

doi: 10. 6046/zrzyg. 2021032

引用格式: 李轶鲲,杨洋,杨树文,等. 耦合模糊 C 均值聚类 and 贝叶斯网络的遥感影像后验概率空间变化向量分析[J]. 自然资源遥感,2021,33(4):82–88. (Li Y K, Yang Y, Yang S W, et al. A change vector analysis in posterior probability space combined with fuzzy C – means clustering and a Bayesian network[J]. Remote Sensing for Natural Resources, 2021, 33(4):82–88.)

耦合模糊 C 均值聚类和贝叶斯网络的遥感影像后验概率空间变化向量分析

李轶鲲^{1,2}, 杨 洋¹, 杨树文^{1,2,3}, 王子浩¹

(1. 兰州交通大学测绘与地理信息学院,兰州 730070; 2. 地理国情监测技术应用国家地方联合工程研究中心,兰州 730070; 3. 甘肃省地理国情监测工程实验室,兰州 730070)

摘要: 在遥感图像变化检测领域中,后验概率空间变化向量分析(change vector analysis in posterior probability space, CVAPS)方法具有诸多优点而被广泛应用。CVAPS 法使用支持向量机(support vector machine, SVM)估计后验概率向量,但对中低分辨率遥感影像分类时 SVM 无法有效处理同物异谱、异物同谱及混合像元问题,从而无法保证最终检测结果的精度。由此,文章针对混合像元问题采用模糊 C 均值聚类(fuzzy C – means, FCM)进行建模,并耦合简单贝叶斯网络(simple Bayesian network, SBN)以解决混合像元问题及估计后验概率向量,实现了一种新的后验概率空间变化向量分析方法。实验结果表明,本文算法的总体精度和 Kappa 系数均优于基于 SVM 的 CVAPS 算法,算法性能受训练样本的数量影响较小,且参数设置简单,耗时少。文章提出的算法有助于提高遥感图像变化检测的精度和效率。

关键词: 遥感图像; 变化检测; 后验概率空间变化向量分析; 模糊 C 均值聚类; 简单贝叶斯网络

中图法分类号: TP 79 **文献标志码:** A **文章编号:** 2097 – 034X(2021)04 – 0082 – 07

0 引言

快速、有效和经济地监测地表变化已成为学术界研究的热点问题,遥感变化检测是非常有效的解决技术手段之一^[1–3]。目前,遥感变化检测技术面临的最大挑战是来自自然环境和遥感波谱相互作用的复杂性所造成的不确定性。这种不确定性不但使得传感器记录的地表光谱信号易于出现混合像素现象^[4],而且也对影像变化检测过程中的各个环节产生了不利影响,从而降低了变化检测最终结果的精度^[5–7]。为此,Chen 等^[8]通过研究分类后比较法(post classification comparison, PCC)和变化向量分析(change vector analysis, CVA)的优缺点^[9],提出了后验概率空间变化向量分析(change vector analysis in posterior probability space, CVAPS)法。该方法能够有效缓解 PCC 容易受累计分类误差影响的问题^[10],且与 CVA 不同,CVAPS 不需要良好的辐射校

正。然而,CVAPS 算法使用支持向量机(support vector machine, SVM)估计后验概率向量,没有专门针对遥感影像中易于出现的混合像素现象进行建模,因而容易造成变化检测精度的损失。

针对混合像元问题,模糊聚类算法^[11]能够以不同的隶属度将遥感影像像元与不同信号类^[12]联系起来,有效解决混合像元的分解。其中,信号类指得是遥感影像中具有典型光谱或纹理特点的像素组成的聚类。由此,本文采用模糊 C 均值聚类(fuzzy C – means, FCM)对遥感影像进行聚类,原因为:①FCM 是一种无参数算法,其对遥感影像数据的统计分布没有要求;②由于 FCM 计算出的模糊隶属度与信号类在影像中的比例强相关,因而将隶属度作为混合像素中的相应信号类的概率是比较合理的。然而,FCM 从遥感影像中提取的信号类与影像中的地物并没有直接的——对应关系^[13]。例如,城市区作为一种地物,其本身由建筑物、绿地、道路等子地物构成,而与这些子地物对应的信号类与城市区形成

