

一种遥感影像核变化检测方法

马国锐¹ 眭海刚¹ 李平湘¹ 秦前清¹

(1 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:提出了一种新的遥感影像核变化检测方法。该方法是将原始空间不同时相的输入矢量通过核函数非线性映射到高维特征空间,然后在高维特征空间中通过传统变化检测方法处理得到新的输入矢量,最后通过半监督的单类支持向量机算法对新的输入矢量构造变化区域与非变化区域的最优分割超平面。试验证实,本文的核变化检测方法具有较高的检测精度和效率。

关键词:变化检测;核函数;单类支持向量机

中图法分类号:P237.4

利用不同时间获取的同一地区的遥感影像进行地表变化检测的应用一直是遥感应用研究的热点^[1-3]。多年来,研究人员提出了多种遥感影像变化检测技术,如分类比较法、代数法、匹配法等,这些方法大多选择一个距离测度和一个阈值,在输入空间中计算两个时相相应输入矢量的距离或相似度,输入矢量可以是像素、提取的特征矢量或者目标的描述值。距离超过给定阈值的像素或区域被认为是发生了显著的变化,距离小于阈值的没有发生变化。事实上,在两个时相的较高维数的输入矢量中,距离等于阈值时的方程将构成一个超曲面(如果距离度量为线性,将构成超平面),超曲面将变化区域与非变化区域分开。在输入空间,变化区域与非变化区域的可分性仅由输入矢量和距离测度度量,输入矢量维数过高和距离测度复杂度增加都会显著地影响算法的性能,降低变化检测的效率。本文引入核函数思想^[4,5],将两个时相的输入矢量非线性映射到高维特征空间,这样一般会增加变化区域与非变化区域的线性可分性^[6]。

1 核变化检测算法

差值法和比值法操作简单,应用最为广泛^[7,8]。这两种算法是在原始输入空间中构造变化区域与非变化区域的分割超曲面,但分割能力

有限,一般只适合单波段图像。本文提出的核变化检测算法将原始空间不同时相的输入矢量通过核函数非线性映射到高维特征空间,在高维特征空间中利用传统变化检测方法处理得到新的输入向量,然后通过半监督的单类支持向量机算法构造变化区域与非变化区域的最优分类超平面。核函数的利用使得大量的内积运算在输入空间而不是在高维特征空间中进行,间接地构造了原始空间更加复杂的非线性分割超曲面,增强了变化检测性能,而几乎没有增加计算负担。

核变化检测算法原理如下:假设一个时相的样本为 $p = \{p_1, \dots, p_l\}$,另一个时相的样本为 $q = \{q_1, \dots, q_l\}$, l 是样本的数目。第 i 个样本的特征 $p_i = \{p_{i,1}, \dots, p_{i,m}\}$, $q_i = \{q_{i,1}, \dots, q_{i,m}\}$, m 是特征的维数。

用线性学习器学习非线性问题一般分两步^[9]。

1) 将两个时相的数据集非线性映射到高维特征空间,特征空间的维数设为 N 维,则

$$\Phi(p) = \{\phi_1(p), \phi_2(p), \dots\}$$

$$\Phi(q) = \{\phi_1(q), \phi_2(q), \dots\}$$

在特征空间里取两个时相的样本差值作为新的输入样本,新样本的数量仍然是 l 个,但每个新样本的维数变为 N 维:

$$\Phi(x) = \{\phi_1(x), \phi_2(x), \dots\} = \Phi(p) - \Phi(q) = \{\phi_1(p) - \phi_1(q), \phi_2(p) - \phi_2(q), \dots\}$$

第 i 个样本变为 $\Phi(x_i) = \Phi(p_i) - \Phi(q_i)$ 或 $\phi_i(x) = \phi_i(p) - \phi_i(q)$ 。

2) 在特征空间里使用线性学习器分类,表示成:

$$f(x) = \sum_{i=1}^N w_i \phi_i(x) + b = \sum_{i=1}^N w_i (\phi_i(p) - \phi_i(q)) + b \tag{1}$$

线性学习器可以表达为对偶形式,即决策规则可以在对偶空间中用测试点和训练点的内积表示^[10]: $f(x) = \sum_{i=1}^l \alpha_i (\Phi(x_i) \cdot \Phi(x)) + b$ 。

使用核函数可以直接在特征空间中计算内积,从而可以将上面两个步骤统一起来,将数据隐式地表达为特征空间,越过本来需要的计算特征映射的问题。

$$\begin{aligned} \Phi(x) \cdot \Phi(x') &= \Phi(p) \cdot \Phi(p') - \Phi(p) \cdot \Phi(q') - \\ &\Phi(q) \cdot \Phi(p') + \Phi(q) \cdot \Phi(q') = K(p, p') - \\ &K(p, q') - K(q, p') + K(q, q') = K(x, x') \end{aligned} \tag{2}$$

