

分类号 TP39
UDC

密级
编号

中国科学院研究生院

硕士学位论文

高分辨率遥感图像的结构变化检测

汤峰峰

指导教师 普林特 副研究员
申请学位级别 工学硕士 学科专业名称 模式识别与智能系统
论文提交日期 2007年5月 论文答辩日期 2007年6月
培养单位 中国科学院自动化研究所
学位授予单位 中国科学院研究生院

答辩委员会主席 卢汉清 研究员

Structural Change Detection in Very High Resolution Satellite Images

Dissertation Submitted to

Institute of Automation, Chinese Academy of Sciences

in partial fulfillment of the requirements

for the degree of

Master of Engineering

by

Fengfeng Tang

Pattern Recognition and Intelligent Systems

Dissertation Supervisor: Associate Professor

Veronique Prinet

独创性声明

本人声明所递交的论文是我个人在导师指导下进行的研究工作及取得的研究成果。尽我所知，除了文中特别加以标注和致谢的地方外，论文中不包含其他人已经发表或撰写过的研究成果。与我一同工作的同志对本研究所做的任何贡献均已在论文中作了明确地说明并表示了谢意。

签名: _____ 日期: _____

关于论文使用授权的说明

本人完全了解中国科学院自动化研究所有关保留、使用学位论文的规定，即：中国科学院自动化研究所有权保留送交论文的复印件，允许论文被查阅和借阅；可以公布论文的全部或部分内容，可以采用影印、缩印或其他复制手段保存论文。

(保密的论文在解密后应遵守此规定)

签名: _____ 导师签名: _____ 日期: _____

摘要

中国的快速发展、迅速现代化正通过其城市化进程展现出来。城乡布局结构发生巨大的变化。矮旧的杂乱的临时房被拆除，代替它们的是规整的大楼、街道。越来越多的农田变成了住宅区、厂区与商业区。如此快速的变化下，大量的问题变得迫切。测绘制图部门需要更新大量地图，国土资源部门需要监测土地利用情况，城市规划部门需要规划设施建设、决策支持……

城市景观的变化可以通过多时相的（multi-temporal）高分辨率卫星或者航空遥感图像监测。因高分辨率遥感图像的精度高、细节表现能力强、信息丰富，它使得场景的解译可以精确到单个目标物级别（比如单幢建筑物，一条道路）。然而开发能快速鲁棒地分析变化本质和变化程度的自动方法仍然是个远没解决好的问题。这样的方法涉及到动态场景中的目标物识别和理解等计算机视觉中的基础问题。

本硕士论文工作就是在这样的背景下展开，围绕城区结构变化检测与理解这一主题进行了研究。我们使用同一地区的不同时间的两幅高分辨率光学遥感图像进行分析。提出了一种新的基于特征类别和特征分布学习方法，进行变化区域检测。本文主要贡献分为两层：从应用的角度看，我们引入了目标物识别领域的一些思想，将其变为适合变化/无变化“识别”问题的方法；从理论方法角度看，基于概率建模我们引入了一个新的模型和计算框架。

本文首先简短地介绍我们要处理的问题，接着对现有的遥感图像变化检测的方法进行综述，并介绍了与我们的方法相关的一些研究工作。在接下来的章节(3,4)里我们细致的描述了我们的方法、实现和最后的实验结果：

- ① 第三章提出了基于外观不变量的高分辨率遥感图像变化检测算法。本文在结构物体边缘直线段提取和直线段关系图割（Normalised Cut）基础上，将图像分割为结构一致区域。在两幅图像对应的分割区域中，我们计算类 SIFT 外观不变量，将其聚类生成“词典”。“词语”被用来刻画每个区域的结构。通过求“词语”直方图距离来量化结构变化。
- ② 第四章提出了基于 MAP-MRF 框架的结构变化检测算法。以第三章的基于外观不变量的变化检测算法为部分基础，我们的新方法融合了形状特征（直线段方向直方图）。我们特征的变化和无变化概率参数通过有监督的估计获得。先验知识项基于 Gibbs 模型定义。

关键词：结构变化分析，变化检测，外观和形状不变量，识别，学习，马尔可夫随机场，概率模型，高分辨率光学图像，遥感

Structural Change Detection in Very High Resolution Satellite Images

Abstract

The phenomena of urbanization in China is a reflect of a fast growth, modernization, and important changes in the repartition of the social classes. Old small houses are demolished, new spatially organized buildings and roads appear; more and more farmlands become residential districts or factories. All these fast changes pose urgent problems: cartographic updating, urban planning, land use monitoring and control...

This evolution of the urban landscape can be observed and monitored using multi-temporal high resolution remote sensing images, airborne or satellite. The accuracy and detailed information of these images make it possible a fine interpretation of the scene, up to the level of the object (e.g. Buildings, roads). However, the automatic processing, that would enable to analyze robustly and quickly the nature and the level of the changes, is still a problem that is yet far from being solved. It raises in particular fundamental questions related to object recognition and understanding dynamic images.

In this master thesis, we study the problem of structural change analysis and understanding from two multi-temporal very high resolution optical images. We propose a new general approach, based on features classes and features distribution learning, for an efficient detection of areas of change. The major contributions of this work are at two levels: from an application point of view, we borrow some ideas from the field of object recognition, and adapt them to the question of change/non change recognition ; from a methodological point of view, we introduce a new model and framework based on probabilistic modeling.

In the present manuscript, after a short introduction in which we state the problem we are dealing with, we will give a brief review of the existing methods of change detection in remote sensing images, introduce some works on related research topics. The following chapters (3,4) then present in details our methodology, implementation, and results:

- ① In chapter 3, we propose a structural change detection method based on invariant appearance features. We first segment the images into structurally consistent regions. For this purpose, we build a relation graph based on straight-lines extracted from the image, and partition this graph using Normalized Cut. Then, SIFT-like features are computed at keypoints and clustered to form a “dictionary” of “words” (characterized by the SIFT cluster centers). They are used as the basic elements to capture the structure of each region. Histograms of the “words” in each region are created. By estimating the distance between the histograms associated to pairwise regions taken from each of the two images, the structural change is quantified.
- ② In chapter 4, we introduce an MRF based approach and label patches of the images as change/non-change with a MAP estimation framework. The appearance features used in chapter 3 are now completed by shape features, characterized by

straight-line direction histograms. Following a supervised approach, we estimate the parameters of the distribution of these features for change and no-change areas separately. The density functions are then computed from these distributions. To complete the model, we define the prior term with a Gibbs model.

Key Words: Structural change analysis, Change detection, Appearance and shape invariants, Recognition, Learning, Markov Random Field, Probabilistic model, High resolution optical image, Remote sensing images.

目 录

第一章 引 言	1
1.1 研究意义与背景	1
1.2 问题描述	1
1.3 本文组织结构	2
1.4 实验平台和数据说明	3
第二章 文献综述	5
2.1 引言	5
2.2 遥感图像的变化检测	5
2.3 结构特征、图和分割问题	8
2.4 基于局部特征的识别	9
2.4.1 低层视觉特征的概述	9
2.4.2 SIFT 特征介绍	9
2.4.2.1 兴趣点检测	10
2.4.2.2 SIFT 描述子的构造	10
2.4.2.3 本节总结	11
2.5 小结	12
第三章 基于外观不变量的高分辨率遥感图像结构变化检测	13
3.1 引言	13
3.2 算法思想与流程	13
3.3 基于直线段关系的图像分割	14
3.3.1 直线段的提取	14
3.3.2 直线段关系图的建立	16
3.3.3 Ncut 算法及分割迭代	17
3.3.4 分割结果评价策略	19
3.4 外观不变量特征	19
3.4.1 兴趣点提取	20
3.4.2 SIFT 特征计算	21
3.4.3 SIFT 特征聚类和“词典”建立	21
3.5 基于直方图统计的变化检测	22
3.6 实验结果及分析	23
3.6.1 实验设定	23
3.6.2 结果分析	23
3.7 小结	31

第四章 基于 MRF 模型的结构变化检测	35
4.1 引言	35
4.2 MRF 模型回顾	35
4.3 模型	38
4.3.1 先验知识项	38
4.3.2 数据项	38
4.3.2.1 外观特征分布	39
4.3.2.2 形状特征分布	39
4.4 问题求解	41
4.5 实验结果与分析	42
4.5.1 参数估计和实验设定	42
4.5.2 结果分析	42
4.6 小结	47
第五章 结束语	49
5.1 本文主要工作	49
5.2 未来工作展望	50
附录 A 图像数据介绍	51
1.1 数据简介	51
1.2 图像等级划分	53
参考文献	55
个人简历及攻读硕士学位期间发表的论文	i
致谢	iii

插图目录

1-1	场景中不同类型的变化: (a): 结构变化, (b): 单个目标物变化, (c): 纹理变化, (d): 表象变化。(a)、(c) 两对图像刻画全局的变化, 是在整个场景尺度下或者场景内一定区域内; 而(b)、(d) 两对图像则是刻画局部的变化, 是在目标物尺度下。	2
1-2	结构变化的示例。它们为图像对 1-1(a) 中的同一区域的截取放大图。	3
1-3	原始的Quickbird 图像(0.61米/像素): 获取于2002年3月14日 (上图) 和2003年9月13日 (下图), 地点是北京城区西北角清华大校园内。	4
2-1	由兴趣点邻域梯度信息生成特征向量。(图片取自 [28])	11
3-1	两组互补梯度方向离散化区间: 虚线为第一组 <i>bins1</i> ; 实线为第二组 <i>bins2</i> 。第二组是将第一组离散化值区间逆时针旋转 22.5 度。每组内标号值 (离散化值) 逆时针递增	15
3-2	梯度方向量化值示意图。	21
3-3	由图 1.3(a) 得到的标准分割图像。	25
3-4	由图 1.3(a) 得到提取直线段图像。	25
3-5	直线段关系图的分割迭代示意图: (a): 迭代1, (b): 迭代2, (c): 迭代3, (d): 迭代4 (最后一层迭代)。	26
3-6	图 3.8(a) 的左上角的放大显示, 颜色显示不同的分割区域, 黑线将分割区域 1, 2, 3 分隔开来。	27
3-7	从图像中提取的特征块局部示意图: 颜色表示其所属的特征类型 (词语)。图 3.9(a) 的中间区域的放大显示。	27
3-8	关系图分割迭代的最后结果(a), 图像分割(b)。	28
3-9	从图像中提取的特征块: 颜色表示其所属的特征类型 (词语) (a) 2002 年数据, (b) 2003 年数据。	29
3-10	使用 χ^2 计算的结构变化, 变化量化值如图上数字所示, 量化值最后被离散化。颜色表示离散化值: 红色, 没有变化; 绿色, 部分变化; 蓝色, 变化。	30
3-11	算法流程图	33
4-1	邻域、团块示意图。 $s = 5$, 邻域 $N_s = \{2, 4, 6, 8\}$, $C_1 = \{5\}$, $C_2 = \{(5, 2), (5, 4), (5, 6), (5, 8)\}$	36
4-2	角度量化带的中心线示意图	40
4-3	特征分布和拟合的概率分布曲线图: (a): 外观特征变化概率分布, (b): 外观特征无变化概率分布, (c): 形状特征变化概率分布, (d): 形状特征无变化概率分布。条柱表示特征分布直方图, “+”表示拟合的分布曲线。	43
4-4	匹配成对的角点: (a) 2002 年数据, (b) 2003 年数据。	45

4-5 真实结构变化二值图与实验计算得到的结构变化二值图: (a): 真实结构变化二值图, (b): 仅利用外观特征的结构变化二值 图, (c): 仅利用形状特征的结构变化二值图, (d): 将(b)、(c)叠 加得到的变化图, (e): 结合形状、外观特征的结构变化二值图。 灰度表示不同的标签值: 黑色表示没有变化, 白色表示发生变 化, 灰色表示两特征分类不一致。	46
4-6 算法流程图	48

表格目录

3-1 不同参数下的分割相似度 Sim (式 3-6) , 变化一个参数的时候 其他参数保持与 3.6.1 节一致。	26
4-1 不同能量项下的变化检测结果统计	43
A-1 Quickbird卫星图像参数表	52

第一章 引 言

1.1 研究意义与背景

中国的快速发展、迅速现代化正通过其城市化进程展现出来。城乡布局结构发生巨大的变化。矮旧的杂乱的临时房被拆除，代替它们的是规整的大楼、街道。越来越多的农田变成了住宅区、厂区与商业区。如此快速的变化下，大量的问题变得迫切。测绘制图部门需要更新大量地图，国土资源部门需要监测土地利用情况，城市规划部门需要规划设施建设、决策支持……

城市景观的改变可以借助多时相的高分辨率（VHR, very high resolution）卫星或者航空遥感图像进行记录和监测。因高分辨率遥感图像的精度高、细节表现能力强、信息丰富，它使得场景的解译可以精确到单个目标物级别（比如单幢建筑物，一条道路）。然而开发能快速鲁棒地分析变化的本质和变化程度的自动方法仍然是个远没解决好的问题。这样的方法涉及到动态场景中的目标物识别和理解等计算机视觉中的基础问题。

自 1999 年国际上第一颗高分辨率商业遥感卫星发射成功以来，已陆续有多颗性能相近的卫星投入运行。空间分辨率达到亚米级的民用卫星遥感图像的出现，促使遥感图像处理的研究人员从传统的基于像素的图像分类方法转而寻找更为适合高分辨率图像的方法。在这样的高分辨率光学遥感图像中，我们能引入目标物的概念。因此新的方法需要引入新的几何形状概念。引入形状约束，加上光谱或者纹理信息，能提供一个重要的线索来优化区域/目标物模型。概率和统计理论尤其适合来分析和理解这种高分辨率图像。它们提供了一种“自然”的方式来为图像中的噪声建模以及融合先验知识。

本论文工作的目标是提出一套新的、适合于两时相高分辨率遥感图像中结构变化分析和理解的方法。本工作的难点在于：一方面变化识别问题本身是一个病态问题（ill-problem），没有一个确定的定义“什么是变化”；另一方面，图像是充满几何、随机噪声的（geometrical and stochastic noise）。从应用的角度看来，本研究能提供有效的工具来进行城区和城乡结合部的变化调查分析和监测。

1.2 问题描述

在开始这个研究前，我们首先遇到的问题是定义“什么是我们要观察的变

化”。图 1-1 展示了遥感场景中不同类型的变化，如结构变化（图 1-1(a)）、单个目标物变化（图 1-1(b)）、纹理的变化（图 1-1(c)）以及难以被去除的表象变化（图 1-1(d)）。表象变化是由视角转换、阴影、遮挡、季节变化或者临时性物体(例如人、汽车等)的出现等因素造成。图 1-1(d) 则集中展示了这些因素引起的表象变化。实际中我们只对场景中真实的变化，或者说是长效变化感兴趣，对于这些表象变化我们要尽可能的消除它们的影响。

在本硕士论文中，我们讨论了两幅粗配准的图像中的结构变化问题。结构变化刻画的是场景中具有相近地理坐标的目标物的出现和消失。图 1-2 就是一个结构变化的典型示例。在图像中，这些房屋的像构成了结构模式或者结构纹理。

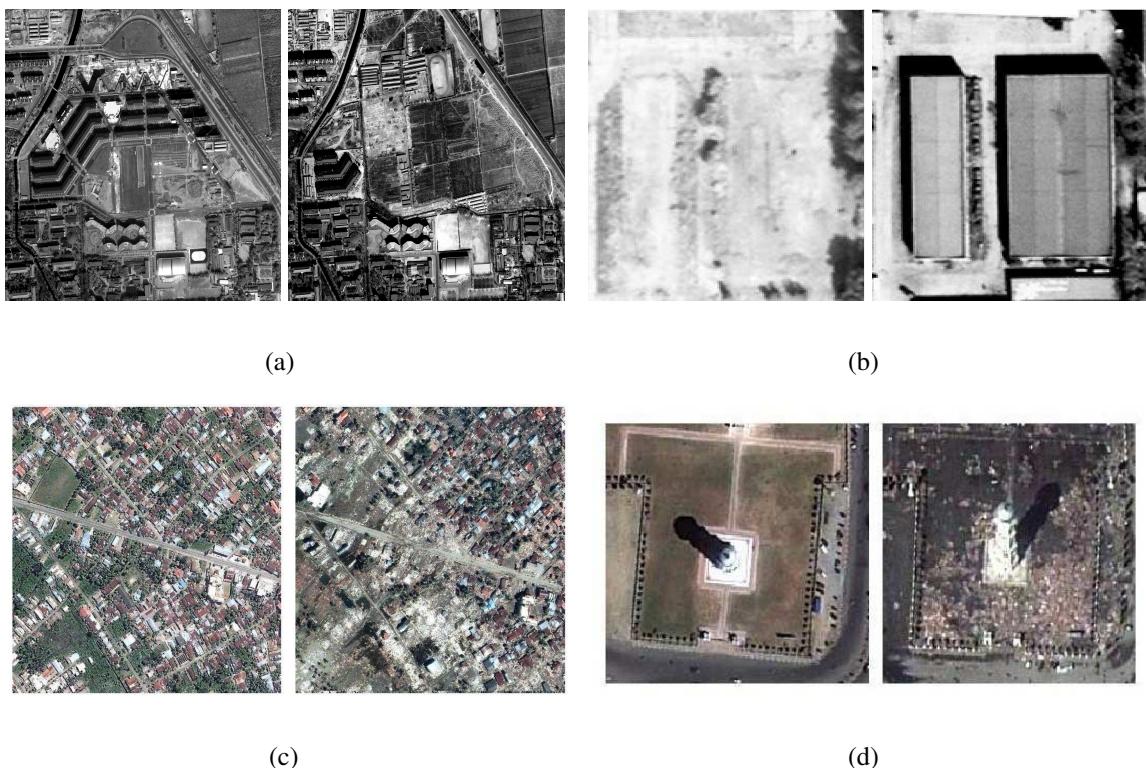


图 1-1 场景中不同类型的变化：(a): 结构变化，(b): 单个目标物变化，(c): 纹理变化，(d): 表象变化。(a)、(c) 两对图像刻画全局的变化，是在整个场景尺度下或者场景内一定区域内；而 (b)、(d) 两对图像则是刻画局部的变化，是在目标物尺度下。

