

基于空间语义模型的高分辨率遥感图像目标检测方法

冯卫东^{①②} 孙显^{*①} 王宏琦^①

^①(中国科学院电子学研究所 北京 100190)

^②(中国科学院大学 北京 100049)

摘要: 该文提出一种基于空间语义模型的方法,用于高分辨率遥感图像复杂场景中典型地物目标的自动检测。该方法通过分割获取图像对象,引入主题模型统计对象的多维特征,提高了对象特性描述的精度。在此基础上,对图像中有意义的地物目标及它们之间的空间关系建模表达和定量计算,通过获取场景的语义解析树,辅助实现对复杂地物目标的准确提取和定位。在测试数据集上的实验结果表明,该文方法具有较高的智能化程度和较强的稳定性。

关键词: 目标检测; 高分辨率遥感图像; 空间语义

中图分类号: TP753

文献标识码: A

文章编号: 1009-5896(2013)10-2518-06

DOI: 10.3724/SP.J.1146.2013.00033

Spatial Semantic Model Based Geo-objects Detection Method for High Resolution Remote Sensing Images

Feng Wei-dong^{①②} Sun Xian^① Wang Hong-qi^①

^①(Institute of Electronic, Chinese Academy of Sciences, Beijing 100190, China)

^②(University of Chinese Academy of Sciences, Beijing 100049, China)

Abstract: A spatial semantic model based method is proposed to solve the issue of automatically detecting geo-objects in high resolution remote sensing images. This method obtains firstly image segments through over-segmentation algorithm, and calculates the multiple features by using topic models, in order to improve the description accuracy of segments attribution. Then, this method investigates and models the spatial relationship between geo-objects in whole images, and a semantic parsing tree of the scene category is extracted, which could be used to detect and locate the geo-objects. The experimental results on the dataset demonstrate the robustness and accuracy of this method.

Key words: Objects detection; High resolution remote sensing images; Spatial semantic

1 引言

近年来,随着遥感信息科学的理论、技术和方法的快速发展,高分辨率遥感的优势日益明显^[1]。利用计算机解译技术分析遥感图像中的复杂场景,提取典型地物目标,也日益成为遥感应用研究的热点课题。

在高分辨率遥感图像中,场景以及一些复杂的地物目标均是由若干目标及其部件集合通过各种关联组合而成的。传统利用低层信息提取目标的方法,如孙显等人^[2]采用的对特征似然建模自动分割目标,以及 Wang 等人^[3]和 Soliman 等人^[4]提出的融合形状和外观特征,解决航空遥感图像中目标识别的方法,由于选用的视觉特征过于片面,且忽略了场景或目

标之间的空间关系,较难取得满意的效果。为此, Fergus 等人^[5]提出将目标模型视为一系列片段的组合,通过最大化模型似然函数以实现目标类型的学习与识别。Sun 等人^[6]、Selvaraj 等人^[7]、Zhang 等人^[8]提出在分等级框架下,以无监督的方式限定目标片段的结构及位置等信息。Li 等人^[9]和 Mottaghi^[10]则通过中低层信息辨识图像的局部目标,先验知识设定图像的高层语义,实现了目标分类。Yang 等人^[11]、Hu^[12]、Ukita^[13]等也采用了类似的思想。这些方法采用不同的方式限定目标结构,实现从区域到目标整体的组合,能够克服目标部分缺失对检测结果的影响。但是这类方法较少考虑目标发生旋转、尺度等变化的影响,同时对图像各目标间的相互关系,以及各目标与由它们构成的图像场景间的约束关系缺乏定量计算。

针对以上问题,本文提出了一种新的基于空间语义模型的目标自动检测方法。本文方法的创新在

2013-01-11 收到, 2013-03-29 改回

国家自然科学基金(41001285)资助课题

*通信作者: 孙显 sunxian0918@yahoo.com.cn

于：(1)与传统的方法不同，该方法对图像中的地物目标及它们之间的空间关系进行建模表达，通过场景中目标空间语义的定量学习和计算，最终获取场景的语义解析树，辅助实现对复杂地物目标的自动提取和检测，有效提高了解译精度；(2)获取图像对象后，引入主题模型统计对象的尺度旋转不变、宽基线、纹理等多维特征，克服了图像成像过程中发生旋转、仿射变换、光照变化等情况对结果的影响，提高了对象特性描述的准确性，为语义信息的提取提供了良好的基础。对图像数据集测试的结果表明，本文提出的这种方法在对多种类型和复杂结构目标的检测和提取中均取得了良好的效果，具有较高的智能化程度和较强的稳定性。

