

基于密度引力和多尺度多特征融合的 遥感影像变化检测

金秋舍^{1,2*}, 王阳萍^{1,2**}, 杨景玉^{1,2***}

¹兰州交通大学电子与信息工程学院, 甘肃 兰州 730070;

²兰州交通大学甘肃省人工智能与图形图像处理工程研究中心, 甘肃 兰州 730070

摘要 针对传统的多特征融合变化检测没有考虑不同特征对变化检测结果的影响及传统的马尔可夫随机场 (MRF) 变化检测质量受空间信息权重影响的问题, 提出了基于密度引力和多尺度多特征融合的变化检测方法。在提取 Gabor 纹理特征的基础上, 通过局部相似性度量和信息熵来获取纹理差异图像, 利用变化矢量分析计算了光谱差异图像; 采用自适应的方法融合了光谱差异和纹理差异; 将密度引力模型与传统 MRF 相结合, 构建了自适应权重的 MRF 模型, 获取了差异图像的变化图。实验结果表明, 该方法能够充分利用不同特征, 而且能够更好地保持图像边缘细节, 提高了变化检测精度。

关键词 图像处理; 变化检测; 密度引力; 多尺度多特征融合; 马尔可夫随机场

中图分类号 TP751

文献标识码 A

doi: 10.3788/LOP56.121003

Remote Sensing Image Change Detection Based on Density Attraction and Multi-Scale and Multi-Feature Fusion

Jin Qiuhan^{1,2*}, Wang Yangping^{1,2**}, Yang Jingyu^{1,2***}

¹School of Electronic and Information Engineering, Lanzhou Jiaotong University, Lanzhou, Gansu 730070, China;

²Gansu Provincial Engineering Research Center for Artificial Intelligence and Graphics & Image Processing, Lanzhou Jiaotong University, Lanzhou, Gansu 730070, China

Abstract The traditional multi-feature fusion change detection does not consider the fact that different features contribute differently toward the change detection results. Furthermore, the traditional Markov random field (MRF) change detection quality is affected by the spatial information weight. This study proposes a novel change detection method based on density attraction and multi-scale and multi-feature fusion. First, the texture difference image is obtained by local similarity measurement and information entropy on the basis of extracting Gabor texture features, and the spectral difference image is calculated by change vector analysis. Then, the adaptive method is used to fuse the spectral and texture differences. Finally, the density attraction model is combined with the traditional MRF to construct an adaptive weighted MRF model and obtain the change map of a difference image. The experimental results show that the proposed method can not only make full use of different features, but also well maintain the image edge details and improve the change detection accuracy.

Key words imaging processing; change detection; density attraction; multi-scale and multi-feature fusion; Markov random field

OCIS codes 100.2960; 280.4750; 110.4234

收稿日期: 2018-11-26; 修回日期: 2018-12-22; 录用日期: 2019-01-11

基金项目: 国家自然科学基金(41761082, 61162016, 61562057)、甘肃省科技计划(18JR3RA104, 1504FKCA038)、甘肃省教育厅科技项目(2017D-08)

* E-mail: 18298378747@163.com; ** E-mail: wangyp@mail.lzjtu.cn; *** E-mail: yangjy@mail.lzjtu.cn

1 引言

遥感影像变化检测是指利用同一地区不同时期的遥感影像,通过图像处理技术分析和判断影像间的变化^[1]。由于遥感影像变化检测方法可以动态监测和分析地表覆盖变化趋势,从而广泛应用于土地利用/覆盖、城市扩展和灾害监测等领域^[2]。变化检测方法根据是否需要先验信息可分为监督变化检测和无监督变化检测,理论上,监督变化检测通过利用标记样本获得更详尽的变化描述,从而优于无监督变化检测。但是,当有少量标记样品可用时,监督变化检测的性能将会很差^[3]。因此,无监督变化检测得到了更为广泛的研究。

一般来说,无监督变化检测方法有两个关键点。

一是双时相影像间变化信息的表达。遥感影像变化检测时,变化信息提取是变化检测的核心,影像中包含的各种特征是承载变化信息的载体,例如光谱、纹理、空间结构和空间上下文特征等^[4],因此,有效地提取不同时相遥感影像中包含不同信息的特征数据,是变化检测的关键环节。传统的变化检测方法主要是依靠光谱特征,检测结果较为零碎,并且容易丢失边缘信息,导致了检测结果准确性和完整性欠缺^[5]。近年来,许多学者已提出多特征融合的变化检测方法,杜培军等^[5]将光谱特征、空间特征、纹理特征等多个特征融合后用于变化检测。赵敏等^[6]通过多尺度分割图像,然后提取像斑的光谱特征、纹理特征及形状特征,并构造特征矢量,最后用于变化检测。以上的多特征融合的变化检测方法,都是给予各个特征相同的权重,没有考虑不同特征对于变化检测的贡献和作用不同,未能自适应地将不同特征融合。此外,也没有考虑到不同尺度纹理特征对于变化检测的影响。因此,需要更有效的变化检测方法将不同特征融合。

