

中图分类号: TP391.41 文献标志码: A 文章编号: 1006-8961(2011)12-2199-07

论文索引信息: 王广学, 黄晓涛, 周智敏. SAR 图像尺度不变特征提取方法研究 [J]. 中国图象图形学报, 2011, 16(12): 2199-2205

# SAR 图像尺度不变特征提取方法研究

王广学, 黄晓涛, 周智敏

(国防科学技术大学电子科学与工程学院超宽带室, 长沙 410073)

**摘要:** 与光学图像相比, SAR 图像噪声干扰明显增强, 导致光学图像处理领域中常用的尺度不变特征提取算法的稳定性在 SAR 图像中明显下降。为此, 提出一种基于 Harris 算子的 SAR 图像尺度不变特征提取方法。该方法首先将单尺度图像特征点检测中具有良好稳定性的 Harris 算子拓展到多尺度图像域, 并结合 Harris 算子极值点的稳定性分析实现尺度不变特征定位, 以提高特征定位的稳定性。进而采用迭代滤波器取代传统卷积滤波器完成特征定位中所需高斯滤波操作, 以提高特征定位的速度。最后利用特征点邻域内的像素梯度信息完成了特征描述字的构造。SAR 图像实测数据验证表明, 与其他尺度不变特征提取算法相比, 本文算法具有更优的稳定性。

**关键词:** Harris 算子; 尺度不变特征; 迭代滤波器; SAR 图像处理

## SAR image scale invariant feature extraction algorithm

Wang Guangxue, Huang Xiaotao, Zhou Zhimin

(School of Electronic Science and Engineering, National University of Defense Technology, Changsha 410073 China)

**Abstract:** Because of the stronger noise, the stable performance of optical method degrades obviously in SAR image scale invariant feature extraction. To deal with it, we propose a new SAR image scale invariant feature extraction algorithm based on Harris operator. As well known, Harris operator has well stable performance in single scale image feature point detection. In this paper, we first adapt it to multi-scale image and select the features positions by analyzing the stability of Harris measure local maximum points. Then to improve the speed, the recursive Gaussian filter is designed to replace the convolution filter. At last, the feature descriptor is designed based on the gradient information of feature point neighborhood. Based on real SAR images, the experimental results show that an obviously stable performance improvement can be obtained through our algorithm.

**Keywords:** Harris operator; scale invariant feature; recursive filter; SAR image processing

## 0 引言

尺度不变特征是图像处理中一类非常重要的图像特征, 在图像配准、目标识别等领域有着广泛的应用前景<sup>[1-4]</sup>。然而与光学图像相比, SAR 图像噪声干扰明显增强, 导致光学图像处理领域常用尺度不

变特征提取算法的稳定性在 SAR 图像中明显下降, 为此需要研究新的适合高噪声 SAR 图像的尺度不变特征提取算法。尺度不变特征的提取由尺度不变特征定位和尺度不变特征描述字构造两部分构成, 以下分别进行介绍。

尺度不变特征定位的目的在于确定特征点在图像中的 3 维坐标(即图像  $x, y$  轴和图像尺度轴的坐

收稿日期: 2010-09-25; 修回日期: 2010-11-10

基金项目: 教育部新世纪优秀人才支持计划项目(NCET-07-0223); 国家自然科学基金项目(60972121)。

第一作者简介: 王广学(1981—), 男, 国防科技大学信息与通信工程专业博士研究生, 主要研究方向为 SAR 图像处理。

E-mail: wgxradar@126.com。

标),其关键在于设计具有平移、旋转、尺度不变性的特征点定位方法。众多文献研究表明<sup>[5-6]</sup>,与其他特征点检测算法相比,Harris 特征点检测算法对图像的平移、旋转和噪声都具有更强的稳定性。然而原始 Harris 算子只在图像原始尺度下进行特征点检测,导致其对图像的尺度变化非常敏感,图像的伸缩将使得由 Harris 算子提取的特征点不具有重复性,因而无法直接应用于尺度不变特征的定位处理。为了获得具有尺度不变特性的特征点检测算法,Lindeberge<sup>[7]</sup>通过对图像尺度变换的特性分析,提出基于多尺度图像域 LOG 算子 3 维邻域极值搜索的尺度不变特征点提取方法。在此基础上 Lowe<sup>[8-9]</sup>采用高斯差分算子(DOG 算子)近似取代 LOG 算子,以提高算法的运行速度,并将其应用到 SIFT 尺度不变特征提取算法中。随后,为了获得更快的运行速度,Bay<sup>[10]</sup>进一步提出基于积分图像的快速 Hessian 算子 3 维极值点搜索尺度不变特征定位方法,并将其应用于 SURF 尺度不变特征提取算法中。实测数据验证表明,以上各种算法虽然在光学图像中都取得了较好的效果,然而由于 LOG 算子、Hessian 算子的二阶微分特性受噪声影响较大,从而导致上述算法在高噪声 SAR 图像中的稳定性明显下降。