文中第 2 节详细叙述了方法的各个环节，第 3 节给出了实验结果并分析，第 4 节提出本文的结论。

2 基于空间语义模型的目标解译

高分辨率遥感图像场景中，一些语义相关目标的出现位置和频率存在一定的规律性。如图 1(a)所示的港口场景，包含水域、舰船、码头等若干种类目标。其中，码头和舰船类目标总是在相对固定的位置同时出现，可以统一划分为驻泊区域，而油库、道路等的位置则相对不固定。通过一系列相似场景的观察，可以构建这些组合的语义框架。可以发现图 1(b)的解析树结构中存储了目标的空间位置、目标出现的可能性等参数。这种语义解析树能体现目标的空间语义，有助于对图像场景的理解和感兴趣目标的检测和识别。

在基于空间语义模型的遥感地物目标解译流程中，首先采用过分割方法获取不同的图像对象，并结合主题模型统计对象的多维特征，获取对象的属性标记。在此基础上，生成该类图像场景的解析树结构，用于辅助实现对复杂场景图像的目标提取。

2.1 图像对象的分割获取

本方法中采用 Shi 等人^[14]提出的 N-cut

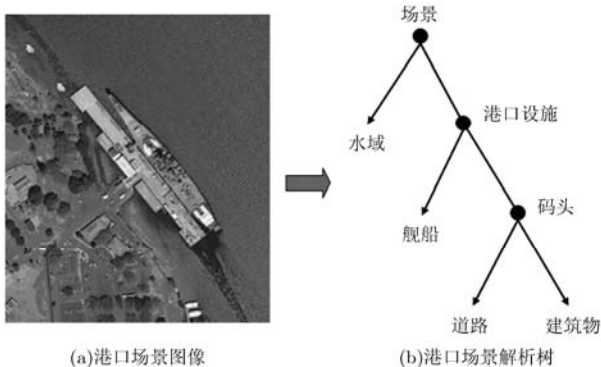


图1 港口场景的语义解析树

(Normalized-cut)算法对遥感图像进行过分割。该算法以归一化划分为分割准则，保证全局最优性，能够在图像前背景混杂，存在干扰噪声等复杂场景下较好地目标与背景相分离，并保持较好的区域特性，为后续的处理打下基础。

分割过程中，给定四向连接图 $G = (V, E)$ ， V 为图中节点的集合，每个节点为一个像素， E 为每对相邻节点连接边的集合。假设将其分为两个不相交的部分 A 和 B ，满足 $A \cup B = V$ ，且 $A \cap B = \emptyset$ 。定义 A 与 B 之间所有边对应权值 $w(i, j)$ 的和为该图的一个分割。

$$\text{cut}(A, B) = \sum_{i \in A, j \in B} w(i, j) \quad (1)$$

N-cut 方法的表达式为

$$\text{Ncut}(A, B) = \frac{\text{cut}(A, B)}{\text{assoc}(A, V)} + \frac{\text{cut}(A, B)}{\text{assoc}(B, V)} \quad (2)$$

其中， $\text{assoc}(A, V) = \sum_{i \in A, j \in V} w(i, j)$ 。图 G 的一个最优分割是能够使 A 与 B 之间的 Ncut 值最小的一种。

2.2 基于主题模型的多特征融合

概率潜在语义分析 (probabilistic Latent Semantic Analysis, pLSA) 模型、潜在狄里克雷分布 (Latent Dirichlet Allocation, LDA) 模型是主题语义模型中的典型代表。本文方法选取感兴趣特征作为特征描述子，采用 pLSA 模型来分析每个候选区域包含的特征信息。这种无监督的学习方式可以充分利用图像中的各种可视及非可视化信息，以此来标记符合目标特性的候选区域。

