{\partial \mathbf{u}_{t+1}}{\partial \mathbf{u}_t}$ 可以通过下式计算得到:

$$\frac{\partial \mathbf{u}_{t+1}}{\partial \mathbf{u}_t} = \frac{\partial \bar{\mathbf{u}}_{t+1}}{\partial \mathbf{u}_t} \cdot \frac{\partial \mathbf{u}_{t+1}}{\partial \bar{\mathbf{u}}_{t+1}} \quad (17)$$

结合式(15)可得:

$$\frac{\partial \bar{\mathbf{u}}_{t+1}}{\partial \mathbf{u}_t} = \mathbf{I} - \sum_{i=1}^{N_i} \overline{\mathbf{K}_i^{t+1}} \cdot \mathbf{A}_i \cdot \overline{(\mathbf{K}_i^{t+1})} \quad (18)$$

其中 \mathbf{A}_i 为对角矩阵 $\mathbf{A}_i = \text{diag}(\varphi_i'(z_1), \dots, \varphi_i'(z_p))$, (φ_i' 为 φ_i 的一阶导数), $\mathbf{z} = \mathbf{k}_i^{t+1} * \mathbf{u}_t$. 在实际应用中, 我们并不需要严格的构建矩阵 \mathbf{K}_i 和 $\overline{\mathbf{K}_i}$ ($\overline{\mathbf{K}_i}$ 与 $\bar{\mathbf{k}_i}$ 有关, $\overline{\mathbf{K}_i} \mathbf{u} \Leftrightarrow \bar{\mathbf{k}_i} * \mathbf{u}$). 而是通过图像 \mathbf{u} 和二维滤波器 $\mathbf{k}_i, \bar{\mathbf{k}_i}$ 的卷积操作计算得到.

接下来根据式(15)计算 $\frac{\partial \mathbf{u}_{t+1}}{\partial \bar{\mathbf{u}}_{t+1}}$, 可得:

$$\frac{\partial \mathbf{u}_{t+1}}{\partial \bar{\mathbf{u}}_{t+1}} = \text{diag}(z_1, \dots, z_p) \quad (19)$$

因此, 联合式(18)和式(19)可以得到 $\frac{\partial \mathbf{u}_{t+1}}{\partial \mathbf{u}_t}$.

考虑梯度 $\frac{\partial \mathbf{u}_t}{\partial \boldsymbol{\theta}_t}$, \mathbf{u}_t 关于 $(\varphi_i', \mathbf{k}_i')$ 的导数可以由下面两式计算得到:

$$\begin{aligned} \frac{\partial \mathbf{u}_t}{\partial \varphi_i'} &= \frac{\partial \bar{\mathbf{u}}_t}{\partial \varphi_i'} \cdot \frac{\partial \mathbf{u}_t}{\partial \bar{\mathbf{u}}_t} \\ \frac{\partial \mathbf{u}_t}{\partial \mathbf{k}_i'} &= \frac{\partial \bar{\mathbf{u}}_t}{\partial \mathbf{k}_i'} \cdot \frac{\partial \mathbf{u}_t}{\partial \bar{\mathbf{u}}_t} \end{aligned} \quad (20)$$

$\frac{\partial \mathbf{u}_t}{\partial \bar{\mathbf{u}}_t}$ 可以由类似式(19)的方法计算得到. 另外, \mathbf{u}_t 关于 λ^t 的梯度由式(21)得到

$$\frac{\partial \mathbf{u}_t}{\partial \lambda^t} = (z_1, \dots, z_p) \quad (21)$$

其中 $z = \frac{1}{2} \left[-1 + \frac{(\lambda^t - \bar{\mathbf{u}}_t) + 2\mathbf{f}}{\sqrt{(\bar{\mathbf{u}}_t - \lambda^t)^2 + 4\lambda^t \mathbf{f}}} \right]$. 在实际应用中, 为了保证在训练过程中 λ^t 为正, 我们设定 $\lambda = e^\beta$. 因此, 在实际编程过程中我们使用 $\frac{\partial \mathbf{u}_t}{\partial \beta_t}$ 取代 $\frac{\partial \mathbf{u}_t}{\partial \lambda^t}$. 此时 $\frac{\partial \mathbf{u}_t}{\partial \beta_t}$ 可以由式(22)表示:

$$\frac{\partial \mathbf{u}_t}{\partial \beta_t} = \frac{\lambda^t}{2} \left[-1 + \frac{(\lambda^t - \bar{\mathbf{u}}_t) + 2\mathbf{f}}{\sqrt{(\bar{\mathbf{u}}_t - \lambda^t)^2 + 4\lambda^t \mathbf{f}}} \right] \quad (22)$$