尺度不变特征描述字构造的目的在于对提取出的特征点进行描述,其关键在于为每个特征点构造稳定、唯一的描述矢量,以提高后续处理中特征匹配的正确率。Bay 等人<sup>[10]</sup>分析指出,与基于特征点邻域内像素灰度信息以及基于邻域空间频率信息构造的特征描述字相比,基于特征点邻域内梯度信息构造的特征描述字具有更优的性能。

鉴于以上分析,提出一种基于 Harris 算子的 SAR 图像尺度不变特征提取算法。为了利用 Harris 算子在图像平移、旋转和噪声变化下的良好稳定性,首先将 Harris 算子扩展到多尺度图像域,在多尺度图像的每个尺度平面上搜索 Harris 算子的  $xy$  2 维邻域极值,以提取候选特征点。在此基础上,利用 Harris 函数值构建一个极值稳定性测度函数,并在多尺度图像的 3 维邻域内对候选特征点进行稳定性测度函数非最大值抑制,以在剔除多余候选特征点的同时,实现更高稳定度的尺度不变特征定位。同时,采用迭代滤波器取代传统卷积滤波器完成了特征定位中所需高斯滤波操作,以提高特征定位速度。最后,基于特征点邻域内梯度信息完成了特征描述字的构造,以便于后续特征匹配处理。SAR 图像实

测数据验证表明,与现有尺度不变特征提取算法相比,本文算法的稳定性有了明显提高。

## 1 图像尺度变换特性分析

此处主要对图像尺度变换的性质进行简要介绍,为本文算法提供理论基础。图像尺度变换是指将图像与某变换核进行卷积运算,而得到各种尺度图像的变换。文献[11]指出,在线性、平移不变性、旋转不变性等假设条件下,高斯函数是唯一满足要求的变换核。因此,对于给定的图像  $I(x, y)$ ,其尺度变换  $L(x, y, \sigma)$  定义为

$$L(x, y, \sigma) = G(x, y, \sigma) * I(x, y) \quad (1)$$

式中  $G(x, y, \sigma) = \frac{1}{2\pi\sigma^2} e^{-\frac{x^2+y^2}{2\sigma^2}}$ ,  $\sigma$  为尺度参数,  $\sigma$  取不同值,即可得到一组多尺度图像序列。设图像  $I'$  与  $I$  图像满足  $I(x, y) = I'(tx, ty)$ ,其尺度变换可表述为

$$L'(x', y', \sigma') = G(x', y', \sigma') * I(x', y') \quad (2)$$

设式(1)(2)中空间 2 维变量  $(x, y)$  与尺度参数  $\sigma$  满足  $x' = tx, y' = ty, \sigma' = t\sigma$ ,并定义  $L(x, y, \sigma)$  的尺度归一化导数为  $D_{i_1 \dots i_m}(x, y, \sigma) = \sigma^m L_{i_1 \dots i_m}(x, y, \sigma)$ ,  $i_1 \dots i_m \in (x, y)$ ,  $D_{i_1 \dots i_m}(x, y, \sigma)$  为  $L(x, y, \sigma)$  对  $i_1 \dots i_m$  的  $m$  阶导数。则由卷积性质可知:

$$L(x, y, \sigma) = L'(x', y', \sigma') \quad (3)$$

$$D_{i_1 \dots i_m}(x, y, \sigma) = D'_{i_1 \dots i_m}(x', y', \sigma')$$

即图像尺度变换及其归一化导数具有尺度不变性,此特性即为尺度不变特征定位的基础。

## 2 算法实现

### 2.1 尺度不变特征定位

Harris 算子是由 Harris 和 Stephen 提出的一种基于图像局部灰度变化特性分析的特征点提取算子<sup>[12]</sup>。其具体表达式如下:

$$\begin{cases} R = \det(M) - k \cdot \text{tr}^2(M) \\ M = G(x, y, \sigma) \otimes \begin{bmatrix} X^2 & XY \\ XY & Y^2 \end{bmatrix} \end{cases} \quad (4)$$

