

基于混合高斯密度模型和空间上下文信息的 遥感影像变化检测方法及扩展

宋妍^{1,2}, 袁修孝¹, 付迎春³

1 武汉大学 遥感信息工程学院, 湖北 武汉 430079;
2 中国地质大学(武汉) 信息工程学院, 湖北 武汉 430074;
3 华南师范大学 地理科学学院, 广东 广州 510631

摘要: 在运用混合高斯密度模型对差分影像建模的基础上, 分别采用顾及上下文信息的概率松弛迭代法和马尔可夫随机场模型法进行影像的变化检测。首先, 提出一种运用遗传 K 均值算法与 EM 算法联合解算高斯混合密度模型参数的方法, 该方法可以自动地解算出模型的统计参数, 结果与手工选择样本的解算结果完全一致。然后, 比较概率松弛迭代法以及马尔可夫随机场模型法的影像变化检测效果, 得出基于模拟退火法的马尔可夫随机场法效果较好的结论。最后, 对传统的基于模拟退火法的马尔可夫随机场方法进行改进, 提出了一种变权马尔可夫随机场方法, 检测结果能更好地保持影像的结构性, 并有效去除了孤立噪声。

关键词: 影像变化检测, 混合高斯密度模型, 遗传 K 均值算法, 期望最大化算法, 马尔可夫随机场模型

中图分类号: TP391.41 **文献标识码:** A

1 引言

遥感影像的变化检测本质上可以视为差分影像的二值分类问题(Rosin, 2002), 可以从统计模式识别理论入手, 通过基于最小错误率的贝叶斯准则(Bayes rule for minimum error BRME)来进行决策, 其关键在于构建差分影像的概率模型。目前, 简单高斯分布模型、广义高斯分布模型以及混合高斯密度模型(Gaussian mixture model GMM)使用最为普遍(佘袁勇, 2005; 张路, 2004; 马国锐 & 李平湘, 2006)。由于混合高斯密度模型对数据适应能力较强, 特别受到关注。然而, 在 GMM 概率模型下, 基于 BRME 的决策过程仅考虑了像素自身的灰度特征, 没有顾及影像的上下文信息。为此, 人们将概率松弛迭代法(文贡坚, 2003)和基于马尔可夫随机场模型(Markov Random Field MRF)(佘袁勇, 2005; 张路, 2004, Bruzzone 2000)的方法引入变化

检测中。这里值得一提的是, Bruzzone(2000)最早用 GMM 模型进行影像变化检测, 并且运用 MRF 模型顾及空间上下文信息对 SAR 影像进行了试验; 张路(2004)采用该方法对香港维多利亚港湾影像进行变化检测取得了较好的效果; 文贡坚(2003)运用概率松弛迭代法对 TM 影像进行变化检测, 亦取得了很好的效果。

本文的研究工作主要由以下 3 个方面展开, 首先, 针对 GMM 采用 EM 算法解算时, 容易陷入局部最小值, 以及自动化程度低的问题, 引入遗传 K 均值法。运用遗传 K 均值算法对差分影像进行粗分类, 根据粗分类结果估计 GMM 模型参数的初始值, 然后在此基础上运用 EM 算法迭代解算得到 GMM 最终参数。遗传 K 均值算法具有搜索到全局最优解的能力, 将它与 EM 算法配合, 可以解决传统 EM 算法, 容易收敛于局部解, 需人工给定初始值的问题。笔者从计算效率和检测效果 2 个方面比较了概率松弛迭代法和 MRF 法变化检测的效果, 得出运用模拟退火法解算的 MRF 具有最佳检测效果的结论。在此基础上, 针对传统 MRF 模型在解算时, 未顾及像素邻域信

收稿日期: 2007-06-04; 修订日期: 2008-03-30
基金项目: 国家 973 计划资助项目(编号: 2006CB701302); 国家创新研究群体科学基金项目(编号: 40721001)
第一作者简介: 宋妍(1980—), 女, 博士, 毕业于武汉大学遥感信息工程学院, 现工作于中国地质大学(武汉)信息工程学院, 发表论文 3 篇。研究方向: 遥感影像变化检测方法, 遥感影像配准, 航空航天影像摄影测量。E-mail: moonriver_song@163.com.

息的缺陷,在变化检测中提出一种变权 MRF模型进行影像变化检测的思路,这种模型可以根据影像的特点对 MRF中的 2 部分能量进行自适应地进行加权,比传统的 MRF 模型有更佳的检测结果 (佘袁勇, 2005;张路, 2004;马国锐 & 李平湘, 2006)。

2 混合高斯密度模型及其参数解算

2.1 混合高斯密度模型

假设差分影像在特征空间中的分布是由一组高斯密度分布成分混合构成的,令混合成分个数为 r 其概率密度模型可表示为 (张路, 2004; Buzzone 2000;钟永强 & 王润生, 2005):

$$f(x) = \sum_{i=1}^r z_i f_i(x) \tag{1}$$

式中, z_i 为第 i 个高斯分布成分的权重因子,且满足归一化条件 $\sum_{i=1}^r z_i = 1$ 及 $z_i > 0$; $f_i(x) = \frac{1}{\sqrt{(2\pi)^d \|\sigma_i\|}} e^{-\frac{1}{2}(x-u_i)^T \sigma_i^{-1} (x-u_i)}$ 为第 i 个高斯成分的密度函数。其中, u_i 为该分布成分的均值向量; σ_i 为该成分的协方差矩阵; d 为该成分的特征空间维数。