4 实验结果与分析

为了评估本文所提出方法的性能, 我们与四种很具有

代表性的图像去噪算法——增强的 Lee 滤波算法、DPAD 算法^[29]、PPBit 算法和 SAR-BM3D 算法进行对比. 对比实验使用图像降噪研究常用的测试图像集. 量化分析时采用峰值信噪比 PSNR(Peak Signal to Noise Ratio)和结构相似性指标 SSIM(the Structural Similarity Index)^[30]来衡量图像降噪的性能. 峰值信噪比 PSNR 的计算公式为

$$\text{PSNR} = 10 \log_{10} \frac{255 \cdot 255 \cdot N}{\|\mathbf{u} - \hat{\mathbf{u}}\|^2} \quad (23)$$

其中, N 表示图像像素个数, \mathbf{u} 表示无噪声图像, $\hat{\mathbf{u}}$ 表示降噪处理后的图像. 结构近似度量 SSIM 的计算公式为

$$\text{SSIM}(\hat{\mathbf{u}}, \mathbf{u}) = \frac{(2\mu_u \mu_{\hat{u}})(2\sigma_{u\hat{u}} + c_2)}{(\mu_u^2 + \mu_{\hat{u}}^2 + c_1)(\sigma_u^2 + \sigma_{\hat{u}}^2 + c_2)} \quad (24)$$

这里, $\mu_u, \mu_{\hat{u}}$ 表示图像 \mathbf{u} 和 $\hat{\mathbf{u}}$ 的平均值, σ_u 和 $\sigma_{\hat{u}}$ 表示各自的标准差. $\sigma_{u\hat{u}}$ 表示 μ_u 和 $\mu_{\hat{u}}$ 之间的协方差. 另外, 常数设置为 $c_1 = (0.01D)^2$, $c_2 = (0.03D)^2$, 其中 D 表示图像的动态范围(针对 8 比特图像, 动态范围是 255). SSIM 的值在 $[0, 1]$ 之间, 1 表示重构结果最好, 0 表示最差.

参考文献[25, 26], 我们在实验中选择扩散步数为 8 步、滤波器尺寸为 7×7 , 每一步的滤波器个数为 48 个, 训练使用的图像样本数为 400.

首先对单视图图像进行处理(如图 2 所示), 实验结果表明: 与增强的 Lee 滤波算法、DPAD 算法以及 PPBit 算法相比, 本文所提出的算法与 SAR-BM3D 算法的处理效果相当, 能够保留细节和较小的图像特征. 同时, 与 SAR-BM3D 算法相比, 本文所提出的算法能够获得更加清晰的边缘信息. 图 3 是 3 视图图像降噪处理的结果及其局部放大图. 对比可以发现, 在细节保持和几何结构保持方面, 本文算法的性能和 SAR-




图2 单视图图像降噪效果对比

BM3D 相当, 优于其他三种算法. 由于本文算法使用的扩滤波器和影响函数在训练时考虑了相干斑噪声的统计特性, 因此可以在去噪的同时有效地保持图像的结构特征.

在表 1 中概括了四种代表性视数 $L=1, 3$ 的降噪结果. 从表 1 中可以看出, 本文算法的指标优于其他几种算法. 这说明本文所提出的算法在降噪处理后的图像质量和图像特征保持方面更加出色. 在图 4 中, 我们同样给出了对真实 SAR 幅度图像的降噪处理结果.




图3 3视图图像降噪效果对比

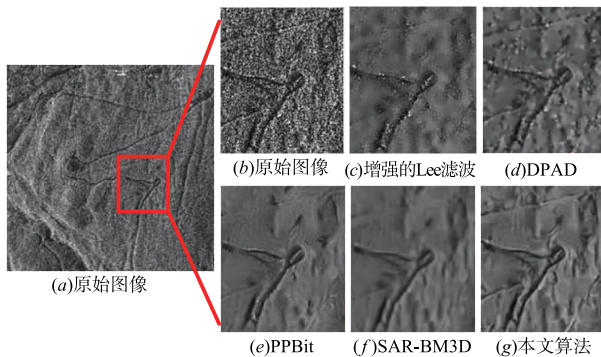


图4 单视SAR图像降噪效果对比

表 1 各种算法的 PSNR/SSIM 性能指标对比

	$L=1$	$L=3$
增强的 Lee 滤波	19.2266/0.3784	21.3911/0.5034
DPAD	22.5563/0.5681	23.1320/0.6332
PPBit	21.5511/0.4374	23.5735/0.5624
SAR-BM3D	22.5487/0.5512	24.6202/0.6524
本文算法	22.7236/0.5676	24.7661/0.6677

通过仔细的视觉效果对比, 我们发现本文算法处理后的图像保留了更多的图像细节特征与边缘信息.