收稿日期: 2021 – 02 – 07; 修订日期: 2021 – 05 – 20

基金项目: 国家自然科学基金项目“基于高分辨率卫星影像的彩钢板建筑与城市空间结构演变关系研究”(编号: 41761082)、国家重点研发计划(地球观测与导航)项目“星空地遥感立体监测技术”(编号: 2017YFB0504201)和兰州交通大学(201806)优秀平台共同资助。

第一作者: 李轶鲲(1978 –),男,博士,副教授,主要从事影像处理的研究。Email: liyikun2003@ hotmail. com。

了多对一的对应关系。又比如,森林中的阴影与水体有着类似的光谱特点,因而很可能被划分成同一信号类,证明同一信号类在不同环境下可能与多种地物形成一对多的关系。因此,需要使用相应的数学模型对信号类与地物间的多对多的关系进行建模,而简单贝叶斯网络 (simple Bayesian network, SBN) 可以很好地解决这一问题^[14-15]。基于以上分析,本文使用 FCM 为 SBN 提供关键参数,以计算遥感影像中像素属于各个地物的后验概率向量,提出了一种新的后验概率空间变化向量法: FCM-SBN-CVAPS。该方法的优点在于: ①使用 FCM 的模糊隶属度,为 SBN 估计像素属于各个信号类的条件概率; ②提出了新的 SBN 学习模型,利用模糊隶属度为 SBN 估计所涉及地物中个信号类的条件频率。

1 耦合 FCM 的 SBN 分类模型构建

1.1 耦合 FCM 的 SBN 模型

为解决遥感影像混合像元建模问题,本文设计了一种 SBN 模型,将 FCM 从遥感影像中发现的信号类与遥感影像中存在的地物建立随机链接。SBN 模型与 FCM 的结合体现在两方面: ①使用 FCM 计算的模糊隶属度建立遥感图像中某像素 $p_{i,j}$ 与信号类 ω_k 间的随机链接,缓解了混合像元现象; ②基于模糊隶属度和地物 L_v 的训练样本,建立信号类 ω_k 与地物 L_v 间的随机链接,解决了信号类与地物间的多对多关系的建模问题。本文使用的 SBN 模型如图 1 所示。




图 1 简单贝叶斯网络

Fig.1 Simple Bayesian network

该模型共 3 层: 第一层为遥感影像的像素,其中 $p_{i,j}$ 为位于该影像 i 行 j 列的像素; 第二层为信号类,其中 ω_k 为遥感影像中具有某种典型光谱或纹理特征的像素所构成的信号类或聚类; 第三层为遥感影像中的地物,其中 L_v 为该影像中的某一类地物。通过该模型,能够计算出像素 $p_{i,j}$ 属于地物 L_v 的后验

概率 $P(L_v | p_{i,j})$ 。根据贝叶斯网络的计算原则, $P(L_v | p_{i,j})$ 可以通过以下公式计算:

$$P(L_v | p_{i,j}) = \sum_{k=1}^n P(L_v | \omega_k) P(\omega_k | p_{i,j}) \quad (1)$$

根据贝叶斯公式, $P(L_v | \omega_k)$ 可表示为:

$$P(L_v | \omega_k) = \frac{P(\omega_k | L_v) P(L_v)}{P(\omega_k)} \quad (2)$$

进一步,将式(2)代入式(1)可得:

$$P(L_v | p_{i,j}) = P(L_v) \sum_{k=1}^n \frac{P(\omega_k | L_v) P(\omega_k | p_{i,j})}{P(\omega_k)}, \quad (3)$$

式中: $P(\omega_k | p_{i,j})$ 为像素 $p_{i,j}$ 属于信号类 ω_k 的程度,可由 FCM 计算得到 (详见 2.2 节); $P(\omega_k | L_v)$ 为地物 L_v 中信号类 ω_k 发生的概率 (估计方法详见 2.3 节); $P(L_v)$ 为地物 L_v 的先验概率; $P(\omega_k)$ 为信号类 ω_k 的概率。综上所述,通过式(3),最终可以计算出像素 $p_{i,j}$ 属于遥感影像中各个地物 L_v ($v = 1, \dots, m$) 的后验概率向量 $\boldsymbol{\rho} = (\rho_1, \dots, \rho_v, \dots, \rho_m)$ (其中 $\rho_v = P(L_v | p_{i,j})$), 实现后验概率空间变化向量框架下的变化检测。