2.2 混合高斯密度模型参数求解

采用 EM 算法求解 GMM 中的参数是一个迭代过程 (Krishna et al 1999)。在 EM 解算前需要确定混合成分的数目 r 如何确定 GMM 中的成分数是一个较为复杂的问题。在遥感影像的分类中,通常根据影像中所包含的类别数目确定 r 值 (骆剑录 & 王钦敏, 2002)。具体到变化检测的问题,在差分影像中,“未变化”像素具有一致的光谱范围,可以将其视为 1 个高斯成分;对于“变化”的像素,如果两期影像间包含 m 种变化类型,则应包含 m 种高斯成分;因此差分影像的混合成分数目 $r=m+1$ 。然而,在差值影像中,不同类型的变化可能具有相同的光谱范围,使得 $r < m+1$ 。因此,人工判读来确定 r 也较为复杂。为了使问题简单化,目前基于 GMM 的变化检测方法是直接将混合成分的数目设为 2 (Buzzone 2000;钟家强 & 王润生, 2005)。本文沿用该思路,将混合成分设置为 2 后面的试验将发现,当将混合成分设置为 2 时,对于具有不同类型变化的影像具有一定的适应性。当设置 $r=2$ 后,EM 算法的计算过程如下:

①初始化 GMM 模型的参数:

$$\lambda^{(0)} = \left\{ u_1^{(0)}, u_2^{(0)}, \sigma_1^{(0)}, \sigma_2^{(0)}, z^{(0)}, z^{(0)} \right\} \tag{2}$$

② 根据各参数估计量的当前值 $\lambda^{(i)}$,计算观测向量 x 的后验概率:

$$p^{(i)}(w_i | x_r, \lambda^{(i)}) = \frac{p^{(i)}(x_r | w_i, \lambda^{(i)})}{p^{(i)}(x_r | \lambda^{(i)})} = \frac{p^{(i)}(x_r | w_i, u_i^{(i)}, \sigma_i^{(i)}) z_i^{(i)}}{\sum_{j=1}^2 p^{(i)}(x_r | w_j, u_j^{(i)}, \sigma_j^{(i)}) z_j^{(i)}} \tag{3}$$

③根据第 i 次迭代计算的后验概率值,计算混合成分的统计量:

$$\lambda^{(i+1)} = \left\{ u_1^{(i+1)}, u_2^{(i+1)}, \sigma_1^{(i+1)}, \sigma_2^{(i+1)}, z^{(i+1)}, z^{(i+1)} \right\} \tag{4}$$

式中,

$$\begin{aligned} u_i^{(i+1)} &= \frac{\sum_{k=1}^N p^{(i)}(w_i | x_k, \lambda^{(i)}) x_k}{\sum_{k=1}^N p^{(i)}(w_i | x_k, \lambda^{(i)})}; \\ \sigma_i^{(i+1)} &= \frac{\sum_{k=1}^N p^{(i)}(w_i | x_k, \lambda^{(i)}) [x_k - u_i^{(i+1)}] [x_k - u_i^{(i+1)}]^T}{\sum_{k=1}^N p^{(i)}(w_i | x_k, \lambda^{(i)})}; \\ z_i^{(i+1)} &= \frac{\sum_{k=1}^N p^{(i)}(w_i | x_k, \lambda^{(i)})}{N}. \end{aligned}$$

其中, N 代表差分影像中的总像素数。

对第②步、第③步进行迭代,直到所计算出的第 $t+1$ 次迭代与第 t 次迭代的统计量的差值小于一给定阈值为止。试验中的阈值取 5×10^{-4} 。

2.3 基于遗传 K 均值算法的 EM 参数估计方法

EM 算法容易陷入局部极小值,因此需要采取一定的策略近似地搜索到全局的最优解,在此基础上,再进行 EM 算法。这里采用遗传 K 均值算法,该算法可以克服传统的 K 均值聚类算法收敛时易陷入局部极值问题和对初始值敏感的缺点,同时又能保持 K-均值算法快速收敛的特点 (Krishna et al 1999)。本文应用它的聚类结果为 EM 算法提供初值。图 1 示意了遗传 K 均值算法流程。

当遗传 K 均值聚类算法完毕,可得到差分影像中各像素的初始类别,由此计算均值、方差以及混合系数,为 EM 算法提供一组初值 $\lambda^{(0)}$,在此基础上可以保证 EM 算法收敛到全局最大值。




图1 遗传K均值聚类算法流程图

Fig 1 Flow chart of genetic K means clustering

3 顾及上下文信息的变化检测方法

事实上,差分影像中每个像素的类属不仅由本身决定,还会受到它的邻域像素的影响,有效地利用空间上下文信息来分析差分图像可以得到更可靠更精确的变化检测结果。

3.1 依据单个像素信息的变化检测方法

运用 BRME 准则进行变化检测,首先需对 2 期影像进行灰度差分,根据式 (5) 计算差分影像中各像素隶属于 2 类别的后验概率,选择具有较大后验概率的类别作为该像素的类属,从而完成变化检测。

$$p(w_i | x) = \frac{p(x | w_i) p(w_i)}{\sum_{j=1}^r p(x | w_j) p(w_j)} \quad (5)$$