1.3 本文组织结构

本论文共分五章。本章主要介绍本学位论文的研究背景与研究意义以及论文的组织结构等。



图 1-2 结构变化的示例。它们为图像对 1-1(a) 中的同一区域的截取放大图。

第二章是对当前遥感图像变化检测技术的综述，以及对与我们的方法相关的研究的介绍。首先介绍了遥感图像的变化检测方法，然后介绍了与我们工作相关的图的分割、基于低层视觉特征的识别等领域的相关研究，并且着重介绍了 SIFT 特征。

第三章主要介绍我们提出的一种基于外观不变量的高分辨率遥感图像变化检测与理解方法。在这一章中，将会对这种方法所涉及的主要问题和步骤进行详细说明和分析，最后给出实验结果并总结。

第四章主要介绍基于 MRF (Markov Random Field) 模型的变化检测方法。这种新方法是部分基于上一章的变化检测方法的。这一章中介绍的算法还不成熟，因此这一章的重点在于描述变化检测概率模型和具体实现。这一章最后会给出初步的实验结果并进行分析，对方法的局限性进行讨论并指明今后工作的方向。

第五章是小结。对本文的主要工作和贡献进行了总结，并对未来此方向的工作进行了展望。

1.4 实验平台和数据说明

论文工作提出的方法在 PC (P4 3.2G/1G 内存) -linux (Mandriva 10.2) 平台下使用 C++ 实现，程序依赖 Intel® 开源视觉算法库 OpenCV 1.0。

实验使用的输入数据是一对 Quickbird 全色图像（分辨率为 0.61米/像素），分别获取于2002年3月14日和2003年9月13日，地点是北京城区西北角清华大学校内。输入图像的示例如图 1-3。图像大小为 1625×1378 像素(于地面上大概 $1000 \times 800m^2$)，灰度深度为8比特。



(a)



(b)

图 1-3 原始的 Quickbird 图像(0.61米/像素): 获取于2002年3月14日 (上图) 和2003年9月13日 (下图), 地点是北京城区西北角清华大学校内。

第二章 文献综述

2.1 引言

本章主要对本研究主题内国内外已有的主要方法进行综述，并介绍后面章节中将要用到的一些基本概念和方法。在 2.2 节中我们对遥感图像变化检测的已有方法做了系统的回顾；在 2.3 节中我们介绍了一些结构特征、图和分割相关的文献；在 2.4 节中我们简单介绍了基于低层视觉特征的识别相关的研究进展并着重介绍了 SIFT 特征；2.5 节总结。

2.2 遥感图像的变化检测

遥感图像变化检测方法按不同的视角可以分为不同的类别 [51, 52, 34]，这里我们按照分析的元素尺度不同分为四类：

① 基于像素的方法

这类方法的处理对象是图像中的每个像素，它们比较适合低分辨率的图像。这类方法又可分为：

- 对图像先分别分类后比较的方法

首先运用统一的分类体系对多时相遥感数据组中的每一时相数据进行单独的分类，然后根据分类的结果进行比较，直接得到变化信息。

- 直接对多时相数据进行变换的方法

这种方法是将两个或多时相的遥感图像数据变换到容易进行判别的特征空间中去。这类方法有：

- 像素差值法 [11, 40, 42]

这里差值是广义的差值，可以是像素值相减，也可以是像素值的比值，还可以是回归残差。这类方法计算简单，概念直接。但是由于图像的噪声的影响，判别的阈值不容易定义。

- 多时相数据统计值的方法 [22, 35]

这类方法适用于具有足够多帧数据的问题。出现变化的坐标处其统计量如标准差会比较大，而没有变化的则相反。另外还可以通过主成份分析（PCA）进行计算。主成分分析法的数学基

础是离散 Karhunen-Loeve 变换（简称 K-L 变换）或霍特林变换（Hotelling）[49]，是建立在图像统计特征基础上的多维线性变换。多时相图像经K-L变换后，其主成分包含时间上的差异统计值。近来 [22]提出了一种使用两图像的灰度联合直方图进行自然场景中物体出现和消失的变化检测方法。Kita 认为物体的出现和消失变化在联合直方图上表现为一定的模式。

- 基于概率模型的方法 [3, 7, 9, 21]

为了处理由复杂的成像条件导致的变化不确定性，有大量工作利用统计和概率模型为判别建模。

Bruzzone [9]提出了一种基于贝叶斯推断的变化检测方法。他认为差值图像中对应有变化的像素值和对应无变化的像素值的概率分布不同，对差值图像进行最大后验概率判决，确定像素属于变化或未变化类。在此基础上他又提出利用马尔可夫随机场（MRF, Markov Random Field）对变化场建模，融合了关于变化的先验知识。Kasetkasem 等在2002年 [21]提出另一种基于马尔可夫场模型的变化检测方法。该方法避免了在差值图像上应用马尔可夫模型 [7]的做法，而是将变化检测问题看成是假设检验问题：每一个假设对应一幅不同的变化图像，其中满足最大后验概率的变化图像，即为最优的检测结果。

而 Benedek 等人 [3]提出了一种使用边缘密度作为结构特征检测航空遥感图像对中建筑区变化的方法。利用边缘密度特征可以判断像素属于建筑区或者非建筑区，这样可得到建筑区分割区域。如果两个对应像素均属于同一类，则判定没有发生变化。他们利用马尔可夫随机场将建筑区分割和变化检测同时进行。

基于像素的方法一般要求较高的配准精度，对光照变化等变化敏感，需要较复杂的预处理。

- ② 基于目标物的方法 [2, 19, 47, 51]

随着图像的分辨率越来越高，在像素尺度上进行变化分析，往往受到细节的影响，在提取对象的基础上进行分析，是应对这种挑战的可行办法。这类方法一般结合光谱和几何信息先从图像中检测物体，然后进行比较分析。

刘炜的硕士论文 [51] 中给出了一种基于轮廓提取和概率模型的建筑物变化算法。首先利用概率模型进行建筑物的轮廓提取，接着计算相应建筑物的变化概率值判断是否发生变化。Bailloeul [47] 提出了一种高分辨率遥感图像和数字地图间的变化检测方法。该方法利用活动轮廓（active contour）进行轮廓提取并与地图目标物配准，寻找变化。

Hazel [19] 提出了一种基于统计光谱异常检测子（statistical spectral anomaly detecto）和竞争区域增长算法（competitive region growth algorithm）提取目标物的方法。最后通过比较两幅图像中得到的目标物生成变化图。其实验的数据为长波红外超频谱图像。

③ 基于图像块或者分割的方法 [8,37,43,51]

Bruzzone [8] 提出一种基于区域的变化检测的方法。首先对二时相图像分别进行分割，每幅图像均分割得到若干个区域，再对分割出来的小区域进行融合，使两幅图像最终获得对应相同的区域块分割。综合考虑图像像素灰度值和纹理信息，定义每一个分割区域的特征向量，基于此特征向量生成二时相图像的差值图像，最后选取合适的阈值来确定变化区域。这种方法的优点在于考虑了图像的空间信息，避免由于去噪处理带来的检测误差。缺点是前期图像分割结果对后期变化检测的精度影响很大。

刘炜将 Kumar 等人 [24] 提出的 DRF 模型（Discriminative Random Fields）改进应用于结构变化分析 [51]。该方法的思想是利用 DRF 模型同时考虑时间域和空间域。变化被定义为时间域上的不连续性，而空间域内，变化一般具有连续性。图像被划分为一定尺寸的图像块，计算对应的图像块的局部变化特征，基于 DRF 模型定义整个图像的变化后验概率，通过最大化这个概率得到图像块的变化状态。

④ 多尺度的方法 [12]

Carvalho 等在 2001 年 [12] 提出一种将多尺度小波分析应用于变化检测的方法。方法是首先通过重采样使两幅图像的像素尺度相同，然后由这两幅图像生成差值图像，再对差值图像采用以三次样条为尺度函数的小波分解算法，得到四幅新的分量图像，分别反映原差值图像的概貌和细节信息，对其进行分析，选取合适的分量图像作假彩色合成，可以直接目视判别出变化区域，避免了阈值的选取。

2.3 结构特征、图和分割问题

最近有出现了一些基于结构特征的变化分析方法 [27, 37, 43, 44, 51]。这里说的结构特征是用线段表征的。如何利用线段来描述图像的结构, Sarkar [37]、Unsalan [43, 44]等人的工作做了很好的研究。

Unsalan [43, 44]的方法基于直线段特征。他们的目标是对图像/图像块进行发展水平的分类: 发达 (developed) 和欠发达地区 (less developed)。他们假设发达地区的直线段方向错落一致, 直线段较长, 而欠发达地区则直线段则较短, 并且方向随机分布。因此 [43]中仅使用简单的直线段的统计特征: 平均长度、长度熵、平均对比度和对比度熵, 来表征区域的发达程度。[44]添加了更为精确的结构描述——直线段关系图。结构的变化导致直线段集的变化, 直接导致了直线段关系图的改变。文中给出了基于有权图和无权图的两类特征。对于无权图, 他们利用回环秩 (circuit rank) 和度序列 (degree sequence) 作为发达程度特征; 对于有权图则使用拉普拉斯割 (Laplacian cut) 将图进行分割再创建特征描述子。文中还与 [37]的方法做了比较。

Sarkar等 [37]在1998年提出了一种基于图谱 (graph spectrum) 和特征聚类 (eigencluster) 的变化量化方法。这种方法处理的是航空遥感图像, 目标是检测和估计地面小块 (例如一个建筑工地) 的发展变化。他们提出使用恒曲率线段作为场景中结构特征的基础, 基于图的方法对结构进行建模。线段作为图的节点。图的边表示线段间的关联。边的连接权值设计得十分精巧。基于 Gestalt 理论, 线段关系权值由线段的曲率和线段间邻近性、平行性、垂直性、闭合性、连续性等特性项按一定规则组合生成。这样的线段可以划分为的特征聚类。这样的聚类在图像上反映了结构特征。最后基于特征聚类构建结构特征值, 利用贝叶斯判决器进行变化/无变化判决。

与这些基于结构特征的变化分析方法一起出现的还有大量关于图分割理论和应用问题的研究工作, 有利用图谱/关系矩阵特征向量的 [16, 37, 38], 有利用最小割/最大流等最小化代价函数的 [23, 5] [6, 29, 39]。这里我们仅简单介绍 Shi 等人 [39]工作的主要思想。

Shi 等人在 [39]中首先提出了一种新的图割准则——归一化割 (Ncut, normalized cut), 证明了求 Ncut 的问题最后可以等价于一个求矩阵特征值和特征向量的问题。文章中以基于像素灰度的图像分割问题为应用目标, 使用了邻域灰度值距离来定义关联权值。Malik [29]利用相同计算框架, 结

合轮廓和纹理信息构建关联权值对图像的分割。这些工作对我们的方法提出有启发意义。

2.4 基于局部特征的识别

2.4.1 低层视觉特征的概述

近几年来，在计算机视觉领域，基于局部不变量描述子（Local Invariant Descriptor）的方法在目标识别和匹配方面取得了显著的进展。2004年，Lowe在[28]中总结了现有的基于不变量技术的特征检测方法，并正式提出了一种基于尺度空间的、对图像缩放、旋转以及仿射变换具有不变性的图像局部特征描述算子——SIFT（Scale Invariant Feature Transform）算子，即尺度不变特征变换算子。Mikolajczyk和Schmid[30]针对不同的场景，对光照变化、仿射变换、图像旋转、尺度变化、图像模糊和图像压缩等6种情况，就多种最具代表性的描述子（如SIFT，GLOH，形状上下文（shape context），PCA-SIFT，可调滤波器（steerable filter），矩不变量（moments），互相关（cross correlation），旋转图像（spin images），差分不变量（differential invariants），复滤波器（complex filter）等10种描述子）进行了实验和性能比较，结果表明，SIFT描述子的性能优异。

SIFT算子可以应用于目标识别、图像配准、图像数据库检索等技术中[1, 28, 30, 32, 41, 46, 50]。Zisserman[41]介绍了使用SIFT思想的一个基于物体识别的视频搜索系统—Video Google，演示了海量视频数据库检索中的快速图像检索。Lowe[28]组合匹配的SIFT特征块，与预先定义的模型做几何匹配，展示了SIFT特征在目标物的识别中的应用。后续还有相关工作将SIFT用于静态的图像以及视频[1]目标物识别。李晓明等人[50]将SIFT特征描述子引入遥感图像处理中，用之进行多种遥感图像的配准。鉴于SIFT特征的这些特性，应用它的方法取得了一定的成果，同时这些应用也预示着基于不变量理论的特征检测技术还有更加广阔的研究和应用空间。

2.4.2 SIFT 特征介绍

由于后面章节中将要用到SIFT特征，在这个小节里我们细致介绍这种特征。SIFT特征的构造包括兴趣点（Keypoints）的检测和描述子的构造两部分。根据Lowe[28]的介绍，构造过程主要分两个步骤：

- ① 检测兴趣点，确定兴趣点位置和所在尺度；
- ② 确定兴趣点主方向，建立描述子。

2.4.2.1 兴趣点检测

为使 SIFT 特征具有尺度不变性，描述子的构造需在特征尺度下进行。在 Lowe 的方法中，SIFT 兴趣点的检测是通过求图像的 DoG (Difference-of-Gaussians) 金字塔多尺度空间的极值来确定兴趣点的坐标和特征尺度的。

初步确定兴趣点坐标和尺度后，Lowe 还通过拟合三维二次函数以精确确定兴趣点的位置和尺度。

2.4.2.2 SIFT 描述子的构造

在构造 SIFT 描述子之前还要为每个兴趣点赋予一个主方向。主方向是指兴趣点邻域梯度方向直方图的峰值柱所对应的方向。描述子构造时以该方向为参照，这样所构造的描述子具有旋转不变性。

在每个兴趣点 (x, y) 处计算其梯度的模值 $m(x, y)$ 和方向 $\theta(x, y)$ ：

$$\begin{aligned} m(x, y) &= \sqrt{(L(x+1, y) - L(x-1, y))^2 + (L(x, y+1) - L(x, y-1))^2} \\ \theta(x, y) &= \tan^{-1}((L(x+1, y) - L(x-1, y))/(L(x, y+1) - L(x, y-1))) \end{aligned} \quad (2-1)$$

其中 $L(x, y) = I(x, y) * G(x, y, \sigma_0)$ 为 σ_0 尺度下的高斯核函数 G 与图像 I 的卷积， σ_0 为兴趣点所在尺度。在实际计算时，以兴趣点为中心的邻域窗口内采样，并用直方图统计邻域像素的梯度方向。梯度直方图的范围是 $0 - 360$ 度，其中每 10 度一个柱，总共 36 个柱。直方图的峰值柱则代表了该兴趣点处邻域梯度的主方向，即作为该兴趣点的方向。

在梯度方向直方图中，当存在另一个相当于主峰值 80% 能量的峰值时，则将这个方向认为是该兴趣点的辅方向。一个兴趣点可能会被指定具有多个方向（一个主方向，一个以上辅方向），这可以增强匹配的鲁棒性。