组合核函数:

$$\begin{aligned} K(x, x') &= K(p, q, p', q') = K(p, p') - \\ &K(p, q') - K(q, p') + K(q, q') \end{aligned} \tag{3}$$

则决策函数为:

$$\begin{aligned} f(x) &= \sum_{i=1}^l \alpha_i (\Phi(x_i) \cdot \Phi(x)) + b = \\ &\sum_{i=1}^l \alpha_i K(x_i, x) + b \end{aligned} \tag{4}$$

考虑到变化区域与非变化区域样本的严重不对称性和变化区域样本不易获取及非变化区域样本也无法穷举的事实,本文采用单类支持向量机算法构造最优分类超平面。单类支持向量机超平面法由 Scholkopf 等人于 1999 年提出,方法是在特征空间中计算一个超平面,使之与原点的距离尽量大,且使尽可能多的训练样本位于超平面的另一侧,变化区域作为正样本,没有变化的区域作为原点而不必选取。

其原始最优化问题为:

$$\begin{aligned} \max_{w, \xi, \rho} & -\frac{1}{2} \|w\|^2 - \frac{1}{vl} \sum_{i=1}^l \xi_i + \rho \\ \text{s. t. } & (w \cdot \phi(x_i)) \geq \rho - \xi_i, \xi_i \geq 0, \rho \geq 0, v \in (0, 1] \end{aligned} \tag{5}$$

最终的决策函数为 $f(x) = \text{sgn}\{ (w \cdot \Phi(x)) - \rho \}$, 其中, sgn 表示符号函数。

为解最优化问题,引入 Lagrange 系数 $\alpha_i \geq 0, \beta_i \geq 0, i = 1, \dots, l$, 对应的 Lagrange 函数为:

$$L_P(w, \xi, \rho; \alpha, \beta) = \frac{1}{2} \|w\|^2 - \frac{1}{vl} \sum_{i=1}^l \xi_i -$$

$$\rho - \sum_{i=1}^l \alpha_i ((w \cdot \Phi(x)) - \rho + \xi_i) - \sum_{i=1}^l \beta_i \xi_i \tag{6}$$

对 w, ξ, ρ 求偏导并令其等于零,得:

$$w = \sum_{i=1}^l \alpha_i \Phi(x_i), \alpha_i = \frac{1}{vl} - \beta_i \leq \frac{1}{vl}, \sum_{i=1}^l \alpha_i = 1$$

代入决策函数,得:

$$\begin{aligned} f(x) &= \text{sgn}\{ \sum_{i=1}^l \alpha_i K(x_i, x) - \rho \} = \\ &\text{sgn}\{ \sum_{i=1}^l \alpha_i K(p_i, q_i, p, q) - \rho \} \end{aligned} \tag{7}$$

代入 Lagrange 函数,得到优化问题的对偶形式:

$$\begin{aligned} \min_{\alpha} & \frac{1}{2} \sum_{i,j=1}^l \alpha_i \alpha_j K(x_i, x_j) \\ \text{s. t. } & 0 \leq \alpha_i \leq 1/vl, \sum_{i=1}^l \alpha_i = 1 \end{aligned} \tag{8}$$

求解该 QP 问题可以得到 α 的值,不为零的 α_i 所对应的样本称为支持向量,根据任一支持向量都可以得出:

$$\begin{aligned} \rho &= (w \cdot \Phi(x_i)) = \sum_{j=1}^l \alpha_j K(x_j, x_i) = \\ &\sum_{j=1}^l \alpha_j K(p_j, q_j, p_i, q_i) \end{aligned} \tag{9}$$

根据 ρ 和 α 及支持向量即可进行决策判断。要测试一个新的样本 $z = \{p, q\}$ 是否是变化区域,根据决策规则,如果 $f(x) \geq 0$,则为变化区域;否则,为非变化区域。

2 试验与分析

试验图像如图 1 所示,图像大小为 490 像素 \times 410 像素,拍摄时间分别为 2002 年 9 月 10 日和 2003 年 4 月 1 日。试验环境为 Windows XP、C++、Pentium 2.8 GHz、512 M 内存。具体步骤如下。

