

文章编号:1001-9014(2011)02-0173-06

基于小波域 Fisher 分类器的 SAR 图像变化检测

辛芳芳, 焦李成, 王桂婷, 万红林

(西安电子科技大学 智能感知与图像理解教育部重点实验室和智能信息处理研究所, 陕西 西安 710071)

摘要: 给出了一种无监督 SAR 图像变化检测算法, 它不需要分布假设, 而是通过联合灰度直方图的分布特性进行判别。算法利用自适应边缘检测提取训练数据, 通过 Fisher 分类器对联合直方图进行判别分析, 得到不同小波层待检测点隶属度, 并根据邻域关系以及上下文进行融合, 得到最终检测结果。对真实 SAR 图像进行检测, 得到了较好的检测结果。

关 键 词:SAR 图像; 变化检测; Fisher 分类器; 小波变换

中图分类号:TP751.1 文献标识码:A

Change detection of SAR images based on wavelet domain Fisher classifier

XIN Fang-Fang, JIAO Li-Cheng, WANG Gui-Ting, WAN Hong-Lin

(Key Laboratory of Intelligent Perception and Image Understanding of Ministry of Education of China,
Institute of Intelligent Information Processing, Xidian University, Xi'an 710071, China)

Abstract: An unsupervised technique for detecting change area between two SAR images was proposed. The detection process is based on distribution property of the joint intensity histograms and need not distribution hypothesis. The algorithm uses adaptive edge detection to get training data. The joint intensity histograms in different levels are used to decide the membership degree of unlabeled points through Fisher classifier. The fusion model which considers the context relationship and inter-scale information improves the sensitivity. The simulation results of two real SAR images show that the algorithm is effective and has better detection results.

Key words: SAR images; change detection; Fisher classifier; wavelet transform

PACS: 84.40. Xb

引言

变化检测是识别目标状态差异或分析不同时间得到的同一地貌的信息来识别地物变化的技术。它是开展环境监控、土地利用/覆盖(LULC, land-use and land-cover)动态研究、森林覆盖和水域检测等方面的关键技术^[1]。如何有效避免乘性噪声, 准确地检测出图像变化区域已成为 SAR 图像变化检测的关键问题^[2~4]。

SAR 图像变化检测技术通常由三步组成, 分别是预处理, 图像比较和变化检测^[2]。预处理用于消除 SAR 图像噪声对后处理的影响, 增加差异影像中变化类和非变化类的可分性。相比差算子, 比算子得到的差异影像可分性更强^[5]。变化检测算法可分为

邻域不相关性算法和邻域相关性算法。邻域不相关性算法仅考虑图像单个点检测结果, 不受周围邻域影响, 如阈值法^[2,3], 这种算法会产生噪点, 并且边缘不平滑^[6]。为了解决这一问题, 提出了邻域相关检测算法^[7~9], 它通过假设像素点与邻域一定范围内的点存在关联, 提高检测性能。以上提出的算法^[2~9], 都是基于差异影像提出的, 针对的是图像一维灰度直方图。文献[10]通过对联合灰度直方图进行分割, 找到背景信息和图像变化信息, 得到遥感图像变化检测结果。但是, SAR 图像数据非常复杂, 直接利用文献[10]中的方法显然不能得到较好的结果。通过分析 SAR 图像联合灰度直方图的特性, 提出基于 Fisher 分类器的变化检测算法。

变化检测过程分为将配准后不同时间的 SAR

收稿日期:2010-05-17, 修回日期:2010-10-04

基金项目:国家863计划(2009AA12Z210); 国家973计划(2006CB705707); 国家自然科学基金(60972148); 教育部重点项目(108115)

作者简介:辛芳芳(1982-), 女, 山东德州人, 博士研究生, 主要研究领域为变化检测、计算智能等, E-mail:xf9258@163.com.