1.2 模糊 C 均值聚类模糊隶属度计算

在中低分辨率遥感影像中,混合像元普遍存在,单一像元可能隶属于多个信号类。为此,本文使用 FCM 以不同的隶属度将像元与不同信号类联系起来,有效的实现了混合像元的分解,以提高后续处理过程的精度。

设影像 $I = \{p_{i,j} | 1 \leq i \leq N, 1 \leq j \leq M\}$ 是由 N 行 M 列像素构成的遥感影像,现将其模糊划分为 n 个信号类, $u_k(i,j)$ ($1 \leq k \leq n$) 表示图像 I 中像素 $p_{i,j}$ 对于第 k 个信号类 ω_k 的隶属度。隶属度集合 $U = \{u_k(i,j) | \text{满足如下约束条件:}$

$$\begin{aligned} u_k(i,j) &\in [0,1], \forall i,j,k \\ \sum_{k=1}^n u_k(i,j) &= 1, \forall i,j \\ 0 < \sum_{1 \leq i \leq N} u_k(i,j) &< N \times M, \forall k \end{aligned} \quad (4)$$

FCM 聚类算法采用各个像素与所在信号类中心的差值平方和最小准则,通过迭代更新隶属度集合 U 和信号类中心 Ψ ,达到使目标函数 J 最小的最优聚类,目标函数 J 的定义如下:

$$J(U, \Psi) = \sum_{1 \leq i \leq N} \sum_{1 \leq j \leq M} (u_k(i,j))^q \|p_{i,j} - \psi_k\|^2, \quad (5)$$

式中: $\Psi = \{\psi_1, \dots, \psi_k, \dots, \psi_n\}$ 为信号类中心点集, 且 ψ_k 是信号类 ω_k 的中心; q 为控制聚类模糊程度的模糊参数。从式(4)可以看出, SBN 中 $P(\omega_k | p_{i,j})$ 与 $u_k(i, j)$ 满足同样的约束条件, 因此可以用 FCM 计算所得的 $u_k(i, j)$ 估计 $P(\omega_k | p_{i,j})$, 实现 SBN 与 FCM 的结合。

1.3 基于模糊隶属度的 SBN 学习

为了计算像素 $p_{i,j}$ 属于地物 L_v 的后验概率 $P(L_v | p_{i,j})$, 需要基于专家提供的地物 L_v 的训练像素集合 T_v 以计算条件概率 $P(\omega_k | L_v)$ 。论文首先定义地物 L_v 中信号类 ω_k 的频率公式为:

$$SF_v(k) = \sum u_k(x, y) \quad \forall p_{x,y} \in T_v \quad (6)$$

由于不同于普通聚类算法如 K 均值聚类, 训练像素 $p_{x,y}$ 关于信号类 ω_k 的隶属度不是 0 或 1, 而是属于 0, 1 之间的一个模糊隶属度 $u_k(x, y)$, 因此需要对训练集 T_v 里的所有像素对信号类 ω_k 的隶属度求和来计算地物 L_v 中信号类 ω_k 的频率。

在计算出训练集 T_v 中所有信号类 $\omega_l (l = 1, \dots, n)$ 的频率 $SF_v(l)$ 后, 条件概率 $P(\omega_k | L_v)$ 被近似为:

$$P(\omega_k | L_v, T_v) = \frac{SF_v(k)}{\sum_l SF_v(l)} \quad (7)$$

另外, 在式(3)中, 先验概率 $P(\omega_k)$ 是计算后验概率 $P(L_v | p_{i,j})$ 的归一化因子。本文使用全概率公式计算 $P(\omega_k)$, 即

$$P(\omega_k) = \sum_v P(\omega_k | L_v) P(L_v) \quad (8)$$

式中 $P(\omega_k | L_v)$ 可以通过式(6)和(7)进行估计。

1.4 后验概率空间变化向量

假设混合像元 $p_{i,j}$ 由植被和水体构成, 且该像元在时相 t_1 和 t_2 拍摄的同一地区的遥感影像中光谱有轻微变化。通过后验概率估计, 该像素在 t_1 时相属于植被和水体的概率分别为 51% 和 49%, 根据最大后验概率分类原则, 该像素应属于植被。而该像素在 t_2 时相属于植被和水体的概率分别为 49% 和 51%, 同样根据最大后验概率分类原则, 该像素应属于水体。因此, 虽然其光谱仅有轻微变化, PCC 会将像元 $p_{i,j}$ 判断为变化像元。显然, PCC 对变化像元的过高估计是由分类错误造成的。为了解决这一问题, Chen 等提出了后验概率空间变化向量法 (CVAPS): 假设像素 $p_{i,j}$ 在 t_1 时相属于地物 L_v 的后验概率为 ρ_v^1 , 将其在 t_1 时相遥感影像中属于所有地物的后验概率记为后验概率向量 $\rho^1 = (\rho_1^1, \dots, \rho_m^1)$, m 为遥感影像中的地物数量; 同样该像