式中, x 为观测向量; w_i 为观测向量的类别; r 为类别总数; $p(x | w_i)$ 为类别 w_i 下观测向量 x 的条件概率。依据第 2 节所述的方法,可求 GMM 模型参数,计算各个像素的后验概率,即可提取影像的变化区域。

3.2 基于概率松弛迭代法的变化检测

基于概率松弛迭代算法的变化检测流程如下(佃袁勇, 2005):

$$U(X_D, C_i) = U_{\text{data}}(X_D) + U_{\text{context}}(C_i) \\ = \sum_{i \leqslant I} \sum_{j \leqslant J} [U_{\text{data}}(x(i, j) | C_i(i, j)) + U_{\text{context}}(C_i(i, j) | \{C(g, h) | (g, h) \in N(i, j)\})] \quad (10)$$

式中, $U_{\text{data}}(X_D)$ 表示差值影像中由像素本身所决定的能量和, $U_{\text{context}}(C_i)$ 表示差值影像由各个像素邻域

①初始决策:根据 (5) 式计算各个像素属于 2 个类别的初始后验概率;

②迭代更新像素的后验概率,定义类 j 和 l 的兼容矩阵 R 为:

$$R(j, l) = \begin{cases} 1, & \text{当 } j=l \\ 0, & \text{当 } j \neq l \end{cases} \quad (6)$$

如果用 $Q_i(j)$ 表示类 j 对点 i 的兼容因素,用 $V(i)$ 表示点 i 的邻域,其总个数记为 n_i , k 为 $V(i)$ 中任意一点,属于类 l 的概率记为 P_{kl} , 则

$$Q_i(j) = \frac{1}{n_i} \sum_{k \in V(i)} \sum_{l=1}^2 R(j, l) P_{kl} \quad (7)$$

当仅考虑八邻域时,在第 $t+1$ 次迭代的后验概率可用式 (8) 进行计算:

$$P_{ij}^{(t+1)} = \frac{P_{ij}^{(t)} [1 + Q_i^{(t)}(j)]}{\sum_{j=1}^2 P_{ij}^{(t)} [1 + Q_i^{(t)}(j)]} \quad (8)$$

③当相邻两次迭代的概率 $P_{ij}^{(t)}$ 和 $P_{ij}^{(t+1)}$ 之差小于某一个给定的阈值或者迭代的次数大于某一给定次数时迭代终止,否则继续进行第 ② 步,对后验概率进行更新。

④比较影像各个像素,分别属于“变化”及“未变化”的后验概率,选择后验概率较大者作为该像素的类属。

3.3 基于 MRF 的变化检测方法

可以将差分影像视为一个马尔可夫随机场,通过计算每个像元属于变化和未变化的后验概率,根据最小化错误概率可提取变化的区域。

若用 C_i 表示差分影像 X_D 的一组类别标记, I, J 分别为影的行、列数: $C_i = \{C_i(1, 1) \cdots C_i(i, j) \cdots C_i(I, J)\}$, $1 \leqslant i \leqslant I, 1 \leqslant j \leqslant J$, $C_i(i, j) \in \{w_1, w_2\}$ (w_1, w_2 分别代表变化与未变化两个类别); 可用 $C = \{C_1 \cdots C_L \cdots C_L\}$; ($1 \leqslant L \leqslant L, L = 2^J$) 来表示所有可能出现的类别组合。按照贝叶斯最小错误率准则,差值影像 X_D 的类别标记变量 C_0 。决策值应使得后验概率最大,即

$$C_0 = \operatorname{argmax} \{P(C_i | X_D)\} \quad (9)$$

使 (9) 式最大化,可化为求 (10) 式的最小值(佃袁勇, 2005):

所决定的能量和。 $U_{data}(x(i,j) | C_1(i,j))$ 表示像素 (i,j) 属于类别 $C_1(i,j)$ 时的能量值, $U_{context}(C_1(i,j) | \{C_1(g,h), (g,h) \in N(i,j)\})$ 表示像素 (i,j) 属于类别 $C_1(i,j)$ 时, 且邻域类别标号为 $C_1(g,h)$ 时的能量值。对于每个像素 (i,j) 有以下表达式:

对原始概率密度形式作对数运算后取反可得:

$$U_{data}(x(i,j) | C_1(i,j)) = (x(i,j) - u_m)^T \sum_{m=1}^M \frac{1}{\sigma_m} \times \frac{1}{(x(i,j) - u_m) - (d/2) \ln(2\pi) - (1/2) \ln(|\sum_{m=1}^M \sigma_m|) - \ln(z_m)} \quad (11)$$

式中, $m = C_1(i,j)$, u_m ($m \in n_c$) 为差分影像中变化像素与未变化像素的均值; $\sum_m$ 为差分影像中变化像素与未变化像素的协方差矩阵, d 为差分影像的维数, z_m 为 GMM 的混合系数。各个统计参数可以通过 §2.3 节所述的方法得到。

$$U_{context}(C_1(i,j) | \{C_1(g,h), (g,h) \in N(i,j)\}) = \sum_{(g,h) \in N(i,j)} \delta_k(C_1(i,j), C_1(g,h)) \quad (12)$$