Received date: 2010-05-17, **revised date:** 2010-10-04

图像进行小波分解,只利用其低通部分从而抑制噪声的影响;对得到的低通子带,分别计算其差异影像并统计图像的二维灰度直方图;通过差异影像提取图像的训练样本点得到预分割变化检测图,训练 Fisher 分类器;根据样本点在二维灰度直方图中的分布情况以及训练后的 Fisher 分类器得到待检测样本的隶属度及其初始分割结果,利用贝叶斯决策论融合同一层邻域关系以及不同层之间的父子节点信息,得到最终变化检测结果。

1 小波域 Fisher 分类器变化检测过程

设定 I_1 和 I_2 是已校准的两幅 SAR 图像,代表不同时间同一地理位置所反映的地貌状况, $\Omega = \{\omega_c, \omega_u\}$ 分别表示变化类标识和非变化类标识。算法主要包括 3 步,1) 训练数据的提取;2) 小波域 Fisher 分类器的训练;3) 初始分割结果的融合。

1.1 训练数据提取

对原有 SAR 图像 I_1 和 I_2 进行小波分解,分解为 J 层,原有的 I_1 和 I_2 设定为第一层。对分解后的小波子带,只取其低通部分,减小噪声的影响^[4]。通过图像边缘检测结果对数据进行统计,从而得到可靠的训练数据。

通过式(1)得到差异影像 Difimg($j \in \{1, 2, \dots, J\}$ 表示分解层)后,利用 Canny 算子检测边缘。这里设定两个边缘检测阈值,大阈值用于检测主要边缘,小阈值用于对主要边缘进行填充。

$$\text{Difimg}^j = 1 - ra^j, \quad (1)$$

$$\text{其中 } \begin{cases} ra^j = \max(0, di^j) & \text{if } I(x, y)_1^j > I(x, y)_2^j, \\ ra^j = \min(0, di^j) & \text{if } I(x, y)_1^j \leq I(x, y)_2^j \end{cases}$$

$di^j = \frac{I(x, y)_1^j}{I(x, y)_2^j}$ 。填充后的图像边缘,存在连接中断的点,定义如果距离该中断点小于 13 的范围内存在其它的边缘点,则该点作为可连续点,其匹配点的选择顺序为:首先选择存在的中断点,若存在多个中断点,则选择最近的一个;如果在该邻域内不存在中断点,则选择连续点,若存在多个连续点,则选择最近的边缘连续点。距离计算公式通过 $d_{xy} = (x_i - x_0)^2 + (y_i - y_0)^2$ 计算。 $[x_0, y_0]$ 是该中断点的坐标, $[x_i, y_i]$ 是其邻域内其它边缘点的坐标。如果不存在这样的点,该中断点就定义为终点。对得到的可连续点与其匹配点,通过 Dijkstra 最短路径算法根据图像梯度图进行连接。

训练数据的提取是通过训练提取参数 p_c 和 p_u

得到的。统计像素数目大于 50 的连通区域内灰度分布情况,与背景信息相比灰度差大于 0.2 的连通区域作为变化类参考点,小于 0.2 的作为非变化类参考点。当超过某一灰度值的像素数目占所有变化类参考像素的一定比例 p_c 时,将这一值作为变化类硬阈值 T_c ;当低于某一灰度值的像素数目占所有非变化类参考像素的一定比例 p_u 时,将这一灰度值作为非变化类硬阈值 T_u 。通过不同层的硬阈值给出每一层的差异影像,1 表示变化点,0 表示非变化点,0.5 表示待检测点,见式(2)。图 1 给出了得到的第一层预分割检测图。

$$\text{label}^j(x, y) = \begin{cases} 1, & \text{if } \text{DI}(x, y) > T_c \\ 0, & \text{if } \text{DI}(x, y) < T_u \\ 0.5, & T_u \leq \text{DI}(x, y) \leq T_c \end{cases}, \quad j \in \{1, 2, \dots, J\} \quad (2)$$

1.2 小波域 Fisher 分类器训练

Fisher 判别算法通过计算图像的类内散布矩阵和类间散布矩阵,找到最优投影面,使投影方向上的类内数据尽量密集而类间数据尽量分散。对每一层训练数据 $\Omega^j = \{\omega_c^j, \omega_u^j\}$, j 表示分解层,分别计算类内散布矩阵和类间散布矩阵 S_w^j, S_b^j ^[11],其表达式为

$$S_w^j = \sum_{l=1}^2 \sum_{(x, y) \in Y_l^j} (g_{(x, y)}^j - v_l^j)(g_{(x, y)}^j - v_l^j)^T, \quad (3)$$

$$S_b^j = \sum_{l=1}^2 n_l^j (v_l^j - \tilde{v}^j)(v_l^j - \tilde{v}^j)^T, \quad (4)$$