式中  $X, Y$  分别为  $x, y$  方向的梯度,  $G(\cdot)$  为高斯平滑窗,  $k$  为给定常数(0.04~0.06),  $M$  为与自相关函数相联系的矩阵,其特征值对应于自相关函数原点处的一阶曲率。文献[12]分析表明当某点  $R$  的

取值较小,则该点处于灰度均匀区域,若取值为负,则该点在边缘上,若为大于某阈值  $T$  的局部最大值,则该点处的像素灰度在各个方向变化都很大,可视作特征点。如前文所述,对于图像旋转、平移、加噪等变化,Harris 算子提取的特征点具有最优的稳定性。为了进一步使提取的特征点具有尺度不变性,以满足尺度不变特征定位要求,首先将其拓展到多尺度图像域。

设  $L(x,y,\sigma_i)$  为由原始图像  $I(x,y)$  经过尺度变换得到的一组多尺度图像序列,  $n$  为尺度采样个数,尺度参数序列  $\sigma_i = s^i \sigma_0$ ,  $\sigma_0$  为起始尺度,  $s$  为尺度变化因子(可取为  $1.2^{[6]}$ )。定义  $L(x,y,\sigma_i)$  中各尺度平面内的 Harris 算子为

$$\begin{cases} R_m(x,y,\sigma_i) = \det(M_m(x,y,\sigma_i)) - \\ \quad ktr^2(M_m(x,y,\sigma_i)) \\ M_m(x,y,\sigma_i) = G(x,y,h\sigma_i) \otimes \begin{bmatrix} D_x^2 & D_x D_y \\ D_x D_y & D_y^2 \end{bmatrix} \end{cases} \quad (5)$$

式中,  $G(\cdot)$  为高斯平滑窗,  $h$  为经验常量(可取为  $1.4^{[6]}$ ),  $D_x$ 、 $D_y$  分别为  $L(x,y,\sigma_i)$  在  $x,y$  方向的尺度归一化一阶偏导数。由前述图像尺度变换性质可知,  $R_m(x,y,\sigma_i)$  具有尺度不变性,从而其在任意尺度平面  $\sigma_i$  内的  $xy$  2 维邻域极值点在具有旋转、平移不变性的同时亦具有尺度不变性。然而,实验分析表明,  $R_m(x,y,\sigma_i)$  中大量极值点的  $x,y,\sigma_i$  3 维坐标仅存在较小的差别,如此大量的相近极值点将会大大增加后续匹配处理的运算量,降低匹配的准确率为此需要将极值点作为候选特征点,做进一步的筛选。针对此问题,文献[6]提出在原有 2 维极值搜索的基础上,进一步筛选出在尺度维邻域具有 LOG 算子最大值的候选点作为最终的特征点,然而由于 LOG 算子与 Harris 算子的特性差异,以上方法的稳定性受到限制。为此,我们基于以下两条准则进行特征点筛选,以提高特征定位稳定性。

1) 噪声稳定性 即对于一个具有相近 3 维坐标的 2 维极值点集合,最终选择的特征点需具有最佳的噪声鲁棒性。

2) 尺度不变性 即对于不同分辨率的原始图像,最终选择的特征点集应满足式(3)所示变换关系。

显然,当极值点的 Harris 算子值与其邻域像素相比相差越大,该极值点就越稳定。此外,随着

$L(x,y,\sigma_i)$  及  $M_m(x,y,\sigma_i)$  计算过程中所含高斯滤波器尺度的增加,Harris 算子值也将更加稳定,因此大尺度平面内的极值点稳定性更高。根据以上分析,定义如下极值点稳定性测度函数:

$$\begin{cases} S(x_i,y_i,\sigma_i) = \\ \quad k_\sigma(\sigma_i) [R_m(x_i,y_i,\sigma_i) - R_{nmax}(x_i,y_i,\sigma_i)] \\ R_{nmax}(x_i,y_i,\sigma_i) = \\ \quad \max \left\{ R(x,y,\sigma_i) \left| \begin{array}{l} x \in \{x_i \pm 1, x_i\} \\ y \in \{y_i \pm 1, y_i\} \\ (x,y) \neq (x_i,y_i) \end{array} \right. \right\} \end{cases} \quad (6)$$