式中, δ_k 是势函数, 其表达式为

$$\delta_k(C_1(i,j), C_1(g,h)) = \begin{cases} -1, & \text{当 } C_1(i,j) = C_1(g,h) \\ 0, & \text{当 } C_1(i,j) \neq C_1(g,h) \end{cases} \quad (13)$$

求式 (10) 最小值的主要方法有 ICM (iterated conditional model) 算法和模拟退火法 (simulated annealing SA) (钟家强 & 王润生, 2005), 如何将 ICM 算法以及 SA 算法应用在变化检测中可参见文献 (佘袁勇, 2005; 张路, 2004; 钟家强 & 王润生, 2005)。当求得了 (10) 式的最小值, 就可得到差分影像最终的类别标号 C_0 , 即为变化检测最终的结果。

3.4 变权 MRF 随机场模型

上述的方法其本质采用优化算法, 使影像中每个像素的自身能量 (U_{data}) 与上下文信息能量 ($U_{context}$) 的加权和达到最小。观察式 (10) 可知, 传统 MRF 模型对这 2 部分能量采用简单相加的策略。实际上, 当像素位于影像不同的区域, 这 2 部分互相作用的方式应该有所不同, 也应该具有不同的加权方式。当像素位于信息匮乏的平坦区域 (例如水体), 由它自身的能量 (U_{data}) 即可很好地进行判决, 此时应赋给该像素的 $U_{context}$ 一个较小的权值; 反之, 当像素位于信息丰富的区域, 仅凭借 U_{data} 来进行决策, 显得不够, 应该充分地考虑邻域信息的影响, 此时应赋

$U_{context}$ 一个较大的权值。为此将式 (10) 中求和公式内每个像素的能量计算公式由简单的相加改为:

$$U_{data}(x(i,j) | C_1(i,j)) + p(i,j) \times U_{context}(C_1(i,j) | \{C_1(g,h), (g,h) \in N(i,j)\}) \quad (14)$$

式中, $p(i,j)$ 为对应于不同像素的权值, 其值应由像素邻域信息确定。

这里采用如下计算方法: 首先计算每个像素的特征值 $t(i,j)$

$$t(i,j) = \sum_{m=1}^w \sum_{n=1}^w |x(m,n) - u(i,j)| \quad (15)$$

式中, w 为局部窗口的大小, $x(m,n)$ 为局部窗口内每个像素的灰度向量, $u(i,j)$ 为局部窗口像素的均值向量。然后统计每个像素的 $t(i,j)$ 的最大值与最小值; 最后设置权值的范围 (p_{min}, p_{max}), 将 $t(i,j)$ 采用线性映射的方式, 映射到 $p_{min} - p_{max}$ 之间, 得到每个像素的 $p(i,j)$ 。

p_{min} 与 p_{max} 是 2 种能量的加权系数, 它们的取值方法与 2 部分能量的取值范围以及像素邻域的结构信息有关, 由两者的定义可知, $-8 \leq U_{context} \leq 0, U_{data}$ 的范围近似为: $0.9999 < U_{data} < 9.21$ (当 $p = 0.9999, U_{data} = 0.0001$; 当 $p = 0.0001$ 时, $U_{data} = 9.21$)。因此, 采用对某幅影像进行试验, 分别得出 p_{min} 与 p_{max} 的取值范围, 那么该范围对于其余影像相似的结构区域也应该是合适的, 因此对于别的影像而言, 也可以运用此参考值。在试验部分, 将对一幅影像进行详细试验, 得出 p_{min} 与 p_{max} 的大致范围, 将其值赋予别的影像测试对。

4 试验及其结果分析

试验采用 3 组影像, 第 1 组为 1987 年和 1992 年的 SPOT 影像, 大小为 512×512 像素 (图 2), 图 3 为其差分影像图; 第 2 组为 1991 年和 2001 年武汉地区 TM 红波段影像 (以下简称 TM①), 大小为 256×256 像素 (图 4), 图 5 为其差分影像图; 第 3 组影像为广东省虎门大桥建成前后的多光谱 TM 影像真彩色合成图 (以下简称 TM②), 大小为 400×400 像素 (图 6), 图 7 为根据两期 TM 多波段数据, 应用变化向量分析法, 所得差分影像图。分别选择三组变化检测图像对中的变化以及未变化样区, 其中, SPOT 影像对变化类 3105 像素, 未变化类样本 3246 像素; TM ① 影像对变化类 2077 像素, 未变化类 1856 像素; TM ② 影像对变化类 2185 像素, 未变化类 1130 像素。




图 2 多时相 SPOT 影像对
(a)1987 年影像;(b) 1992 年影像

Fig.2 SPOT image pair in different period
(a) 1987 image; (b) 1992 image



图 3 差分影像
Fig.3 Differential image



图 4 多时相 TM 红波段影像对
(a) 1991 年影像;(b) 2001 年影像

Fig.4 TM red band image pair in different period
(a) 1991 image;(b) 2001 image



图 5 差分影像
Fig.5 Differential image




图 6 两期多光谱 TM 影像
(a) 前期影像;(b)后期影像

Fig.6 Multi-spectral TM imagery pair
(a) prior period image; (b) posterior period image