另一个关键点是需要一个评判标准来判断像元是否发生变化,其核心是阈值分割^[7]。阈值分割是通过设定一个阈值来区分差异图像中的变化区域和未变化区域。由于遥感成像过程不稳定,且包含复杂的地物,很难选择一个最优的阈值用于变化检测,此外该方法抗噪性能差。为了解决这些问题,已经提出了许多对噪声具有稳健性的变化检测方法,例如改进的模糊 C 均值聚类(FCM)算法^[8],基于马尔可夫随机场(MRF)的方法^[9],基于最大期望(EM)的方法^[10]。其中,基于 MRF 的变化检测方法由于其完整的数学理论而受到广泛关注。MRF 模型不

仅具有很强的抗噪性能,而且充分考虑了图像像元之间的空间邻域关系。然而 MRF 模型中邻域像元对中心像元的影响相同,对于均匀区域的变化检测结果较好,而边缘区域会产生过平滑现象。此外忽略像元的各向异性,不能较好地保持图像细节。Tso 等^[11]通过在 MRF 中引入多尺度线特征以限制过度平滑的分类,提高了分类精度。王冬雪等^[12]通过在 MRF 的能量函数中加入边缘系数以保持图像边缘信息。Zhang 等^[13]通过邻域像元和中心像元之间的距离,定义了 MRF 的空间信息权重。以上方法虽然一定程度上改善了变化信息的分类精度,但是仍然对噪声敏感。此外,仅利用距离改变空间信息权重而忽略图像局部统计特性,并不合理,因此需要更有效的变化检测方法在解决空间信息权重的同时保留图像边缘细节。

为了解决上述问题,本文先利用信息熵融合获得不同尺度的纹理特征,然后利用标准差融合纹理特征和光谱特征,从而保留了更多有用的特征数据,提高了变化检测精度。同时,将密度引力模型引入到 MRF 模型中,改变 MRF 模型各向同性的性质,使其能够更好地描述像元之间的空间邻域关系,从而改善了变化信息的分类效果。

2 算法流程

图 1 给出本文算法流程图。1) 利用局部相似性度量和信息熵提取纹理差异图像,利用变化矢量分析(CVA)计算光谱差异图像,通过采用自适应权的方式将纹理差异图像和光谱差异图像融合;2) 用

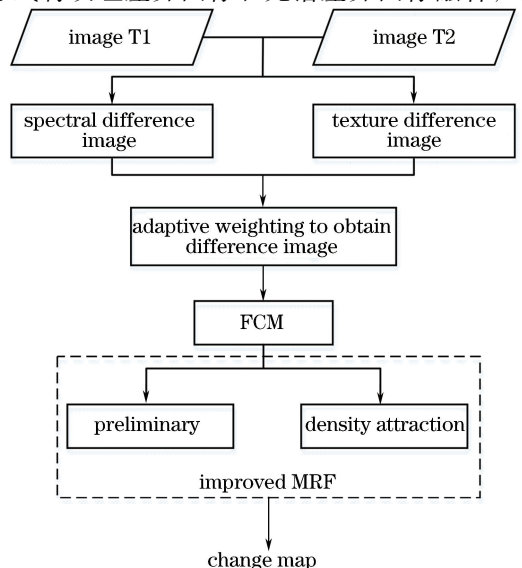


图 1 所提算法流程图

Fig. 1 Flow chart of proposed algorithm

FCM 聚类算法^[14]对差异图像进行初始聚类,得到初始变化检测结果和每个像元的初始类别标签;
3) 引入密度引力来估计 MRF 模型的自适应权重参数;4) 通过基于密度引力的 MRF(DAMRF)得到图像的变化图。

3 基本原理

3.1 Gabor 纹理特征提取

Gabor 滤波器^[15-16]可以获得较高的时域和频域分辨率,它和人类视觉系统中简单细胞的视觉刺激响应相似。此外,可以同时的空间域和频率域获得最优的局部化特性,并且具有良好的方向选择和尺度选择,几乎不受光照变化的影响,因而非常适合用于提取和表征图像的纹理信息。图 2 给出 Gabor 滤波器示意图。

二维 Gabor 函数本质上是复正弦调制的高斯




图 2 Gabor 滤波器示意图

Fig. 2 Schematic of Gabor filter

3.2 纹理差异图像

距离相似度是度量两类样本相似性的主要表现方式之一,包括绝对值距离、欧氏距离和卡方距离等

核函数,可以表示为

$$\phi_{u,v}(i,j) = \frac{\|k_{u,v}\|^2}{\sigma^2} \exp\left[-\frac{\|k_{u,v}\|^2(\|i\|^2 + \|j\|^2)}{2\sigma^2}\right] \times \left\{ \exp\left[ik_{u,v}\left(\begin{matrix} i \\ j \end{matrix}\right)\right] - \exp\left(-\frac{\sigma^2}{2}\right) \right\}, \quad (1)$$