其中, $g_{(x, y)}^j = (I(x, y)_1^j, I(x, y)_2^j)$ 为 I_1^j, I_2^j 上 (x, y) 处的灰度值对, $Y_l \in \{Y_c^j, Y_u^j\}$ 表示第 j 层变化类和非变化类训练数据, $n_l^j \in \{n_c^j, n_u^j\}$ 表示该层变化类和非变化类包含的具体训练数据个数, T 表示矩阵转置, $v_l^j = \frac{1}{n_l^j} \sum_{i \in Y_l^j} g_i^j$ 表示类别 $l \in \{c, u\}$ 的均值, $\tilde{v}^j = \frac{1}{n_c^j + n_u^j} \sum_{(x, y) \in Y_l^j} g_{(x, y)}^j$ 是全局均值。

求 Fisher 分类器的最优投影面,也就是使准则函数 T_{FDA}^j 获得最大值, W^j 为最优投影矩阵。可以求得 W^j 为式(5)中特征值 λ^j 所对应的特征向量 φ^j 。

$$T_{\text{FDA}}^j = \frac{(W^j)^T (S_b^j) W^j}{(W^j)^T (S_w^j) W^j}, \quad (5)$$

其中 $S_b^j \varphi^j = \lambda^j S_w^j \varphi^j$, $W^j = (\varphi_1^j, \varphi_2^j, \dots)$ 。将待检测点两个灰度值 $g_{(x, y)}^j$ 投影到最优投影面,根据式(6) 判别类别, w^j 为分类阈值。

$$T_{(x, y)}^j(x) = \text{sgn}((W^j)^T g_{(x, y)}^j + w^j), \quad (6)$$

其中 $w^j = -(W^j)^T \times \frac{(n_c^j \times v_c^j + n_u^j \times v_u^j)}{n_c^j + n_u^j}$ 。通过以上

判别,可以得到每一层的初始分割结果. 而待检测点的隶属度 $u_c^j(x)$ 和 $u_u^j(x)$ 则由下式决定

$$\begin{aligned} T_c^j(g_{(x,y)}^j) &= (\mathbf{W}^j)^T g_{(x,y)}^j - (\mathbf{W}^j)^T \times \frac{(n_c^j \times v_c^j)}{n_c^j}, \\ T_u^j(g_{(x,y)}^j) &= (\mathbf{W}^j)^T g_{(x,y)}^j - (\mathbf{W}^j)^T \times \frac{(n_u^j \times v_u^j)}{n_u^j} \\ u_c^j(x) &= \begin{cases} 1 & \text{if } T_u^j(g_{(x,y)}^j) < 0, T_c^j(g_{(x,y)}^j) < 0 \\ \frac{\text{abs}(T_u^j(x))}{\text{abs}(T_c^j(x)) + \text{abs}(T_u^j(x))} & \text{else} \end{cases} \\ u_u^j(x) &= \begin{cases} 1 & \text{if } T_u^j(g_{(x,y)}^j) > 0, T_c^j(g_{(x,y)}^j) > 0 \\ \frac{\text{abs}(T_c^j(x))}{\text{abs}(T_c^j(x)) + \text{abs}(T_u^j(x))} & \text{else} \end{cases}, \quad (7) \end{aligned}$$

根据得到的隶属度和初始分割结果,可以将各分解层检测结果进行邻域相关融合和上下层融合.

1.3 基于空间邻域关系和上下文关系的融合

沙宇恒^[12]在 Hyeokho Choi 和 Richard G 提出的 HMT 模型^[13]基础上,在融合过程中加入了邻域信息,提出了基于空间邻域关系和上下文关系的融合,其后验概率模型可以表示如下

$$p_{g|l,y}^j(x|\hat{l}^j, y^j) = \frac{p_g^j(x)p_{\hat{l}|g}^j(\hat{l}^j|g)f(y^{(n)}|g)}{\sum_{l=1}^2 p_g^j(l)p_{\hat{l}|g}^j(\hat{l}^j|g=l)f(y^{(n)}|g=l)}, \quad (8)$$

