

一种运用纹理和光谱特征消除投影差影响的建筑物变化检测方法

袁修孝^{1,2} 宋妍¹

(1 武汉大学遥感信息工程学院,武汉市珞喻路 129 号,430079)

(2 武汉大学测绘遥感信息工程国家重点实验室,武汉市珞喻路 129 号,430079)

摘要:针对不同时期高分辨率遥感影像变化检测中城区建筑物因投影差差异所产生的误检测现象,提出了一种综合应用光谱和纹理特征的建筑物变化检测方法。以变化和未发生变化地物影像的散度作为可分性依据,首先对光谱差分影像在混合高斯密度模型下建模,并采用马尔可夫最小错误概率准则提取初始变化区域,往往含有错判的建筑物。然后将误判建筑物影像类和真实变化影像类构成训练集,通过引入多通道 Gabor 滤波器,提取训练集的纹理差分特征,并采用分类别 PCA 变换实施纹理差分特征的选择。最后对选择出的纹理差分特征依据高斯混合密度模型建模,并用马尔可夫最小错误概率提取真变化区域,即可去除光谱信息检测所产生的伪变化。试验表明,本文方法能够较好地解决建筑物变化的错判问题,提高了影像变化检测的精度。

关键词:影像变化检测;多通道 Gabor 滤波器;分类别 PCA 变换;混合高斯密度模型;马尔可夫最小错误概率
中图法分类号:TP751; P237.3

目前的遥感影像变化检测研究多集中于中、低分辨率遥感影像^[1,2],主要用于土地利用变化分析、环境污染监测等。由于高分辨率卫星遥感影像可以提供更为丰富的地物细节,对其进行变化检测,对于城市绿地调查、城市扩张以及军事目标的变化分析有着重要的意义。然而,对于可见光遥感影像(如 TM、SPOT、IKONOS)的变化检测一般从像素的光谱差分入手,就两期影像的建筑物而言,由于不同时期影像投影差的差异会造成变化检测错误。如果充分利用高分辨率遥感影像的纹理特征,可以有效地减少变化误检测。为此,本文应用多通道 Gabor 滤波器提取影像纹理特征,考虑不同期影像纹理的相似性,通过纹理差分可大大减弱因投影差引起的误检测;同时,以影像类别间的散度为依据,采用分类别 PCA 变换方法选择纹理特征,有针对性地选择可分性良好的多通道 Gabor 滤波器纹理特征,再辅助光谱特征进行变化检测,可以较好地解决建筑物群由于投

影差的差异所引起的伪变化检测问题,从而提高了影像变化检测的精度。

1 影像变化检测类别可分性判据

本文采用散度作为影像类别间的可分性指标。设有 i 和 j 影像类,其散度^[3]为:

$$D_{ij} = \frac{1}{2} \text{tr}((\sigma_i - \sigma_j)(\sigma_i^{-1} - \sigma_j^{-1})) + \frac{1}{2} (\mathbf{u}_i - \mathbf{u}_j)^T ((\sigma_i^{-1} + \sigma_j^{-1})(\mathbf{u}_i - \mathbf{u}_j)) \quad (1)$$

式中, σ_k 、 \mathbf{u}_k ($k=i, j$) 为第 k 类影像的协方差矩阵和均值向量。

在实际应用中,常采用转换散度:

$$\text{TD}_{ij} = 2000e^{-\frac{D_{ij}}{8}} \quad (2)$$

Jensen 指出,当转换散度大于 1 700 时,影像类别间的可分性较好;反之,影像类别间的可分性将很差^[4]。

2 影像纹理特征提取

1999年, Trgve 试验证明, 用多通道 Gabor 滤波器提取的纹理特征对图像分割具有较好的效果^[5]。为此, 本文采用多通道 Gabor 滤波器在不同尺度和方向上对影像进行滤波并提取纹理特征。