素在 t_2 时相的后验概率向量记为 $\rho^2 = (\rho_1^2, \dots, \rho_v^2, \dots, \rho_m^2)$ 。因此相应的后验概率变化向量可定义为

$$\Delta\rho = \rho^1 - \rho^2 \quad (9)$$

式中 $\Delta\rho$ 为像素 $p_{i,j}$ 在 t_1 和 t_2 时相的后验概率的变化向量。相应的, 像素 $p_{i,j}$ 在后验概率向量空间的变化幅度为:

$$\|\Delta\rho\| = \sqrt{\sum_{v=1}^m (\rho_v^1 - \rho_v^2)^2} \quad (10)$$

最后, 使用自动阈值算法对基于式(10)生成的变化幅度图进行处理, 得到变化二值图。

1.5 FCM - SBN - CVAPS 检测模型

综上所述, 构建的 FCM - SBN - CVAPS 变化检测算法的主要流程如图 2 所示。




图 2 耦合模糊 C 均值聚类和贝叶斯网络的变化检测模型

Fig. 2 Change detection model coupling fuzzy C - means clustering and Bayesian network

2 实验结果及分析

基于构建的 FCM - SBN - CVAPS 模型, 论文进行了变化检测、参数敏感性测试、训练样本数量影响分析、算法耗时分析及综合性能比较等方面的测试实验。

本文以甘肃省兰州市兰州新区为研究区。研究区位于兰州市北部, 东南与兰州市皋兰县毗邻, 西北与兰州市永登县相邻, 中心位置为 $E103^\circ 29' \sim 103^\circ 49'$, $N36^\circ 17' \sim 36^\circ 43'$ 。研究区主要包括建筑物, 农田, 森林, 荒地, 山地等地物类型。本实验选择了 2016 年和 2017 年的两景 Landsat8 影像, 影像大小为 650 像素 $\times$ 650 像素。对实验数据做了辐射定标、大气校正及图像拉伸等预处理。实验系统的运行环境为英特尔 Core i7 - 10700 2.90GHz 8 核处理器。为提高精度, 实验中对生成的初始变化二值图都进行了去噪处理和形态学闭运算 (填充空洞) 处理。

2.1 变化检测示例

为验证所提出算法的有效性, 本文实现了基于 SVM 的 CVAPS 算法 (简称 SVM - CVAPS^[8]), 并与

FCM - SBN - CVAPS 算法对比。其中 FCM - SBN - CVAPS 为 50 信号类,模糊参数 $q = 3.5, 5\ 000$ 训练样本/地物,阈值算法为 Otsu; SVM - CVAPS 为 5 000 训练样本/地物,阈值算法为 Kapur^[15]。结果如图 3 所示。通过对比,从中可直观地观察到 FCM - SBN - CVAPS 算法和 SVM - CVAPS 算法变化检测性能的差异。其中,图 3(c)中红线划分的区域为人工检测到的变化区域。图 3(d)和图 3(e)中红线划分的区域

分别为 FCM - SBN - CVAPS 算法和 SVM - CVAPS 算法检测到的变化区域。图 3(d)和图 3(e)中蓝色框内为算法错检的变化区域。从图中可以发现,相比 FCM - SBN - CVAPS 算法,SVM - CVAPS 算法错检区域范围明显更大。图 3(c)中黄框内为两个算法都漏检的区域,而绿框内为 SVM - CVAPS 算法漏检的区域。因此,与 FCM - SBN - CVAPS 算法相比 SVM - CVAPS 算法漏检的区域更多一些。