$p_g^j(l)$ 表示在尺度 j 上,当像素灰度值为 g 的概率质量函数(PMF), $f(y^{(n)}|g=l)$ 表示图像块 $y^{(n)}$ 中 g 的类别是 $l \in \{c, u\}$ 时对应的隶属度, \hat{l} 表示在尺度 j 时背景的标号,它表示了像素点 x 的父节点及其八邻域的主要类别,对变化检测图像来说, $\hat{l} \in \{c, u\}$. 从而灰度值 g 根据最大后验概率准则得到其类别为

$$\hat{g}^j = \underset{g^j}{\operatorname{argmax}} p_{g|l,y}^j(g|\hat{l}^j, y^j), \quad (9)$$

2 参数设置及实验对比

将提出的算法应用于 2 对 SAR 图像,Bern 实验数据和 Ottawa 实验数据在下文中给出实验结果并对结果进行分析.

2.1 实验设置

通过 2 组实验证所提出算法的有效性. 首先给出当提取参数变化时,检测结果的有效性,并分析提取参数对检测结果的影响;其次通过对比相关实验^[5~7,9,11,12]证明提出的算法可以很好的检测图像中的变化部分. 这里 EM 算法采用高斯模型,FFL-ARS 中的小波分解层数为 5 层. 所有算法的差异影

像均由式(1)得到. 评价指标主要通过漏检(变化类像素被判为非变化类像素),虚警(非变化类像素被判为变化类像素),总错误检测(漏检+虚警)和 Kappa 系数来决定. 总错数越少,Kappa 系数越高,算法性能越好.

在实验过程中,参数的设置如下(1)小波分解为三层;(2)图像边缘检测的阈值,大阈值设为 0.6,小阈值设定为 0.4;(3)训练提取参数 p_c 为 80%, p_u 为 98%~90%,后面的实验可以看出,当 p_u 在一定范围内变化时,检测结果不会有太大变化.

2.2 实验数据描述

Ottawa 地区 LADARSAT SAR 图像,大小为 290 × 350,其变化过程是由于雨季来临而造成的河水泛滥. 图 1(a)和图 1(b)分别在 1997 年 5 月和 1997 年 8 月获得,图 1(c)为变化参考图,其中变化目标数为 16049.

Bern 实验的 SAR 图像是由欧洲遥感 2 号卫星 SAR 传感器获得,大小为 301 × 301,其变化区域是由于城市水灾造成. 图 2(a)和图 2(b)分别为 1999 年 4 月和 1999 年 5 月的图像,图 2(c)为变化参考图,其中包括变化类像素 1155 个.

2.3 实验结果及分析

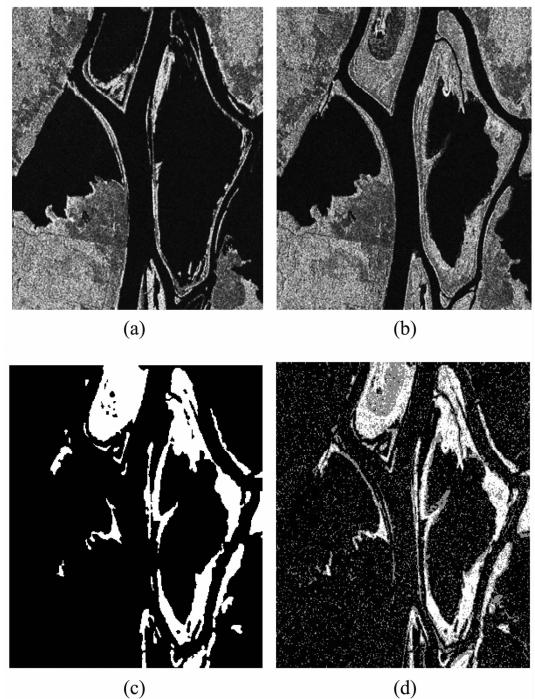


图 1 Ottawa 地区实验数据 (a)1997 年 5 月图像 (b)1997 年 8 月图像 (c) 变化参考图 (d) 预分割变化检测图

Fig. 1 Multi-temporal Ottawa SAR images of 290 × 350 (a) May, 1997 (b) August, 1997 (c) available reference map (d) tag map