式中,  $(x_i,y_i,\sigma_i)$  为极值点坐标,为  $R_m$  极值点 Harris 算子值,  $R_{nmax}$  为相应邻域内 Harris 算子的最大值。  $k_\sigma(\sigma_i)$  为尺度加权因子(通过实验分析将其设为  $\sigma_i^4$ )。根据  $R_m$  的尺度不变性,可以证明  $S(x,y,\sigma_i)$  的极值点位置亦具有尺度不变性。因此,基于  $S(x,y,\sigma_i)$  对候选特征点进行邻域非最大值抑制,既可得到具有最佳噪声稳定性的极值点,又满足尺度不变性的要求。综上所述,将尺度不变特征定位方法归纳如下:

1) 对原始图像进行图像变换得到一组多尺度图像,并计算各尺度平面内的 Harris 算子值  $R_m(x_i,y_i,\sigma_i)$ ;

2) 对任意尺度平面  $\sigma_i$ , 搜索  $R_m(x_i,y_i,\sigma_i)$  的  $xy$  2 维邻域极值点作为候选特征点(邻域大小设为  $3 \times 3$ );

3) 对任意候选特征点  $(x_i,y_i,\sigma_i)$ , 计算其相应的极值稳定性测度函数值  $S(x,y,\sigma_i)$ , 选取  $xy\sigma$  3 维邻域内具有最大  $S(x,y,\sigma_i)$  值的候选点作为最终特征点(邻域大小设为  $3 \times 3 \times 3$ )。

## 2.2 迭代高斯滤波器

需要指出的是特征定位的过程中,多尺度图像序列  $L(x,y,\sigma_i)$  及矩阵序列  $M_m(x,y,\sigma_i)$  的计算分别包含二维高斯滤波操作  $G(x,y,\sigma_i)$ 、 $G(x,y,h\sigma_i)$ 。由于传统基于卷积实现的高斯滤波器的计算量与滤波尺度成正比,因而采用此种滤波器将会导致运算量随着  $\sigma_i$  的增大迅速增加,从而降低特征定位的速度。设图像大小为  $M \times N$ , 以后续实验所设参数为例:  $n = 8, \sigma_0 = 1, h = 1.4, s = 1.2$ , 高斯卷积滤波器截止长度取为尺度参数  $\sigma_i$  的 8 倍加 1。则完成所有 2 维高斯滤波  $G(x,y,\sigma_i)$ 、 $G(x,y,h\sigma_i)$  所需的乘法次数  $Mul$  和加法次数  $Add$  分别为

$$\begin{aligned} Mul &= Mul_1 + Mul_2 = (284 + 382)MN \\ Add &= Add_1 + Add_2 = (268 + 366)MN \end{aligned} \quad (7)$$

针对上述问题, 决定设计迭代滤波器进行高斯滤波以提高算法速度。由于 2 维高斯滤波器的可分离性, 只需设计 1 维高斯迭代滤波器。首先根据高斯函数傅里叶变换的实对称性, 假设 1 维迭代滤波器由 1 个前向因果滤波器与一个后向非因果滤波器串联构成, 如图 1 所示。




图 1 迭代高斯滤波器  
Fig. 1 Recursive Gaussian filter

并且其传输函数  $H(z)$  满足:

$$\begin{cases} H(z) = H_+(z) \cdot H_-(z) \\ H_+(z) = \frac{d-1}{d-z^{-1}} \cdot \frac{d^*-1}{d^*-z^{-1}} \\ H_-(z) = \frac{d-1}{z-d} \cdot \frac{d^*-1}{z-d^*} \end{cases} \quad (8)$$

表 1  $G(x, y, \sigma_i), G(x, y, h\sigma_i) 0 \leq i \leq 7$  迭代滤波器系数  
Tab. 1 Coefficient of  $G(x, y, \sigma_i), G(x, y, h\sigma_i) 0 \leq i \leq 7$

	$G(x, y, \sigma_i) 0 \leq i \leq 7$								$G(x, y, h\sigma_i) 0 \leq i \leq 7$							
	$\sigma_0$	$\sigma_1$	$\sigma_2$	$\sigma_3$	$\sigma_4$	$\sigma_5$	$\sigma_6$	$\sigma_7$	$\sigma_0$	$\sigma_1$	$\sigma_2$	$\sigma_3$	$\sigma_4$	$\sigma_5$	$\sigma_6$	$\sigma_7$
a	-0.75	-0.88	-1.01	-1.23	-1.23	-1.34	-1.43	-1.51	-0.99	-1.11	-1.22	-1.32	-1.42	-1.50	-1.57	-1.64
b	0.25	0.30	0.35	0.39	0.45	0.50	0.55	0.60	0.34	0.39	0.44	0.49	0.54	0.59	0.64	0.69
c	0.500	0.41	0.33	0.17	0.21	0.16	0.12	0.09	0.35	0.28	0.22	0.17	0.13	0.10	0.07	0.05