(1)特征提取 特征提取是语义建模分析的基础。考虑到遥感图像来源和图像质量存在差别，场景往往较为复杂，而且部分目标存在旋转、侧偏，甚至遮挡等现象，本文采用 Harris-Affine，最大稳定极值区域和纹理 3 类特征进行处理。其中，Harris-Affine 特征参照文献^[15]叙述的流程进行提取，并采用 128 维的向量表示。最大稳定极值区域特征使用椭圆形区域进行表达，本文方法参照文献^[16]叙述的流程进行提取，并将这些椭圆区域用圆形区域归一化替代，进而使用 SIFT 描述子进行描述。该特征也是 128 维。对于 Texton 纹理特征则采用 LM 滤波器进行表达^[17]，分别选取 8 个尺度(0.6 至 2.0，步长为 0.2)和 8 个角度(间隔 45°)，共 64 维特征。在多特征融合时，将 3 类特征顺序串接成一个新的矢量，共计 320 维，然后输入 pLSA 模型进行统计。

(2)pLSA 建模统计 pLSA 模型通过统计文档中单词出现的频率来确定主题^[18]。这一模型引入图像分析中时，将图像候选区域视为文档(document)，将待分割提取的目标类别视为文档主题(topic)，而

候选区域中包含的特征则是文档中出现的单词(word)^[19]。pLSA模型统计训练图像上的特征分布,而后将这些分布拟合成若干个已知主题类别的混合。对于每幅图像,计算得到原始图像的特征描述子后,在各个尺度上按照不同的划分将其分配给每个候选区域,用特征描述子的直方图形式来表达候选区域信息。

假设存在 N 个样本候选区域(文档),对应 M 个特征(词汇)分布, $n(s_i, f_j)$ 表示候选区域 s_i 中特征 f_j 的出现次数,而隐含目标类别(主题)变量 t_g 与单个特征在特定候选区域中的出现概率相关联。隐含概率语义模型对图像候选区域、类别和特征这三者进行建模 $P(f_j, s_i, t_g)$, 如图2所示,阴影节点为可观察到的随机变量,非阴影节点为不可观察到的变量信息。每个节点箭头下对应着一个实例。可以发现,特征和候选区域的产生式模型 $P(s_i, f_j) = P(s_i) \cdot P(f_j | s_i)$ 能够通过条件概率计算得到。




图2 隐含概率语义模型

$$P(f_j | s_i) = \sum_{g=1}^G P(f_j | t_g) P(t_g | s_i) \quad (3)$$

其中,条件分布 $P(f_j | t_g)$ 建模特征和目标类别间的关系, $P(t_g | s_i)$ 建模目标类别和候选之间的关系。 G 为目标类别数目,由于只区分目标前景和背景,取 $G = 2$ 。

隐含概率语义模型的目的是学习概率 $P(f_j | t_g)$ 和 $P(t_g | s_i)$, 这些概率通过期望最大化算法^[20]拟合得到。

E 步骤:

$$P(t_g | s_i, f_j) = \frac{P(f_j | t_g) P(t_g | s_i)}{\sum_{v=1}^V P(f_j | t_v) P(t_v | s_i)} \quad (4)$$

M 步骤:

$$\left. \begin{aligned} P(f_j | t_k) &= \frac{\sum_{i=1}^N n(s_i, f_j) P(t_g | s_i, f_j)}{\sum_{m=1}^M \sum_{i=1}^N n(s_i, f_m) P(t_g | s_i, f_m)} \\ P(t_g | s_i) &= \frac{\sum_{j=1}^M n(s_i, f_j) P(t_g | s_i, f_j)}{\sum_{j=1}^M n(s_i, f_j)} \end{aligned} \right\} \quad (5)$$

E 步骤和 M 步骤重复迭代直至满足期望约束。

求得模型参数后,对各个图层中的待标记区域按上述步骤求解对应的标记概率向量 c , 即式(5)中的 $P(t_g | s_i)$, 概率值越大,说明该候选区域属于目标的可能性越大,反之亦然。