式中: (i,j) 表示像元位置; u 和 v 是 Gabor 滤波器的方向和尺度; σ 表示高斯函数的标准差; $\|\cdot\|$ 是归一化算子; $k_{u,v}$ 表示滤波器的覆盖范围, $k_{u,v} = k_v \exp(i\varphi_u)$,其中 φ_u 通过 u 决定滤波器方向, $\varphi_u = \pi u/8$, k_v 表示中心频率, $k_v = k_{\max}/f_v$, k_{\max} 为最大频率, f_v 为在尺度 v 中频域内核之间的间隔因子;

二维 Gabor 变换提取纹理特征实际上就是用二维 Gabor 函数 $\Psi_{u,v}(i,j)$ 与图像 $f(i,j)$ 的卷积(用 $*$ 表示),即

$$I_{vu} = f(i,j) * \phi_{u,v}(i,j). \quad (2)$$

多种形式。Li 等^[17]提出一种局部相似性度量法,用于提取纹理相似性图像,通过利用八邻域系统来充分考虑纹理特征的空间相关性,可以描述为

$$S_{vu}(t_1,t_2) = \frac{1}{1 + d_{vu}(t_1,t_2)}, \quad (3)$$

$$d_{vu}(t_1,t_2) = \sqrt{[I_{vu_{t_1}}(i,j) - I_{vu_{t_2}}(i,j)]^2 + \sum_{(i,j) \in \omega} \left[\frac{I_{vu_{t_1}}(i,j) - I_{vu_{t_2}}(i,j)}{h} \right]^2}, \quad (4)$$

式中: $S_{vu}(t_1,t_2)$ 为局部相似性度量; $d_{vu}(t_1,t_2)$ 为 2 个时相影像在 u 个方向 v 个尺度上对应 Gabor 特征变化指数; $I_{vu_{t_1}}(i,j)$ 和 $I_{vu_{t_2}}(i,j)$ 分别是 t_1 时刻

和 t_2 时刻的 Gabor 纹理特征; ω 是以 (i,j) 为中心像元的八邻域系统; h 为邻域像元与中心像元的距离。邻域系统及距离示意图如图 3 所示。




图3 邻域系统及距离示意图。(a)以 (i, j) 为中心的邻域系统;(b)中心像元 (i, j) 与其邻域的距离

Fig. 3 Schematic of neighborhood system and distance. (a) Neighborhood system centered at (i, j) ; (b) distance between center pixel (i, j) and its neighborhood

通过(4)式得到的不同尺度不同方向的相似性图像包含的纹理信息内容不同,变化检测时,如果将所有尺度和方向的相似性图像都等同对待,将会使得数据的冗余信息较大,进而使得变化检测的效果不好。此外,不同尺度不同方向的相似性图像对于变化检测的贡献也不同。因此,为了能够更加充分地利用不同尺度不同方向的相似性图像,利用信息熵把不同尺度和方向的相似性图像加权融合。

根据灰度信息熵来定义每个尺度和方向相似性图像的权重。影像的灰度分布的聚集特性可以利用图像的信息熵来描述,图像中包含的信息量即纹理信息越丰富,信息熵就越大,因此,第 v 个尺度第 u 个方向的相似性图像的信息熵可以描述为

$$H_{vu} = - \sum_{\gamma=0}^Z p(\gamma) \times \ln p(\gamma), \quad (5)$$

式中: $p(\gamma)$ 表示灰度级 $\gamma(0 \leq \gamma \leq Z)$ 出现的概率, Z 表示最大灰度级; H_{vu} 表示第 v 个尺度 u 个方向的相似性图像的信息熵。

信息熵可以用来衡量相似性图像所包含的信息量,信息量越大的相似性图像,其对应的权重越大。

$$W_{vu} = \frac{H_{vu}}{\sum_v \sum_u H_{vu}}, \quad (6)$$

因此,纹理差异图像可以表示为

$$\Delta D_T = \sum_v \sum_u \frac{W_{vu}}{S_{uv}(t_1, t_2)}, \quad (7)$$

式中: S 和 K 分别表示总的尺度和方向; W_{vu} 表示所有尺度方向上的归一化权重值。

3.3 光谱差异图像

同一区域不同时相的多光谱遥感图像 X_1 和 X_2 ,其中包含 B 个波段且大小为 $M \times N$,图像已经过预处理,包括辐射校正和配准等。 X_{h_b} ($h=1, 2$)为 X_h 在第 $b(1 \leq b \leq B)$ 个波段上对应的灰度值,光

谱差异图像是通过减去2个图像的相应光谱波段而获得的变化矢量,可以描述为

$$\Delta D_S = \sqrt{\sum_{b=1}^B (X_{2_b} - X_{1_b})^2}, \quad (8)$$

式中: B 表示图像波段个数。

3.4 自适应融合光谱差异和纹理差异图像

光谱差异图像和纹理差异图像进行结合,使得图像变化检测在充分考虑遥感图像光谱特征的同时考虑到图像的纹理特征。通过将光谱差异信息和纹理差异信息加权融合,从而获得异质性图像 ΔX ,即