图 7 变化向量分析法所得差分影像
Fig.7 Change vector analysis
differential result

4.1 基于遗传 K 均值的 GMM 参数解算

为验证基于遗传 K 均值的 GMM 参数解算方法的正确性,首先采用手工选择样本的方法为 EM 算法提供初始值,并统计 EM 算法收敛时变化与未变

化影像类的统计参数、迭代次数与计算时间。然后将本文提出方法的解算结果与其比较。试验结果列于表 1。

手工选择样本的方法如下:

$$T_n = a(x_{max} - x_{min})$$

$$T_c = (1 - a)(x_{max} - x_{min}) \tag{16}$$

式中， x_{min} 、 x_{max} 分别为差分影像的最小和最大灰度值； a 为调节因子， $a \in [0, 1, 0.5]$ 。

在选择了 T_u 和 T_c 之后，将差分影像中小于 T_u 的

像素构成未变化类样本，大于 T_c 的像素构成变化类样本，计算 2类影像的均值和方差，设置 GMM 中混合成分的权 $c_i=0.5(i=1, 2)$ ，以此作为 GMM 模型参数的初值。

表 1 传统选择阈值与本文方法解算 GMM 统计参数结果
Table 1 Comparison between artificial threshold and proposed method

影像	a 值	迭代次数 /CPU时 /s	未变化类			变化类		
			权	均值	标准偏差	权	均值	标准偏差
SPOT	0.1	7/35.14	0.04	1.56	1.02	0.96	39.93	43.12
	0.2	26/124.92	0.63	18.50	7.44	0.36	73.62	58.57
	0.3	22/107.53	0.63	18.50	7.43	0.36	73.57	58.56
	0.4	21/102.36	0.63	18.50	7.44	0.36	73.60	58.56
	0.5	20/98.45	0.63	18.50	7.44	0.36	73.57	58.56
	本文方法	15/73.38	0.63	18.52	7.48	0.36	74.06	58.60
TM①	0.1	10/12.05	0.05	2.25	1.01	0.94	70.35	66.44
	0.2	63/72.93	0.78	10.38	4.92	0.22	82.91	67.90
	0.3	48/55.04	0.78	10.38	4.93	0.22	82.93	67.90
	0.4	20/30.19	0.80	9.22	4.36	0.20	80.90	67.56
	0.5	8/9.33	0.77	10.50	4.50	0.23	83.13	67.94
	本文方法	10/11.36	0.77	10.50	4.50	0.23	83.13	67.94
TM②	0.1	8/25.36	0.73	26.33	6.08	0.27	60.16	37.90
	0.2	8/22.96	0.73	26.33	6.08	0.27	60.16	37.90
	0.3	8/23.25	0.73	26.33	6.08	0.27	60.16	37.90
	0.4	8/23.10	0.73	26.33	6.08	0.27	60.16	37.90
	0.5	8/23.02	0.73	26.33	6.08	0.27	60.16	37.90
	本文方法	5/15.06	0.73	26.31	6.08	0.27	59.90	37.87

表 1 中“本文方法”指的是，由基于遗传 K 均值算法解算后，再经过 EM 算法迭代解算出的统计参数。由表 1 可知，对于 3 组试验影像：① 当 a 为 0.1 时，由于 a 值过小容易造成 2 个类别的样本太少，致使 EM 算法收敛于局部极小值，该现象在前 2 组试验中对中表现明显。② 当 a 为 0.2—0.5 时，解算出的 2 个类别的统计参数基本相同，可认为此时统计出的参数即为 GMM 的真值。③ 本文方法所解算

的 GMM 统计参数与手工选择的结果基本相同。这说明基于遗传 K 均值的 EM 算法能正确解算 GMM 参数方法。④ 对于 3 组试验，当由遗传 K 均值进行粗分类后，用 EM 解算系数的效率均较高，此时 EM 能够更加快速地收敛到真值。综上所述，本文方法总可以解算出正确的 GMM 参数，并可较快使得 EM 收敛。图 8 显示了本文的解算方法的变化检测结果。




图 8 未顾及上下文信息时 GMM 的变化检测结果
(a) SPOT 检测结果；(b) TM ① 检测结果；(c) TM ② 检测结果

在第 2.2 节中,笔者指出在变化检测中近似地设置 GMM 中的 $r=2$ 。图 8 的试验结果初步说明这种近似是有实际意义的。在本文所选择的 3 幅试验数据中,均存在不同类型的变化, SPOT 试验对中算法将道路的增加以及建筑用地的增多检测出来;在 TM ② 试验对中,将农田增多的变化以及人工地物的增多, 2 种不同类型的变化提取出来;在 TM ③ 试验对中,该策略检测出大桥建成的变化以及周边农田的增加。

4.2 顾及上下文信息的影像变化检测策略比较

分别运用概率松弛迭代法、ICM 解算 MRF 的方法以及 SA 解算 MRF 的方法进行变化检测。此时取用的权值均为 $p=0.8$ 。通过对计算时间、去孤立噪声和保持结构信息几个指标的比较,得到如下试验结果。

表 2 3 种方法的计算时间

Table 2 Consumed CPU times for three methods/s			
影像	概率松弛迭代法	ICM 解算 MRF 模型	SA 解算 MRF 模型
SPOT	10.41	10.0	940.0
TM①	1.95	2.0	127.0
TM②	4.35	2.0	324

图 9 是运用 3 种方法所得到的 SPOT 影像的变化检测结果,显示的大小为原结果的 30%。为清晰地比较,选择图 9 中的①、②两个区域放大成图 10 (原始影像大小)。图 10 中的 (a)~(c) 影像对应于图 9 中的①