由图 2 可知迭代滤波器脉冲响应接近于理想高斯脉冲响应, 通过实验验证亦表明采用上述迭代滤波器与采用高斯卷积滤波器相比, 算法的性能并无明显变化。同时由式(9)结合 2 维高斯滤波的可分离性可知, 采用迭代滤波器完成所有 2 维高斯滤波

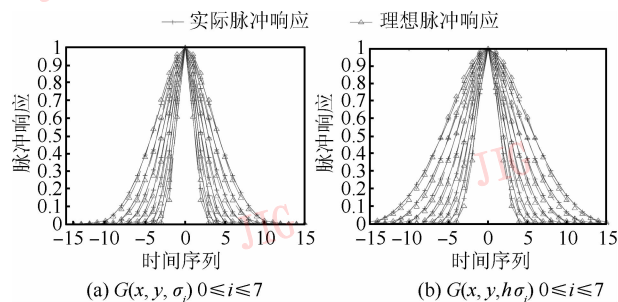


图 2 迭代高斯滤波器响应

Fig. 2 Response of recursive gaussian filter

式中,  $d, d^{-1}, d^*, d^{*-1}$  为滤波器的 4 个极点 ( $|d| > 1$ ), 显然  $H(z)$  亦具有实对称性。式(8)化简可得:

$$\begin{cases} H_+(z) = \frac{c}{1+az^{-1}+bz^{-2}} \xleftarrow{Z} v(n) = \\ \quad cs(n) - av(n-1) - bv(n-2) \\ H_-(z) = \frac{c}{1+az+bz} \xrightarrow{Z} y(n) = \\ \quad cx(n) - ay(n+1) - by(n+2) \end{cases} \quad (9)$$

式中  $s(n)$  为原始信号,  $a = |d|^{-2}, b = -2\text{Re}(d), c = 1 + a + b$ 。对于任意给定高斯滤波器  $G(z|\sigma)$ , 定义如下代价函数:

$$L = \int_{-\pi}^{+\pi} (G(z|\sigma) - H(z))^2 \Big|_{z=e^{j\Omega}} d\Omega \quad (10)$$

采用非线性 Levenberg-Marquardt 法使代价函数  $L$  最小的极点值  $d$ , 即可得到使迭代滤波器响应与理想高斯滤波器最为接近所需的迭代系数  $a, b, c$ 。表 1 所示为采用上述方法根据实验参数设置所得  $G(x, y, \sigma_i), G(x, y, h\sigma_i)$  对应的迭代滤波器系数。图 2 所示为相应迭代滤波器的脉冲响应。

所需的计算量如式(11)所示, 明显小于高斯卷积滤波器, 且只与滤波器个数有关, 而与滤波器的尺度  $\sigma_i$  大小无关。

$$\begin{aligned} Mul &= Mul_1 + Mul_2 = (96 + 96)MN \\ Add &= Add_1 + Add_2 = (80 + 80)MN \end{aligned} \quad (11)$$

### 2.3 尺度不变特征描述

由第 1 节介绍可知, 与基于特征点邻域内像素灰度信息以及基于邻域空间频率信息构造的特征描述字相比, 基于特征点邻域内梯度信息构造的特征描述字具有更优的性能。为此亦采用此种方法构建特征描述字, 其具体过程如下。

为了保持尺度不变特征描述的旋转不变性, 首先定义特征点的主方向。设  $(x_f, y_f, \sigma_f)$  为某个特征点的 3 维坐标, 以该点为中心在多尺度图像  $L(x, y, \sigma_i)$  的尺度平面  $\sigma_f$  上取半径为  $6\sigma_f$  圆形邻域。

在此邻域内以  $\sigma_f$  为采样步长,分别计算各采样点处的梯度(即分别求  $L(x,y,\sigma_i)$  在  $x,y$  方向偏导数  $L_x, L_y$ ),并将所得结构乘以一个方差为  $2.5\sigma_f$  的高斯距离加权函数,如图 3 所示(颜色深度代表高斯加权)。在  $[-\pi,\pi]$  内搜索一个长度为  $\frac{\pi}{3}$  的连续区间,使得梯度方向位于该区间的所有采样点的梯度和具有最大模值,该梯度和方向即视为特征点的主方向。