$$\Delta X = W_S \Delta D_S + W_T \Delta D_T, \quad (9)$$

式中: W_S 和 W_T 分别是光谱差异信息和纹理差异信息的权重, $W_S + W_T = 1$ 。将光谱特征差异和纹理特征差异以固定权重融合不能充分地表达图像信息。为此,采用自适应权重的策略结合光谱和纹理特征差异。标准差描述了图像中灰度分布的离散程度。在光谱丰富的区域,对应的光谱分布均匀,标准差较小,相反,如果光谱信息分布是异质的,则纹理是主要特征,对应的标准差较大。因此,当图像的标准差小于设定阈值时,则调整权重,以光谱信息占主导地位,反之为纹理信息分配更大的权重。

t_1 时刻遥感影像的标准差是 S_{std1} , t_2 时刻遥感影像的标准差是 S_{std2} ,给出阈值 k_1 和 k_2 ,光谱和纹理差异图像的归一化权重为

$$W_S = \begin{cases} \max(S_{std1}, S_{std2}) / (S_{std1} + S_{std2}), \\ S_{std1} < k_1 \text{ and } S_{std2} < k_2 \\ \min(S_{std1}, S_{std2}) / (S_{std1} + S_{std2}), \\ \text{other} \end{cases}, \quad (10)$$

式中: $k_r = M_{\text{mean}}(t_r) + n_r S_{\text{std}}(t_r)$, $r=1, 2$ 。对于包含丰富纹理特征的影像,设定的阈值较小,反之设定的阈值较大。 $M_{\text{mean}}(k_r)$ 表示 t_r 时期影像的灰度均值, $S_{\text{std}}(t_r)$ 表示 t_r 时期影像的标准差, n_r 表示自适

应指数, $n_r \in [-2, 2]$ 。

3.5 基于密度引力的 MRF 变化检测

3.5.1 紧密程度

与中心像元 x_i 属于同一类的邻域像元个数越多, 且邻域像元距离中心像元 x_i 越近, 则中心像元 x_i 的紧密程度越大, 因此, 中心像元 x_i 的紧密程度与其邻域像元的个数成正比, 与像元之间的距离成反比, 从而紧密程度可以表示为

$$w_{ij} = \frac{k \cdot x_i}{\sum_{j \in N_i} d_{ij}}, \quad (11)$$

式中: w_{ij} 表示邻域像元和中心像元 x_i 的紧密程度; k 表示与中心像元同属一类的邻域像元个数; d_{ij} 表示中心像元和邻域像元的欧几里得距离。当以 x_j 为中心像元时, 其紧密程度可以表示为

$$w_{ji} = \frac{k \cdot x_j}{\sum_{i \in N_j} d_{ji}}, \quad (12)$$

式中: N_i 和 N_j 分别表示中心像元 x_i 和 x_j 的邻域系统。

3.5.2 基于密度引力模型的 MRF

X 是差异影像, 即异质性图像, $L = \{l_1, l_2, l_3, \dots, l_m\}$ 是差异影像的类别标签, m 是类别数, l_m 表示为某一类的类别标签。在 MAP-MRF 框架中, 最大后验概率 (MAP) 方法可以用来更加准确地描述初始变化图的类别标签, 对于每个像元 x 有

$$\hat{L} = \operatorname{argmax}\{p(X | L)p(L)\}, \quad (13)$$

式中: \hat{L} 为先验概率。

最大化 (13) 式的后验概率等价于最小化每个像元的能量函数, 即

$$U_{\text{MRF}} = U_{\text{spectral}}(x) + U_{\text{spatial}}(x), \quad (14)$$

式中: $U_{\text{spectral}}(x)$ 为差异图像中像元的光谱能量函数; $U_{\text{spatial}}(x)$ 为根据中心像元的邻域像元计算的空间能量项。

在高斯模型中, 像元的光谱能量函数 U_{spectral} 可以表示为

$$U_{\text{spectral}}(x) = \frac{1}{2} \ln(2\pi\sigma_m^2) + \frac{1}{2} (x - \mu_m)^2 (\sigma_m^2)^{-1}, \quad (15)$$

式中: μ_l 和 σ_l^2 分别是类别 l 的均值和方差, l 表示类别标签。像元的空间能量函数 U_{spatial} 可以表示为

$$U_{\text{spatial}}(x) = \beta \sum_{j \in N_i} I[l(x_i), l(x_j)], \quad (16)$$

$$I[l(x_i), l(x_j)] = \begin{cases} -1, & l(x_i) = l(x_j) \\ 0, & l(x_i) \neq l(x_j) \end{cases}, \quad (17)$$

式中: β 为惩罚系数, 用来控制像元 x_i 的邻域像元 $j \in N_i$ 时对 x_i 的影响程度; N_i 为中心像元 x_i 的邻域系统, $i \notin N_i$; $l(x_i)$ 是像元 x_i 的类别标签, $l(x_j)$ 是像元 x_j 的类别标签。(18) 式是 MRF 中的 Potts 模型, 用于描述类别标签的先验概率。