2.1 Gabor 多通道滤波器

Gabor 函数 $h(x, y)$ 是被复正弦函数调制了的高斯函数, 其表达式^[6]为:

$$h(x, y) = g(x', y') e^{2\pi(U_0 x + V_0 y)j} \quad (3)$$

式中, $g(x', y') = \frac{1}{2\pi\sigma_x\sigma_y} e^{-\frac{1}{2}[(\frac{x'}{\sigma_x})^2 + (\frac{y'}{\sigma_y})^2]}$ 。其中, σ_x, σ_y 为 x 和 y 方向的尺度参数; (U_0, V_0) 为中心频率, 由其可计算调制函数的径向中心频率 $F_0 = \sqrt{U_0^2 + V_0^2}$ 及其调制方向 $\theta = \arctan(V_0/U_0)$; $(x', y') = (x\cos\theta + y\sin\theta, -x\sin\theta + y\cos\theta)$ 为旋转后的空间域坐标。

2.2 纹理特征提取

利用 Gabor 滤波器提取影像的纹理特征时, 一般给定一组径向中心频率 F_0 和调制方向 θ , 并采用式(3)对影像进行卷积运算, 可得到影像在不同方向和频率上的滤波影像。滤波影像的局部均值可用于表征影像的纹理特征。

$$u(x, y)_{F_0\theta} = \frac{\int_{y-\frac{n}{2}}^{y+\frac{n}{2}} \int_{x-\frac{n}{2}}^{x+\frac{n}{2}} |W_{F_0\theta}(x, y)| dx dy}{n} \quad (4)$$

式中, $u(x, y)_{F_0\theta}$ 为滤波影像所提取的影像特征; $W_{F_0\theta}(x, y)$ 为滤波后所得的空间域影像; n 为纹理分析窗口大小。

心理学研究表明, 30° 的方向带宽更符合人类视觉系统的特征^[6]。为此, 本文按照 30° 的间隔依次选取多通道 Gabor 滤波方向角参数 $\theta = (0, \frac{\pi}{6}, \frac{2\pi}{6}, \frac{3\pi}{6}, \frac{4\pi}{6}, \frac{5\pi}{6})$, 中心频率取经验值 $F_0 = (\frac{\sqrt{2}}{16}, \frac{\sqrt{2}}{8}, \frac{\sqrt{2}}{4})$ 。

2.3 纹理特征差分影像选择方法

对两期影像采用多通道 Gabor 滤波器提取纹理特征并作差分, 可得到纹理差分特征。这些差分特征间的相关会造成信息的冗余以及存储和计算负担。这里采用基于散度的分类别 PCA 变换^[3]对纹理差分特征进行选择, 既可保留原始差分特征的物理意义, 又具有较快的计算速度和较小的存储量。

如果人工挑选出的未变化和已变化的训练样区影像分别记为 $\mathbf{X}^{(1)}, \mathbf{X}^{(2)}$, 对其纹理差分特征分别作 PCA 变换, 则有:

$$\begin{bmatrix} y_1 \\ y_2 \\ \vdots \\ y_L \end{bmatrix}^{(i)} = \begin{bmatrix} p_{11} & p_{21} & \cdots & p_{L1} \\ p_{12} & p_{22} & \cdots & p_{L2} \\ \vdots & \vdots & \vdots & \vdots \\ p_{1L} & p_{2L} & \cdots & p_{LL} \end{bmatrix}^{(i)} \begin{bmatrix} x_1 \\ x_2 \\ \vdots \\ x_L \end{bmatrix}^{(i)} \quad (5)$$

式中, L 为特征维数; $i=1, 2$ 。

对两类纹理差分特征分别进行 PCA 变换后, 可计算两类影像间的散度:

$$D_{12} = \sum_{l=1}^L \left(\frac{(\sigma_1^2(l) - \sigma_2^2(l))^2}{\sigma_1^2(l)\sigma_2^2(l)} + \frac{\sigma_1^2(l) + \sigma_2^2(l)}{\sigma_1^2(l)\sigma_2^2(l)} (u_1(l) - u_2(l))^2 \right) \quad (6)$$