区。可以看出,在去除孤立噪声点方面,概率松弛迭代法效果最优,运用 SA 算法解算 MRF 的方法次之,运用 ICM 解算 MRF 的方法最差。图 10 中的 (d)~(f) 影像是图 9 中② 区的结果,概率松弛迭代法损失了大量的影像细节信息,ICM 和 SA 方法较好地保持了结构细节信息。综合表 2 结果可知,3 种方法中,概率松弛迭代法虽然解算的速度很快,对噪声也有较好的抑制作用,但检测的结果模糊了大量的变化信息;基于 MRF 模型的方法,当运用 ICM 解法时,计算速度较快;运用 SA 解法时,花费的时间最长,但是具有最佳的检测效果。图 11 是运用 3 种方法对 TM ① 试验对进行变化检测的结果,其大小为原始大小的 70%,对影像的分析可以得出与 SPOT 影像变化检测相同的结论。图 12 是 TM 试验对② 的检测结果,大小为原始大小的 44%。对其分析,可发现在去除孤立噪声点方面,概率松弛迭代方法表现最优,但它将 2 期影像中大桥的建成变化遗漏了;基于 ICM 解算的 MRF 方法以及基于 SA 解算的 MRF 方法均具有较优的检测效果,检测出了大桥的建成以及周边地区的变化;从目视效果上很难分辨两者的优劣。为此,笔者统计了这 2 种结果中面积小于 5 的变化图斑,认为它们是孤立噪声,得到 ICM 解算结果中有 278 个变化图斑;而 SA 解算结果中有 67 个。因此认为 SA 算法比 ICM 算法具有更好的去除孤立噪声效果。



图 9 对于 SPOT 影像的 3 种顾及上下文信息方法的变化检测结果
(a) 概率松弛迭代法; (b) ICM 解算 MRF; (c) SA 解算 MRF

Fig. 9 Three contextual change detection results in SPOT imagery
(a) probability relaxation iteration result (b) solution to MRF results (c) SA solution to MRF result




图 10 图 9 中 3 种顾及上下文信息的变化检测结果比较
(a) 松弛迭代; (b) ICM; (c) SA; (d) 松弛迭代; (e) ICM; (f) SA

Fig. 10 Three contextual change detection compare results




图 11 对于 TM①影像的 3 种顾及上下文信息方法的变化检测结果
(a) 松弛迭代;(b) ICM;(c) SA

Fig. 11 Three contextual change detection compare results in TM① imagery
(a) probability relaxation iteration;(b) ICM;(c) SA



图 12 对于 TM②影像的 3 种顾及上下文信息方法的变化检测结果
(a) 松弛迭代;(b) ICM;(c) SA

Fig. 12 Three contextual change detection compare results in TM② imagery
(a) probability relaxation iteration;(b) ICM;(c) SA

对 3 幅试验对,统计 3 种顾及上下文信息的变化检测方法的精度,放入表 3 中。

表 3 基于 GMM 3 种顾及上下文信息方法精度结果比较

Table 3 Accuracy comparison of three contextual change detection method based on GMM

	检测 方法	总体精 度 %	Kappa 系数	生产者精度 %		使用者精度 %	
				Wc	Wn	Wc	Wn
SPOT	PR I	85.69	0.71	89.02	82.50	82.95	88.70
	ICM	85.58	0.71	89.79	81.55	82.31	89.30
	SA	86.03	0.72	88.99	83.21	83.52	88.76
TM①	PR I	92.68	0.85	88.97	96.82	96.91	88.70
	ICM	91.41	0.83	92.39	90.30	91.42	91.38
	SA	92.58	0.85	93.31	91.76	96.91	92.45
TM②	PR I	81.71	0.62	62.33	97.56	95.44	75.99
	ICM	88.29	0.76	83.47	92.24	89.80	87.21
	SA	89.39	0.78	83.20	92.47	92.47	87.30

4.3 采用变权 MRF 策略的变化检测

4.3.1 权值对变化检测结果的影响

第 3.2 中运用 SA 算法解算 MRF 模型时,采用的权 p 为定值。但在笔者试验过程中发现,权值对变化检测的结果有显著的影响。这里给出在不同权值下采用 SA 算法对变化检测结果的影响。

图 13(a)~(c)为 SPOT 影像在不同 p 值下的变化检测结果,图 13(d)~(f)是 TM①影像在不同 p 值下的变化检测结果。可以看出,随着 p 值的减小,邻域对最终变化检测结果的影响也越来越小。表现为,检测结果的细节越来越丰富,孤立的区域逐渐增多。由此可推断,当 p 趋近无穷小时,其结果将与基于单个像素的 Bayes 决策检测结果相似,此时孤立噪声最多。相反,随着 p 值的增大,邻域对最终变化检测结果的影响越来越大,表现为孤立的