图 3 变化检测算法研究区比较示例

Fig.3 Comparison examples of change detection algorithms in the study area

2.2 算法参数敏感性测试

论文使用 FCM 对影像的 7 个波段进行聚类处理。首先,为 FCM 设定 3 种不同聚类数(10,30 及 50)和 6 种不同模糊参数 $q(1.0,1.5,2.0,2.5,3.0,3.5,4.0)$,以测试其对最终变化检测结果的影响。其中,当 $q = 1.0$ 时,FCM 退化为普通 C 均值聚类。另外,本实验从原始图像中选取了 5 类地物作为训练样本:建筑物(29 326 像素),农田(19 926 像素),森林(80 120 像素),荒地(32 224 像素),山地(144 312)。总训练像素数量为 305 908(约占实验图像总像素的 36.20%),每种地物的平均训练像素数量为 61 182。

具体实验结果如图 4 所示。从实验结果可发现:当模糊度参数 $q = 1.0$ 及 1.5 时,FCM 模糊度不够,无法有效反映 Landsat8 影像的混合像元现象,因而导致在所有聚类数下,变化检测 Kappa 系数值较低(均不超过 0.50)。特别是当 $q = 1.0$ 时 FCM 退化为普通 C 均值聚类,Kappa 系数均不超过 0.40。

当模糊参数 q 大于等于 2.0 时,对于所有聚类数,变化检测 Kappa 系数均大于 0.75,并且随着 q 的继续




图 4 基于不同聚类数和模糊参数 q 的 FCM - SBN - CVAPS 算法的 Kappa 系数

Fig.4 The Kappa coefficient of FCM - SBN - CVAPS algorithm based on different clustering number and fuzzy parameter q

增大,Kappa 系数没有显著变化。以上结果表明混合像元问题极大地影响变化检测精度。

2.3 训练样本数量对 Kappa 系数影响

为了比较不同数量训练样本对 FCM - SBN - CVAPS 算法的影响,针对每类地物随机选取了 1 000,2 000,3 000,4 000 和 5 000 个训练像素。相应的,总训练像素数分别约占实验图像总像素的 0.59% ,1.18% ,1.76% ,2.37% ,2.96%。实验结果如图 5 所示,图上每种聚类数的模糊参数 q 选用图 4 中具有最佳 Kappa 系数的模糊参数值。进一步分析表明:训练样本数量对变化检测的 Kappa 系数的影响很微弱,训练样本为 1 000 时与训练样本为 5 000 时的 Kappa 系数值的差异分别为 0.02(聚类数 10),0.00(聚类数 30),0.00(聚类数 50)。因此,本文所提出的方法只需要较少的训练样本就可以取得相对较好的变化检测效果。并且,随着训练样本的增加,Kappa 系数没有明显下降,足见本文所提方法对过度训练问题有较好的鲁棒性。




图 5 不同数量训练像素对 FCM - SBN - CVAPS 及 SVM - CVAPS 算法 Kappa 系数的影响

Fig.5 Effects of different number of training pixels on the Kappa coefficients of FCM - SBN - CVAPS and SVM - CVAPS algorithms

为了进一步通过比较验证所提出算法的有效性,实验测试了 SVM - CVAPS 算法在不同数量训练样本条件下的变化检测性能,结果如图 5 所示。结果表明,随着训练样本的增加,SVM - CVAPS 算法的 Kappa 系数没有明显改善,甚至有时增加训练样本后 Kappa 系数出现下降现象。训练样本为 1 000 时与训练样本为 5 000 时的 Kappa 系数值的差异为 0.04。与本文提出的 FCM - SBN - CVAPS 算法相比,SVM - CVAPS 算法对训练样本数量更为敏感,且这种影响并不总是正向的。造成这一结果的原因可能在于:①训练样本选择对 SVM 的分类性能有

较大的影响,而本实验的训练像素是从手动划分的训练区域中随机选取的;②相比其他分类器,SVM 在小样本条件下具有更好的鲁棒性^[8],因此样本的增加不一定会导致更好的分类性能。

2.4 算法耗时分析

FCM 是 FCM - SBN - CVAPS 算法中最为耗时的步骤,并且随着聚类数的增加,FCM 所消耗的时间有极大的增长。其后继 SBN 训练和变化检测所消耗时间则少得多,并且与训练像素的数量没有明显的关系。相比之下,SVM - CVAPS 算法中训练和分类步骤消耗了最多的时间,耗时与训练样本数正相关,而其变化检测时间耗时则很少,且与训练样本数量没有明显关联。总体上,FCM - SBN - CVAPS 算法比 SVM - CVAPS 算法耗时少:FCM - SBN - CVAPS 算法的最小耗时约为 62 s,最大耗时约为 314 s;而 SVM - CVAPS 算法最小耗时约 60 s,最大耗时约为 535 s。值得注意的是,在消耗最少时间的情况下,FCM - SBN - CVAPS 算法的 Kappa 系数为 0.78,比 SVM - CVAPS 算法高 0.17;在消耗最多时间的情况下,FCM - SBN - CVAPS 算法的 Kappa 系数为 0.80,比 SVM - CVAPS 算法高 0.13。