若用式(7)定义权值 a_l , 表明 PCA 变换后的第 l 维特征对类别可分性的贡献:

$$a_l = \frac{D_{12}(l)}{D_{12}} \quad (7)$$

则可用式(8)定义贡献因子 $\bar{E}_l^{(i)}$, 表示原始特征 l 对类 i 的重要度:

$$E_l^{(i)} = \frac{1}{L} \sum_{k=1}^L a_l (p_{lk}^{(i)})^2 \quad (8)$$

根据 $\bar{E}_l^{(i)}$ 在类别 i 内对原始特征降序排列, 排序越靠前说明该特征对于该类别越重要。根据各个特征在类别内的排序位置 $K_l^{(i)}$, 可定义特征 l 对于类别可分性的重要度:

$$R_l = \frac{\sum_{i=1}^2 (L - 1 - K_l^{(i)})}{L} \quad (9)$$

R_l 越大说明特征 l 对类别可分性越重要。选择较大的 R_l 构成初始特征集 B , 并计算 B 中各特征间的相关系数。根据相关系数将 B 分为 q 个子集, 保证子集内特征相关性较强, 子集间相关性很弱。各子集内的特征按 R_l 值降序排列, 随后可根据封二彩图 1 进行特征选择。

3 根据顾及上下文信息的混合高斯密度模型提取变化区域

对于光谱差分以及选择出的纹理差分特征, 均需提取变化区域。有试验表明^[1,2], 采用混合高斯密度模型 (Gaussian mixture model, GMM) 对差分影像建模, 并运用马尔可夫模型最小错误率贝叶斯决策提取变化区域, 可以兼顾像素的自身统计特性及其邻域统计特征, 检测效果较好。这里沿用该策略, 分别对两种特征差分影像提取

变化区域。

3.1 混合高斯密度分布模型

GMM 假设差分数据在空间中的分布是由一组数量有限的高斯密度分布成分混合构成的,设共有 r 个这样的分布成分,则差分影像的总体概率密度为:

$$f(x) = \sum_{i=1}^r \omega_i f_i(x) \quad (10)$$

式中, $f_i(x) = \frac{1}{(\sqrt{2\pi})^d \sqrt{\|\boldsymbol{\sigma}_i\|}} e^{-\frac{1}{2}(x - \boldsymbol{u}_i)^T \boldsymbol{\sigma}_i^{-1} (x - \boldsymbol{u}_i)}$

为第 i 个高斯成分的密度函数; \boldsymbol{u}_i 为该分布成分的均值向量; $\boldsymbol{\sigma}_i$ 为该成分的协方差矩阵; d 为特征空间维数; ω_i 为第 i 个高斯分布成分的权重,且满足归一化条件 $\sum_{i=1}^r \omega_i = 1, \omega_i > 0$ 。

3.2 混合高斯密度分布模型参数求解

一般采用期望最大化算法(expectation maximization, EM)对 GMM 中的参数进行估计。EM 算法分为 E 步和 M 步, E 步用于计算似然函数的期望 Q 函数, M 步用于选择使期望最大的参数。当 M 步选择好参数后,再将选择的参数代入 E 步,计算 Q 函数,如此反复至迭代收敛。由于变化检测问题中,无论采用光谱差分特征还是纹理差分特征,都将影像中的像素分为变化与未变化两类,因此,式(10)中的 $r=2$ 。文献[7]给出了 EM 的具体计算过程。

3.3 基于 GMM 的马尔可夫随机场模型提取变化区域

将差值影像视为一个马尔可夫随机场(Markov random field, MRF),估计每个像元上变化与未变化的先验概率,通过最小错误率贝叶斯决策(简称最小错误概率准则)提取变化区域。此时,将所有像素的类别标记为一个整体,用 C_l 表示。 $C_l = C_l(i, j) (1 \leq i \leq I, 1 \leq j \leq J, C_l(i, j) \in \{W_1, W_2\}, W_1, W_2$ 分别代表变化与未变化两个类别),记 $C = C_l (1 \leq l \leq L, L = 2^U)$,表示差值影像 X_D 中所有可能出现的组合。按照最小错误概率准则,差值影像 X_D 的类别标记变量 C_l 决策值应使得后验概率最大,即

$$C_k = \underset{C_l \in c}{\operatorname{argmax}} \{P(C_l | X_D)\} = \underset{C_l \in c}{\operatorname{argmax}} \{P(C_l)P(X_D | C_l)\} \quad (11)$$