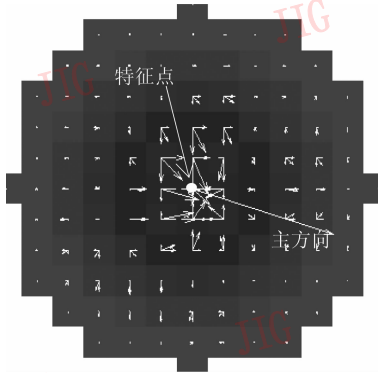


图 3 特征点主方向定义

Fig. 3 Definition of feature point direction

将坐标轴旋转到特征点的主方向,在  $L(x,y,\sigma_i)$  的尺度平面  $\sigma_f$  上取  $20\sigma_f \times 20\sigma_f$  方形邻域,并将划分成 16 个  $5\sigma_f \times 5\sigma_f$  的子区域。在方形邻域内以  $\sigma_f$  为采样步长,分别计算各采样点处梯度值,并将其与一个高斯距离加权函数相乘得到加权后的梯度值,高斯权函数的方差取为  $4\sigma_f$ ,如图 4 所示(颜色深度代表高斯加权)。在各子区域内根据加权梯度值构造特征矢量  $V_j = (\sum L_x, \sum L_y, \sum |L_x|, \sum |L_y|)$ ,将 16 个子区域的特征矢量依次组合并进行归一化,即可得到一个满足尺度、旋转、平移不变性的 64 维特征描述字。




图 4 特征描述字构造

Fig. 4 Design of feature description word

### 3 实验分析

为了验证本文方法的有效性,以下基于两组实测 SAR 图像数据将本文算法与光学领域常用的 SIFT 算法、SURF 算法进行实验比较。为了便于分析,通过门限设置使 3 种算法在同一场景中提取的特征点数大致相当。

表 2、表 3、图 5、图 6 为基于第 1 组图像数据(图像 1 和图像 2,大小为  $605 \times 825$ )及基于第 2 组图像数据(图像 3 和图像 4,大小为  $600 \times 1200$ )所得实验结果。由图 5 和图 6 可知两组 SAR 图像数据中都存在明显的噪声干扰。表 2 和表 3 中重复特征点定义为经手动配准后两幅图像中位置差小于 4 个像素的特征点对(如图 5 和图 6 中各圆心及正方形中心所示,圆圈和正方形大小代表各点特征尺度大小)。正确匹配特征点定义为采用经典最近邻向量法对各种算法所得尺度不变特征进行匹配所得结果中包含的重复特征点对(如图 5 和图 6 中各圆心所示)。实验所用计算机为 P4(3.0G)、编程语言为 Matlab7.0。

表 2 第 1 组图像数据实验结果

Tab. 2 Result of experiments on first images set

	特征点数				运行时间 /s
	图像 1	图像 2	重复	正确匹配	
SIFT 算法	50	50	13	6	13.313
SURF 算法	54	47	11	6	4.384
本文算法 (卷积高斯滤波)	54	53	27	14	41.175
本文算法 (迭代高斯滤波)	53	51	25	13	13.692

表 3 第 2 组图像数据实验结果

Tab. 3 Result of experiments on second images set

	特征点数				运行时间 /s
	图像 1	图像 2	重复	正确匹配	
SIFT 算法	50	50	13	6	18.516
SURF 算法	51	53	8	4	5.784
本文算法 (卷积高斯滤波)	51	53	24	12	59.482
本文算法 (迭代高斯滤波)	47	52	23	12	19.138