2.5 算法性能综合比较

本文采用“变化/非变化”混淆矩阵对 FCM - SBN - CVAPS 算法、FCM - SBN - PCC 算法、SVM - CVAPS 算法和 SVM - PCC 算法的性能进行了综合比较。对比结果如表 1 所示。

表 1 变化检测算法性能比较					
Tab.1 The performance evaluation of change detection algorithms					
算法	参数	错检率/%	漏检率/%	总体精度/%	Kappa 系数
FCM - SBN - CVAPS	50 聚类 $q = 3.5$	20.38	16.59	97.40	0.801 0
FCM - SBN - PCC	1 000 训练样本	54.06	15.65	92.02	0.554 8
SVM - CVAPS	$cp = 13$ $gamma = 3$	38.97	19.79	95.07	0.666 9
SVM - PCC	5 000 训练样本	73.28	10.59	82.22	0.340 9

1)本文算法无论从总体精度还是 Kappa 系数都取得了最好的结果,总体精度与 Kappa 系数比 SVM - CVAPS 的算法分别高 2.33 百分点和 0.134 1。二者都存在过度估计变化像元的现象,但 FCM - SBN - CVAPS 算法的错检率低了 18.59 百分点,表现相对更优。

2)FCM - SBN - CVAPS 算法的性能要明显优于 FCM - SBN - PCC 算法。其总体精度和 Kappa 系数比 FCM - SBN - PCC 算法分别高出 5.38 百分点和 0.246 2。且过度估计变化像元的程度明显比 FCM -

SBN – PCC 算法低(错检率低 33.68 百分点),表明与 PCC 模型相比,CVAPS 模型不易于受累计分类误差的影响,进一步证明了 CVAPS 变化检测算法的优越性。

3 结论

本文所提出的 FCM – SBN – CVAPS 算法针对中低分辨率遥感影像的混合像元问题进行建模,同时使用后验概率向量进行变化检测,有效提高了检测精度和效率。与 SVM – CVAPS 算法相比,本文算法在总体精度和 Kappa 系数上都比较理想,此外,算法耗时少,参数设置要求低,不易受过度训练的影响。因此,本文算法具有更高的鲁棒性和实用性。

但类似于许多变化检测算法,FCM – SBN – CVAPS 算法生成的初始变化二值图有许多细小的斑块和孔洞,需要进一步的处理,计划未来在模型中引入空间信息以解决这一问题。

参考文献 (References) :

[1] 李德仁. 利用遥感影像进行变化检测[J]. 武汉大学学报(信息科学版),2003,28(s1):7–12.
Li D R. Change detection from remote sensing images[J]. Geomatics and Information Science of Wuhan University,2003,28(s1):7–12.

[2] Coppin P, Jonckheere I, Nackaerts K, et al. Digital change detection methods in ecosystem monitoring: A review[J]. International Journal of Remote Sensing,2004,25(9):1565–1596.

[3] Tewkesbury A P, Comber A J, Tate N J, et al. A critical synthesis of remotely sensed optical image change detection techniques[J]. Remote Sensing of Environment,2015,160:1–14.

[4] 王艳恒,高连如,陈正超,等. 结合深度学习和超像元的高分遥感影像变化检测[J]. 中国图象图形学报,2020,25(6):1271–1282.
Wang Y H, Gao L R, Chen Z C, et al. Deep learning and superpixel – based method for high – resolution remote sensing image change detection[J]. Journal of Image and Graphics,2020,25(6):1271–1282.

[5] Singh A. Digital change detection techniques using remote sensed data[J]. International Journal of Remote Sensing,1989,10(6):989–1003.

[6] Yetgin Z. Unsupervised change detection of satellite images using

local gradual descent[J]. IEEE Transactions on Geoscience and Remote Sensing,2012,50(5):1919–1929.

[7] 郝明,史文中,邓喀中. 空间信息准确性增强遥感变化检测[M]. 北京:测绘出版社,2017.
Hao M, Shi W Z, Deng K Z. Remote sensing change detection based on enhanced spatial information[M]. Beijing:Surveying and Mapping Press,2017.