2.3 解析树计算

语义解析树可以有效表达图像中目标之间的相互关系。获取训练图像集中的对象属性后,可以建立关于对象之间的图结构,每个节点之间的边界权重代表不同训练图像中对象之间的相互关系。

方法中通过计算相似矩阵来获取对象的相互关系。定义训练图像数量为 N , 每幅图像中包含 N 个对象。假设 M 为 $F \times F$ 维的邻接相关矩阵,那么 M_{ij} 代表第 i 个和第 j 个对象对的相互关系:

$$M_{ij} = R(O_i, O_j) + S(O_i, O_j) \quad (6)$$

(1) $R(O_i, O_j)$ 代表对象 O_i 和 O_j 之间的类别相似度,计算如下:

$$R(O_i, O_j) = D_{KL}(c_i || c_j) \cdot (s_i - s_j) \quad (7)$$

其中 $D_{KL}(\cdot)$ 为 KL(Kullback-Leibler)距离, c_i 和 c_j 为对象 O_i 和 O_j 的类别属性向量, s_i 和 s_j 为对象 O_i 和 O_j 的面积大小。

(2) $S(O_i, O_j)$ 代表对象 O_i 和 O_j 之间的位置相似度。

$$S(O_i, O_j) = R(x_i x_j) + R(y_i y_j) \quad (8)$$

其中 $R(x_i x_j) = \frac{C(x_i x_j)}{\sqrt{C(x_i x_i) C(x_j x_j)}}$, $C(x_i x_j)$ 为输入图

像中 x_i 和 x_j 的协方差。且存在 $x_i = \{x_{in}\}$, $y_i = \{y_{in}\}$, $\{x_{in}, y_{in}\}$ 是第 n 幅图像中第 i 个对象的中心坐标, $i, j = 1, 2, \dots, F, n = 1, 2, \dots, N$ 。

图3给出了一个相关邻接图的示例。构建所有相关邻接图后,对其进行迭代聚类。在每一个步骤,邻接图被聚为两类,分析每一个聚类的属性,如果一个对应于某个聚类的相关邻接矩阵方差较小而均值较大,则说明属于某个目标的一个部分,将不再被继续细分。分类结果相继叠加,构成如图1所示的解析树。




图3 相关邻接图示例

2.4 场景及目标解译

使用学习得到的语义解析树来检测该类场景图像中的感兴趣目标，步骤如下：

(1)输入待处理图像，按照与训练相同的参数进行过分割；

(2)统计各个对象的局部显著度特征、宽基线特征、区域纹理特征以及边缘特征信息；

(3)使用主题模型计算以直方图分布的形式表达的图像中各个候选对象的类别概率；

(4)从语义解析树中的自上而下选取节点，与各个候选对象利用 KL 距离进行相似匹配，获得各个子树的相似度值，选取最大相似度值对应的节点可得到目标所属的类别和所在区域。

在典型的地物目标的检测应用时，由于训练完成后，已知解释树中各个节点对应的目标类别，例如机场场景中飞机、油罐等。此时，只需还原需要检测目标类型对应的节点，就能够从图像中得到飞机、油罐等区域。进一步地，可以通过目标所在区域的最小外接矩形以及不同颜色来标识检测的目标及其类别。

3 实验及分析

实验中选取遥感目标数据集中的机场和港口共 2 类场景以及航母、体育场、港口、机场共 4 类复杂地物目标进行提取实验。实验数据均来自 QuickBird 图像，分辨率为 0.6 m，图像尺寸为 800 × 600 像素大小左右，每一类别 50 幅数据，总计 300 幅训练图像。每类抽取其中 10 幅用于训练，人工标记出真实结果，40 幅用于测试。图 4 给出了机场类场景图像的训练样本示例。

3.1 参数设置和性能分析

图 5 给出了用 N-cut 进行多尺度分割的结果。过分割处理中主要的参数是分割区域数目，即分割系数。当选择分割结果区域数目过少，会影响结果区域外观特性的均匀性，从而影响分类与标注方法的性能；相反区域选择过多，会降低方法的效率。取数据集中的 50 幅机场类别图像进行实验。表 1 显示了分割结果区域数目变化对语义计算准确率的影响。