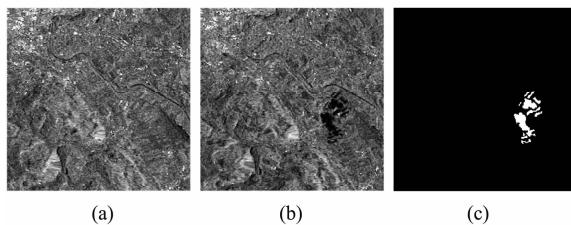


图2 Bern城市SAR图像 (a) 1999年4月图像 (b) 1999年5月图像 (c) 变化参考图

Fig.2 Multi-temporal Bern SAR images of 301×301 (a) April, 1999 (b) May, 1999 (c) reference map

为了验证参数变化的有效性,我们改变训练提取参数 p_u 和 p_c . 对于 Bern 数据,通过表 1 可以看出,当 p_u 在 0.9 到 0.98 之间变化, $p_c = 0.8$ 时,总错误检测数始终小于 400;随着 p_u 的增加,Kappa 系数一直增大,当 $p_u = 0.98$, $p_c = 0.8$ 时,Kappa 系数最大,为 0.8722;当 $p_u = 0.94$, p_c 分别是 0.7、0.8 和 0.9 时,总错误数从 354 降低到 326 后又增加到 404;可以看出,当 $p_c = 0.9$ 时,总错误数增加到了 400 以上,虚警数增加到了 300 以上. 这主要是因为,当提取样本时,设定变化和非变化类像素灰度差是 0.2,它保证了非变化类像素的可靠性,但是增加了变化类像素的风险. 提高 p_c 的值,增加了错误样本的数目,从而导致总错误数的增加. 而 p_u 越大,检测背景越干净. 实验结果看出,当 $p_c = 0.8$ 时,检测结果较好.

当 p_u 在 0.9 到 0.98 之间变化, $p_c = 0.8$ 时,Ottawa 总错误检测数先从 2248 逐渐降低到 2147,后又增长到 2794. 可以看出,当 p_u 过大时漏检数会增多. 在检测过程中,变化类参考点的提取是有限制的,要求提取的区域内像素的数目大于一定的值(一般设为 50 个像素),这样就使得检测像素中有较多变化类点,而增加 p_u 的值,后又经过邻域融合以及上下文融合,会增加变化点判为非变化点的概率,这也是漏检数增大的原因. 当 $p_u = 0.94$, p_c 从 0.7 增加到 0.9 时,漏检率下降,虚警率增加,在 $p_c = 0.8$ 时总错误率最低,从而得到较好的检测结果. 这一过程与 Bern 实验数据相同,因此, p_c 选择 0.8 较为合适.

与 2.1 中提到的六个算法进行比较,仿真结果如图 3、图 4 所示,其定量分析指标在表 2 中给出,给出的结果所对应的训练提取参数为 $p_u = 0.94$, $p_c = 0.8$.

EM-MRF、EM-HNN、GGKIT、LN-GKIT 及 WR-GKIT 都是基于分布假设来进行检测的,当假设模型与实际情况不符时,会产生很大的影响,比如 Bern 实验中的 EM-HNN 结果,其 Kappa 系数只有 0.1. 文中算法不需要假定任何模型,而是通过两幅 SAR 图像在空间中联合灰度直方图分布的特性给出,适用范围较大. LN-GKIT 的模型较适合 Bern 实验数据,

表 1 Bern 实验数据和 Ottawa 实验数据提取参数对应的检测结果

Table 1 Bern data and Ottawa data detection results with different extraction parameters

参数值	Bern 实验数据				Ottawa 实验数据			
	漏检数	虚警数	总错误数	Kappa 系数	漏检数	虚警数	总错误数	Kappa 系数
$p_u = 0.9, p_c = 0.8$	186	174	360	0.8413	879	1369	2248	0.9158
$p_u = 0.92, p_c = 0.8$	198	166	364	0.8382	1515	681	2196	0.9170
$p_u = 0.94, p_c = 0.7$	207	147	354	0.8407	2686	329	3015	0.8814
$p_u = 0.94, p_c = 0.8$	138	188	326	0.8600	1672	475	2147	0.9181
$p_u = 0.94, p_c = 0.9$	86	318	404	0.8388	412	2179	2591	0.9082
$p_u = 0.96, p_c = 0.8$	143	176	319	0.8621	1907	351	2258	0.9130
$p_u = 0.98, p_c = 0.8$	137	157	294	0.8722	2659	137	2796	0.8895