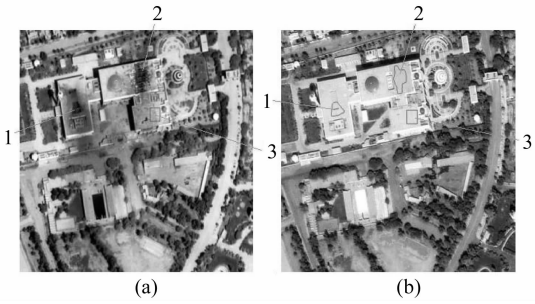


图 1 遭破坏前后的影像和样本
Fig. 1 Images and Samples

1) 训练样本选取。采用半自动人机交互方式提取变化区域,如图 1 中数字 1 标识的区域,训

练样本共 321 个,每个样本的元素取两个时相的 R、G、B 分量,共 6 维。

2) 测试样本选取。取其他变化区域为测试样本的正样本,如图 1 中数字 2 标识的区域,正样本共 692 个,再取某处没有显著变化的区域为负样本,如数字 3 标识的区域,负样本共 284 个,测试样本合计 976 个。测试样本的元素取值同训练样本,并对训练样本和测试样本分别进行尺度变化,使每个元素的值落在 $[-1,1]$ 区间中。

3) 模型选择与训练。模型选择包括支持向量机的选择、核函数的选择和相关参数的选择。本文采用单类支持向量机进行训练,取 RBF 为单个的核函数,其组合核函数为:

$$K(x,x')=K(p,q,p',q')=\exp\{-\gamma|p-p'|^2\}-\exp\{-\gamma|p-q'|^2\}-\exp\{-\gamma|p'-q|^2\}+\exp\{-\gamma|q-q'|^2\}\tag{10}$$

相关的参数涉及 ν 和 γ ,由于 ν 是间隔错误样本点个数所占总样本点个数份额的上界,也是支持向量个数所占总样本点个数份额的下界,而

且训练样本是经过确认的发生了显著变化的区域,可信度较高,故此处取 $\nu=0.01$,保证 99% 的样本决策正确。对参数 γ 的选择一般有三个可以参考的标准:最少的支持向量、最大化分类间隔、最大检测精度。本试验中,三者随参数 γ 的变化趋势如图 2、图 3 和图 4 所示。从图中可以看出,支持向量个数随 γ 的增大而逐渐增多,分类间隔随 γ 的增大而逐渐减小。根据这两个标准,似乎选择的 γ 越小越好,但测试数据的检度精度曲线却出现了一个峰值(图 4),在 $\gamma=0.062\ 5$ 处具有最大的检测精度 96.8%。这是因为在 ν 相对确定的情况下, γ 决定特征空间中决策平面的收缩程度, γ 越小,决策平面越宽松,正的测试样本检测率越高,但负测试样本由于含有较多非显著的变化区域,所以会出现较多误检。随着 γ 的增大,决策平面逐渐向样本点收缩,负测试样本的检测精度提高,但同时使得检测算法的推广性能变差,正测试样本的检测率逐渐下降,总体测试样本的检测精度随 γ 呈非单调变化。