在兴趣点所在的尺度（即高斯金字塔结构的某一层），以兴趣点为中心将坐标轴旋转为兴趣点的方向，以确保旋转不变性。接下来以兴趣点为中心取 8×8 的窗口。图 2-1 左部分的中央黑点为当前兴趣点的位置，每个小格代表兴趣点邻域内的一个像素，箭头方向代表该像素的梯度方向，箭头长度代表梯度模值，图中的圈代表高斯加权的范围（越靠近兴趣点的像素梯度方向信息贡献越大）。然后在每个 4×4 的小块上计算 8 个方向的梯度方向直方图，直方图的每个柱为具有相似梯度方向的梯度模值的累加。这样就形成了一个子特征向

量，如图 2-1 右部分所示。此图中一个兴趣点的 8×8 邻域块由 2×2 个子特征向量组成，每个子特征向量有 8 个方向向量幅值信息。这种邻域梯度方向性信息联合的思想增强了算法抗噪声的能力，同时对于含有定位误差的特征匹配也提供了较好的容错性。

实际计算过程中，为了增强匹配的稳健性，Lowe 建议对每个兴趣点使用 4×4 个种子点来描述，这样对于一个兴趣点就可以产生 128 个数据，即最终形成 128 维的 SIFT 特征向量。此时 SIFT 特征向量已经去除了尺度变化、旋转等几何变形因素的影响，再继续将特征向量归一化，则可以进一步去除光照变化的影响。

2.4.2.3 本节总结

从理论上说，SIFT 是一种相似不变量，即对图像尺度变化和旋转是不变量。然而，由于构造 SIFT 特征时，在很多细节上进行了特殊处理，使得 SIFT 对图像的复杂变形视角变化、仿射变换、光照变化和噪声具有了较强的适应性 [30, 46]，同时运算速度比较快，定位精度比较高。Lowe 的方法提取的 SIFT 特征向量具有如下优点：

- 该方法对光照仿射变换、几何形变具有不变性；
- 独特性（distinctiveness）好，信息量丰富，适用于在海量特征数据库中进行快速、准确的匹配 [41]，同时特征组合后可适应识别中的遮挡问题；
- 兴趣点的精确定位不仅提高了精度，而且大大提高了兴趣点的稳定性；

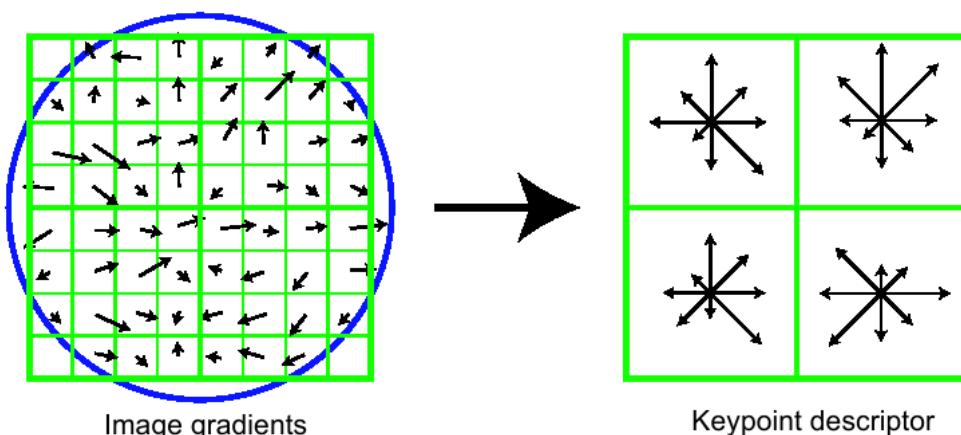


图 2-1 由兴趣点邻域梯度信息生成特征向量。（图片取自 [28]）

- 在构造描述子时，以子区域的统计特性，而不是以单个像素作为研究对象，提高了对图像局部变形的适应能力；
- 对于 16×16 的兴趣点邻域，在处理梯度幅度时进行了高斯函数的加权处理，强化了中心区域，淡化了边缘区域的影响，从而提高了特征对几何变形的适应性。

2.5 小结

通过对研究的问题域内的发展和研究现状的总结可以看出，遥感图像的变化检测问题目标多样，使用的数据类型繁多，无法开发普遍适用的方法。现有的方法均处理一类特定数据，解决一类特定问题。没有哪一种算法能证明一定优于别的算法。

针对我们定义的问题，目前还没专门为之提出的方法。因此下面的章节中，我们会研究和提出针对这种结构变化的检测方法。

第三章 基于外观不变量的高分辨率遥感图像结构变化检测

3.1 引言

这一章我们提出了基于外观不变量的高分辨率遥感图像结构变化检测方法。我们借用目标物识别和基于内容的图像检索领域最近提出的基于局部特征检索、识别 ([28, 30, 41]) 的思想，开发用于高分辨率遥感图像结构变化“识别”的方法。

本章的内容组织如下：3.1 节引言，列出章节组织；3.2 节介绍本章提出的方法的主要思想，同时给出算法的流程；3.3 节详细介绍了基于直线段关系的图像分割方法，给出了分割目标、方法选择和结果评判标准；3.4 节详细介绍了外观不变量特征的计算和描述区域结构的“词典”的建立；3.5 节介绍我们的变化检测的实现；3.6 节给出了实验的设定，讨论分析了实验结果；3.7 节总结，讨论了本章提出的方法的优点和不足，以此为基础分析了下一步工作如何展开。

3.2 算法思想与流程

为了明确研究工作的目标，我们定义工作为：1) 找到结构变化发生的区域；2) 初步计算图像对中结构的变化程度。处理这个结构变化问题，我们遵循两条指导性原则：局部特征和全局模式一并体现区域结构；度量相似性比度量变化本身要容易、直接。我们有两幅不同时间拍摄的同一地区的图像 I^1 和 I^2 ，并且此两幅图像已经进行了粗配准。我们提出的方法其最基本的假设前提是：现实世界中的一个场景可以由有限个特定类型的图像局部外观特征 (appearance features)¹ 描述，相似的场景应当含有相似的特征分布。而这种局部外观特征具有不受图像的获取条件影响的性质。

我们先将其中一幅图像粗略的分割为结构近似一致的区域，我们随后从输入图像建立一个“词语”“词典”，所有的区域被该“词典”中的“词语”来描述。最后两图像中对应的区域的变化是通过计算它们的“词语”统计量的相似性来获得的。具体的流程见本章最后的图 3-11。

¹当前我们称一类特定的图像局部外观特征为一个特征类型，也称这样的一类特定图像局部外观特征可被“词典”中的一个“词语”描述。

3.3 基于直线段关系的图像分割

变化检测的一般方法是基于像素、目标物或者固定大小的图像块的，对于我们定义的结构变化，这里我们希望能从变化本身发生的范围内——即包含且仅包含变化的自由（非规则）轮廓区域——进行分析。然而分割往往是和变化检测相互依赖、同时进行的，因此这里我们仅假设结构变化发生的最小范围是一个具有相同结构特征的区域，从而预先将图像划分为结构近似一致的区域作为变化分析的对象。

与 [37, 43]的思想类似，我们用直线段关系来表述结构。因为从认知科学的角度，人类视觉系统也依赖于各种边缘线段提取的，线段是人类认识物体结构的重要信息，同样我们认为直线段是遥感图像中物体结构的重要信息；而另一方面由于成像情况的不一致性以及高分辨率遥感图像的复杂性，我们希望采用稳定的特征，物体的边缘直线段就是这样的特征。

3.3.1 直线段的提取

我们假定直线段是图像中建筑物和道路等结构区域的一种稳定特征，它们是图像中建筑物和道路等物体的边缘。为了获得稳定的直线段，我们实验了两大类方法：基于Hough变换的方法 [33]、基于线段支持域的方法 [10]。由于高分辨率遥感图像的复杂性，基于线段支持域的方法更为鲁棒，这也是我们最后的选择。这一小结所描述的算法出自文献 [10, 43]，除梯度计算选择不同外，其余部分均一致。为完整地介绍整个计算框架，在这里我们将详细介绍该算法的实现。

算法先求得图像沿 x 和 y 方向的偏导 I_x 和 I_y ，也即梯度图像 $\mathbf{G}(I)$ 。将梯度图像中的每个像素按其方向等角度间距离散化，生成一个具有 8 个离散化值的角度离散化图像，将具有相同角度离散化值的相邻点连接起来，形成一个区域，称为直线段支持域。可以假定直线段支持域是一椭圆，那么椭圆支持域的长轴即为所求直线段。

为了抑制离散化的绝对截断带来的断裂线段，需要将梯度方向归入两组互为补充的离散化值中，如图 3-1，第二组是将第一组离散化值区间逆时针旋转 22.5 度。这样就存在两组候选直线段支持域，将每个像素分配给能获得最长线段的支持域从而获得最终的直线段支持域。最后对所得的支持域做椭圆拟合，椭圆的长轴即为所提取的直线段。

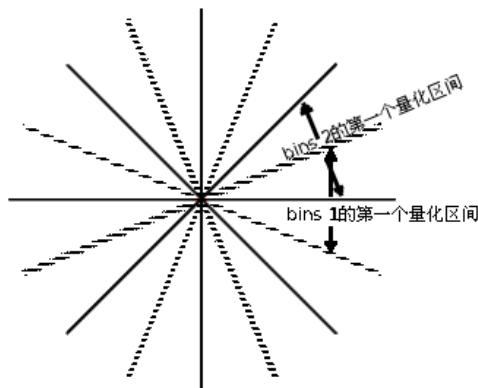


图 3-1 两组互补梯度方向离散化区间：虚线为第一组 $bins_1$ ；实线为第二组 $bins_2$ 。第二组是将第一组离散化值区间逆时针旋转 22.5 度。每组内标号值（离散化值）逆时针递增

直线段提取的伪代码如下所示：

```

Input:  $sizeX \times sizeY$  的图像  $I$ 
Output: 一个直线段结构数组  $Lines$ , 直线段数量  $n$ 
Data: 两组互相补充的角度离散化截断点数组  $bins_1, bins_2$ , 高斯差分核标准差  $\sigma$ 

for  $i \leftarrow 0$  to  $sizeY$  do
|  $I_x(\cdot, i) \leftarrow I(\cdot, i) * GaussianDifferentialKernel(\sigma)$ 
end

for  $j \leftarrow 0$  to  $sizeX$  do
|  $I_y(j, \cdot) \leftarrow I(j, \cdot) * GaussianDifferentialKernel(\sigma)$ 
end

 $I_{Angle} \leftarrow GradientAngle(I_x, I_y)$ 
 $I_{label}^1 \leftarrow AngleLabeling(I_{Angle}, bins_1)$ 
 $I_{label}^2 \leftarrow AngleLabeling(I_{Angle}, bins_2)$ 
 $I_{region}^1 \leftarrow NeighborWithSameLabelMerging(I_{label}^1)$ 
 $I_{region}^2 \leftarrow NeighborWithSameLabelMerging(I_{label}^2)$ 

```

设置一个支持域处理状态矩阵 $I_{processed}$, 初始设置待处理的支持域点为 0

```

 $n \leftarrow 0$  for  $i \leftarrow 0$  to  $sizeX$  do
    for  $j \leftarrow 0$  to  $sizeY$  do
        if  $I_{processed}(i, j) \neq 1$  then
             $r_1 \leftarrow I_{region}^1(i, j)$ ,  $r_2 \leftarrow I_{region}^2(i, j)$ 
             $line_1 \leftarrow FitLineToSupportRegion(r_1, I_{region}^1)$ 
             $line_2 \leftarrow FitLineToSupportRegion(r_2, I_{region}^2)$ 
            if  $line_1.length > line_2.length$  then
                |  $Lines[n] \leftarrow line_1$ 
            else
                |  $Lines[n] \leftarrow line_2$ 
            end
        设置直线段  $n$  的支持域对应坐标的处理状态为 1
         $n \leftarrow n + 1$ 
    end
end

```

算法 3-1: 直线段提取 (Burns [10]、Unsalan [43])

为了抑制噪声对直线段检测的影响, 我们设置了一个梯度模值阈值 $T_{NormGradient}$, 如果某像素坐标处梯度模值低于该阈值, 则不会进入后面的角度离散化和支持域生成等步骤。

3.3.2 直线段关系图的建立

首先我们假设具有强结构的区域直线段间的关联紧密, 用直线段作为图的节点, 构造反映直线段间关联强度的图, 使用适当的图割 (graph cut) 算法可以将图分成相互关联较弱的子图, 也即将直线段聚类。再将分类的直线段映射回原图像, 接着给图像点贴上最近直线段所在的类的标签, 从而将图像切为具有相似结构的分区。关键的问题是如何构造这个直线段关系图以及选择图割算法。

结构丰富的区域——一般多为密集城区和住宅区——有大量的人造物体如建筑物、道路、铁路等, 相对于非结构化的区域——多为森林和农田——结构丰富区域的直线段更密集, 方向分布集中, 且大量相互平行或垂直。那么我们

可以假设当两直线段相距越近，它们属于同一个物体或者同一个结构区域的概率越大，关联应当更强；同时我们应突出相互平行或者垂直的直线段的关联。

因此我们这样建立直线段关系图： $G = (V, E)$ ，其中节点集合 V 为提取的直线段；连接节点对（直线段对） (i, j) 的边 $e_{ij} \in E$ 的关联权 w_{ij} 定义为两直线段间最小距离和方向夹角的函数。

$$w_{ij} = |\cos(2\alpha_{ij})| \exp(-\frac{d_{ij}^2}{\beta^2}) \quad (3-1)$$

其中 α_{ij} 是直线段 i 和 j 的夹角； d_{ij} 为直线段 i 和 j 间的最小距离； β 是一个尺度常数，它控制直线段彼此产生影响的最远距离， $|\cdot|$ 表示求绝对值。

我们用直线段关系矩阵 W 来表示这个直线段关系图，

$$W(i, j) = w_{ij} = w_{ji}$$

它是对称的、正定的。

3.3.3 Ncut算法及分割迭代

我们通过图分割（graph partitioning）的方法将给定图像分裂为结构近似一致的分割。我们已有图 $G = (V, E)$ ，分割的目标是将节点划分成不相交的集合 V_1, V_2, \dots, V_m 。这样使得集合内的关联度高，而集合间的关联度低。图 $G = (V, E)$ 可以先被分为两个不相交的子图，其节点分别记为 A 和 B ，实现方法是去掉 A 中节点到 B 中节点之间的连接边。两个集合 A 和 B 之间的关联程度，可以用去掉的边的权值之和来表示，这个总权值称为割（cut）

$$cut(A, B) = \sum_{i \in A, j \in B} w_{ij} \quad (3-2)$$

分割问题形式化的一种方法，是寻找图中的最小割（minimum cut），不断重复这个步骤直到区域足够一致。但是最小割准则倾向于分割成较小的孤立节点，这在寻找相似结构的大块区域时十分不利。Shi [39]提出了规一化割（normalized cut，Ncut），

$$Ncut(A, B) = \frac{cut(A, B)}{asssoc(A, V)} + \frac{cut(A, B)}{asssoc(B, V)} \quad (3-3)$$

其中

$$asssoc(A, V) = \sum_{i \in A, j \in V} w_{ij}$$

$$asssoc(B, V) = \sum_{i \in B, j \in V} w_{ij}$$

根据这个定义，较小的孤立点集的割不具备最小的归一化割，这一点对我们的分割十分重要。

Input: 直线段关系矩阵 W

Output: 分割向量 y

- 1 建立图 $G = (V, E)$
- 2 计算度矩阵 D ，它是一个 $N \times N$ 的对角矩阵，其中对角线上的值为
- 3

$$D(i, i) = \sum_j W(i, j) \quad (3-4)$$

- 4 解特征方程 $D^{-\frac{1}{2}}(D - W)D^{-\frac{1}{2}}x = \lambda x$ ，求得第二小特征对应的特征向量 \hat{x}

- 5 $\hat{y} \leftarrow D^{-1}\hat{x}$

- 6 找到一个值将 \hat{y} 二值化为 y ，即将图 G 分为两个子图 $G_1 = (V_1, E_1)$ 和 $G_2 = (V_2, E_2)$ ，满足 $Ncut(V_1, V_2)$ 最小。

- 7 判定子图是否需要向下继续分割，是则重新开始子图的分割，若无子图需要分割算法停止。

算法 3-2: Ncut 分割过程 (Shi [39])

由如上算法可知分割过程是个迭代过程。对于我们的分割问题，我们需要自己定义一个迭代结束准则。当分割得的子图的内聚度足够大时，我们认为应当停止分割，从而避免过细的分割；同时我们在算法开始时希望迭代更多的进行，而在后期希望其倾向于结束。所以我们将定义一个惩罚项，随着迭代的进行增大对迭代的惩罚。基于如上分析，我们定义子图 p 迭代停止准则 (Iteration Stopping Criteria, ISC) 函数为：

$$\frac{assoc(G_p^l, G_p^l)}{conn(G_p^l)} > T_{ISC} \exp(-\frac{l}{\delta}) \quad (3-5)$$