从 (17) 式可以看出, 邻域像元对中心像元的影响相同, 并没有考虑像元之间的距离、局部图像的统计特性和邻域像元是否为边界像元等因素^[18]。由地理学第一定理可知, 图像的像元之间存在引力, 距离越近的像元之间同属于一个类别的概率越大。由于 MRF 模型是各向同性的, 并不符合实际问题, 而 DAMRF 是在传统的 MRF 模型中引入密度引力模型^[19], 可自适应地确定空间信息权重, 改善变化检测结果的分类效果。因此, (17) 式可以重新描述为

$$I_{\text{SA}}[l(x_i), l(x_j)] = \begin{cases} -A_{\text{SA}_{ij}}, & l(x_i) = l(x_j) \\ 0, & l(x_i) \neq l(x_j) \end{cases}, \quad (18)$$

(16) 式可以描述为

$$U_{\text{spatial}}(x) = \beta \sum_{j \in N_i} I_{\text{SA}}[l(x_i), l(x_j)], \quad (19)$$

式中: $A_{\text{SA}_{ij}}$ 是中心像元 x_i 和邻域像元 x_j 之间的密度引力, 可以用于描述邻域像元对中心像元的影响; I_{SA} 是 MRF 模型中的势函数。

文献[19]中考虑的是数据点之间的密度引力, 而本文考虑的是图像像元之间的密度引力。此外, 本文考虑像元之间紧密程度时, 利用的是与中心像元类别相同的邻域像元个数。密度引力模型有效地表达了图像像元之间的空间相关性, 其描述了中心像元与邻域像元距离越近, 紧密程度越高, 密度引力越大, 反之越小。因此, 两个像元之间的密度引力与其紧密程度成正比, 与像元之间的空间距离成反比。因此, 对于两个像元 x_i 和 x_j 之间的密度引力可以描述为

$$A_{\text{SA}_{ij}} = \frac{1}{D_{ij}} \times w_{ij} \times w_{ji}, \quad (20)$$

式中: D_{ij} 表示两个像元 x_i 和 x_j 之间的欧几里得距离; w_{ij} 和 w_{ji} 表示分别以 x_i 和 x_j 为中心像元时的紧密程度。值得注意的是, 在本文中邻域像元与中心像元之间的密度引力指定在 3×3 邻域窗口中, 假定窗口外的其他像元因距离太远而不能给中心像元任何吸引力^[18]。此外, 邻域窗口的形状不仅限于 3×3 邻域窗口的形状, 也可以采用其他形状的邻域窗口。

DAMRF 的贡献有:1) 考虑到中心像元和邻域像元之间的距离;2) 在密度引力模型中使用紧密程度来更好地描述邻域像元对中心像元的影响。因此,DAMRF 在一定程度上可以解决边界像元错误分类的问题。

4 实验结果与分析

4.1 实验数据

利用 2 组高分辨率遥感影像来验证本文算法在遥感影像变化检测中的性能,第 1 组是使用西安地区 2014 年 7 月和 2018 年 4 月的高分二号遥感影像,通

过空间分辨率为 0.8 m 的全色影像和空间分辨率为 3.2 m 的多光谱影像融合得到多光谱遥感影像,影像大小为 322 pixel \times 217 pixel。2014 年和 2018 年的多时相遥感影像如图 4(a)、(b)所示,依据目视解译和实地调查制作的参考变化图如图 4(c)所示。第 2 组是使用兰州地区 2016 年 4 月和 2018 年 4 月的 QuickBird 遥感影像,空间分辨率是 0.61 m,数据大小为 258 pixel \times 263 pixel,2016 年和 2018 年的多时相遥感影像如图 5(a)、(b)所示,依据目视解译和实地调查制作的参考变化图如图 5(c)所示。2 组遥感影像已经过辐射校正、几何校正和配准。



图 4 第 1 组实验的遥感影像数据和参考变化图。(a) 2014 年;(b) 2018 年;(c)参考变化图

Fig. 4 Remote sensing image data and reference change map in first set of experiments.

(a) 2014; (b) 2018; (c) reference change map



图 5 第 2 组实验的遥感影像数据和参考变化图。(a) 2016 年;(b) 2018 年;(c)参考变化图

Fig. 5 Remote sensing image data and reference change map for second set of experiments.

(a) 2016; (b) 2018; (c) reference change map

4.2 实验结果

为了验证所提算法的有效性,通过单一特征与 MRF、固定不同的权重与 MRF、自适应权重与 MRF、自适应权重与 DAMRF 进行对比实验,2 组遥感影像的变化检测结果如图 6、图 7 所示,其中变化区域用黑色表示,未变化区域用白色表示,此外,图 6 的自适应权重 $W_S=0.68, W_T=0.32$,图 7 的自适应权重 $W_S=0.54, W_T=0.46$ 。此外,利用 3 个指标来定量地评价实验结果,分别是虚检率 P_F 、漏检率 P_M 和总体精度 P_T 。具体地来讲, $P_F=N_F/N_u$, N_F 是在参考变化图中未发生变化但是在检测时被分类为变化像元的数量, N_u 是检测结果中的变化

像元的数量。 $P_M=N_M/N_c$,其中, N_M 是在参考变化图中发生变化但是在检测时被分类为未变化像元的数量, N_c 是参考变化图中变化像元的数量。 P_T 是正确分类为变化像元和未变化像元数量之和与参考变化图中总的像元数量的比值。2 组影像的定量评价表分别如表 1 和表 2 所示。