语义计算准确率以计算得到的语义解析树结构和人工标记的解析树结构的节点匹配度为依据，计算效率以分割系数为 10 的时间为基准。可以发现，当分割系数选择 30 时，能在效率与准确率方面取得折中。

表1 不同分割区域数目对分类准确度的影响

分割系数	10	20	30	40	50	60
分类准确度(%)	72	84	91	93	95	95
计算效率(%)	100	120	150	210	300	380

为了验证选取 3 类特征计算的必要性，从数据集中针对各类目标随机抽取等量图像组成新的测试图像集，分别进行了 3 类特征均保留、忽略每一类特征时对应的 4 组实验，表 2 给出了各种情况对本文方法性能的影响。结果表明，这些特征对方法正确检测目标都具有积极的作用，其中，最大稳定极值区域所起的作用相对较大，采用该类特征主要是为了降低仿射变换对检测方法的影响。表中的 ROC-EER 为检测性能的等错误率值。

表2 各类特征被忽略对检测性能的影响

特征类型	两类特征均保留	忽略 Harris-Affine 特征	忽略最大稳定极值区域特征	纹理特征
ROC-EER	5.9	9.7	12.8	7.3

表 3 给出了旋转变化对本文方法检测性能的影响，实验中将测试图像按照 30° 间隔旋转。表 4 列出了尺度变化对本文方法性能的影响，实验中将测试图像按照不同的尺度因子进行缩放。表 5 显示了仿射变化对本文方法性能的影响，实验中按照测试图像中目标的侧转程度，将其侧转角度粗略分为 4 类，分别是 0°、30°、60° 及 90°，结果表明方法对旋转、尺度变化和小角度侧转均具有较高的稳定性，但是当侧转角度较大时，方法的性能有较为明显的下降。



图 4 机场类别样本图像示例

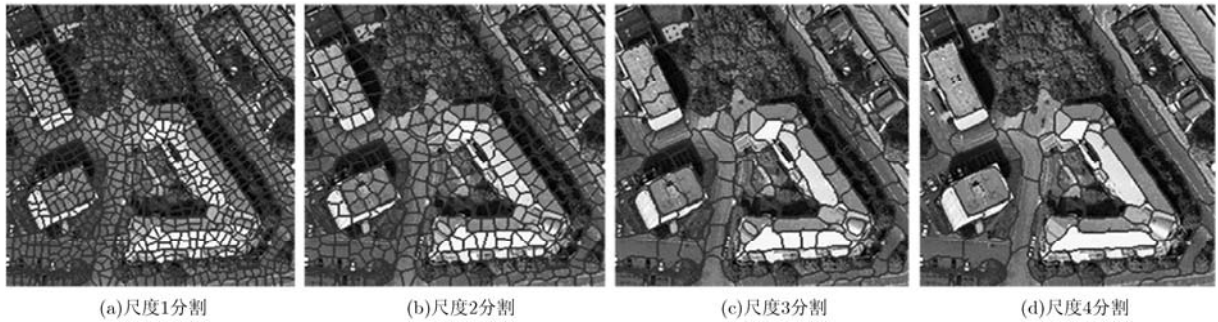


图 5 多尺度分割结果

表3 旋转变化对检测性能的影响

旋转角度(°)	-90	-60	-30	0	30	60	90
ROC-EER	5.0	4.9	4.7	4.7	4.8	5.0	5.2

表4 尺度变化对检测性能的影响

尺度因子	0.25	0.50	1.00	1.50	2.00	2.50
ROC-EER	6.3	5.6	4.7	4.9	5.4	6.1

表5 仿射变化对检测性能的影响

侧转角度(°)	-90	-60	-30	0	30	60	90
ROC-EER	18.4	11.9	5.8	4.6	6.0	12.5	18.3

3.2 目标检测结果分析

图 6 给出了测试图像与计算得到的解析树结果。可以发现，这些场景受光照、尺度变化的影响不一，跑道的方向也各式各样，甚至部分目标还存在被阴影、云层遮挡的现象，然而分层语义仍然能够准确体现机场场景的目标和空间结构。停机坪、机窝、机库由于关联紧密，被划分为一个大类，即驻泊区域，主跑道、滑行道、联络道等也被划分成为跑道大类，这些大类作为语义节点，是和指挥塔、候机楼等关联较为松散的部分相并列的。值得注意的是，一些附属建筑、油库等并不在每个训练图像中出现的目标类别被视为背景而自动去除，降低了虚警率和计算效率，也在一定程度上体现了该方法的鲁棒性。