其中 G_p^l 为迭代第 $l > 0$ 层的子图 p ， $conn(G_p^l) = |V_p^l|$ 是子图 G_p^l 中关联数量，而 T_{ISC} , δ 分别是控制最大阈值和下降速度的常数。 G^0 是最初由图像中提取的

直线段构建的关系图，最后分割区域的数量 K 决定于图像本身以及设定的参数。分割区域用它们的编号 k 来表示， $1 \leq k \leq K$ 。

由于图 $G = (V, E)$ 是由图像中提取的直线段建立的，所以图的分割不是对图像本身操作。通过将 V （即直线段）重投影到图像中来，再将图像中像素分配到离它最近的直线段所在的分割中去，这样我们最后得到了具有近似一致结构的图像分割区域。

3.3.4 分割结果评价策略

鉴于图像分割是一个没有统一标准的开放性问题，我们需要自己定义分割评判标准。我们提出使用手工分割（附加了我们对结构的知识和理解）的结果作为标准分割来评价分割结果，并参考评价结果配置算法参数。图 3-3 为手工生成的标准分割。我们期望一方面分割的数量相同，另一方面对应分割区域重叠区域面积最大。我们定义 $Ncut$ 分割 S_{Ncut} 和标准分割 S_g 间的相似度 Sim 为：

$$Sim(S_g, S_{Ncut}) = \frac{1}{N_{Ncut}} \exp\left(-\frac{2|N_g - N_{Ncut}|}{N_g + N_{Ncut}}\right) \sum_{k=1}^{N_{Ncut}} \frac{2A_{maxinter}(P_{Ncut}^k, P_g^h)}{A(P_{Ncut}^k) + A(P_g^h)} \quad (3-6)$$

其中 $A_{maxinter}(P_{Ncut}^k, P_g^h)$ 为 $Ncut$ 分割的第 k 个区域 P_{Ncut}^k 与和它重叠面积最大的标准分割中的第 h 个区域 P_g^h 的最大相交区域面积； $A(P_{Ncut}^k)$ 是 $Ncut$ 分割的 k 区域的面积； N_{Ncut}, N_g 分别是 $Ncut$ 分割和标准分割的区域数。指数级项惩罚分割数量不一致，而求平均项（求和项）惩罚相交面积小。相似度越高说明 $Ncut$ 分割的结果与我们期望的结果越接近。

3.4 外观不变量特征

我们认为相似的场景应当有相似的特征类型（即所谓特征袋（bag-of-features），或词语字典（words dictionary）[13, 31, 32]）描述，因此通过比较由图像计算得的特征类型可以判定两个场景是否相似。

为了使特征体现长效变化的影响，而尽量避免表象变化的干扰，我们需要分析造成表象变化的因素，仔细设计选择外观特征。同时我们希望外观特征对尺度变化不敏感，并且图像中结构物体的排列角度也不会影响外观特征。我们选择建筑物的角点为兴趣点（keypoint），这样的点具有一定的尺度稳定性。以兴趣点为中心，我们计算图像小块（一般是 16×16 的窗口大小）中的梯度方向直方图作为局部外观特征。我们知道归一化梯度对图像灰度的仿射变换具有不

变性，用局部平均梯度模值归一化梯度即满足对光照变化的稳定。特征块建立前，我们保证所有特征块的主梯度方向均一致，就可以满足对结构物体的排列角度的不变性。

由于不靠大量数据集来训练，变化“识别”的问题应当和一般目标物识别有些差别：我们没有正（包含目标物）负（不包含目标物）样本；我们的目标不是描述一个特定的场景，而是比较一对图像的相似性。角点检测子和 SIFT 描述子作用于两幅图像进行特征块提取。通过聚类特征块来生成词语字典。每一个特征块按照欧氏距离最小准则被分配字典中的某个词语（即特征空间中最邻近的聚类中心）。最后每幅图像均可以由相同字典中的一组词语描述。这样两个不同场景但含有相同局部几何结构特征（例如两个住宅区的建筑群场景）的图像/分割区域将有相似的词语描述。

3.4.1 兴趣点提取

我们认为结构物体（建筑物）的几何结构由其角点所在的图像块的关系体现。一般建筑物的角点处梯度方向直方图具有一定的尺度稳定性。这里我们使用 Harris 角点检测子 [18] 提取图像角点，并提出一个策略对每个角点验证其稳定性，去除由植被等因素带来的不稳定角点。

Harris 角点检测子是假设将图像做微小移动，每个像素自相关矩阵可以约等于

$$C(x, y) = \begin{bmatrix} \sum_{(x_k, y_k) \in W} I_x^2(x_k, y_k) & \sum_{(x_k, y_k) \in W} I_x(x_k, y_k)I_y(x_k, y_k) \\ \sum_{(x_k, y_k) \in W} I_x(x_k, y_k)I_y(x_k, y_k) & \sum_{(x_k, y_k) \in W} I_y^2(x_k, y_k) \end{bmatrix} \quad (3-7)$$

其中 $I_x(x_k, y_k), I_y(x_k, y_k)$ 分别是图像点 (x_k, y_k) 处灰度值函数 $I(x, y)$ 沿的 x 和 y 方向的偏导， W 是 (x, y) 的一个邻域。求该矩阵的特征值，如果两特征值均很大，表明沿两个特征向量方向移动，自相关值均较大，在图像中符合这种情况的是物体的角。

我们提出的角点稳定性判定如下：给定三个尺度，这里我们设为 s_1, s_2, s_3 ，在以角点为中心的 $s_1 \times s_1, s_2 \times s_2, s_3 \times s_3$ 三个正方形区域内分别计算归一化的梯度方向直方图，如果任意两对梯度方向直方图之距离的乘积大于给定的阈值 T_{rohars} ，我们认为该角点对尺度敏感，需要剔除。将两幅图像得到的角点合并，生成了兴趣点集，这里的合并在图像上的操作即是将图像 I^1 上的得到的角点直接投影到图像 I^2 上，同样也将图像 I^2 上的得到的角点直接投影到图像 I^1 上。

最后对于无结构的分割区域我们加上适量的随机点作为兴趣点，以保证后续特征类型直方图的有效性。

3.4.2 SIFT 特征计算

严格意义上来说，我们计算的特征只是基于 SIFT 的思想，我们只是在描述子层和标准的 SIFT 一致。这里我们仍然称我们的特征为 SIFT 特征，这并不影响理解。

我们首先计算图像的梯度，我们将兴趣点处的梯度方向作为待求特征变换图像块的主梯度方向，设其方向角为 α 。将该图像块中所有的梯度方向块均旋转一个角度 α ，这样“归一化”的梯度图像块具有相同的主方向，从而保证了 SIFT 特征的旋转不变性（结构物体的排列角度不变性）。为了消减截断效应，在对图像块求梯度方向直方图前，须对梯度块用一高斯窗加权。接着我们将图像块内每个像素的梯度用块内梯度模平均值归一化。

与 Lowe 的 SIFT 特征计算一样，我们将 $n \times n$ 的窗口等分为 $p \times p$ 个小块， $p < n$ 。在这样的 $\frac{n}{p} \times \frac{n}{p}$ 大小的小块中我们计算梯度方向加权直方图。我们认为梯度沿某方向的正负并不重要，这里计算梯度角度的范围是 0 – 180 度。离散化角度的四个方向如图 3-2 所示。另外我们还设置一个梯度模值阈值 $T_{GradSIFT}$ ，对于小于该阈值的像素点，我们认为其梯度由噪声引起，设置该点的梯度方向为无，那么小块可以由一个长度为 5 的向量来表征，向量每一项由小块内具有相应梯度方向量化值的像素的梯度模值求和得到。将这个 $p \times p$ 小块的特征变换向量排列构成的 $p \times p \times 5$ 维的向量即为 SIFT 特征的数学表示。

3.4.3 SIFT 特征聚类和“词典”建立

将得到的 SIFT 特征通过聚类算法把外观相似的特征块聚合为一类，形成描述该特征的“词语” [1, 20]，其中 K 均值（K-Means）聚类算法 [48] 是“词典”

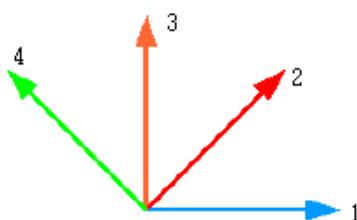


图 3-2 梯度方向量化值示意图。

建立最常用的算法。这里我们也选择它作为我们的特征聚类算法。这里我们不具体介绍该算法，仅给出相关要点：

- 初始化。随机的将每个 SIFT 特征分配一个类别值。
- 将同一类别的 SIFT 特征向量累加，并最后求均值向量，作为类别的中心。
- 将每个 SIFT 特征向量按欧氏距离最小准则重新分配类别，并更新类别中心。
- 当类别改变的 SIFT 特征向量与特征的总数比小于某一给定阈值或者迭代超过一定数目终止。

K 均值聚类算法需要先给定聚类数目。理论上分类越细对图像的描述越精确，但是由于我们的区域内的兴趣点有限，需要选择一个中间值保证变化检测的鲁棒性。

K 均值聚类完成以后，图像中的每一个特征块都属于某一个类别，我们称之为可由某“词语”描述。那么计算一个分割区域内各个“词语”出现的频率，这样就构成了一个“词语”直方图。目标物识别和图像检索中使用这样的“词语”直方图来描述纹理或者物体 [1, 20, 45]，我们也利用这样的直方图来描述区域的结构。

3.5 基于直方图统计的变化检测

表示或者说量化两图像中对应区域变化最简单直接的方法就是计算词语直方图的距离，距离越小，变化越小，反之则越大。

我们仅按照一幅图像生成分割，然后将分割边界投影到另一幅图像上，从而得到了相同的分割。

我们使用 χ^2 距离量化区域间的相似性。图像对的任意一个给定区域 k 的变化程度为：

$$D_k = \chi^2(hist^1(k), hist^2(k)) = \sum_{j=1}^n \frac{(hist^1(k)[j] - hist^2(k)[j])^2}{hist^1(k)[j] + hist^2(k)[j]} \quad (3-8)$$

其中 $hist^1(k)$ 和 $hist^2(k)$ 分别为由图像 1 和 2 中区域 k 计算得得词语直方图， $hist^1(k)[j], hist^2(k)[j]$ 分别为直方图 $hist^1(k)$ 和 $hist^2(k)$ 的第 j 项， n 是特

征类型数。由此定义我们知道大的 χ^2 距离反映场景的大的差异，反之则是小的差异。

为了与人工估计的“真实变化”相比较，我们将 D_k 离散化为 $\{0, 0.5, 1\}$ ，分别对应于“不变”、“部分变化”、“完全变化”。最后变化估计的评估值定义为：

$$Q = \frac{1}{K} \sum_{k=1}^K (\hat{D}_k - gt(k))^2 \quad (3-9)$$

其中 \hat{D}_k 的 D_k 离散化值， $gt(k)$ 是区域 k 的真实变化值（真实变化值取值属于 $\{0; 0.5; 1\}$ ）， K 是区域总数。 Q 越小变化估计值越接近真实值，相反则估计存在较多错误。

3.6 实验结果及分析

3.6.1 实验设定

参数如下设置：

- 直线段提取 $T_{NormGradient} = 10$ 。
- 直线段关系图建立 $\beta = 30$ （式 3-1）。
- 直线段关系图分割迭代停止准则 $T_{ISC} = 0.06$, $\delta = 10$ （式 3-5）。
- Harris 角点的稳定性的判定 $s_1 = 5$, $s_2 = 9$, $s_3 = 17$, $T_{rohars} = 0.1$ 。
- SIFT 特征计算 $T_{GradSIFT} = 10$, $n = 16$, $p = 4$, 高斯窗的大小 $\sigma = 4$ 。
- K-Means 聚类类别数为 17，算法当小于或等于 1% 的点重新分配类别时停止。

3.6.2 结果分析

我们输入图像 1.3(a)，按算法 3-1 提取其直线段，如图 3-4 所示。在我们的 P4 机器上运行时间 2 分钟。

由得到的直线段，构造直线段关系图，使用 NCut 算法进行图像的分割，算法进行了 4 层迭代，所有的子图先后满足迭代停止准则，运行时间为 17 分钟，得到结果如图 3-5，最后的生成图像分割如图 3-8 所示。

分割完成后我们利用前面定义的分割相似性函数对不同参数下的分割进行评价，结果见表 3-1。当变化一个参数的时候其他参数保持不变（这里我们其他参数与上一小节中的设置值一致），这样得出每个参数对分割的影响。由于对分割数大于标准分割惩罚不足，所以我们的参数没有选取表中的最优值，而是参考分割评价结果，选取能生成在视觉上与期望更加一致结果的参数。

由于我们的分割是基于直线段关系的，所以在结构丰富的区域，分割可以得到好的效果，见图 3-6。分割明显将有不同方向和结构水平的边缘线段分隔开来。而关系图分割方法的缺点是空旷无结构的区域则会被分裂到周围区域，不能分割出较完整的无结构区域。

通过兴趣点检测、SIFT 特征计算和聚类等步骤最后生成的两幅图像的特征类型（词语）的空间分布如图 3-9所示。可以看出不同的词语（由颜色表示）表示不同的局部几何结构特征。例如红色的词语多在低纹理区域，而绿色的多在建筑物区域（见图 3-7）。

最后每个区域被判定为“结构变化”、“无结构变化”和“部分结构变化”，见图 3.9(b)；而手工标定的真实变化如图 3.9(a)所示。由于我们知道图像中存在结构变化区域和无变化区域，可以将变化量化值归一化到 $[0, 1]$ 范围。由归一化结果和真实变化比较可知，我们的方法对结构变化没有漏检，但其中两个区域被错误分类，一个无变化区域被判断为部分结构变化， $Q = 0.075$ （式 3-9）。但是如果我们将仔细观察图像中心的分割区域，可以发现存在明显的变化，但是这并不是我们定义的结构变化，所以并未被识别为结构变化。这就显示出了局部几何结构特征相对于全局纹理特征在结构变化检测的优势。