4.3 实验分析

图 6(a)~(d)和图 7(a)~(d)分别显示的是单一特征和固定权重后利用 MRF 分类方法得到的变化检测结果。图 6(e)~(f)和图 7(e)~(f)分别显示的是自适应权重后利用 MRF 分类方法和自适应权重后利用 DAMRF 分类方法得到的变化检测结果。




图 6 第 1 组实验中不同权重及分类方法的变化检测结果。(a) $W_S=0, W_T=1, \text{MRF}$; (b) $W_S=0.4, W_T=0.6, \text{MRF}$; (c) $W_S=0.6, W_T=0.4, \text{MRF}$; (d) $W_S=1, W_T=0, \text{MRF}$; (e) 自适应权重, MRF; (f) 自适应权重, DAMRF

Fig. 6 Results of change detection under different weights and classification methods for first set of experiments. (a) $W_S=0, W_T=1, \text{MRF}$; (b) $W_S=0.4, W_T=0.6, \text{MRF}$; (c) $W_S=0.6, W_T=0.4, \text{MRF}$; (d) $W_S=1, W_T=0, \text{MRF}$; (e) adaptive weight, MRF; (f) adaptive weight, DAMRF




图 7 第 2 组实验中不同权重及分类方法的变化检测结果。(a) $W_S=0, W_T=1, \text{MRF}$; (b) $W_S=0.4, W_T=0.6, \text{MRF}$; (c) $W_S=0.6, W_T=0.4, \text{MRF}$; (d) $W_S=1, W_T=0, \text{MRF}$; (e) 自适应权重, MRF; (f) 自适应权重, DAMRF

Fig. 7 Results of change detection under different weights and classification methods for second set of experiments. (a) $W_S=0, W_T=1, \text{MRF}$; (b) $W_S=0.4, W_T=0.6, \text{MRF}$; (c) $W_S=0.6, W_T=0.4, \text{MRF}$; (d) $W_S=1, W_T=0, \text{MRF}$; (e) adaptive weight, MRF; (f) adaptive weight, DAMRF

目视解译图 6 和图 7 可以看出,图 6(d)和图 7(d)仅利用光谱特征进行变化检测时,出现的虚检现象较多。图 6(a)和图 7(a)仅利用纹理特征进行变化检测时,存在较多的漏检。图 6(b)~(c)和图 7(b)~(c)将光谱特征和纹理特征加权融合时,

漏检现象得到了抑制。图 6(e)和图 7(e)利用自适应加权融合光谱和纹理特征,虽然虚检和漏检现象相对固定,权重得到减少,但是丢失了图像边缘细节。而图 6(f)和图 7(f)得到的变化检测结果要优于其他几个结果,边缘细节保持相对较好,检测结果

表1 图6变化检测结果的定量评价

Table 1 Quantitative evaluation of change detection results for Fig. 6

Method and parameter	False alarm rate $P_F/\%$	Missed detection rate $P_M/\%$	Overall accuracy $P_T/\%$
$W_s=0$, $W_T=1$, MRF	13.1	33.2	89.3
$W_s=0.4$, $W_T=0.6$, MRF	16.6	28.3	89.2
$W_s=0.6$, $W_T=0.4$, MRF	16.3	27.5	89.5
$W_s=1$, $W_T=0$, MRF	22.4	29.2	87.6
Adaptive weight, MRF	15.9	26.4	89.7
Adaptive weight, DAMRF	14.8	23.3	90.8

表2 图7变化检测结果的定量评价

Table 2 Quantitative evaluation of change detection results for Fig. 7

Method and parameter	False alarm rate $P_F/\%$	Missed detection rate $P_M/\%$	Overall accuracy $P_T/\%$
$W_s=0$, $W_T=1$, MRF	45.5	34.6	84.2
$W_s=0.4$, $W_T=0.6$, MRF	48.6	23.4	83.3
$W_s=0.6$, $W_T=0.4$, MRF	41.7	20.5	86.8
$W_s=1$, $W_T=0$, MRF	56.7	30.2	79.7
Adaptive weight, MRF	36.2	16.7	88.3
Adaptive weight, DAMRF	34.8	13.8	89.6

更为完整而且与地物真实变化更为接近。

从表1和表2可以看出,图6(f)和图7(f)显示了更好的变化检测结果,变化检测结果的总体精度分别为90.8%和89.6%,从图8和图9可以看出,自适应权重变化检测精度最高,特征自适应融合后利用DAMRF的变化检测方法可以有效地提高变化检测的总体精度。此外,与视觉上的评价结果一致,当仅利用光谱进行变化检测时,虚检率较高,虚检率分别为

22.4%和56.7%;仅利用纹理特征时,漏检率最高,漏检率分别为33.2%和34.6%;而自适应权重后利用DAMRF分类方法的变化检测的漏检率和虚检率是所有对比方法中最低的。此外,并不是利用更多特征变化检测的效果就会越好,不同特征对于变化检测的贡献不一样,主导地位也不一样,当光谱特征取固定值为0.4的时候,可以看出虚检率相对于只用纹理特征的虚检率反而增加,且总体精度也小于只利用纹理特征。