式中, $P(C_l)$ 是先验概率; $P(X_D | C_l)$ 是差值影像在某一状态下的条件概率。

使式(11)最大可等效于求式(12)的最小值:

$$U(X_D, C_l) = U_d(X_D) + U_c(C_l) = \sum_{1 \leq i \leq I} \sum_{1 \leq j \leq J}$$

$$[U_d(\mathbf{X}(i, j) | C_l(i, j)) + U_c(C_l(i, j) | \{C_l(g, h), (g, h) \in N(i, j)\})] \quad (12)$$

式中, $U_d(\mathbf{X}_D)$ 为单个像素的统计特征; $U_c(C_l)$ 描述了相邻像素之间的相互依赖关系,具体的解析式可参见文献[2]。

求解式(12)的最小值,可采用 ICM(iterated conditional models)、模拟退火法(SA)以及最大后验边缘概率法。原理上讲,SA 能以较大概率搜索到全局最优值^[1],因此,本文采用 SA 算法求解。

4 综合光谱特征和纹理特征的变化检测流程

首先对两期影像目视判读,确定未变化的地物类型 $n_i (i=1, 2, \dots, N)$,以及变化类型 $c_j (j=1, 2, \dots, M)$,选取相应的训练样区。求光谱差分影像,依式(2)分别计算 n_i 与 c_j 间的转换散度 $(1 \leq i \leq N, 1 \leq j \leq M)$ 。然后,运用 GMM 对光谱差分特征建模,并依据最小错误概率准则提取光谱差分的区域,得到初步的变化检测结果。根据初步检测结果以及转换散度,挑选出光谱差分中可分性差的未变化地类与变化地类。

假设“未变化的建筑物”为 $\mathbf{X}^{(1)}$,将所有“变化”类别合并为 $\mathbf{X}^{(2)}$,并设 $\mathbf{X} = \mathbf{X}^{(1)} \cup \mathbf{X}^{(2)}$ 。按照分类别 PCA 变换选择纹理差分特征,选择出的纹理差分特征对于 $\mathbf{X}^{(1)}$ 和 $\mathbf{X}^{(2)}$ 具有良好的可分性。基于 GMM 对选择出的纹理差分建模,采用 MRF 最小错误概率进一步提取 \mathbf{X} 的变化区域,剔除其中的伪变化。最后,结合两步检测的结果,形成最终的变化检测结果。

5 试验及其结果分析

5.1 试验数据及预处理

试验选用 2003 年、2004 年所获取的同一城区两期多光谱 IKONOS 影像,每期影像包含了 4 个波段的数据,其标称空间分辨率为 4 m。首先采用仿射变换模型对两期影像进行几何配准,然后利用线性模型进行相对辐射校正。封二彩图 2 为经过配准及辐射校正后的两期红(R)波段影像。

5.2 变化检测特征可分性分析和特征选择

经判读,两期影像中未发生变化的地类有植被、水池、道路、水泥地和建筑物,分别记为 n_1 、 n_2 、 n_3 、 n_4 和 n_5 ;发生实质性变化的地类有:① 植被变为裸露地(记为 c_1),② 裸露地变为建筑物(记为 c_2)。为分析特征可分性,在光谱差分影像

上选取 5 个未变化地类及两个变化地类构成训练样区(ROI)。封二彩图 3 为两期影像 R 波段的差分影像以及 ROI 选择,光谱差分特征的转换散度结果见表 1。

表 1 光谱差分特征的转换散度

Tab. 1 Transform Divergence of Spectral Difference Imagery

	n_1	n_2	n_3	n_4	n_5
c_1	2 000	2 000	2 000	2 000	1 963
c_2	2 000	2 000	2 000	2 000	1 584

