

文章编号: 1001-2486(2007)04-0072-05

遥感影像中采用多维特征的目标定位检测*

耿振伟, 粟毅, 郝文贤

(国防科技大学 电子科学与工程学院, 湖南 长沙 410073)

摘要: 给出一种在复杂场景的遥感影像中定位人造目标的方法, 通过提取多种有利于检测人造目标的特征, 并将其组合成特征矢量, 采用非参数的均值漂移聚类方法进行分割, 从而把目标从复杂场景中分离出来, 通过检测影像中的房屋建筑物, 结果表明该方法具有很好的稳健性和自动性。

关键词: 均值漂移; 检测; 遥感

中图分类号: TP391 **文献标识码:** A

Object Detection with Multiple Features in Remote Sensing Image

GENG Zhen-wei, SU Yi, YU Wen-xian

(College of Electronic Science and Engineering, National Univ. of Defense Technology, Changsha 410073, China)

Abstract: A method is presented for the localization of manmade objects in remote sensing images with complex scenes. The methodology was based on mean shift clustering in high dimension by extracting multiple features of manmade objects and forming them into a feature vector. By clustering the feature vectors, the manmade objects were segmented from the complex scenes. Results obtained on the detection of architectures in the image show that this methodology has good robustness and autonomy.

Key words: mean shift; detection; remote sensing

在目标识别系统中, 感兴趣区域定位以及目标检测是其中关键的一步。遥感影像中人造目标通常由其形状和颜色特征来刻画描述, 随着环境条件和光照的变化, 同一场景的遥感影像中, 目标可能会呈现出不同的特征, 这给定位和检测目标带来了挑战。在过去几十年中, 围绕目标定位、检测、分割等问题, 人们提出了各种各样的方法, 但只有少部分是针对户外的复杂环境的, 比如森林、植被、岩石及河流等与人造目标并存的。在过去的应用中, 基于模型的目标检测比较典型^[1], 但其通常以三维模型作为参照。与三维相比, 二维遥感影像缺少丰富的目标信息, 只有拍摄角度和拍摄距离可以作为先验知识, 二维目标的检测过程主要是寻找突显信息的过程, 如检测角点、直线、轮廓等, 把这些低层视觉特征组合起来, 用以在输入影像中检测人造目标的对称性、共线性及平行性等被认为是非常有效的, 尤其当影像内容没有先验信息时^[2]。因此, 本文通过提取多种特征, 并把这些特征组成特征矢量, 然后采用非参数聚类分析方法对特征矢量进行聚类以检测出人造目标, 比采用单一特征分别分类后再合并分类结果^[3]要更直接有效。在聚类方法中, 非参数方法比参数方法更适合处理分布未知的真实数据。在非参数聚类方法中, K 均值及其各种改进是人们最熟悉的, 但 K 均值有两个不足, 一是所聚的类受限于球状分布, 二是必须预先规定聚类的数目。另外, 不属于 K 类的数据点会使均值的计算偏离数据密集的区域, 从而导致错误的结果。均值漂移算法则很好地避免了 K 均值的上述不足, 它通过迭代计算出数据分布的模式点, 从而自动确定聚类的数目, 并描述出类的边界, 是一种优秀的非参数聚类方法。为检测复杂场景影像中的人造目标, 本文提取了基于熵测度的规则度、基于结构测度的表面一致性和基于偏差测度的局部偏差等特征, 并把上述提取的特征与图像坐标按相同的权重组成特征矢量, 采用均值漂移方法对特征矢量进行聚类, 聚类过程中, 通过设定阈值, 滤除数据点较少的类, 从而能在复杂场景的遥感影像中把要检测的人造目标从背景中完整地分割出来。

* 收稿日期: 2006-09-20

作者简介: 耿振伟(1972-), 男, 博士生。

1 检测方法原理

1.1 均值漂移方法及原理

均值漂移是一种稳健的特征空间分析方法,最初由 Fukunaga 和 Hostetler^[4]于 1975 年在模式识别论文中提出,其本质属于核密度估计,能有效地估计局部概率密度梯度。近年来,均值漂移方法在计算机视觉领域得到越来越广泛的应用^[5]。

给定 d 维空间的 n 个点 $x_i \in R^d (i=1, \dots, n)$, 点 x 的多元核密度估计函数可表示为:

$$\hat{f}_{h,K}(x) = \frac{c_{k,d}}{nh^d} \sum_{i=1}^n k\left(\left\|\frac{x-x_i}{h}\right\|^2\right) \quad (1)$$