由于本文所提出算法的运算量主要集中在图像的卷积操作, 因此其非常适用于并行实现. 我们在表 2 中给出了对两幅不同大小图像进行降噪处理的运算时间, 同时还给出了其他四种对比算法的处理时间. 四种对比算法通过 matlab 实现, 但核心部分通过 C 语言编译. 本文算法基于 matlab 实现. 表 2 同时还给出了本文所提出的算法通过 GPU 并行处理实现所需的运算时间. 通过对比可以发现, 本文所提出的算法所需的处理时间(尤其是在 GPU 并行运算的情况下)少于其他算法.

表 2 不同大小图像的降噪处理时间

	增强的 Lee 滤波	DPAD	PPBit	SAR-BM3D	本文算法
256×256	4.6	20.5	13.2	42.4	3.05(0.03)
512×512	17.8	82.3	48.9	169.1	9.33(0.09)

5 结束语

本文提出了一种简便高效的相干斑去噪算法, 该算法不仅具有出色的去噪性能而且计算效率高. 该算法采用最新提出的可训练非线性扩散模型, 并且根据相干斑噪声的统计特性对模型中的线性滤波器和影响函数进行优化设计. 该模型非常适用于 GPU 并行运算, 从而可以大大提升其运算效率. 实验结果表明, 与其他四种对比算法相比该相干斑去噪算法性能指标相当甚至更优, 并且本文所提算法计算效率远高于这两种算法.

参考文献

- [1] Kay S M. Fundamentals of Statistical Signal Processing: Estimation Theory [M]. Englewood Cliffs, NJ: Prentice Hall, 1993.
- [2] Lee J S. Digital image enhancement and noise filtering by use of local statistics [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 1980, 2(2): 165-168.
- [3] Frost V S, Stiles J A, et al. A model for radar images and its application to adaptive digital filtering of multiplicative noise [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 1992, 4(2): 157-166.
- [4] Kuan D T, Sawchuk A A, et al. Adaptive noise smoothing filter for images with signal-dependent noise [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 1985, 7(2): 165-177.