依 Jensen 的结论,由表 1 可以看出,光谱差分特征对 n_5 与 c_2 的可分性较差。因此,单纯运用光谱差分特征作变化检测会引起错判,会将未变化的建筑物错误地判断为变化。

设 n_5 为 $\mathbf{X}^{(1)}$,将 c_1 与 c_2 取并得 $\mathbf{X}^{(2)}$,分别提取 $\mathbf{X}^{(1)}$ 与 $\mathbf{X}^{(2)}$ 的纹理特征并依据 § 2.3 中分类别 PCA 准则进行纹理差分特征的选择,得表 2。

表 2 n_5 与变化类别的纹理特征转换散度

Tab. 2 Texture Transformation Divergence Between n_5 and Change Class

$(F_0, \theta, \text{Band})$	$(\frac{\sqrt{2}}{4}, \frac{4\pi}{6}, R)$	$(\frac{\sqrt{2}}{8}, \frac{3\pi}{6}, R)$	$(\frac{\sqrt{2}}{4}, \frac{2\pi}{6}, G)$
TD_{n_5, c_2}	1 825	1 799	1 799
TD_{n_5, c_1}	2 000	2 000	2 000

表 2 数据系取第一行参数即径向中心频率 F_0 和方向角 θ 对 Band 波段影像进行纹理提取并作差分而计算出的转换散度,此值均大于 1 700。由此可以看出,用表 2 的纹理特征进行差分可以较好地变化类别中区分出未变化的建筑物。

5.3 变化检测结果分析

5.3.1 基于光谱差分提取变化区域结果

运用四维光谱特征进行变化区域的提取,结果如封二彩图 4。其中,黑色代表初始判断为未变化的区域,白色代表初始提取的变化区域。封二彩图 4 中标注的区域 1、2 分别对应彩图 2 中的

1、2 区域,这两个区域本属未变化建筑物区域,由于两期影像投影差的差异,单纯运用光谱特征将造成错误的检测结果。

5.3.2 融合光谱和纹理特征的变化检测结果

封三彩图 5 为用表 2 中参数 $(\frac{\sqrt{2}}{4}, \frac{4\pi}{6}, R)$ 提取的两期纹理特征,对两者差分,并将初始判断为未变化的像素用黑色掩模,可得封三彩图 6。封三彩图 6 中的 1、2 区与封三彩图 4 中的对应,此时由于它们的纹理特征相似,差值显示为灰色,而真正的变化区域依旧保持高的差异,显示为白色。因此通过纹理特征辅助可将伪变化从真正的变化中去除。

取表 2 的三组参数提取两期影像纹理特征并作差分,对初始判断为变化的像素进一步提取真变化区域,并去除其中的伪变化,得到最终的变化检测结果(封三彩图 7)。

从封三彩图 7 可以看出,两期建筑物由投影差不同而引起的伪变化基本被消除,而两期影像中的典型变化被保留。

与遥感影像分类精度的评定方法类似,可以构造变化检测中变化类别与未变化类别的变化检测混淆矩阵(如表 3)。其对角线数据表明检测结果与真实情况相符的程度,其值越大表明检测效果越好;非对角线上的元素表示检测错误的样本数。根据混淆矩阵可以计算出变化检测的总体精度与 Kappa 系数。总体精度反映了总体上的检测准确程度,Kappa 系数反映了检测结果的内部一致性,它比总体精度有更好的代表性^[1]。为了体现本文方法的优势,表 3 中每组精度指标均有两项,括号内的第一个数为仅运用光谱差分的精度,第二个数为加入纹理特征的精度。结果表明,纹理特征的加入提高了检测率,使总体精度和 Kappa 系数分别提高了 9.9% 和 16.3%。