些区域、噪声减少,但同时检测结果中的细节变得越来越模糊。当 p 值增大到一定程度时,整个检测

结果都将模糊不清。可见, p 值对于最终的检测结果有着不可忽视的影响。




图 13 不同的权值对变化检测结果的影响

Fig. 13 Different change detection results under different p value

为了得到 $p_{\min}$ 与 $p_{\max}$ 的参考取值范围,分别取权值为 0.2, 0.3, 0.4, 0.5, 0.6, 1, 2, 5, 10, 15, 20, 200, 1000, 对这 13 种不同权值的结果进行统计。分别统计在不同权值 p 下,变化图斑面积小于 5 的个数 N ,以及变化轮廓大于 20 的边缘数目 M ,并认为前者代表了检测结果在去除孤立噪声方面的效果,后者代表了检测结果在保持结构特征方面的效果,绘制出图 14。在图 14(a)–(b)中,为了表示的方便,横坐标代表权值 p 取 $x=1$ 对应 $p=0.2$, $x=2$ 对应于 $p=0.3$,以此类推, $x=13$ 对应 $p=1000$ 。在图 14(a)中纵坐标 y 代表图斑面积小于 5 的个数 N ,图 14(b)中纵坐标 y 代表变化轮廓大于 20 的边缘数目 M 。由此,图 14(a)的结果代表了在不同权值下,孤立噪声的去除情况;当 $0.2 \leq p \leq 0.6$,权值较小,结果中还存在较多的面积小于 5 的变化图斑,随着 p 值的增大,变化图斑的数目减少;当 $p \geq 2$ 后,逐渐趋于稳定。图 14(b)代表了不同权值下,结构保持的情况;当 $0.2 \leq p \leq 0.6$ 时,权值较小,此时结构情况保持较好,随着权值的增大,结构保持情况渐渐变差,当 $p > 2$ 后,减小的趋势变缓。在本次的实验中可以看出, $p_{\min}$ 的取值范围在 0.4–0.6 之间,而

$p_{\max}$ 的取值范围在 5–10 之间。




图 14 不同权值下定权 MRF 的效果

a) 在去除孤立噪声方面的效果; (b) 在保持结构特征方面的效果

Fig. 14 With different p MRF change detection statistical result

(a) effect of removing isolated noise

(b) effect of preserve structural change information

4.3.2 变权 MRF变化检测试验

在得到了 p_{min} 与 p_{max} 的取值范围后, 变权 MRF 策略进行变化检测, 对 SPOT 影像取 $p_{min}=0.5$, p_{max}

$=8$; 对 TM 影像取 $p_{min}=0.5$, $p_{max}=8$ 可得到图 15 的变化检测结果。




图 15 变权 MRF变化检测结果
(a) SPOT 影像变化检测结果; (b) TM①影像变化检测结果; (c) TM②影像变化检测结果
Fig 15 Variable weight MRF change detection results
(a) SPOT result (b) TM① result (c) TM② result

图 16对变权与定权的试验结果进行进一步地比较。图 16(a)– (c)的影像对应于图 13(a)– (c)和图 15(a)中的区域③, 显示了变权 MRF策略在结构保持性方面的作用。当固定权 $p=8$ 时, 由于上下文的能量权值过大, 导致③区结构性的变化消失; 当 p 不断减小时, 这一结构性的变化逐渐显现出来, 可看到图 16(b)中, 当 $p=0.05$ 时, ③区结构性的变化很好地被检测出来了; 当采用变权策略时, 由图 16(c)可看出, 这一信息也较好地被检测出来。




图 16 变权结果与定权结果比较

Fig 16 Compare variable weight result with constant weight result

图 16(g)– (i)的影像对应于图 13(a)– (c)和图 15(a)中的④区影像, 显示了变权 MRF策略在去除孤立噪声点方面的性能。当固定权 $p=8$ 时, ④区的孤立噪声点被很好地抑制了, 而当固定权 $p=0.05$ 时, 孤立噪声点突出。当采用变权策略时, 其结果与 $p=2$ 时的结果非常相似。由此可知, 采用变权策略可以在结构信息保持与去除孤立噪声方面达到一个较好的平衡, 既可以保持结构信息又能

够去除孤立噪声点。

表 4 变权 MRF方法的检测结果				
Table 4 Variable weight MRF change detection result				
TM①		验证数据		
		变化	未变化	使用者精度 %
结果	变化	2731	499	84.55
	未变化	374	2747	88.02
	生产者精度 %	87.95	84.63	
总体精度: 86.25%		Kappa系数: 0.73		
TM②		验证数据		
		变化	未变化	使用者精度 %
结果	变化	1962	127	93.92
	未变化	115	1729	93.76
	生产者精度 %	94.46	93.16	
总体精度: 93.85%		Kappa系数: 0.88		
TM③		验证数据		
		变化	未变化	使用者精度 %
结果	变化	1824	104	95.95
	未变化	361	1026	87.78
	生产者精度 %	83.47	97.12	
总体精度: 90.98%		Kappa系数: 0.82		

图 16(d)– (f)影像对应于图 13(d), (f)和图 15(b)中的⑤区影像。图 16(d)结果为固定权值 $p=8$ 的检测结果, ⑤区中的明显结构性变化未能被完全检测出来; 图 16(e)为固定权值 $p=0.05$ 时的检测结果, 此时, 虽然结构变化被完整地检测了出来, 但结果中存在孤立噪声; 图 14(f)为变权 MRF