其中, $k(\cdot)$ 为核函数的轮廓, h 为核函数的带宽。具有该轮廓的核函数为 $K(x) = c_{k,d}k(\|x\|^2)$, $c_{k,d}$ 是一个归一化的常量, 保证核函数 $K(x)$ 积分为 1, 且严格正定。如果 $k(\cdot)$ 的导数存在, 令 $g(\cdot) = -k'(\cdot)$, 则可以用 $g(\cdot)$ 轮廓定义核函数 $G(x) = c'g(\|x\|^2)$, c' 也是归一化的常量。取(1)式的梯度, 则可得到:

$$m_{h,c}(x) = \frac{1}{2} h^2 c \frac{\nabla \hat{f}_{h,K}(x)}{\hat{f}_{h,c}(x)} \quad (2)$$

其另一表现形式

$$m_{h,c}(x) = \frac{\sum_{i=1}^n x_i g\left(\left\|\frac{x-x_i}{h}\right\|^2\right)}{\sum_{i=1}^n g\left(\left\|\frac{x-x_i}{h}\right\|^2\right)} - x \quad (3)$$

称作均值漂移矢量, (2)式中 c 是一个常量。从(2)式可以看到, 均值漂移矢量始终指向密度函数梯度的最陡下降的方向, 以 K 为核的密度函数梯度估计的零值点可以通过以 G 为核的均值漂移矢量迭代得到, 不需要估计密度函数。数据点的迭代过程可表示为:

$$x^{(k+1)} = x^{(k)} + m_{h,c}(x^{(k)}) \quad (4)$$

通过这种迭代过程, 数据点可收敛至其分布的模式点, 即概率密度函数梯度的零值点, 也是最数据分布最密集处。如图 1 所示。

采用均值漂移算法聚类具有如下特性:

- (1) 无须假定待处理的数据服从某种分布, 如高斯分布。
- (2) 无须指定聚类的数目。
- (3) 聚类过程与初始类心选择无关。
- (4) 聚类是通过迭代计算寻找数据分布模式点过程中自动确定每个数据点所属的类, 以及类的数目。
- (5) 因不断迭代计算, 所以聚类过程的计算量较大。

1.2 特征定义及均值漂移聚类过程

1.2.1 检测人造目标提取的特征

(1) 规则度

在 3×3 的邻域里考虑熵的测度, 熵测度刻画了边缘的可能性, 而且在给定邻域里平滑或规则的熵能突出表示邻域内的边界, 从而会暗示为人造目标的可能。熵 H 的定义如下:

$$H = - \sum_w \sum_\theta p_w(\nabla) \log p_w(\nabla) \quad (5)$$

这里 p_w 指像素点为边缘点的可能性, 本文取为 $\nabla/4$ 。

在任一像素位置 (u, v) 和方位 θ 下的空间差异测度可表示为:




图 1 数据点收敛

Fig. 1 Data point convergence

$$\begin{cases} \nabla(u, v, \theta(0^\circ)) = \sqrt{[I(u-1, v) - I(u+1, v)]^2} \\ \nabla(u, v, \theta(45^\circ)) = \sqrt{[I(u+1, v+1) - I(u-1, v-1)]^2} \\ \nabla(u, v, \theta(90^\circ)) = \sqrt{[I(u, v+1) - I(u, v-1)]^2} \\ \nabla(u, v, \theta(135^\circ)) = \sqrt{[I(u+1, v+1) - I(u-1, v-1)]^2} \end{cases} \quad (6)$$

(2) 表面一致性

典型的人造目标表面会表现出明显的一致性,结构测度可以表示出一个像素与其周围的一致性,结构熵和共现矩阵在过去已经被用于表示目标的规则性和相似性。这里也考虑计算这些测度,首先空间差异表示为 $SD(u, v) = \sum_{u=1}^3 \sum_{v=1}^3 \delta(u, v)$, 这里 $\delta(u, v)$ 是指示函数,当像素点的亮度值与其邻域内 (u, v) 处的像素点亮度值相同时为 1。区域内的分布用均值和方差刻画,其中,

$$m = \frac{1}{M} \sum_u \sum_v SD(u, v), \quad \sigma^2 = \frac{1}{M} \sum_u \sum_v SD(u, v)^2 - m^2$$

这里, M 是邻域内所有像素的个数,于是整个区域的一致性特征可表示为:

$$U(u, v) = \frac{1}{1 + \sigma^2} \quad (7)$$

(3) 局部偏差

在实际情况中,需要检测的目标通常尺寸比较小,背景往往占场景的大部分。因此,图像中目标区域的确定可以通过计算邻域内灰度值与周围较高的偏差来获得,可采用双窗口技术来估计背景像素的分布。即一个小窗口被套在一个大窗口里,用来检测像素的分布,两个窗口的比较可用来确定像素值偏差的程度。

对于 3×3 邻域,计算其均值和方差分别为:

$$\mu_1 = \frac{1}{M} \sum_w I(u, v), \quad \sigma_1^2 = \frac{1}{M} \sum_w I^2(u, v) - \mu_1^2$$