表 3 变化检测精度

Tab. 3 Accuracy of Change Detection

	未变化	变化	总计	生产者精度
未变化	(1 253, 1 428)	(395, 220)	1 648	(76.0%, 86.7%)
变化	(70, 70)	(245, 245)	315	(77.8%, 77.8%)
总计	(1 323, 1 498)	(640, 445)	1 963	
使用者精度	(94.7%, 95.4%)	(32.3%, 55.0%)		
	总体精度: (76.3%, 85.2%)		Kappa 系数: (38.0%, 54.3%)	

6 结 语

纹理特征是遥感影像中重要的空间结构信息,

在图像目标识别中起着关键作用。本文的研究发现在运用高分辨率遥感影像进行变化检测时,不能仅仅考虑其光谱特征,而要综合地考虑纹理特征。研究中引入 Gabor 纹理特征,该特征的引入解决了

由于建筑物投影差而引起的误判,提高了影像变化检测的精度。更深入的研究正在进行之中。

参 考 文 献

- [1] 张路. 基于多元统计分析的遥感影像变化检测方法研究[D]. 武汉:武汉大学,2004
- [2] 佃袁勇. 基于遥感影像的变化检测研究[D]. 武汉:武汉大学,2005
- [3] 黄睿,何明一. 基于分类别 PCA 散度的高光谱图像分类波段选择[J]. 电子与信息学报,2005,27(10): 1 588-1 592
- [4] Swain P H, Davis S M. Remote Sensing: the Quantitative Approach [M]. New York: McGraw Hill Book Company, 1978
- [5] Trygve R. Filtering for Texture Classification: a

Comparative Study [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 1999, 21 (4):291-310

- [6] 赵银娣. 马尔可夫模型的扩展及其在高分辨率影像分类中的应用[D]. 武汉:武汉大学,2006
- [7] 余鹏,封举富. 一种新的基于高斯混合模型的纹理图象分割方法[J]. 武汉大学学报·信息科学版, 2005,30(6):514-517

第一作者简介:袁修孝,博士,教授,博士生导师。主要从事航空航天遥感高精度对地目标定位理论与方法、高分辨率卫星遥感影像几何处理、影像变化检测与数据更新等的研究与教学工作。代表成果:GPS 辅助空中三角测量等。已出版专著 2 部,发表论文 60 余篇。

E-mail:yxxqxhyw@public.wh.hb.cn

A Building Change Detection Method Considering Projection Influence Based on Spectral Feature and Texture Feature

YUAN Xiuxiao^{1,2} SONG Yan¹

(1 School of Remote Sensing and Information Engineering, Wuhan University, 129 Luoyu Road, Wuhan 430079, China)

(2 State Key Laboratory of Information Engineering in Surveying, Mapping and Remote Sensing, Wuhan University, 129 Luoyu Road, Wuhan 430079, China)

Abstract: A change detection method for high-resolution remotely sensed imagery is designed by combined the texture features with spectral features. The method can decrease change detection errors caused by building projection difference between two period imageries. It utilizes transform divergence between change and no-change to establish change detection strategy. Firstly, the differential spectral features are modeled by using Gaussian mixture model (GMM) and initial change area is obtained by using MRF minimum error probability. But for high-resolution imagery, the projection difference will disturb change area's result. For decreasing these errors, the texture features are extracted by multi-channel Gabor filter. When using these texture features, it is necessary to reduce these texture features' correlation and relieve computation burden. A class-within PCA is adopted to select texture features. Using selected texture features, the initial change area is modeled by using GMM and "false change" is got rid of using MRF minimum error probability. The experiment has shows that the mentioned method can remove false change caused by projection difference and improve change detection accuracy.

Key words: remote sensing imagery change detection; multi-channel Gabor filter; divergence of class-within PCA; Gaussian mixture model; Markov random field minimum error probability

About the first author: YUAN Xiuxiao, Ph. D. professor, Ph. D supervisor. He is concentrated on the research and education in high precision photogrammetric point determination, POS-supported aerial photogrammetry, geometric processing of high-resolution satellite imageries, and image change detection and data update, etc. He published 2 monographs and more than 60 papers.

E-mail: yxxqxhyw@public.wh.hb.cn