表 2 Bern 实验数据和 Ottawa 实验数据不同算法检测结果的定量分析指标

Table 2 Bern data and Ottawa data detection results in different algorithms

算法	Bern 实验数据				Ottawa 实验数据			
	漏检数	虚警数	总错误数	Kappa 系数	漏检数	虚警数	总错误数	Kappa 系数
EM-MRF	33	3853	3886	0.3523	2253	400	2653	0.8970
EM-HNN	33	15332	15365	0.1066	3246	370	3616	0.8557
FFL-ARS	399	87	486	0.7541	2260	941	3201	0.8775
GGKIT	129	274	403	0.8366	2419	288	2707	0.8941
LN-GKIT	271	62	333	0.8384	279	3016	3295	0.8860
WR-GKIT	575	4	579	0.6642	519	2074	2593	0.9077
Ours	138	188	326	0.8600	1672	475	2147	0.9181
MTEP	189	176	365	0.8348	1931	1319	3250	0.8778

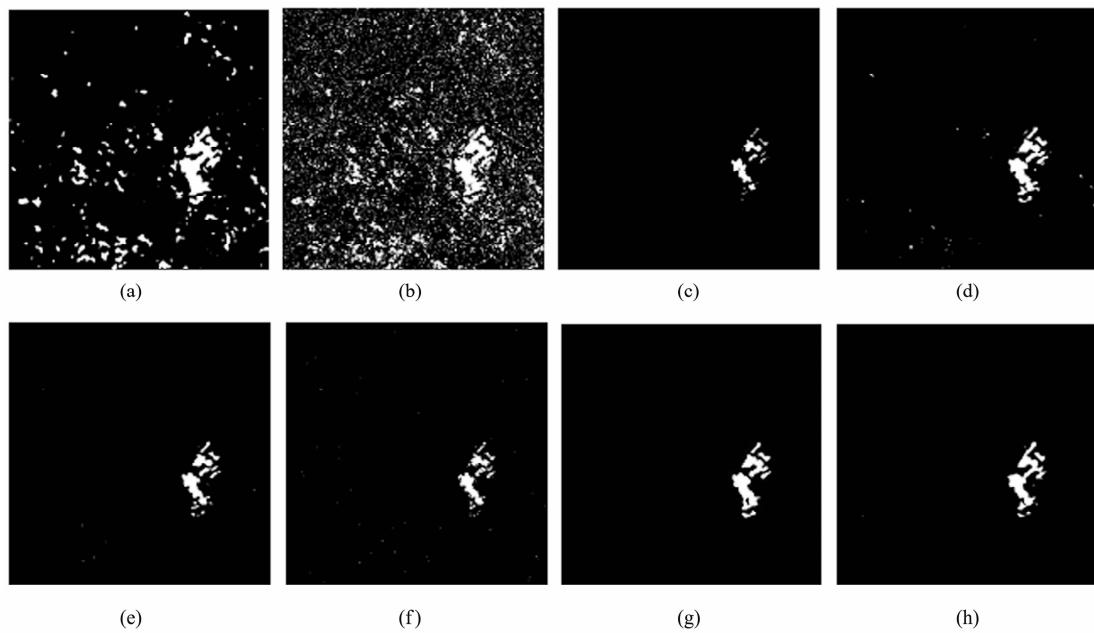


图3 Bern 实验数据检测结果 (a) EM + MRF (b) EM + HNN (c) FFL-ARS (d) GGKIT (e) LN-GKIT (f) WR-GKIT (g) 实验算法 (h) MTEP 算法

Fig. 3 Comparisons of experimental results of Bern SAR images (a) EM + MRF (b) EM + HNN (c) FFL-ARS (d) GGKIT (e) LN-GKIT (f) WR-GKIT (g) our methods (h) MTEP algorithm