M 是邻域内所有像素的个数。同时有一个 9×9 的大窗口与 3×3 小窗口具有相同的中心点,对其也用同样的公式计算均值 μ_2 和方差 σ_2^2 ,于是偏差测度表示为:

$$D(u, v) = \frac{|\mu_1 - \mu_2|}{\sigma_1 \sigma_2} \quad (8)$$

由此,一个具有较大偏差值的像素预示着其为目标的可能性比较大。

1.2.2 聚类过程

均值漂移聚类过程为迭代计算均值漂移特征矢量及窗口滑动的过程,通过迭代最终可确定模式点,即类心,同时也在此过程中将数据点划分为不同的类。为提高收敛速度,本文取核函数为 Epanechnikov 核^[6]。

如果提取的特征共有 P 维,再加入平面二维坐标,则特征共有 $P+2$ 维,把这 $P+2$ 维特征采用相同权重组合成一个特征矢量,记为 x_i 和 $z_i (i=1, \dots, n)$, 分别是 $P+2$ 维特征空间的输入和输出点。对于每一点(像素),采用均值漂移聚类过程如下:

(a) 初始化,令 $j=1, y_{i,j} = x_i$;

(b) 按(3)式计算均值漂移矢量,不断滑动窗口,迭代计算,直至其为零,得到收敛点 $y = y_{i,c}$;


(c) 令 $z_i = y_{i,c}$, 对所有 z_i 满足距离小于 h 聚类至 $\{C_p\}_{p=1, \dots, m}$;

(d) 标记聚类,即对 $i=1, \dots, n$, 标记 $L_i = \{p \mid z_i \in C_p\}$, 使每一类对应一块区域,并为该类内所有数据点赋予相同的属性,即为图像中该区域内的所有像素赋同一颜色值;


(e) 对已经聚好的类,通过设定阈值,去除数据点少的类,即在图像中将小面积区域划归为背景,从而使聚类后图像的区域仅为背景和目标。

2 实验结果



截取一幅航空影像,为 0.5m 分辨率的 CCD 影像,图 2(a)中 1,2,3 为建筑物,分别对该影像提取上述特征,即规则度、一致性和局部偏差,得到结果如图 2(b)、(c)、(d)所示,将这三种特征与二维平面坐标组合成 5 维特征矢量,用均值漂移进行特征聚类,并设定类内最少数据点为 20 这一阈值以滤除小面积区域,得到结果如图 2(f)所示。图 2(e)为特征空间的点集表示,其中目标点集被标定指出。同样的特征点集,即将同样的特征数据采用 K 均值分类结果如图 2(g)所示,滤除小区域后结果如图 2(h)所示。由实验结果,我们认为均值漂移聚类是先定位出特征点的类心,再描述区分出不同的特征点,因而能将目标与背景很好地分割出来,而 K 均值聚类只是基于距离测度,不能有效地定位出任意形状特征点的类心,所以结果一团混乱,即使滤除小面积区域,也无法做到把目标与背景完全分离。由此,也验证了均值漂移是一种优秀的特征空间分析方法。



(e) 特征空间点集表示



(f) 分类结果

(g) K 均值分类结果

(h) (g) 去除小区域

图2 航空影像采用本文方法及 K 均值方法的结果比较Fig.2 Results of an airborne image adopted with our method when comparing with K -means

3 小结

遥感影像中地面人造目标与自然场景具有不同的特征,提取有利于区分地面人造目标的特征是在影像中定位检测目标的重要前提,提取特征后,如何对特征空间进行有效地分析,以分离出与目标相关的特征点是目标检测的主要过程。针对特征空间分布模型未知,采用具有稳健性、自动性的均值漂移非参数方法通过聚类来定位检测出人造目标。实验证明,本文方法是一种有效的基于非参数聚类的目标定位检测方法。

参考文献:

- [1] Arman F, Aggarwal J K. CAD-based Vision: Object Recognition in Cluttered Range Images Using Recognition Strategies[J]. Computer Vision, Graphics, and Image Processing, 1993, 58(1):33-47.
- [2] Lowe D G. Perceptual Organization and Visual Recognition[M]. Kluwer Academic Publishers, 1995.
- [3] Shah S, Aggarwal J K. Multiple Feature Integration for Robust Object Localization[C]//IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR'98) 765, 1998.
- [4] Fukunaga K, Hostetler L D. The Estimation of the Gradient of a Density Function, with Applications in Pattern Recognition[J]. IEEE Trans. Information Theory, 1975, 21:32-40.
- [5] Comaniciu D, Meer P. Mean Shift: A Robust Approach Toward Feature Space Analysis[J]. IEEE Trans. Pattern Anal. Machine Intell., 2002, 24: 603-619.
- [6] Scott D W. Multivariate Density Estimation[M]. Wiley, 1992.