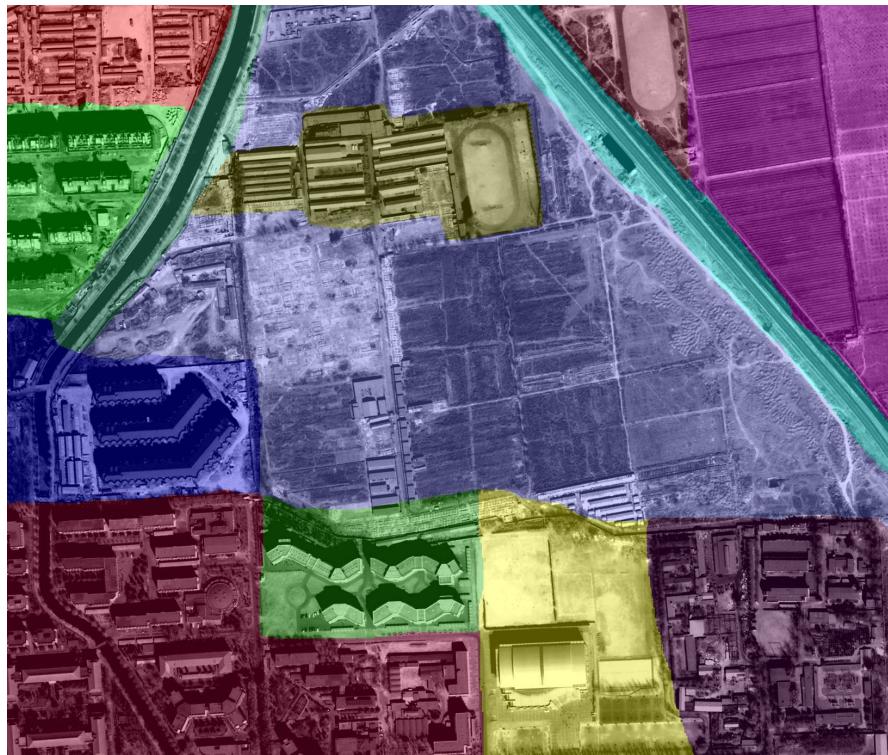


图 3-3 由图 1.3(a) 得到的标准分割图像。



图 3-4 由图 1.3(a) 得到提取直线段图像。

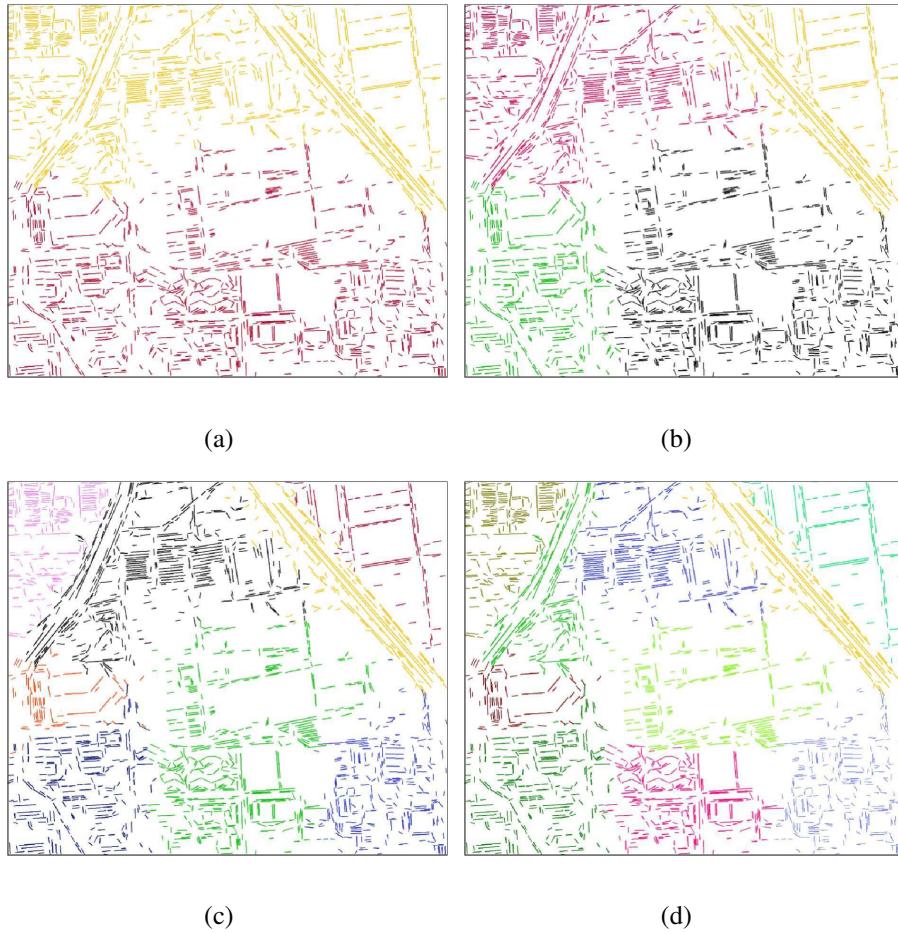


图 3-5 直线段关系图的分割迭代示意图: (a): 迭代1, (b): 迭代2, (c): 迭代3, (d): 迭代4 (最后一层迭代)。

β (式 3-1)	25	30	35	40
分割相似度 Sim	0.67	0.60	0.45	0.39
$T_{ISC} = 0.06$ (式 3-5)	0.04	0.06	0.08	0.10
分割相似度 Sim	0.35	0.60	0.60	0.83
$\delta = 10$ (式 3-5)	5	10	15	20
分割相似度 Sim	0.60	0.60	0.60	0.60

表 3-1 不同参数下的分割相似度 Sim (式 3-6), 变化一个参数的时候其他参数保持与 3.6.1 节一致。

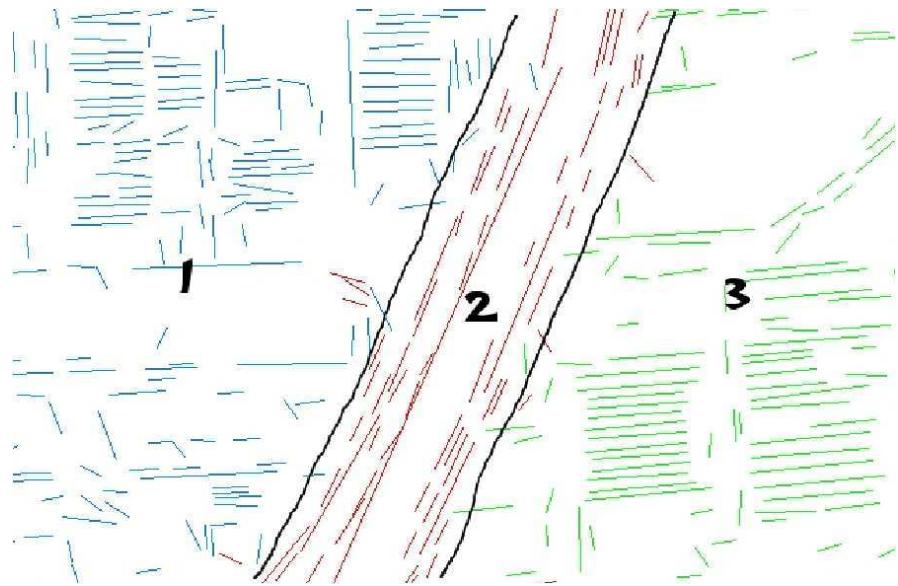


图 3-6 图 3.8(a) 的左上角的放大显示，颜色显示不同的分割区域，黑线将分割区域 1, 2, 3 分隔开来。

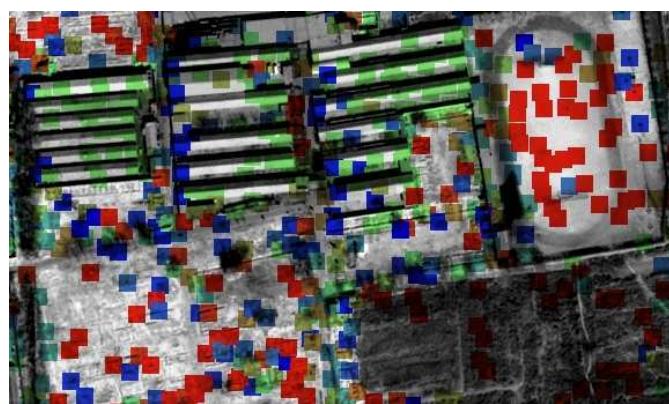
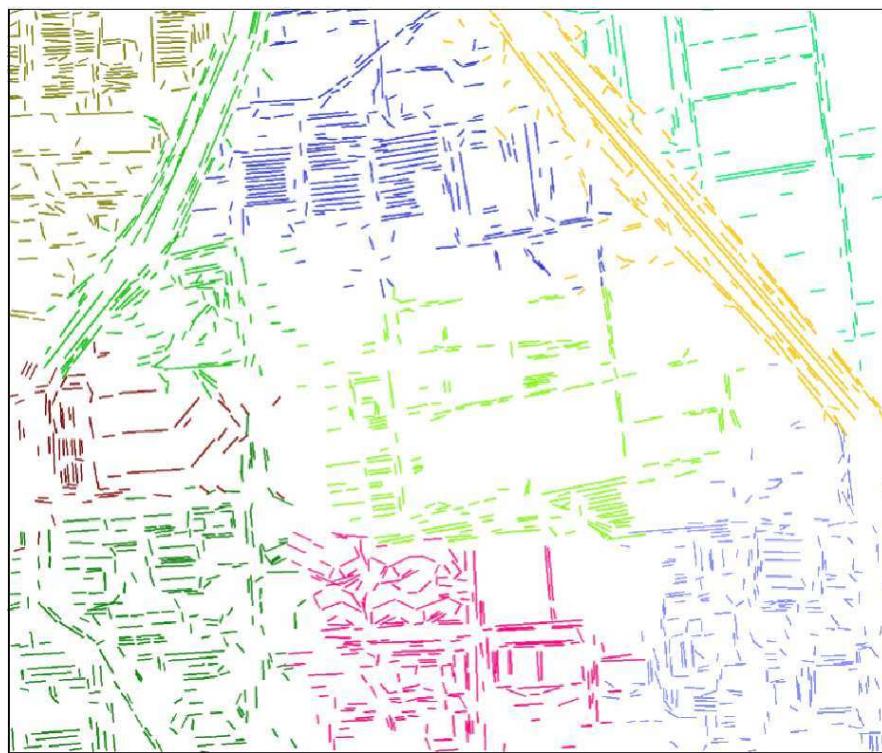


图 3-7 从图像中提取的特征块局部示意图：颜色表示其所属的特征类型（词语）。
图 3.9(a) 的中间区域的放大显示。



(a)



(b)

图 3-8 关系图分割迭代的最后结果(a)，图像分割(b)。

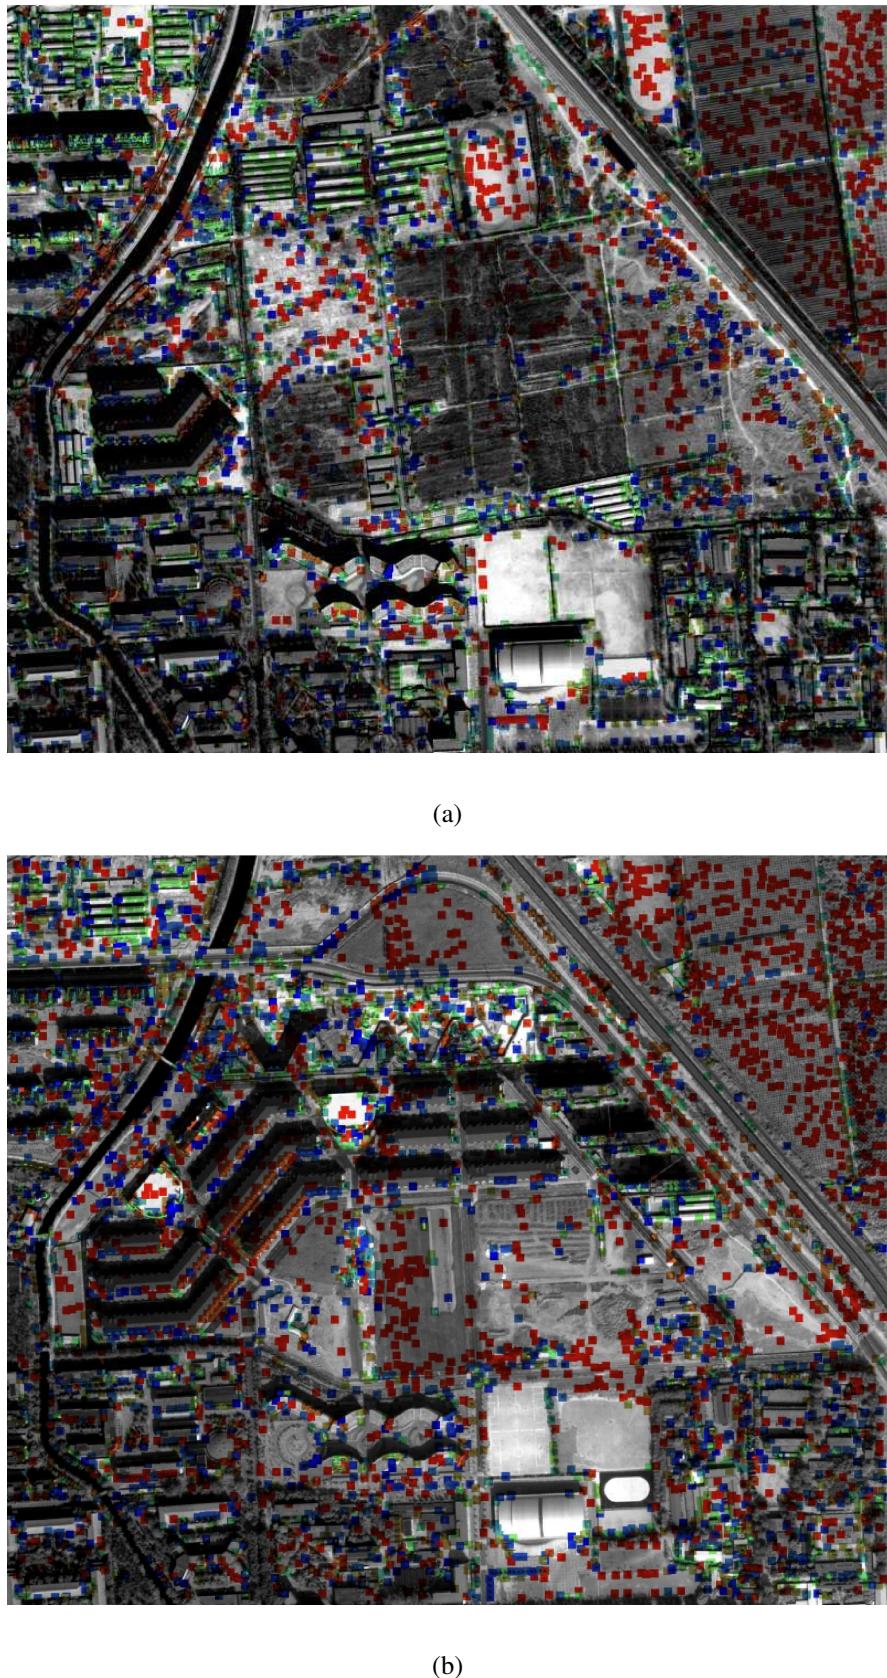
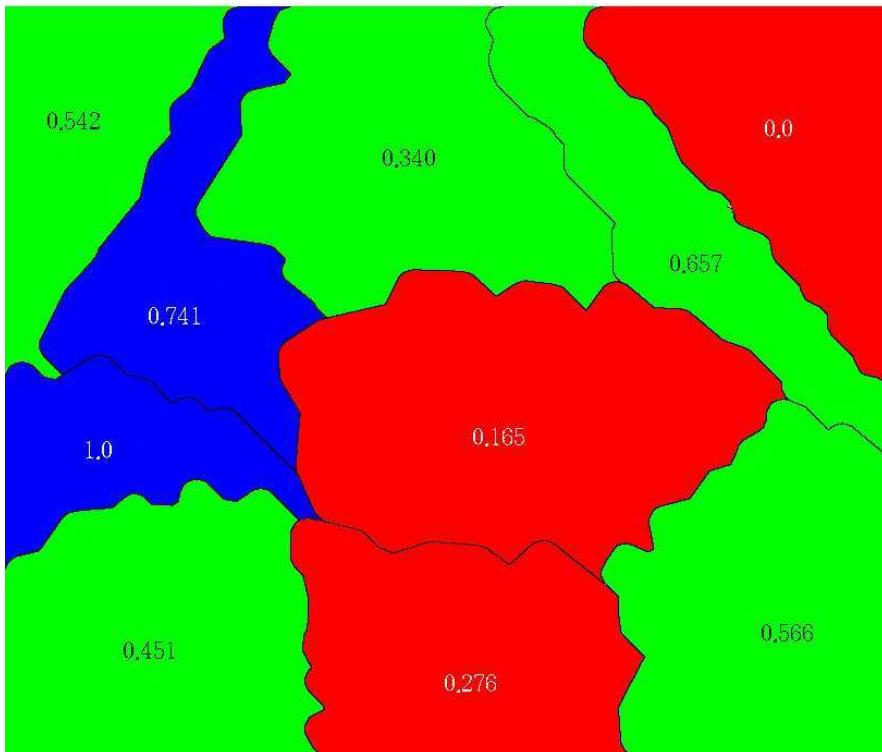


图 3-9 从图像中提取的特征块：颜色表示其所属的特征类型（词语）(a) 2002 年数据，(b) 2003 年数据。



(a) 手工标定的变化图（作为真实变化）



(b) 程序给出的计算结果

图 3-10 使用 χ^2 计算的结构变化，变化量化值如图上数字所示，量化值最后被离散化。

颜色表示离散化值：红色，没有变化；绿色，部分变化；蓝色，变化。

3.7 小结

这一章细致地介绍了我们提出的一种从粗配准的一对高分辨率遥感图像进行结构变化检测和分析的计算框架，并展示了实验结果。该框架主要分为两个部分：第一部分集成了前人基于支持域的直线段提取、图的归一化割等工作，实现了一种将图像分割为结构近似一致区域的算法，其中我们自己定义了直线段关系图的权函数、关系图分割停止准则和图像分割评价策略；第二部分借鉴目标物识别和图像检索领域基于局部特征表示物体的思想，进而提出一个场景可以由有限个局部外观特征类型（词语）来描述，两幅图像相同区域的词语直方图的距离可以作为其相似性度量。

我们提出的方法其优点在于：它不需要图像的精确配准，也不需要预先进行分割处理；由于训练直接在图像上完成，特征（即“词语”）随输入图像改变而改变，更能描述待处理的图像的信息。

通过实验结果我们可以看出基于局部外观不变量的方法在结构变化检测还是有较好的检测能力的，但是仍然可以从如下方面改进：

- ① 基于图的图像的分割。由直线段定义的分割模型仅对于有结构区域有效，能根据结构一致性将图像分割成不同区域。在这个意义上来说，比一般基于像素或者纹理的方法处理结构图像分割更有效。然而对于无结构的区域，它就表现出不足了。我们可以通过附加新的信息（比如纹理）来帮助将图像中的点投影到直线段分割集中，或者在图的分割完成后细致处理图像的分割问题。
- ② 兴趣点。使用角点作为兴趣点，能反映区域的结构信息，却在无结构区域无法得到足够多的点；如果采用随机或者规则采样点作为兴趣点则无法很好的反映结构。面对这样的两难境地，我们仍然选择 Harris 角点作为兴趣点，但对于无结构区域，则统计局部兴趣点密度作为结构特征。由于遥感图像的低对比度和场景的复杂性，检测鲁棒的角点位置仍然很困难，阈值设置过低各种噪声造成的点被选入兴趣点集，而阈值过高有会导致部分角点漏检。两幅图像间由于存在配准误差，导致对应兴趣点在两图像间有相对位移，而并非直接的投影，因而我们的兴趣点会存在重复和位置错误等，影响后续操作。可以通过加入两图像中兴趣点匹配处理，减小这种影响。