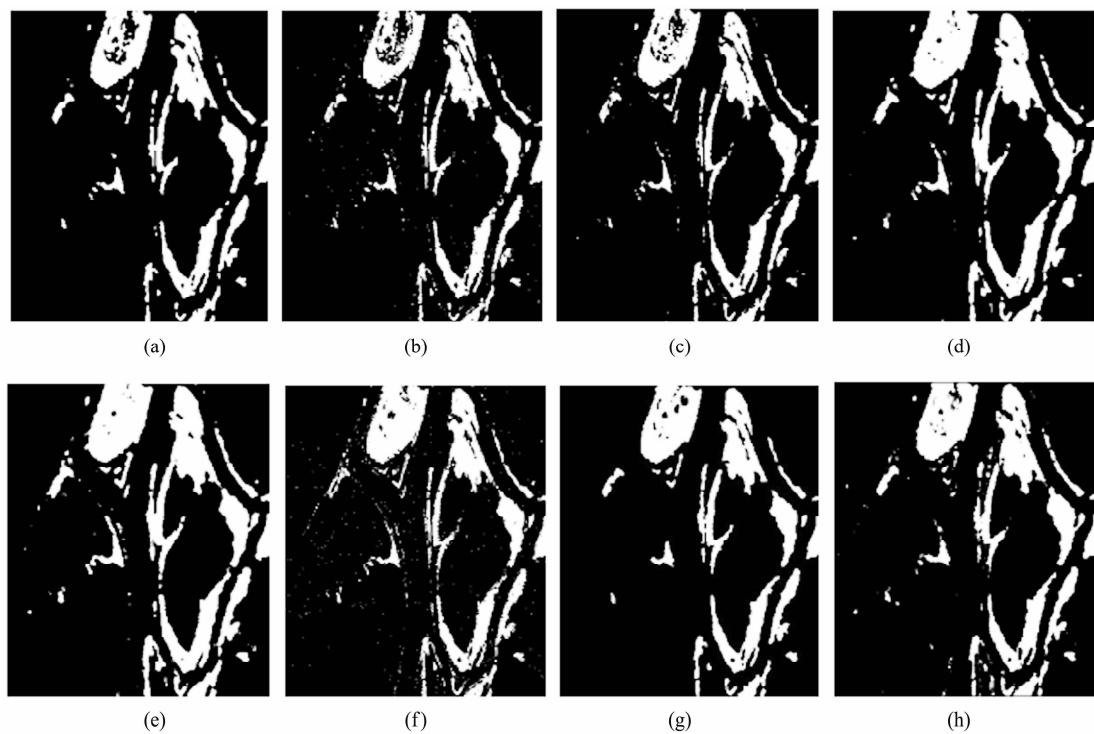


图4 Ottawa 实验数据检测结果 (a) EM + MRF (b) EM + HNN (c) FFL-ARS (d) GGKIT (e) LN-GKIT (f) WR-GKIT (g) 实验算法 (h) MTEP 算法

Fig. 4 Comparisons of experimental results of Ottawa SAR images (a) EM + MRF (b) EM + HNN (c) FFL-ARS (d) GGKIT (e) LN-GKIT (f) WR-GKIT (g) our methods (h) MTEP algorithm

总错误数也是最小的,可以看出,当 $p_u > 0.92$ 时,文中算法的性能要优于 LN-GKIT 算法,当 $p_u = 0.98, p_c$

$= 0.8$ 时总错误数比 LN-GKIT 少 39. FFL-ARS 算法利用平稳小波信息,通过提取可靠层得到可靠的同

质区域。由于平稳小波的平滑性,图像边缘区域可能在分解过程中模糊化,从而导致边缘区域的变化部分在提取可靠层时被判定为非变化区域,产生许多漏检点,降低了检测精度。虽然 EM-MRF 以及 EM-HNN 算法也考虑了空间邻域关系,但是检测结果显然不如文中算法。虽然在实验初始阶段,并没有进行降噪处理,但是文中只利用了低通子带小波系数,而含有大部分噪声的高通子带并没有考虑其中,从而在检测过程降低了噪声的影响,而空间邻域以及不同尺度小波系数的融合,进一步降低了 SAR 图像噪声。实验结果看出,文中算法检测的结果较好。MTEP 算法虽然是有监督检测算法,但是由于它是邻域不相关检测,仅检测图像阈值,效果并不理想。