- [5] Kuan D T, Sawchuk A A, et al. Adaptive restoration of images with speckle[J]. *IEEE Transactions on Acoustics, Speech, and Signal Processing*, 1987, ASSP-35(3):373–383.
- [6] Lopes A, Nezry E, et al. Maximum a posteriori speckle filtering and first order texture models in SAR images[A]. *Proceedings of IEEE International Geoscience and Remote Sensing Symposium* [C]. New York, USA: IEEE, 1990. 2409–2412.
- [7] Guo H, Odegard J, et al. Wavelet based speckle reduction with application to SAR based ATD/R[A]. *Proceedings of IEEE International Conference on Image Processing*[C]. New York, USA: IEEE, 1994. 75–79.
- [8] Gagnon L, Jouan A. Speckle filtering of SAR images—a comparative study between complex wavelet-based and standard filters[A]. *Proceedings of International Society for Optical Engineering* [C]. USA: SPIE, 1997. 80–91.
- [9] Achim A, Tsakalides P, Bezarianos A. SAR image denoising via Bayesian wavelet shrinkage based on heavy-tailed modeling[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2003, 41(8):1773–1784.
- [10] Solb S, Eltoft T. Homomorphic wavelet-based statistical despeckling of SAR images[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2004, 42(4):711–721.
- [11] Achim A, Kuruoglu E E, Zerubia J. SAR image filtering based on the heavy-tailed Rayleigh model[J]. *IEEE Transactions on Image Processing*, 2006, 15(9):2686–2693.
- [12] Bhuiyan M I H, Ahmad M O, Swamy M N S. Spatially adaptive wavelet-based method using the cauchy prior for denoising the SAR images[J]. *IEEE Transactions on Circuits System Video Technology*, 2007, 17(4):500–507.
- [13] Bianchi T, Argenti F, Alparone L. Segmentation-based MAP despeckling of SAR images in the undecimated wavelet domain[J]. *IEEE Geoscience and Remote Sensing Letters*, 2008, 46(9):2728–2742.
- [14] Ranjani J J, Thiruvengadam S J. Generalized SAR despeckling based on DTCWT exploiting interscale and intrascale dependences[J]. *IEEE Geoscience and Remote Sensing Letters*, 2011, 8(3):552–556.
- [15] Argenti F, Bianchi T, Lapini A, Alparone L. Fast MAP despeckling based on laplacian-gaussian modeling of wavelet coefficients[J]. *IEEE Geoscience and Remote Sensing Letters*, 2012, 9(1):13–17.
- [16] Zhong H, Li Y, Jiao L C. SAR image despeckling using Bayesian nonlocal means filter with sigma preselection[J]. *IEEE Geoscience and Remote Sensing Letters*, 2011, 8(4):809–813.
- [17] Parrilli S, Poderico M, et al. A nonlocal SAR image denoising algorithm based on LLMMSE wavelet shrinkage[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2012, 50(2):606–616.
- [18] Kervrann C, Boulanger J, Coupe P. Bayesian non-local means filter, image redundancy and adaptive dictionaries for noise removal[A]. *Proceeding of International Conference on Scale Space Methods and Variational Methods in Computer Vision* [C]. Berlin, Germany: Springer, 2007. 520–532.
- [19] Deledalle C A, Denis L, Tupin F. Iterative weighted maximum likelihood denoising with probabilistic patch-based weights[J]. *IEEE Transactions on Image Processing*, 2009, 18(12):2661–2672.
- [20] Dabov K, Foi A, et al. Image denoising by sparse 3D transform-domain collaborative filtering[J]. *IEEE Transactions on Image Processing*, 2007, 16(8):2080–2095.
- [21] Aubert G, Aujol J F. A variational approach to removing multiplicative noise[J]. *SIAM Journal on Applied Mathematics*, 2008, 68(4):925–946.
- [22] Steidl G, Teuber T. Removing multiplicative noise by douglas-rachford splitting methods[J]. *Journal of Mathematical Imaging and Vision*, 2010, 36(2):168–184.
- [23] Yun S, Woo H. A new multiplicative denoising variational model based on the root transformation[J]. *IEEE Transactions on Image Processing*, 2012, 21(5):2523–2533.
- [24] Feng W, Lei H, Gao Y. Speckle reduction via higher order total variation approach[J]. *IEEE Transactions on Image Processing*, 2014, 23(4):1831–1843.
- [25] Chen Y, Pock T. Trainable nonlinear reaction diffusion: A flexible framework for fast and effective image restoration[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2016, PP(99):1–1.
- [26] Chen Y, Yu W, Pock T. On learning optimized reaction diffusion processes for effective image restoration[A]. *Proceedings of IEEE Conference on Computer Vision and Pattern Recognition* [C]. New York, USA: IEEE, 2015.
- [27] Roth S, Black M J. Fields of experts[J]. *International Journal of Computer Vision*, 2009, 82(2):205–229.
- [28] Graves A, Schmidhuber J. Offline handwriting recognition with multidimensional recurrent neural networks[A]. *Proceedings of 15th Conference and Workshop on Neural Information Processing Systems* [C]. London, UK: Springer, 2012. 545–552.
- [29] Aja-Fernandez S, Alberola-Lopez C. On the estimation of the coefficient of variation for anisotropic diffusion speck-

le filtering[J]. IEEE Transactions on Image Processing, 2006, 15(9):2694-2701.

- [30] Wang Z, Bovik A C. Image quality assessment: from error visibility to structural similarity[J]. IEEE Transactions on Image Processing, 2004, 13(4):600-612.

作者简介



郑世超 男,1986 年生于山东日照.现为北京航空航天大学计算机学院博士后.主要研究方向为遥感图像处理.
E-mail: jerryiszsc@163.com



冯文森 男,1986 年生于河南南阳.现为北京科技大学自动化学院教师博士后.主要研究方向为遥感图像处理、模式识别.
E-mail: sanmumuren@ustb.edu.cn



牛建伟 男,1969 年生于河南.现为北京航空航天大学计算机学院教授.主要研究方向为嵌入式与移动计算、移动视频处理.
E-mail: niujianwei@buaa.edu.cn