- ③ SIFT 描述子。对旋转或者轻微的移动仍然有一定敏感性，原因在于选取的主方向不鲁棒。可以统计梯度方向直方图，最后选用值最大的柱对应的方向作为主方向，提高其鲁棒性。
- ④ 聚类算法和相似性度量方法。它们的选择是一个要点。由于遥感图像的复杂性，抽取的特征块在特征空间中存在重叠，K 均值这种确定性聚类方法会造成分类边界附近的特征被错误的分类。通过直方图距离来度量相似性的方法只利用了一阶统计信息，丢失了其他信息。因此可以选用概率模型来估计特征的分布，同时一个分割区域内的相似性则由配对的特征块属于同一分布的概率之积来表示。

下一章的工作就是为验证这些改进方案而展开的。

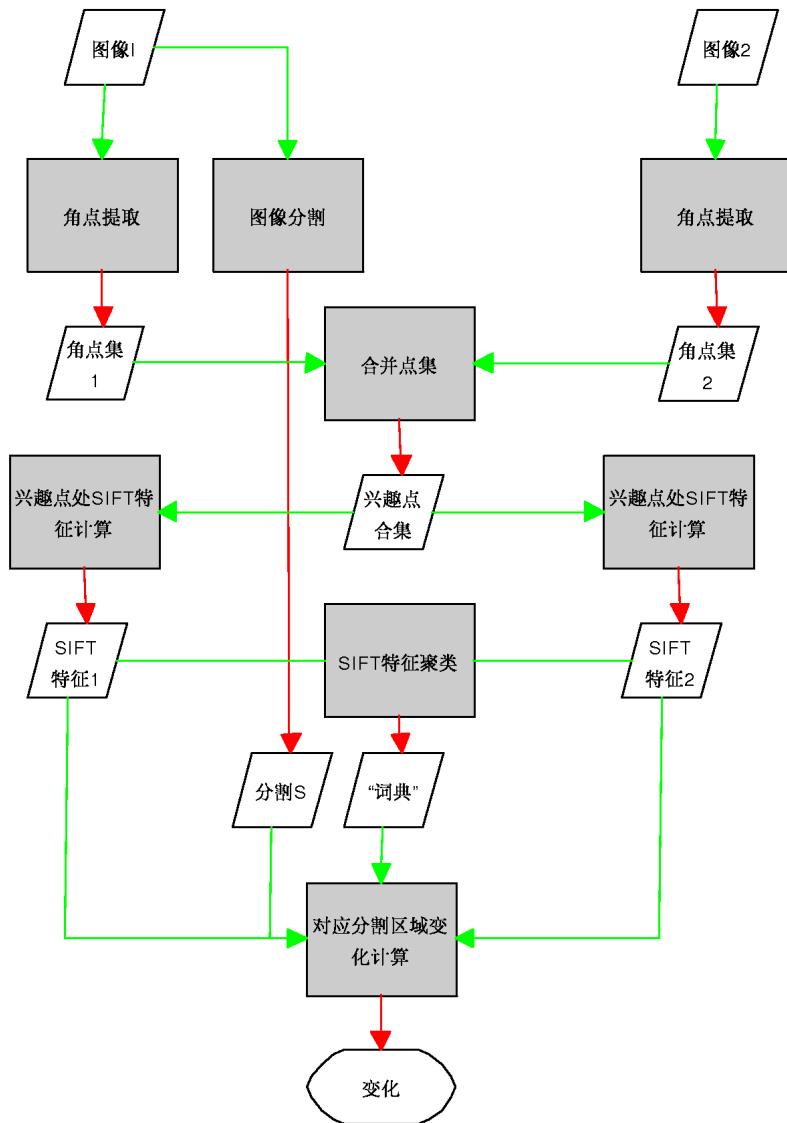


图 3-11 算法流程图

第四章 基于 MRF 模型的结构变化检测

4.1 引言

基于 MRF 模型进行变化检测已有一些研究 [3,7,21]。其中一些方法 [7,21] 利用图像的光谱信息进行像素级变化非变化的判别。对于高分辨率图像，在光照和视角变化影响下，这样的方法对于我们提到的表象变化的处理能力不足，不适于解决结构变化问题。还有方法 [3] 使用单一的结构特征（例如边缘线段密度）进行像素级变化判别。单一的特征往往对于部分的结构表达能力不足，融合多种特征有利于结合各特征的优势，更精确的描述区域结构。同时这些基于像素的方法对图像的配准要求较高，制约了高分辨率遥感图像的实际应用。我们要提出的方法的意义在于：将 MRF 模型应用于高分辨率遥感图像的结构变化检测；定义了一种融合多特征的、反映高分辨率图像中结构变化信息的数据项。

本章将介绍一种新的基于 MRF 模型（Markov Random Field）的结构变化检测计算框架。方法的主要思想是将图像对中的对应的时空区域看成随机场中的一个基元（Site）——“格子¹”（Grid），通过最大后验概率（MAP, maximum a posteriori）推断格子的标签值——变化/无变化。我们首先定义表征变化/无变化的条件概率密度函数。这个条件概率密度（数据项）是基于形状和外观特征的直方图距离的。条件概率分布的参数是通过有监督的学习得到。外观不变量特征与第 3 章相似，而形状特征描述的是场景中一个格子内的结构组织。我们的先验项是一个 Gibbs 模型，定义了相邻格子的标签值满足平滑性约束。

本章的内容组织如下：4.1 节引言，介绍方法的主要思想，列出章节组织；4.2 节简单回顾了一下 MRF 模型；4.3 节着重介绍我们的模型、数据项、先验项；4.4 节主要介绍 ICM 优化方法；4.5 节中我们给出实验的结果分析；4.6 节总结，讨论了本章提出的方法的优点和不足，提出下一步的改进。

4.2 MRF 模型回顾

由于能刻画随机变量间的相互影响，马尔可夫随机场理论为时间、空间相关的过程建模提供了一个方便有效的方法。它被大量用于计算机视觉和图像处

¹本章中出现格子和格子对两个术语。格子一般指随机场中的基元，但也可以是图像中的块，根据上下文可以确定；格子对就是指图像对中对应的图像块。

理问题 [26]。

我们先约定一些记号，然后以图像问题为例子简单介绍 MRF。我们记被研究的对象由许多的基元组成，我们为每一个基元设定一个标号，这些标号的集合记为 S ，假设有一个有 m 个基元的对象

$$S = \{1, \dots, m\} \quad (4-1)$$

定义 N_i 表示基元 i 的邻域，邻域有如下的性质：

- ① 一个基元不属于它自己的邻域： $i \notin N_i$ ；
- ② 邻域关系是可以互换的： $i \in N_{i'} \iff i' \in N_i$ 。

对于规则的格子组成的集合 S ， i 的邻域可以定义为在半径 r 内的基元

$$N_i = \{i' \in S \mid \|x_{i'}, x_i\| \leq r, i' \neq i\} \quad (4-2)$$

其中 x_i 为基元 i 在度量空间的坐标， $\|\cdot, \cdot\|$ 表示定义的空间距离， r 取整型值，表示邻域系统的阶数。那么在边界上的基元的邻域点要少一些。所有点的邻域组成了邻域系统，

$$N = \{N_i \mid \forall i \in S\} \quad (4-3)$$

这里我们只讨论一阶邻域系统。 (S, N) 构成一个关系图，在这个关系图上我们再定义团块（clique）。它可以是单个基元，也可以是邻域内的一对基元，或者是邻域内的三个不同基元，等等。我们分别记为 $C_1, C_2, C_3, \dots, C = C_1 \cup C_2 \cup C_3 \dots$ 表示团块系统。

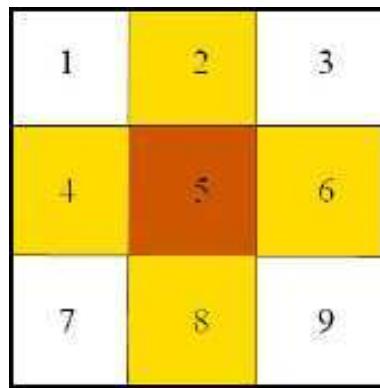


图 4-1 邻域、团块示意图。 $s = 5$ ，邻域 $N_s = \{2, 4, 6, 8\}$ ， $C_1 = \{5\}$ ， $C_2 = \{(5, 2), (5, 4), (5, 6), (5, 8)\}$

马尔可夫随机场理论下，图像被视为定义在 S 上的一个随机变量集 $L = \{L_1, \dots, L_m\}$ ，其中每一个随机变量 L_i 的取值 l_i 属于一个给定集合。我们

用 $L_i = l_i$ 表示随机变量 L_i 取 l_i 的事件。 $(L_1 = l_1, \dots, L_m = l_m)$ 表示联合事件。 $P(L_i = l_i)$ 记为事件 $L_i = l_i$ 的概率，缩写为 $P(l_i)$ ，记 $P(L = l) = P(L_1 = l_1, \dots, L_m = l_m)$ ，缩写为 $P(l)$ 。那么满足下面条件的 L 被成为马尔可夫随机场，

$$P(l) > 0, \forall l \in \mathbb{L} \quad (4-4)$$

$$P(l_i | l_{S - \{i\}}) = P(l_i | l_{N_i}) \quad (4-5)$$

其中 \mathbb{L} 为所有可能的 l 组成的空间；对于我们的两类分类问题，可以记 $l_i \in \{0, 1\}$ 。 $S - \{i\}$ 为集合的差。这组公式表明马尔可夫性，即无后效性在空间中的作用形式。基元通过邻域系统来与周围发生关联，这种空间上局部的条件转移概率最终会决定全局的概率分布。

如前面讨论的，马尔可随机场可以描述为一个关于图像局部性质的场。它概念很直观，我们容易理解。但是局部的转移概率的确定是一个制约它的大问题。但是有了吉布斯随机场（Gibbs Random Field, GRF）问题就迎刃而解了。吉布斯随机场是一个关于全局性质的随机场，Hammersley 等多人证明了吉布斯随机场和马尔可夫随机场的等价性，因此使得我们可以在贝叶斯估计计算框架下进行图像问题的处理 [15, 17, 25, 26]。

建立在 (S, N) 上的随机场 L 满足吉布斯分布时被称为吉布斯随机场。

$$P(l) = \frac{1}{Z} e^{-\frac{1}{T} E(l)} \quad (4-6)$$

Z 是归一化因子， T 是温度常量， E 就是能量函数，它是所有团块的能量和 $E(l) = \sum_{c \in C} V_c(l)$ ， V_c 是定义在团块 c 上的势能函数。假设两阶团块系统已足够，我们有：

$$E(l) = \sum_{\{i\} \in C_1} V_1(l_i) + \alpha \sum_{\{i, j\} \in C_2} V_2(l_i, l_j) \quad (4-7)$$

这样问题转化为了求全局能量的问题，虽然概念上不够直接，但是计算直接。有了这个工具，我们就能很方便的在贝叶斯估计计算框架下对图像问题进行处理。

根据贝叶斯定律，我们知道

$$P(l, \mathbf{X}) = P(l|\mathbf{X})P(\mathbf{X}) = P(l)P(\mathbf{X}|l) \quad (4-8)$$

这里 \mathbf{X} 是观测变量。由于 Gibbs-MRF 的等价性，上面的等式可以重新记为：

$$\begin{aligned} P(l) \equiv P(l|\mathbf{X}) &= \frac{1}{Z} \exp\left(-\frac{1}{T}(E_1(\mathbf{X}, l) + \alpha E_2(l))\right) \\ &= \frac{1}{Z} \exp\left(-\frac{1}{T}\left(\sum_{\{i\} \in C_1} V_1(X_i, l_i) + \alpha \sum_{\{i,j\} \in C_2} V_2(l_j, l_i)\right)\right) \end{aligned} \quad (4-9)$$

其中 Z 是归一化常量， α 是控制平滑强度的常数， $E_1(\mathbf{X}, l)$ 是似然能量项，描述数据本身的概率分布，或称为数据项。最大化 $P(l)$ 等价于最小化总能量 $E = \sum_i V_1(i) + \sum_i \sum_j V_2(i, j)$ 。因此在 MAP 框架下，我们能得到最优的估计值 \hat{l} ：

$$\hat{l} = \arg \min_l \left(\sum_i V_1(i) + \alpha \sum_i \sum_j V_2(i, j) \right) \quad (4-10)$$

4.3 模型

我们将输入图像对 I^1 和 I^2 规则的分为 $N \times N$ 的格子。每个格子对的标签 $l_i \in \{0, 1\}$ 作为随机场的基元。我们赋予每个标签结构变化的语义，即可最后获得图像的结构变化检测值，其中 1 表示没有结构变化，0 表示发生结构变化。获得了 m 维观测数据向量 \mathbf{X} 后，现在我们需要定义整个图像上的结构变化/无变化概率 $P(l|\mathbf{X})$ 的能量函数 E 。

4.3.1 先验知识项

我们通过 Potts 模型来定义先验知识项

$$V_2(i, j) = \sum_{j \in N_i} (l_i - l_j)^2 \quad (4-11)$$

其中 N_i 是基元 i 的一阶邻域。此先验知识项将对 l 加上平滑约束：相邻的标签值应当相似。

4.3.2 数据项

此数据项是基元变化/无变化概率的函数。我们假设基元变化/无变化概率由图像局部提取的特征决定，并且独立同分布。若 $p_n(X_i)$ 为无结构变化的概率， $p_c(X_i)$ 为有结构变化的概率，我们有：

$$V_1(X_i, l_i) = -\ln(p_n(X_i)^{l_i} + p_c(X_i)^{1-l_i} - 1) \quad (4-12)$$

其中 l_i 是分配给基元 i 的标签值。当观测的特征更倾向于有结构变化时，即 $p_c(X_i) > p_n(X_i)$ ，若 $l_i = 0$ （有结构变化），则使得能量较小，模型得到的概率是有结构变化概率；反之当观测的特征更倾向于无结构变化时，即 $p_n(X_i) > p_c(X_i)$ ，若 $l_i = 1$ （无结构变化），才使得能量较小，模型得到的概率是无结构变化概率。

观察数据 X 为从两幅图像计算得的形状和外观特征，分别记为 S 和 A ，它们相互独立。另外我们假设每个格子的特征的分布是独立同分布的。格子对 i 的结构变化概率 $p_c(X_i) = p_c(A_i, S_i) = p_c^A(A_i)p_c^S(S_i)$ ，其中 $p_c^A(A_i)$ 为外观变化概率， $p_c^S(S_i)$ 为形状变化概率；而无结构变化概率 $p_n(X_i) = p_n^A(A_i)p_n^S(S_i)$ ，其中 $p_n^A(A_i)$ 为外观无变化概率， $p_n^S(S_i)$ 为形状无变化概率。

4.3.2.1 外观特征分布

外观特征 A 定义为格子对中 SIFT 特征类型直方图的 χ^2 距离。具体见第 3 章。经过对 A 统计（图 3-5），我们注意到 A 近似服从 Γ 分布。那么我们假设存在结构变化的 A 服从分布 $p(A|a_c, b_c)$ ，而不存在结构变化的 A 服从分布 $p(A|a_n, b_n)$ ：

$$p_c^A(A|a_c, b_c) = \frac{1}{b_c^{a_c} \Gamma(a_c)} X^{a_c-1} \exp\left(-\frac{X}{b_c}\right) \quad (4-13)$$

$$p_n^A(A|a_n, b_n) = \frac{1}{b_n^{a_n} \Gamma(a_n)} X^{a_n-1} \exp\left(-\frac{X}{b_n}\right) \quad (4-14)$$

其中 $\Gamma(\cdot)$ 伽玛函数， a, b 为 Γ 分布的参数，下标 c, n 分别表示变化和无变化。参数通过监督学习得到：在计算得到所有的变化格子和无变化格子的特征 A 后，我们使用最小平方误差估计求概率分布的参数。