从 Ottawa 实验可以看出与上节相同的结论,正由于考虑了小波系数的影响以及邻域信息的利用,使本算法检测结果优于其他检测结果,表 1 中的 Ottawa 数据可以看出,文中算法的仿真结果其 Kappa 系数几乎都到达 0.9,而其他方法只有 WR-GKIT 的结果到达 0.9。通过实验可以看出,相比 Bern 实验数据,Ottawa 实验数据在检测过程中可以得到较好的结果。Bern 实验 90601 个像素中,变化点仅占全部像素数目的 1.27%,而 Ottawa 实验变化点占全部数据的 15.81%。Ottawa 数据一维灰度直方图的分布图中,变化类像素的灰度峰值相比 Bern 数据更明显,变化类像素所占比例也多于 Bern 实验,从而易于从噪声中区分,算法可以得到更好的结果。

3 结论

给出了一种无监督 SAR 图像变化检测的邻域相关检测技术。对已配准、已校正的两时相 SAR 图像,通过边缘检测提取图像不同小波分解层的训练数据。利用训练数据对 Fisher 分类器进行训练,并对两幅图像不同层构成的联合灰度直方图进行判别分析,得到待检测点的隶属度。最后通过空间邻域及小波上下文内容的隶属度融合,得到最终的检测结果。在小波分解中,只利用低通小波,做到降噪处理,之后的尺度内融合以及尺度间融合进一步降低了信号的影响。从实验结果看出,算法是可行的,且不需要假定任何的统计模型,完全根据信号空间分布特性来进行判别,提高了算法的可用性。

文中算法可以得到较为稳定的结果,但是需要提取的训练数据受边缘检测结果的影响。如果 SAR 图像边缘检测结果非常复杂或者边缘无法检测,则此算法效果较差。相比较其他算法,该算法对于水域检测效果较好。

REFERENCES

- [1] Lu D, Mausel P, Brondizio E, et al. Change detection techniques[J]. *Int. J. Remote Sensing.*, 2004, **25**(12): 2365—2407.
- [2] Bazi Y, Bruzzone L, Melgani F. An unsupervised approach based on the generalized gaussian model to automatic change detection in multitemporal SAR images[J]. *IEEE Trans. Geosci. Remote Sens.*, 2005, **43**(4): 874—888.
- [3] Moser G, Serpico S B. Generalized minimum-error thresholding for unsupervised change detection from SAR amplitude imagery[J]. *IEEE Trans. Geosci. Remote Sens.*, 2006, **44**(10): 2972—2983.
- [4] Francesca B, Lorenzo B. A detail-preserving scale-driven approach to change detection in multitemporal SAR images [J]. *IEEE Trans. Geosci. Remote Sens.*, 2005, **43**(12): 2963—2972.
- [5] Villasenor D, Fatland D R, Hinzman L D. Change detection on Alaska's north slope using repeat-pass ERS-1 SAR imagery[J]. *IEEE Trans. Geosci. Remote Sens.*, 1993, **31**(1): 227—236.
- [6] Radke R J, Andra S, Al-Kofahi O, et al. Image change detection algorithms: a systematic survey[J]. *IEEE Trans. I. P.*, 2005, **14**(3): 294—307.
- [7] Bruzzone L, Prieto D F. Automatic analysis of the difference image for unsupervised change detection[J]. *IEEE Trans. Geosci. Remote Sens.*, 2000, **38**(3): 1171—1182.
- [8] Pajares G. A Hopfield neural network for image change detection[J]. *IEEE Trans. Neural network*, 2006, **17**(5): 1250—1264.
- [9] Marchesi S, Bovolo F, Bruzzone L. A context-sensitive technique robust to registration noise for change detection in VHR multispectral images[J]. *IEEE Trans. I. P.*, 2010, **19**(7): 1877—1889.
- [10] Kita Y. A study of change detection from satellite images using joint intensity histogram[C]. In: *19th International Conference on Pattern Recognition*, 2008: 1—4.
- [11] Dekker R J. Speckle filtering in satellite SAR change detection imagery[J]. *Int. J. Remote Sens.*, 1998, **19**(6): 1133—1146.
- [12] Sha Y H, Cong L, Sun Q, et al. Unsupervised image segmentation using Contourlet domain hidden Markov trees model[J]. *Lecture Notes in Computer Science*, 2005, **3656**: 32—39.
- [13] Choi H, Baraniuk R G. Multiscale image segmentation using wavelet-domain hidden Markov models[J]. *IEEE Transactions on Image Processing*, 2001, **10**(9): 1309—1321.