检测结果,此时在结构保持与去除孤立噪声 2 个方面达到一个较好的平衡。

为了进一步说明变权 MRF 方法在变化检测方法中的性能,对上述 3 组试验影像对统计混淆矩阵,并且计算 Kappa 系数,结果见表 4。

5 结 论

本文探讨了采用混合高斯密度模型进行多时相遥感影像变化检测的几个关键技术问题。首先,提出运用遗传 K 均值算法对 GMM 模型参数估计,通过对差分影像的粗分类结果对 EM 算法赋初始值,试验表明,该方法自动化程度高,且可以正确地解算 GMM 模型的参数。其次,对目前顾及上下文信息的概率松弛和 MRF 模型两种影像变化检测方法进行了对比试验研究,证明运用模拟退火的方法解算 MRF 模型虽然花费的时间较长,但可以获得最佳的变化检测效果。最后,分析了 MRF 方法中单个像素能量与像素邻域能量在变化检测中相互影响的关系,提出了一种变权 MRF 方法,既可以较好地保持检测结果的结构信息,又可以去除孤立噪声点,取得了不错的影像变化检测结果。虽然,本文的试验取得了较好的结果,但应该指出的是,本文将 GMM 模型中的混合成分数直接设置为 2 是一种针对实际问题的近似。虽然在本文的 3 幅试验影像中,取得了较好的结果,但是这种近似的适用条件需要进一步地论证,从而完善变化检测方法。

REFERENCES

Brizzone L. 2000. Automatic analysis of the difference image for unsupervised change detection. IEEE Geoscience and Remote

Sensing Letters 38(3): 1171– 1182

Dian Y Y. 2005. Research on change detection in remote sensing imagery. Wuhan: Wuhan University

Krishna K, Namasinha Murty M. 1999. Genetic K means algorithm. IEEE transactions on Systems Man and Cybernetics Part B. 29(3): 433– 439

Luo J C, Wang Q M, Ma J H, et al. 2002. The EM -based maximum likelihood classifier for remotely sensed data. Acta Geodaetica Et Cartographica Sinica. 31(3): 234– 239

Ma G R, Li P X. 2006. Based on fusion and GMM change detection approach of remote sensing images. Journal of Remote Sensing. 10(6): 847– 853

Rosin P L. 2002. Thresholding for change detection. Computer Vision and Image Understanding. 86(2): 79– 95

Wen G J. 2003. Detection changes area from newly remotely-sensed imagery. Wuhan: Wuhan University

Zhang L. 2004. Change detection in remotely sensed imagery using multivariate statistical analysis. Wuhan: Wuhan University

Zhang J Q, Wang R S. 2005. Multitemporal remote sensing image change detection based on adaptive parameter estimation. Acta Geodaetica Et Cartographica Sinica. 34(4): 331– 336

附中文参考文献

佃袁勇. 2005. 基于遥感影像的变化检测研究. 武汉: 武汉大学

骆剑承, 王钦敏, 马江洪等. 2002. 遥感图像最大似然分类方法的 EM 改进算法. 测绘学报, 31(3): 234– 239

马国锐, 李平湘. 2006. 基于融合和广义高斯模型的遥感影像变化检测. 遥感学报, 10(6): 847– 853

文贡坚. 2003. 从新卫星遥感影像中自动发现变化区域. 武汉: 武汉大学

张路. 2004. 基于多元统计分析的遥感影像变化检测方法研究. 武汉: 武汉大学

钟家强, 王润生. 2005. 基于自适应参数估计的多时相遥感图像变化检测. 测绘学报, 34(4): 331– 336

Research and extension of remote sensing image change detection method based on gaussian mixture model and contextual information

SONG Yan^{1,2}, YUAN Xu-xiao¹, FU Ying-chun³

1. School of Remote Sensing and Information Engineering, Wuhan University, Hubei Wuhan 430079, China;

2. Faculty of Information Engineering, China University of Geosciences, Hubei Wuhan 430074, China;

3. Department of Geography, South China Normal University, Guangdong Guangzhou 510631, China

Abstract Multi-temporal remotely sensed imagery change detection is a hot topic in recent years. Most researchers pay attention to statistical pattern recognition principal to solve the problem. In this paper, we discuss the problem from three aspects. Firstly, we focus on GMM model statistic coefficients resolve method. The Expectation Maximization (EM) is the most commonly method to calculate GMM coefficients. However, EM algorithm often converges to local value. So we combine genetic kmeans algorithm (GKA) with EM to modify it. Using the initial clustering result obtained by GKA, we are able to initialize EM globally. The combination helps EM search out globally optimal solution and enhances the automatic degree. When we get the global optimal results, it is easy for us to obtain change detection result using Bayes Rule for Minimum Error (BRME). However, the BRME doesn't take into account the image's contextual information. It is well known that one pixel belongs to "change" or "no change" depends not only on itself, but also on its neighbor pixels. There are two ways to model contextual information. The first is probability relaxation iteration, and the second is Markov Random Field (MRF). MRF has two commonly used solution methods: one is Iterated Conditional Method (ICM), and the other is Simulated Annealing (SA). In this paper, we compare the three spatial contextual change detection methods using visual effect and kappa coefficient. The experiment shows that MRF based on simulated annealing has better performance than the other two. Through the above experiments, we find that traditional MRF deals all pixels equally and ignores the neighbor local features. In fact, in different region, the spatial information has different impact. We analyze the impact and propose variable weight MRF method. It can adaptively vary spatial impact according to different image local features. It has virtues of preserving structural change and filter noises. The experiment proves that variable weight MRF gets the best result.

Key words change detection; gaussian mixture model; genetic K means clustering; expectation maximization algorithm; markov random field