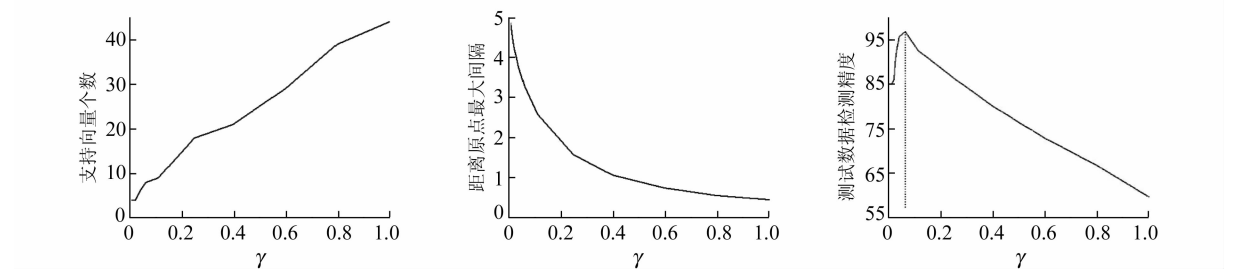


图 2 支持向量随 γ 变化的曲线图

Fig. 2 Number of Support Vectors as Function of γ

图 3 分类间隔随 γ 变化的曲线图

Fig. 3 Margin from the Origin as Function of γ

图 4 检测精度随 γ 变化的曲线图

Fig. 4 Detection Accuracy as Function of γ

4) 变化检测。根据选取的 ν 和最优的 γ ,对待检测区域的每个像素进行预测,对变化的像素进行

标记。如图 5 所示,采用传统的差值法和比值法变化检测方法得到的差异影像结果如图 6、图 7 所示。

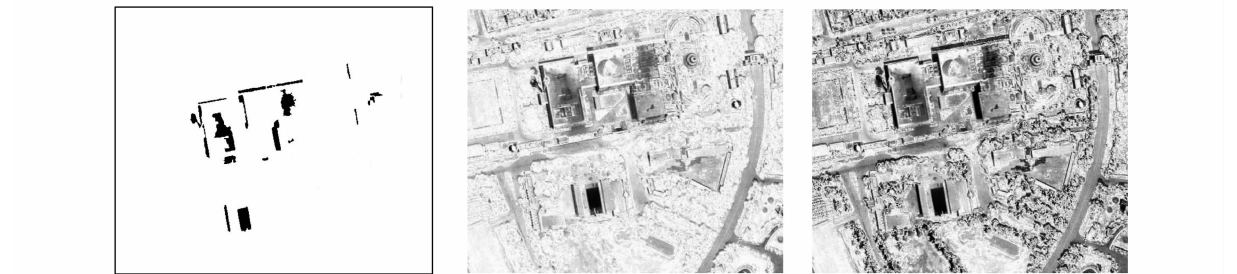


图 5 核变化检测结果标识

Fig. 5 Kernel Change Detection Result

图 6 差值变化检测差异图

Fig. 6 Difference Change Detection Result

图 7 比值变化检测差异图

Fig. 7 Ratio Change Detection Result

比较图 6 和图 7 可以发现,差值法和比值法均显著地增强毁伤变化和阴影变化,比值法在更好地突出毁伤变化的同时,也增强了树木阴影等许多微弱变化。传统的变化检测方法需要人工确

定阈值才能得到变化的二值影像图,本文方法是根据样本中获取的参数和模型直接得到变化的检测结果。从图 5 可以看出,核变化检测可以很好地检测出显著的毁伤变化,对树木的阴影等非显著的弱小变化具有很好的抵抗作用,但对建筑物阴影变化也都检测出来了,这是因为本文的方法依赖图像的高精度配准,基于像素的变化检测方法对投影差非常敏感,这是本文方法的不足之处。不过相对于毁伤变化,阴影变化一般更加具有规则的几何形状和狭长的结构,据此可以去除这些不感兴趣的显著变化,得到最终的变化检测结果。

参 考 文 献

[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(3):7-12

[2] 廖明生,朱攀,龚健雅. 基于典型相关分析的多元变化检测[J]. 遥感学报,2000, 4(3):197-201

[3] 方针,张剑清,张祖勋. 基于城区航空影像的变化检测[J]. 武汉测绘科技大学学报,1997,22: 240-244

[4] Burges C J C. A Tutorial on Support Vector Machines for Pattern Recognition [J]. Data Mining and Knowledge Discovery, 1998, 2(2): 121-167

[5] 邓乃扬,田英杰. 数据挖掘的新方法——支持向量机[M]. 北京: 科学出版社,2004

[6] Bernhard S, Sebastian M, Chris J C B, et al. Input Space Versus Feature Space in Kernel-Based Methods[J]. IEEE Transactions on Neural Networks, 1999, 10(5): 1 000-1 017

[7] 范海生,马蒿乃,李京. 采用图像差值法提取土地利用变化信息方法——以攀枝花仁和区为例[J]. 遥感学报,2001,5(1):75-80

[8] 冯德俊,李永树,邓芳. 基于小波系数差值法的变化信息自动发现[J]. 遥感信息,2004(2):13-15

[9] Nello C, John S T. An Introduction to Support Vector Machines and Other Kernel-Based Learning Methods [M]. Cambridge: Cambridge University Press, 2000

[10] John S T, Nello C. Kernel Methods for Pattern Analysis [M]. Cambridge: Cambridge University Press, 2000

第一作者简介:马国锐, 博士生。研究方向为信号处理、遥感影像特定目标检测与识别。
E-mail: maguorui_rs@yahoo. com. cn

A Kernel Change Detection Algorithm in Remote Sensing Image

MA Guorui¹ SUI Haigang¹ LI Pingxiang¹ QIN Qianqing¹

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

Abstract: A kernel change detection algorithm (KCD) is proposed. The input vectors from two images of different times are mapped into feature space of high dimension via a nonlinear mapping. Which will usually increase the linear separation of change and no-change regions. Then, a simple linear distance measure between two feature vectors of high dimension is defined in features space, which corresponds to the complicated nonlinear distance measure in input space. Furthermore, the distance measure's dot is expressed in the combination of kernel functions and large numbers of dot operations processed in input space not in feature place by combined kernel tactic, which avoids the operation burden in high dimension space. The soft margin single-class support vector machine (SVM) is taken to select the optimal hyper-plane. Results show that KCD has excellent performance in speed and accuracy.

Key words: change detection; kernel function; single-class support vector machine

About the first author: MA Guorui, Ph.D candidate, majors in image processing, change detection.
E-mail: maguorui_rs@yahoo. com. cn