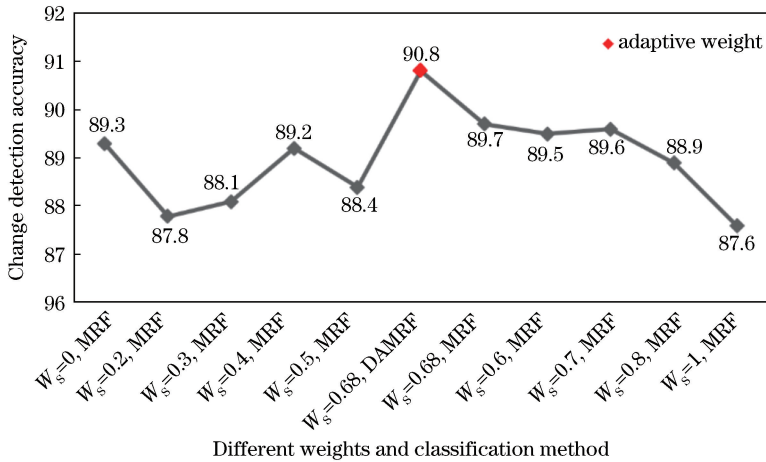


图8 第1组实验中检测精度的连续曲线图

Fig. 8 Continuous graph of detection accuracy for first set of experiments

根据实验结果,可以得出以下结论:

1) 仅利用光谱特征进行变化检测的结果较为零碎,产生了虚检现象和一定的漏检现象,并且变化结果中包含较多孤立的像元点,这是由于遥感影像地物复杂,存在大量的混合像元,并且会有“同物异谱”和“同谱异物”现象,从而导致检测结果出现虚

检。仅利用纹理特征则虚检率减少,但是容易出现漏检现象,这是因为纹理特征反映了地物的内部结构信息,其克服了同类地物呈现的光谱异质性带来的影响,但是对于不同地物则无法作为主要的区分依据。当分别固定光谱特征权重和纹理特征权重时,虽然变化检测总体精度有所提高,但是不能自适




图9 第2组实验中检测精度的连续曲线图

Fig. 9 Continuous graph of detection accuracy for second set of experiments

应地确定不同特征的贡献,而所提方法能自动调节权重,可以更加合理地利用不同特征,检测结果中地物完整性和准确性都有所提高。

2) 利用 MRF 的变化检测方法,虽然变化检测结果可以有较好的分类精度,但是却不能很好地保持变化检测结果的边缘细节,原因是 MRF 是各向同性的,邻域像元对中心像元有相同的影响。DAMRF 的变化检测结果优于传统 MRF,这是因为 DAMRF 利用密度引力模型,可以自适应地确定空间信息权重,改变了传统 MRF 固定权重的方式,符合实际情况,更好地描述了邻域像元对中心像元的影响,减少了变化检测结果的边缘损失的情况。

5 结 论

提出了基于密度引力和多尺度多特征融合的变化检测方法,该方法首先考虑到了不同特征的贡献不同,实现了光谱特征和纹理特征的自适应加权组合,并且利用信息熵将不同尺度不同方向的纹理特征自适应融合。该方法充分利用了影像的光谱特征和纹理特征,使得融合后的结果保留了更多的特征信息。将密度引力模型与传统 MRF 相结合,构建了自适应权重的 MRF, DAMRF 能够自适应地计算中心像元和邻域像元之间的密度引力,根据距离和紧密相关程度确定邻域像元对中心像元的影响,改变传统 MRF 空间权重相同的问题,并且能够更好地保持变化图的边缘细节和克服噪声的影响。实验结果表明,该方法提高了变化结果的准确性和完整性。该方法适用于同类地物但是光谱异质性明显的高分遥感影像。能够较好地检测出影像中地物的变化,但是没有考虑到形状特征对于变化检测的影响,并且 DAMRF 对于线状的地物分类效果并不是很

理想。下一步工作将考虑到形状特征对于变化检测的影响,从而将其应用到更为复杂的高分遥感影像中。

参 考 文 献

- [1] Du P J, Liu S C, Zheng H. Land cover change detection over mining areas based on support vector machine[J]. Journal of China University of Mining & Technology, 2012, 41(2): 262-267.
杜培军, 柳思聪, 郑辉. 基于支持向量机的矿区土地覆盖变化检测[J]. 中国矿业大学学报, 2012, 41(2): 262-267.
- [2] Li L, Shu N, Wang K, *et al.* Change detection method for remote sensing images based on multi-features fusion[J]. Acta Geodaetica et Cartographica Sinica, 2014, 43(9): 945-953, 959.
李亮, 舒宁, 王凯, 等. 融合多特征的遥感影像变化检测方法[J]. 测绘学报, 2014, 43(9): 945-953, 959.
- [3] Jia L, Li M, Wu Y, *et al.* Semisupervised SAR image change detection using a cluster-neighborhood kernel[J]. IEEE Geoscience and Remote Sensing Letters, 2014, 11(8): 1443-1447.
- [4] Wang G H, Li J L, Wang H B, *et al.* Change detection based on adaptive fusion of multiple features [J]. Remote Sensing for Land & Resources, 2018, 30(2): 93-99.
王光辉, 李建磊, 王华斌, 等. 基于多特征融合的遥感影像变化检测算法[J]. 国土资源遥感, 2018, 30(2): 93-99.
- [5] Du P J, Liu S C. Change detection from multi-temporal remote sensing images by integrating multiple features [J]. Journal of Remote Sensing,