图 7 给出了利用解析树对部分遥感图像中的复

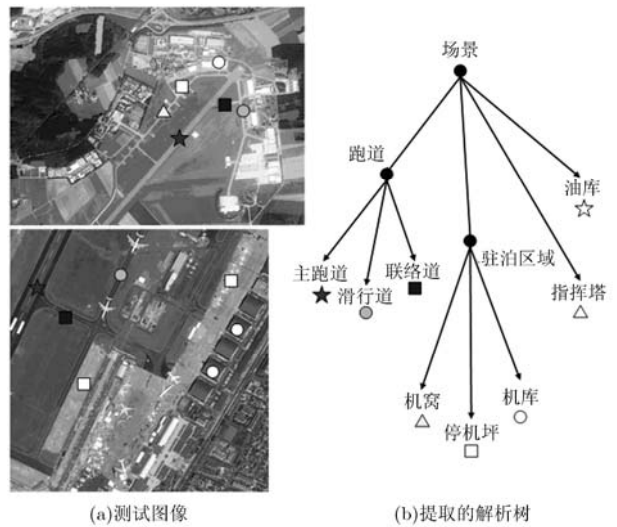


图6 测试图像与语义解析树提取结果

杂或组合性的地物目标进行检测的结果。对于部分目标包含大量的可变示例，如舰船，部分目标包含大量的旋转和遮挡，如飞机，以及部分复杂场景中的目标，本文的方法均能较好地进行处理。

本文方法主要包括训练和测试两大流程，其中，训练包括图像多尺度分割、特征提取、pLSA 建模统计、语义树提取几个环节，而测试包括图像多尺度分割、特征提取、pLSA 建模统计、目标检测提取几个环节。表 6 列出了实验中各个算法步骤的耗时。编译环境为 Matlab 2010a，测试环境为 Win7 操作系统，CPU 8 核 3.40 GHz，内存为 8 G DDR3。表 6 给出了所有图像训练的时间和每一幅图像测试




图 7 部分遥感地物目标的检测结果

表6 实验中各个算法步骤耗时(s)

	多尺度 分割	特征 提取	建模 统计	语义树 提取	目标 检测	总计
训练	1162	378	857	422	-	2819
测试	19	5	12	-	7	43

的平均时间。可以发现，尽管训练需要占用不少时间，但是对于单幅图像的目标检测处理速度仍然是较快的，具有一定的实用性。

4 结束语

遥感图像中的空间语义关系在目标检测、场景分类中起着重要的指导作用。本文提出了一种基于空间语义模型的目标自动解译方法，采用过分割获取图像对象，引入主题模型统计对象的尺度旋转不变等多维特征，避免了遥感图像成像过程中较常出现的旋转、仿射变换、光照变化等干扰。同时通过提取场景的语义解析树检测目标，相比从底层信息入手检测目标的思路具备更高的准确性和鲁棒性。对图像数据集测试的结果表明，本文方法在对高分辨率遥感图像复杂场景中典型地物目标的定位和提取中具有较好的实用性。这种引入高层信息并与中低层信息结合的综合处理方法，也将是高分辨率遥感图像理解的未来发展趋势。