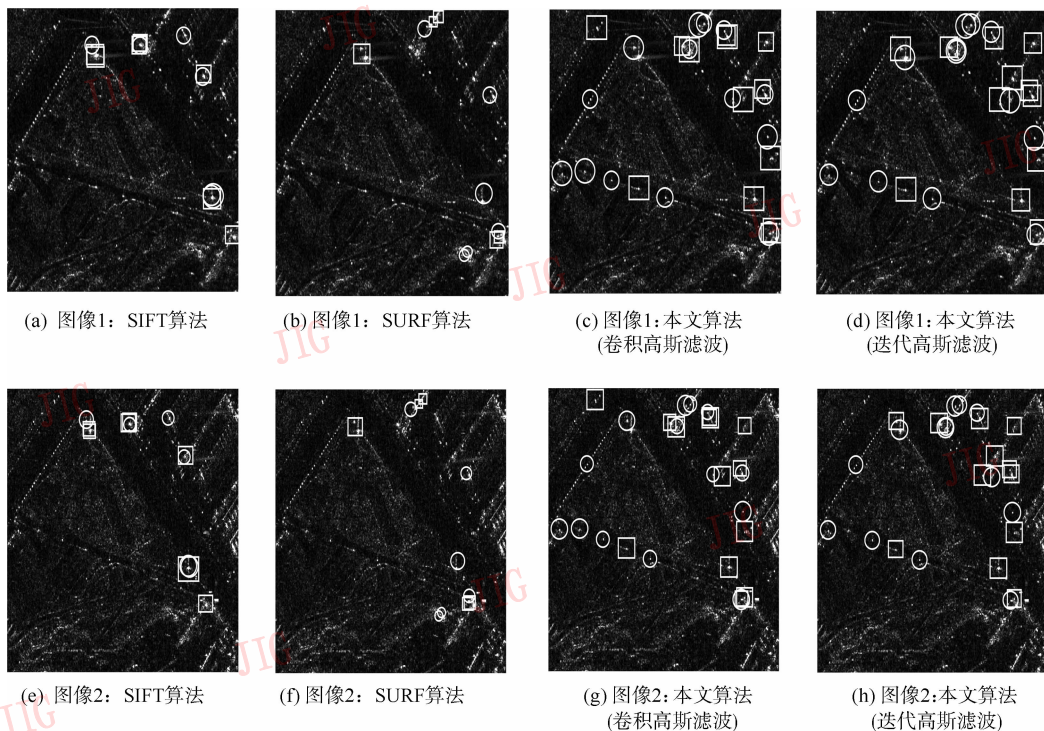


图 5 基于第 1 组图像数据的实验结果  
Fig. 5 Result of experiments on first images set

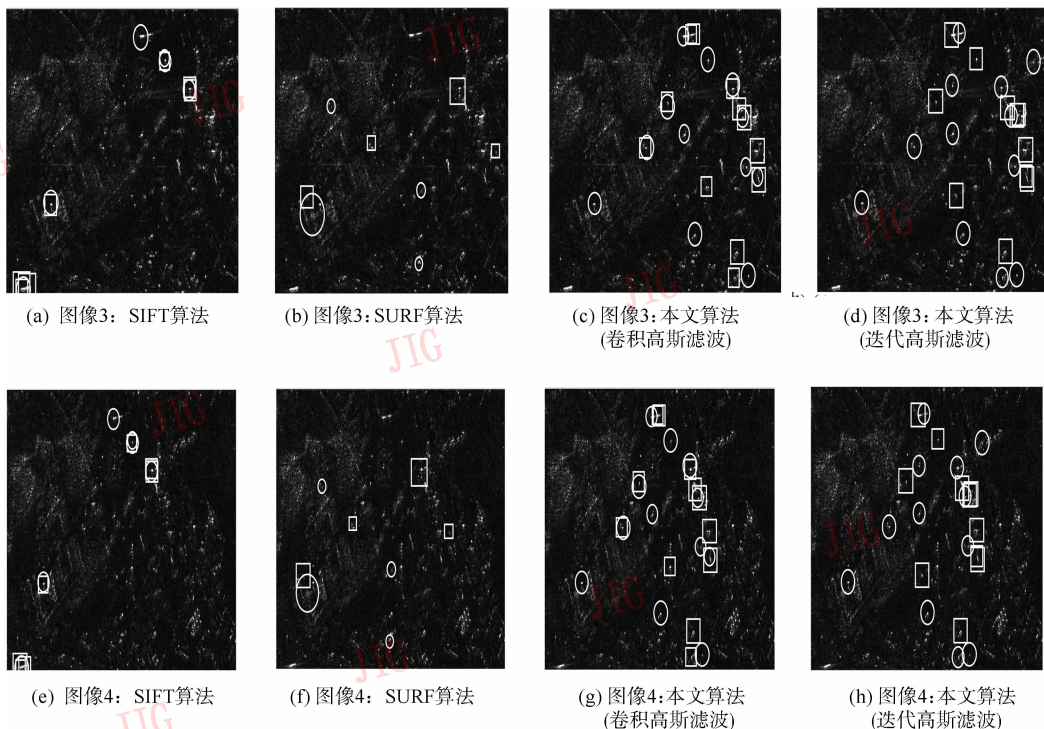


图 6 基于第 2 组图像数据的实验结果  
Fig. 6 Result of experiments on second images set

由表 2 和表 3 中重复特征点数目可知,所提算法中特征定位方法的稳定性明显高于 SIFT 和 SURF 算法。而由表中最终所得正确特征匹配点数可知本文算法的整体稳定性亦明显优于其他两种算法。并且由表中算法运行时间可知,本文算法通过采用迭代高斯滤波取代卷积高斯滤波可使本文算法的运算速度大大提高(与 SIFT 法接近),而算法稳定性基本保持不变。此外综合重复特征点数、正确特征匹配点数这两个参数可知,本文算法、SIFT 算法、SURF 算法中特征描述方法的稳定性大致相当,这是因为 3 种算法所采用特征描述方法的原理基本相同所致。