[8] Chen J, Chen X, Cui X, et al. Change vector analysis in posterior probability space: A new method for land cover change detection[J]. IEEE Geoscience and Remote Sensing Letters,2011,8(2):317–321.

[9] 蔡怵晟,向泽君,蔡衡,等. 结合特征选择的 CVA 多尺度遥感影像变化检测[J]. 测绘通报,2020(8):101–104.
Cai F S, Xiang Z J, Cai H, et al. CVA multi – scale remote sensing image change detection combined with feature selection[J]. Bulletin of Surveying and Mapping,2020(8):101–104.

[10] 张春森,吴蓉蓉,李国君,等. 面向对象的高空间分辨率遥感影像箱线图变化检测方法[J]. 国土资源遥感,2020,32(2):19–25. doi:10.6046/gtzyyg.2020.02.03.
Zhang C S, Wu R R, Li G J, et al. High resolution remote sensing image object change detection based on box – plot method[J]. Remote Sensing for Land and Resources,2020,32(2):19–25. doi:10.6046/gtzyyg.2020.02.03.

[11] 王昶,张永生,王旭,等. 基于深度学习的遥感影像变化检测方法[J]. 浙江大学学报(工学版),2020,54(11):2138–2148.
Wang C, Zhang Y Y, Wang X, et al. Remote sensing image change detection method based on deep neural networks[J]. Journal of Zhejiang University (Engineering Science),2020,54(11):2138–2148.

[12] Daschiel H, Datcu M. Design and evaluation of human – machine communication for image information mining[J]. IEEE Transactions on Multimedia,2005,7(6):1036–1046.

[13] Ichoku C, Karnieli A. A review of mixture modeling techniques for sub – pixel land cover estimation[J]. Remote Sensing Reviews,1996,13(3–4):161–186.

[14] 胡玉玺,李轶鲲,杨萍. 基于上下文敏感的贝叶斯网络及方向关系的遥感图像检索[J]. 国土资源遥感,2017,29(3):70–76. doi:10.6046/gtzyyg.2017.03.10.
Hu Y X, Li Y K, Yang P. Retrieving of remote sensing images based on content – sensitive Bayesian networks and direction relations[J]. Remote Sensing for Land and Resources,2017,29(3):70–76. doi:10.6046/gtzyyg.2017.03.10.

[15] Kapur J N, Sahoo P K, Wong A K C. A new method for gray – level picture thresholding using the entropy of the histogram[J]. Computer Vision, Graphics, and Image Processing,1985,29:273–285.

A change vector analysis in posterior probability space combined with fuzzy C – means clustering and a Bayesian network

LI Yikun^{1,2}, YANG Yang¹, YANG Shuwen^{1,2,3}, WANG Zihao¹

(1. Faculty of Geomatics, Lanzhou Jiaotong University, Lanzhou 730070, China; 2. National – Local Joint Engineering Research Center of Technologies and Applications for National Geographic State Monitoring, Lanzhou 730070, China; 3. Gansu Provincial Engineering Laboratory for National Geographic State Monitoring, Lanzhou 730070, China)

Abstract: The change vector analysis in posterior probability space (CVAPS) method has been widely used in the

change detection of remote sensing images owing to its many advantages. It uses the support vector machine (SVM) to estimate the posterior probability vector. However, in the classification of low and medium resolution remote sensing images, SVM cannot effectively deal with the problems of the same object with the different spectra, different objects with the same spectrum, and mixed pixels and thus cannot guarantee the accuracy of the final detection results. Therefore, this paper adopts the fuzzy c – means (FCM) clustering for modeling and couples the FCM with a simple Bayesian network (SBN) to solve the problem of mixed pixels and estimate the posterior probability vector, thus achieving a new posterior probability space change vector analysis method. The experimental results indicate that, compared to the SVM – based CVAPS algorithm, the algorithm proposed in this study shows higher overall accuracy, higher Kappa coefficient, more reliable performance that is less affected by the number of training samples, simpler parameter setting, and lower time consumption. Therefore, the algorithm proposed in this paper helps to improve the accuracy and efficiency of the change detection of remote sensing images.

Keywords: remote sensing image; change detection; change vector analysis in posterior probability space; fuzzy C – means clustering; simple Bayesian network

(责任编辑: 张 仙)