参考文献

- [1] 李德仁. 论 21 世纪遥感与 GIS 发展[J]. 武汉大学学报(信息科学版), 1995, 28(2): 127-131.
- [2] 孙显, 付琨, 王宏琦. 基于空间语义对象混合学习的复杂图像场景自动分类方法研究[J]. 电子与信息学报, 2011, 33(2): 347-354.
- [3] Wang Wu-di, Sun Xian, Qi Xiang, *et al.*. Automatic extraction method for complicated structure buildings in remote sensing images based on probabilistic latent semantic analysis model[C]. 2011 3rd International Conference on Computer Design and Applications (ICCD), Xi'an, 2011: 450-454.
- [4] Soliman S and Mahmoud S. A classification system for remote sensing satellite images using support vector machine with non-linear kernel functions[C]. The 8th International Conference on Informatics and Systems (INFOS), Cairo, 2012: 181-187.
- [5] Fergus R, Perona P, and Zisserman A. A sparse object category model for efficient learning and exhaustive recognition[C]. Proceedings of IEEE Conference on Computer Vision and Pattern Recognition, San Diego, 2005: 380-387.
- [6] Sun Hao, Sun Xian, Wang Hongqi, *et al.*. Automatic target detection in high-resolution remote sensing images using spatial sparse coding bag-of-words model[J]. *IEEE Geoscience and Remote Sensing Letters*, 2012, 9(1): 109-113.
- [7] Selvaraj K, Fathima A, and Vaidehi V. Multi-class object detection by part based approach[C]. 2012 International Conference on Recent Trends in Information Technology (ICRTIT), Chennai, Tamil Nadu, 2012: 114-118.
- [8] Zhang Huigang, Wang Junxiu, Bai Xiao, *et al.*. Object detection via foreground contour feature selection and part-based shape model[C]. 2012 21st International Conference on Pattern Recognition (ICPR), Tsukuba, 2012: 2524-2527.
- [9] Li Yu, Sun Xian, Wang Hongqi, *et al.*. Automatic target detection in high-resolution remote sensing images using a contour-based spatial model[J]. *IEEE Geoscience and Remote Sensing Letters*, 2012, 9(5): 886-890.
- [10] Mottaghi R. Augmenting deformable part models with irregular-shaped object patches[C]. 2012 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Venue, 2012: 3116-3123.
- [11] Yang K, Zhang L, Rui Y, *et al.*. Part book for image parsing[C]. Proceedings of IEEE Conference on Computer Vision and Pattern Recognition, Venue, 2012: 17-24.
- [12] Hu W. Learning 3D object templates by hierarchical quantization of geometry and appearance spaces[C]. Proceedings of IEEE Conference on Computer Vision and Pattern Recognition, Venue, 2012: 2336-2343.
- [13] Ukita N. Articulated pose estimation with parts connectivity using discriminative local oriented contours[C]. Proceedings of IEEE Conference on Computer Vision and Pattern Recognition, Venue, 2012: 3154-3161.
- [14] Shi J and Malik J. Normalized cuts and image segmentation [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2000, 22(8): 888-905.
- [15] Mikolajczyk K and Schmid C. An affine invariant interest point detector[C]. Proceedings of the 8th International Conference on Computer Vision, Vancouver, Canada, 2002: 1-8.
- [16] Martin R, Marfil R, Nunez P, *et al.*. A novel approach for salient image regions detection and description[J]. *Pattern Recognition Letters*, 2009, 30(16): 1464-1476.
- [17] Julesz B. Textons, the elements of texture perception, and their interactions[J]. *Nature*, 1981, 290: 91-97.
- [18] Blei D, Andrew Y, Michael J, *et al.*. Latent dirichlet allocation[J]. *Journal of Machine Learning Research*, 2003, 3: 993-1020.
- [19] Li F F, Rullen V R, and Koch C. Rapid natural scene categorization in the near absence of attention[J]. *Proceedings of the National Academy of Sciences of the United States of America (PNAS)*, 2002, 99(14): 9596-9601.
- [20] Dempster A, Laird N, and Rubin D. Maximum likelihood form incomplete data via the EM algorithm[J]. *Journal of the Royal Statistical Society*, 1977, 39(1): 1-38.

冯卫东：男，1969 年生，高级工程师，研究方向为模式识别、数据组织与挖掘技术。

孙显：男，1981 年生，助理研究员，研究方向为模式识别、遥感图像解译。

王宏琦：男，1964 年生，研究员，研究方向为模式识别、遥感图像解译。