在 SIFT 特征块的直方图计算上，与上一章相比，兴趣点的选择上有一些不同。原因是考虑角点由于图像配准的误差以及视角变化等因素的影响，在对应两个格子的坐标可以有可接受的位移。其策略是：统计每个格子的角点数量，以格子对 (G_i^1, G_i^2) 中角点数量多的格子的角点集为主角点集（我们假设格子 G_i^1 的角点集 S_i^1 为主角点集）；主角点集 S_i^1 中的点在角点集 S_i^2 的对应点可以有一定的位移误差；匹配按照坐标最邻近的准则进行；对于失配情况则直接将该点投影到 S_i^2 中；最后删除匹配半径内所有待匹配的点，进入下一对角点匹配步骤中；如果主角点集的点均匹配完成而副点集仍然有角点，则转换主副角点集，直到没有待匹配点。这里我们不再对无结构区域生成随机点，如果这里的匹配点数小于给定的阈值 T_{nkeypt} ，我们认为该区域为无结构区域且无变化。

4.3.2.2 形状特征分布

形状变化/不变概率是基于直线长度加权的离散化直线段方向角直方图¹的。具体的说，每个格子的 S 定义为图像 I^1 和 I^2 中对应区域

¹ 为简单起见后面一律简称“直线段方向直方图”

内的直线段方向直方图的 EMD 距离 (Earth Moving Distance) [36]: $S = EMD(hist^1, hist^2)$ 。形状特征概率分布函数也定义为 Γ 分布概率密度函数 (图 3-5)。同样使用监督学习的方法得到参数。

要计算直线段方向直方图, 首先利用算法 3-1 分别计算两幅图像 I^1 和 I^2 的直线段。将每个格子内的直线段按其方向角生成直线段长度加权的离散化方向角直方图, 直方图有 8 个柱, 见图 4-2。为了降低直线段方向角量化截断的影响, 直线段能对夹着它的两条中心线所在的柱产生贡献。我们定义格子内直线段方向直方图第 k 柱为

$$hist(k) = \frac{8}{\pi} \sum_{h \in L_k} l_h \left| \frac{\pi}{8} - \alpha_h \right| \quad (4-15)$$

其中 L_k 是所有与第 k 柱中心线夹角小于给定角度的 (这里设为 $\frac{\pi}{8}$) 的所有直线段组成的集合, α_h, l_h 分别为集合中第 h 条直线段与第 k 柱中心线夹角和直线段的长度。我们将非直线的像素也进行统计, 保证格子对的直线段方向直方图具有相同的和。这样我们的直方图有 9 个柱。

EMD 距离计算时, 需要自定义一个代价矩阵。我们考虑直线段也会由于视角或者配准原因发生角度差异, 那么我们定义直线段从属于一个柱变化为属于另外的柱的代价应当与这两个柱的角度差成正比。另外如果原来不存在的直线段出现或者存在的直线段消失表明结构变化很明显, 那么 EMD 距离应当大, 因此对应代价必然最大, 所以我们定义这样的最大代价为 5。直线段方向角改变使得所属柱发生变化从而产生的代价, 根据变化前后所属柱的角度差由小到

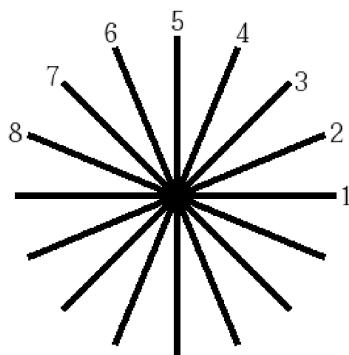


图 4-2 角度量化带的中心线示意图

大的顺序，依次设定为 1, 2, 3, 4。同样当格子对 i 内直线段数量均低于给定阈值 T_{nline} 并且直线段平均长度也都低于给定阈值 T_{len} ，那么我们认为该区域为无结构区域且无变化。无变化的无结构区域的标签值为 0。

4.4 问题求解

基于贝叶斯框架的 MRF 求解通常有：模拟退火 SA (Simulated Annealing)，迭代条件模 ICM (Iterated Conditional Modes)，最高置信度优先 HCF (Highest Confidence First) 和图割 (Graph Cut) 等等算法。ICM 算法计算量较小，没有较复杂的操作，适合通过计算机来实现，因而使用较多，我们这里也采用这种算法。

ICM 算法是由 Besag [4] 提出，可以替代 Gibbs 采样器，用于计算最大化后验分布函数。ICM 算法是采用逐个像素的扫描方式，根据条件分布逐点对图像进行估计。

假定二维随机场的大小为 $M \times N$ ，ICM 算法的步骤如下：

- 1 对要计算的随机场每一基元的状态进行初始化，状态记为 ω_0 ，取迭代计数值 $k = 0$
- 2 从基元 1 到基元 MN，计算每个基元在取不同的状态值时的局部能量
- 3 比较每个点取不同状态的局部能量值，选择能够使局部能量达到最小的状态作为该点的当前状态值
- 4 重复步骤 2~3，直到收敛

算法 4-1: ICM 算法

我们根据式 4-12 初始化能量函数。迭代时等概率的生成基元标签 $l_i \in \{0, 1\}$ ，如果该标签值能减小能量值即接受。

标准 ICM 算法要求每一个基元的状态标签值都不再变化时，才算是达到收敛状态。但实验表明这一标准太苛刻，往往会带来冗余的迭代次数。因此，可以选用其他标准作为迭代的收敛条件：

- ① 使用全局能量函数的相对变化量作为判断依据。在当前的迭代得到的结果与上一次迭代结果的差与当前能量的比值小于给定值时，停止迭代。
- ② 使用固定的迭代次数 N_i 。当整幅图的扫描次数达到 N_i 时，终止迭代。

4.5 实验结果与分析

4.5.1 参数估计和实验设定

我们设置图像中格子大小为 $N = 128$, 图像被分成 $13 \times 11 = 143$ 个格子。设置匹配点阈值 $T_{nkeypt} = 9$, 直线段数量阈值和直线段平均长度阈值 $T_{nline} = 9, T_{len} = 15$ 。控制先验项的 α (式 4-9) 取值为 0.04。随机场状态初始化为 $\omega_0 = \mathbf{0}$ 。我们设 ICM 当前的迭代次数得到的结果与上一次迭代结果的差与当前能量的比值小于 0.01, 或者迭代次数超过 5000 次终止。

人工标定一个结构变化二值图作为真实变化图, 见图 4.5(a)。根据该二值图, 将图像格子对分为两组集合, 无结构变化格子对集 G_n 和有结构变化的格子对集 G_c 。利用这两个集合分别训练外观特征变化/无变化概率参数 $(a_c^A, b_c^A), (a_n^A, b_n^A)$ 和形状特征变化/无变化概率的参数 $(a_c^S, b_c^S), (a_n^S, b_n^S)$ (见式 4-13, 4-13)。特征分布和拟合的概率分布曲线如图 4-3 所示。

由拟合得到:

$$(a_c^A, b_c^A) = (2.8114, 0.2129), (a_n^A, b_n^A) = (3.4872, 0.1718)$$

$$(a_c^S, b_c^S) = (2.1329, 0.0273), (a_n^S, b_n^S) = (1.5648, 0.0394)$$

4.5.2 结果分析

我们得到的匹配的角度对如图 4-4 所示, 我们得到的结果有较好的匹配, 但是所得到的角度对数量太少, 对外观特征的精确度造成影响。

为了理清外观特征和形状特征关联性和互补性, 我们的实验分三步进行: 1) 仅使用外观特征, 即设形状特征变化/无变化概率 $p_c^S(S_i) = 1, p_n^S(S_i) = 1$, 利用我们定义的模型计算变化标签向量值; 2) 仅使用形状特征, 即设外观特征变化/无变化概率 $p_c^A(A_i) = 1, p_n^A(A_i) = 1$, 计算变化标签向量值; 3) 结合形状和外观特征计算变化标签向量值。得到的结果如图 4-5 和表 4-1 所示。

我们将单独利用一种特征计算得的结构变化二值图像叠加得到了图 4.5(d)。这里我们可以看到, 形状和外观特征具有一定的互补性 (反映为不一致的分类判断结果), 那么融合特征信息是有意义的。同样从中我们还可以看到一些错误的分类, 那么这些错误分类一部分可以通过加入平滑约束消除, 而另一部分则是由于特征的局限造成, 平滑约束将无能为力。

融合两特征后, 我们可以发现分类结果不比单独使用形状特征好, 造成这

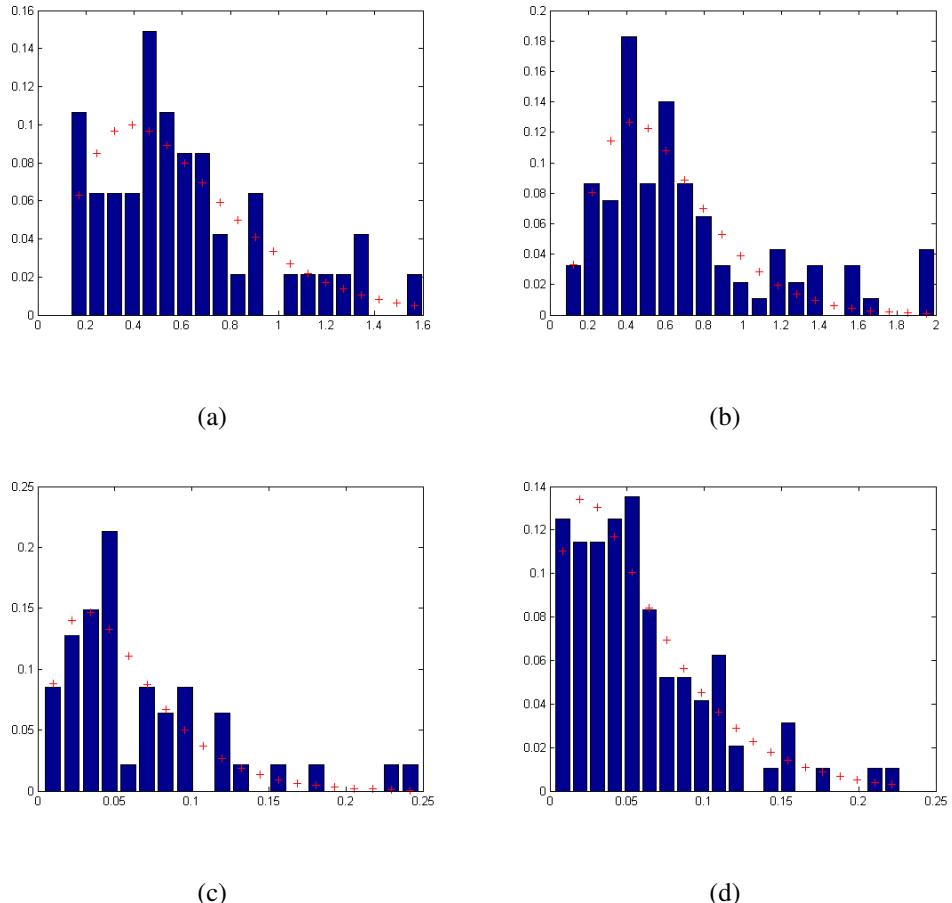


图 4-3 特征分布和拟合的概率分布曲线图: (a): 外观特征变化概率分布, (b): 外观特征无变化概率分布, (c): 形状特征变化概率分布, (d): 形状特征无变化概率分布。条柱表示特征分布直方图, “+”表示拟合的分布曲线。

能量函数的类型	仅使用外观特征信息	仅使用形状特征信息	结合两特征信息
错误分类数	64	49	55
错误分类率	44.7%	34.2%	%38.4

表 4-1 不同能量项下的变化检测结果统计

种结果的原因有两层：1)一方面由于特征变化/无变化概率分布参数的训练集过小，参数并不能反映特征变化/无变化概率分布；2)一方面由于模型中特征的融合是通过概率的直接乘积实现，两个特征其中任意一个的错误判断都会影响最后的判断。

实验中，平滑约束设置较小，我们发现如果增大平滑约束实验结果中错误率会增加，这是由于我们计算得的特征变化/无变化概率均太小，并且其参数差异不大，分布存在较大重叠区域。