## 4 结 论

针对 SAR 图像中噪声干扰增强,使得光学领域常用尺度不变特征提取算法在 SAR 图像应用中稳定性较差的特点,通过对影响尺度不变特征提取算法稳定性的各项因素进行分析,提出一种基于 Harris 算子的尺度不变特征提取算法。该方法首先将单尺度图像特征点检测中具有良好稳定性的 Harris 算子拓展到多尺度图像域,并在多尺度图像的每个尺度平面上搜索 Harris 算子  $xy$  2 维邻域极值作为候选特征点;而后采用一个基于 Harris 函数值构建的极值稳定性测度函数对每一个候选特征点的稳定性进行测量,在此基础上选取最稳定的候选点作为最终尺度不变特征点,以提高尺度不变特征定位的稳定性。同时,为了提高特征定位处理的速度,采用迭代滤波器取代传统卷积滤波器完成了所需高斯滤波操作。算法最后基于特征点邻域内梯度信息完成了特征描述字的构造。实测 SAR 图像数据验证表明,本文算法的稳定性明显高于光学领域常用的 SIFT 算法和 SURF 算法,可较好地适应 SAR 图像尺度不变特征提取的需要。需要指出的是虽然通过采用迭代高斯滤波取代了卷积高斯滤波,使得算法的运行速度明显提高,但与 SURF 算法仍有明显差距,为此将在后续工作中研究更加高效的改进方法。

## 参考文献 (References)

- [ 1 ] Li Qiaoliang, Wang Guoyou. Robust scale-invariant feature matching for remote sensing image registration [ J ]. IEEE Geoscience and Remote Sensing Letters, 2009, 6(2) : 287-291.
- [ 2 ] Su Juan, Xu Qingsong, Zhu Jinghua. A scene matching algorithm based on SURF feature [ C ] // Proceedings of 2010 International Conference on Image Analysis and Signal Processing. Xiamen, Fujian: Huaqiao University, 2010: 434-437.
- [ 3 ] Zhao Jiong, Fan Yangyu, Fan Weitao. Fusion of global and local feature using KCCA for automatic target recognition [ C ] // Proceedings of Fifth International Conference on Image and Graphics. Xian, Shanxi: Northwest Polytechnical University, 2009: 958-962.
- [ 4 ] Geng Cong, Jiang Xudong. Face recognition using sift features [ C ] // Proceedings of 16th IEEE International Conference on Image Processing. Cairo, Egypt: IEEE Press, 2009: 3313-3316.
- [ 5 ] Schmid C, Mohr R, Bauckhage C. Evaluation of interest point detectors [ J ]. International Journal of Computer Vision 2000, 37(2) : 151-172.
- [ 6 ] Mikolajczyk K, Schmid C. Scale and affine invariant interest point detectors [ J ]. International Journal of Computer Vision 2004, 60(1) : 63-86.
- [ 7 ] Lindeberg T. Feature detection with automatic scale selection [ J ]. International Journal of Computer Vision, 1998, 30(2) : 79-116.
- [ 8 ] Lowe D G. Distinctive image features from scale-invariant key points [ J ]. The International Journal of Computer Vision, 2004, 60(2) : 91-110.
- [ 9 ] Lowe D G. Object recognition from local scale-invariant feature [ C ] // Proceedings of IEEE International Conference of Computer Vision. Kerkyra, Greece: IEEE Press, 1999: 1150-1157.
- [ 10 ] Bay H, Tuvellars T, Gool L V. SURF: speeded up robust feature [ C ] // Proceedings of the European Conference on Computer Vision. Graz, Austria: University of Liubljana, 2006: 404-417.
- [ 11 ] Lindeberg T. Scale-space theory: a basic tool for analysis structures at different scales [ J ]. Journal of Applied Statistics, 1994, 21(2) : 224-270.
- [ 12 ] Harris C, Stephen M. A combined corner and edge detector [ C ] // Processing of 4th Alvey Vision Conference. Manchester, England: University of Manchester, 1988: 147-151.