- 2012, 16(4): 663-677.
- 杜培军, 柳思聪. 融合多特征的遥感影像变化检测[J]. 遥感学报, 2012, 16(4): 663-677.
- [6] Zhao M, Zhao Y D. Object-oriented and multi-feature hierarchical change detection based on CVA for high-resolution remote sensing imagery [J]. Journal of Remote Sensing, 2018, 22(1): 119-131.
- 赵敏, 赵银娣. 面向对象的多特征分级 CVA 遥感影像变化检测[J]. 遥感学报, 2018, 22(1): 119-131.
- [7] Tong G F, Li Y, Ding W L, *et al.* Review of remote sensing image change detection[J]. Journal of Image and Graphics, 2015, 20(12): 1561-1571.
- 佟国峰, 李勇, 丁伟利, 等. 遥感影像变化检测算法综述[J]. 中国图象图形学报, 2015, 20(12): 1561-1571.
- [8] Hao M, Zhang H, Shi W Z, *et al.* Unsupervised change detection using fuzzy *c*-means and MRF from remotely sensed images[J]. Remote Sensing Letters, 2013, 4(12): 1185-1194.
- [9] He P F, Shi W Z, Miao Z L, *et al.* Advanced Markov random field model based on local uncertainty for unsupervised change detection [J]. Remote Sensing Letters, 2015, 6(9): 667-676.
- [10] Niu P H, Li W H, Li X C. Remote sensing image change detection based on greedy EM algorithm for HMRF [J]. Opto-Electronic Engineering, 2011, 38(11): 50-56.
- 牛鹏辉, 李卫华, 李小春. 基于贪心 EM 算法的 HMRF 遥感影像变化检测[J]. 光电工程, 2011, 38(11): 50-56.
- [11] Tso B, Olsen R C. A contextual classification scheme based on MRF model with improved parameter estimation and multiscale fuzzy line process [J]. Remote Sensing of Environment, 2005, 97(1): 127-136.
- [12] Wang D X, Li Y. The hyperspectral image classification method based on improved Markov model[J]. Information & Communications, 2016, 29(1): 16-17.
- 王冬雪, 李姚. 基于改进马尔科夫分类模型的高光谱图像分类方法[J]. 信息通信, 2016, 29(1): 16-17.
- [13] Zhang Q, Zhang L P, Huang X. Classification of high-spatial resolution imagery based on distance-weighted Markov random field with an improved iterated conditional mode method [J]. International Journal of Remote Sensing, 2011, 32(24): 9843-9868.
- [14] Peng Y F, Song X N, Zi L L, *et al.* Remote sensing image retrieval based on convolutional neural network and modified fuzzy *C*-means [J]. Laser & Optoelectronics Progress, 2018, 55(9): 091008.
- 彭晏飞, 宋晓男, 訾玲玲, 等. 基于卷积神经网络和改进模糊 *C* 均值的遥感图像检索[J]. 激光与光电子学进展, 2018, 55(9): 091008.
- [15] Zhang Q C, Tong G F, Li Y, *et al.* River detection in remote sensing images based on multi-feature fusion and soft voting[J]. Acta Optica Sinica, 2018, 38(6): 0628002.
- 张庆春, 佟国峰, 李勇, 等. 基于多特征融合和软投票的遥感图像河流检测[J]. 光学学报, 2018, 38(6): 0628002.
- [16] Ye Z, Bai L, Nian Y J. Hyperspectral image classification algorithm based on Gabor feature and locality-preserving dimensionality reduction[J]. Acta Optica Sinica, 2016, 36(10): 1028003.
- 叶珍, 白璘, 粘永健. 基于 Gabor 特征与局部保护降维的高光谱图像分类算法[J]. 光学学报, 2016, 36(10): 1028003.
- [17] Li Z X, Shi W Z, Zhang H, *et al.* Change detection based on Gabor wavelet features for very high resolution remote sensing images [J]. IEEE Geoscience and Remote Sensing Letters, 2017, 14(5): 783-787.
- [18] Zhang H, Shi W Z, Wang Y J, *et al.* Spatial-attraction-based Markov random field approach for classification of high spatial resolution multispectral imagery[J]. IEEE Geoscience and Remote Sensing Letters, 2014, 11(2): 489-493.
- [19] Wen X F, Yang Z C, Chen M. Density attraction clustering algorithm between data points[J]. Journal of Frontiers of Computer Science and Technology, 2018, 12(12): 1996-2006.
- 温晓芳, 杨志翀, 陈梅. 数据点的密度引力聚类新算法[J]. 计算机科学与探索, 2018, 12(12): 1996-2006.