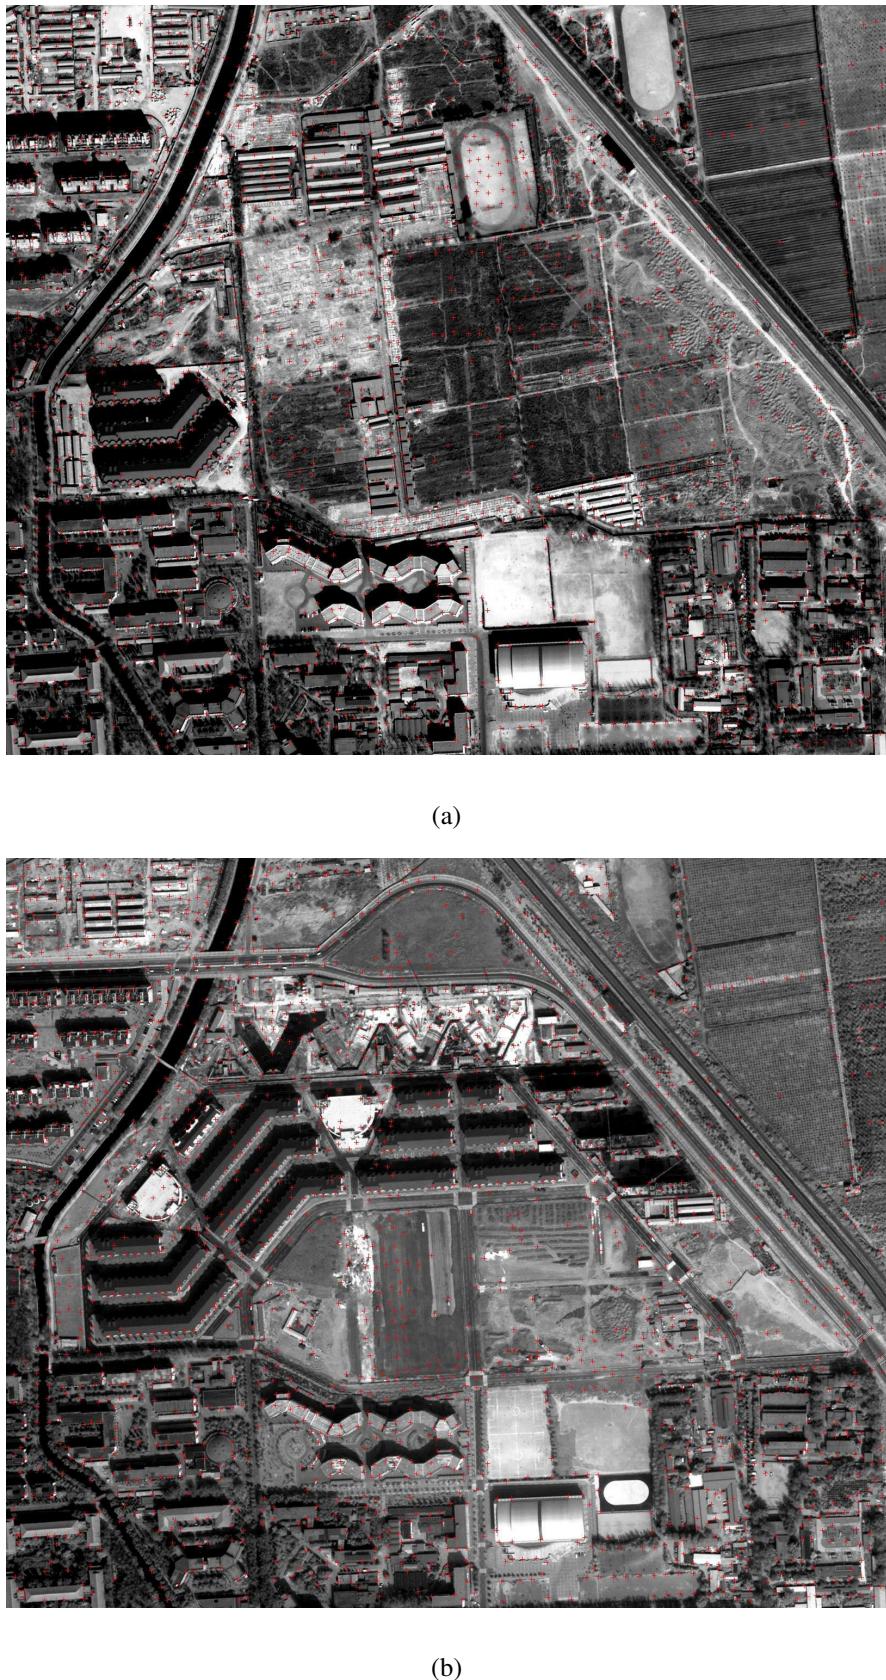


图 4-4 匹配成对的角点: (a) 2002 年数据, (b) 2003 年数据。

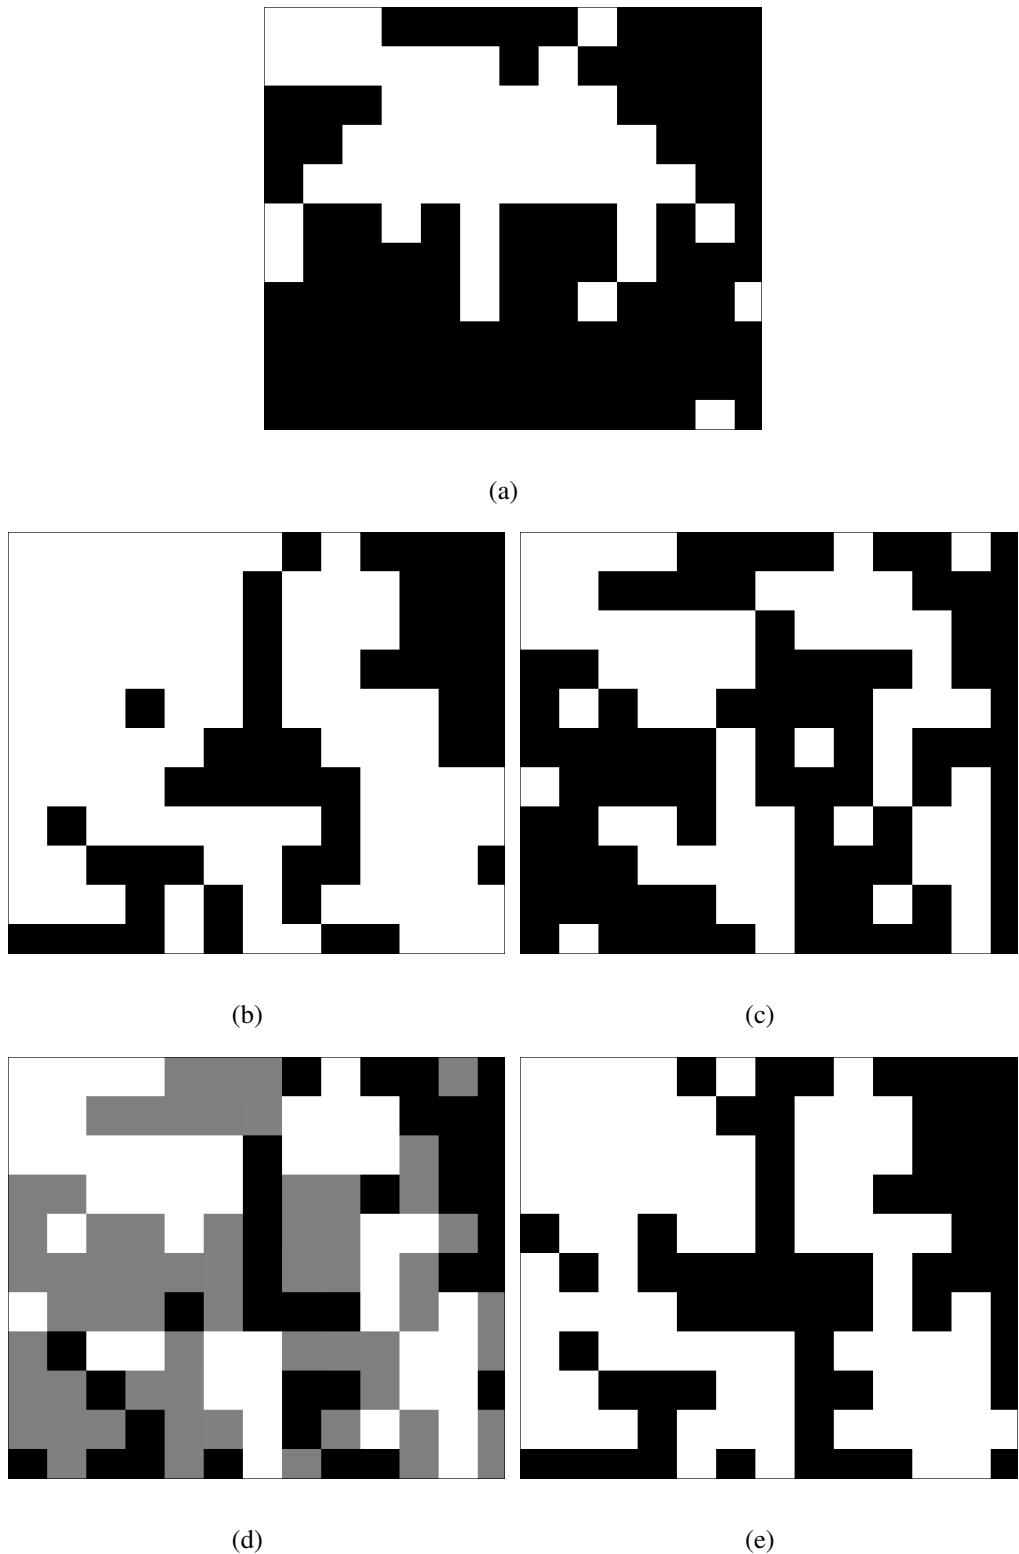


图 4-5 真实结构变化二值图与实验计算得到的结构变化二值图: (a): 真实结构变化二值图, (b): 仅利用外观特征的结构变化二值图, (c): 仅利用形状特征的结构变化二值图, (d): 将(b)、(c)叠加得到的变化图, (e): 结合形状、外观特征的结构变化二值图。灰度表示不同的标签值: 黑色表示没有变化, 白色表示发生变化, 灰色表示两特征分类不一致。

4.6 小结

这一章细致的介绍了我们提出的一种基于 MRF 模型的结构变化检测方法，并展示了初步的实验结果。这个方法的创新性在于：提出了一个基于概率模型、融合多种特征信息的结构变化检测计算框架；两幅图像对应的图像块的变化/无变化概率可以由两种具有一定互补性的结构特征——外观特征和形状特征——变化/无变化概率表征；特征的变化/无变化概率的参数可以通过有监督的学习得到。

虽然我们得到的初步结果并不能让人满意，但是我们也应该看到这个模型本身蕴涵的巨大潜力。一方面概率模型处理这种复杂图像最自然的模型，因为它能很好的对噪声的影响进行建模；另外一方面对于先验知识以及多特征的融合也很容易表达。

通过对实验结果的分析可知上一章中存在的问题有些仍然存在，另外新的问题也伴随新的方法出现。这里我们主要讨论新的视角下的改进：

- ① 特征变化/无变化参数估计。用于训练的数据并不具有代表性，并且样本数量少，这样训练得的参数并不反映真实的分布。可以通过选择强特征数据作为训练集，学习的参数具有普适性。
- ② 模型。当前我们的模型是通过求特征变化/无变化概率乘积来实现信息融合的。一个更合适的方法是“投票”的办法来决定最后的标签值。
- ③ 优化方法。我们选用的 ICM 算法是一种确定性过程算法，在算法的每一步迭代过程中寻找使局部能量函数达到最小值的解。因此，ICM 算法具有很快的收敛速度。但是 ICM 算法由于只搜索单一趋势的干扰，算法可能陷入局部极小值。如果能预先得到粗略的变化的范围，以此来初始化状态值，能得到较好的结果。而这个变化范围可以由特征本身大概给出。

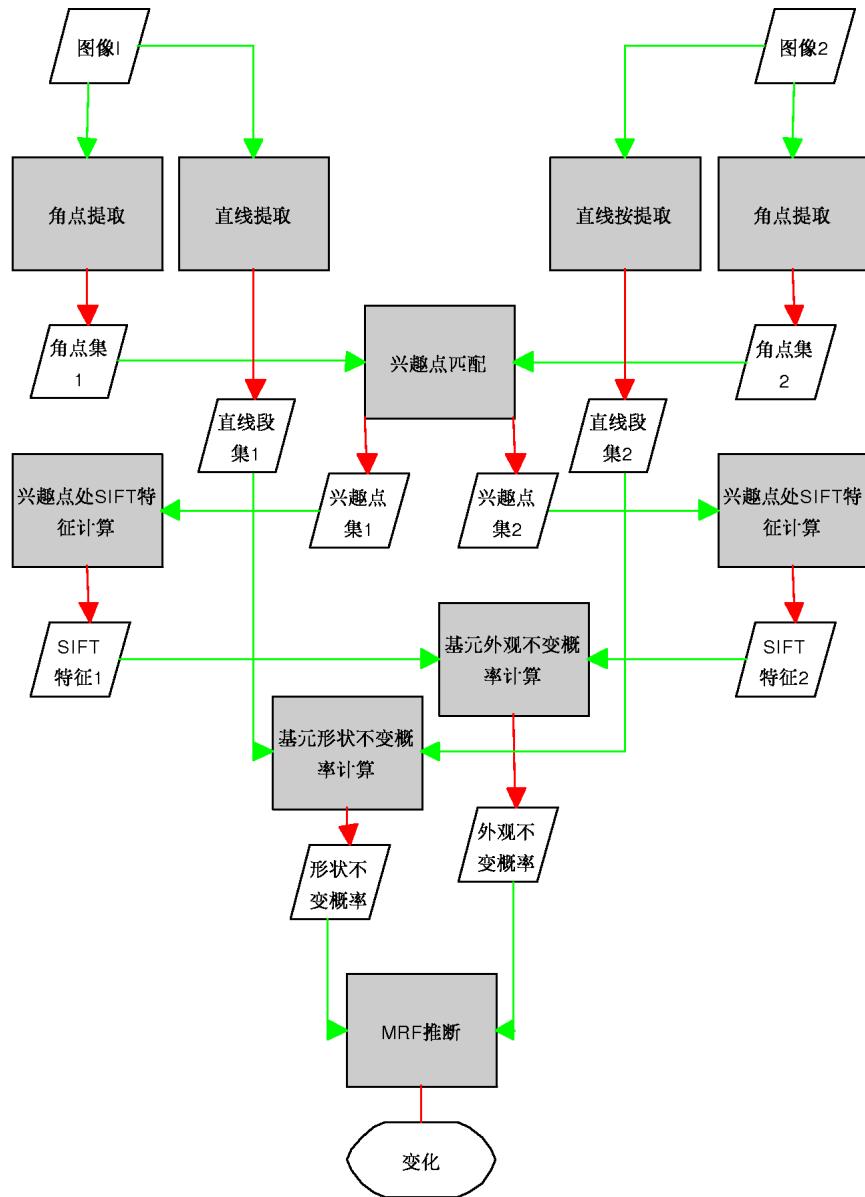


图 4-6 算法流程图

第五章 结束语

本章我们将对本文的工作及主要贡献进行总结，并对下一步的工作进行展望。

5.1 本文主要工作

本文在对以前遥感图像中变化检测技术的分析和总结的基础上，以高分辨率 Quickbird 卫星图像数据为实验数据，围绕城区结构变化检测与理解这一主题进行了研究。本文主要工作及贡献如下：

① 提出了基于直线关系图 Ncut 割的图像分割算法

本文提出了一种建立在结构物体边缘直线段提取和直线段关系图割基础上，将图像分割为结构一致区域的算法。在这种算法中，我们提出了描述图像结构的直线段关系权准则，给出了 Ncut 算法迭代的停止准则，并建立了分割评判的标准。由于我们的分割是直接基于直线关系的，所以在结构丰富的区域分割可以得到好的效果，而在空旷无结构的区域则不能分割出较完整的无结构区。

② 提出了基于外观不变量的变化检测算法

我们提出了一种基于类 SIFT 外观不变量类型直方图距离的高分辨率遥感图像的变化检测算法。此算法的主要思想是现实世界中的一个场景可以由有限个特定类型的图像局部外观特征描述，而这种局部外观特征具有不受图像的获取条件影响的性质；如果一个场景中存在变化，那么会表现为外观特征类型统计量的不同。通过实例可以看到这种算法对能够“识别”结构变化，不受非结构变化的影响。

③ 提出了基于 MRF 模型的变化检测算法

以基于外观不变量的变化检测算法为部分基础，我们又提出了融合形状变化描述子，基于 MRF 模型的变化检测算法。此算法是为了融合更多关于结构变化信息项而提出的计算框架，以提高变化检测的计算能力。MRF 模型可以整合变化场内在的性质和每个基元相互间的影响。由于与 GRF 等价，这些概率函数定义又可以转化为一个能量函数的定义，因而实现多种信息融合的能量很强。我们在实验图像上进行试验并获得了

初步的实验结果，充分展示了这种算法的潜力和优势，为今后的工作奠定了基础。

5.2 未来工作展望

本文提出的一种以结构一致性为评价准则的图像分割方法和两种结构变化检测方法，都展示出了巨大的潜力，也为今后的工作打下了良好的基础。未来的工作可以从如下方面展开：

① 基于直线关系图 Ncut 割的图像分割算法的改进

由于算法依赖于有效的直线段检测，改进边界和突脊检测，减少断裂的线段和漏检的线段将有利于提升整个算法的性能。并且我们的在关联权值函数较为简单，无法包含诸如构成物体的轮廓线这样的信息。因此我们希望在关联权值函数中加入 Gestalt 关系的描述，比如闭合（Closure），更精细化该函数的描述能力。由于我们的分割算法对于无结构区域表现出的缺陷，需要加入纹理信息进行分割，以弥补直线段描述段不足。

② 基于外观不变量的变化检测算法的改进

针对算法的局限性，改进可以在算法的每一层进行：更精确地合并来自两个图像的两组Harris角点，将来自一幅图像的角点配准到另一幅图像；加入多尺度的特征描述子；改进聚类方法；寻找更精巧的基于概率模型统计值来测量一个分割区域的结构水平或者对应的两个区域的结构变化。

③ 基于 MRF 模型的变化检测算法改进

通过第 4 章最后的实验分析可知，我们提出的算法还有一定局限性，目前还无法在真实图像试验中取得很好的实验结果。但是，我们也应该看到这个模型本身蕴涵的巨大潜力，在今后的工作中，我们可以就其局限性研究相应的对策，对模型加以改进。

④ 算法中学习的改进

实验中特征学习和分布参数估计的数据集太小，为解决随之带来的问题，我们未来应当利用更多的数据进行训练和学习。

附录 A 图像数据介绍

1.1 数据简介

本文中使用 Quickbird 卫星图像作为实验数据。Quickbird 卫星是由 Ball 航天技术公司、柯达公司和 Fokker 空间公司联合研制，并于 2001 年 10 月 18 日通过美国 DigitalGlobe 公司成功发射的。它是目前世界上空间分辨率最高的商用卫星，其突出的优越性表现在：全色分辨率可达 0.6 米，多光谱分辨率可达 2.44 米，是同类卫星 Ikonos 的 1.63 倍；多光谱有红、绿、蓝、近红外四个波段，与 Ikonos 相同；图像幅宽 16.5 千米，是 Ikonos 的 1.5 倍；在没有地面控制点的情况下，地面定位圆误差精度可达 23 米；采用 11 比特/秒数据格式，增加了灰度级数，减少了阴影部分信息的损失。有关 Quickbird 卫星参数如表 A-1 所示。与同期光学卫星图像及航拍图像相比，Quickbird 卫星图像具有以下应用优势：

- ① 空间分辨率高。最明显的优势即在于此，以往只有航空遥感才可获取的高分辨率影像，现在通过卫星也可取得与航片相媲美的空间数据。以往卫星遥感数据成图最大比例尺大约为 1:25000（如 SPOT 数据），而 Ikonos 卫星数据最大成图比例尺可达 1:2500，Quickbird 卫星数据将更高，能达 1:1500~1:2000。这种大比例尺的图像不仅能满足传统遥感用户的需求，也将满足如城市规划建设、地籍管理、地震和洪水应急救灾等要求大比例尺地图行业的需求。在传统遥感应用中，也将增加应用的深度，比如用 Landsat 或 SPOT 数据只能监测大面积作物生长趋势，很难细分小块作物的种类和长势，而 Quickbird 卫星等数据则很容易做到这一点，高分辨率数据将使解译工作变得简单。
- ② 不受地形条件的限制。对航空飞机难以到达的偏远山区、条件恶劣地区以及南极等遥远地区同样可获取数据。
- ③ 因空域管制严，航飞申请手续繁琐等原因，对小面积区域，如一个小镇、一个工业园区等，相对航拍数据获取而言，它更容易获得，并且数据更新更快。由于以上所示的优越性，目前 Quickbird 图像广泛应用于农作物检测与产量估计、测绘制图、环境监测、军事与国防等多个领域。

Quickbird卫星图像参数	
卫星发射时间	2001年10月18日
卫星轨道高度	450公里
卫星回访时间	1—3.5天（与纬度有关）
卫星轨道倾角	98° 太阳同步
卫星轨道周期	93.4分钟
辐照宽度	以星下点轨迹为中心，左右各272公里
成像方式	推扫式成像
星下点成像	沿轨/横轨迹方向（+/-25度）
立体成像	沿轨/横轨迹方向
每轨拍摄	约57景
图像分辨率和光谱特性	全色：61厘米到72厘米 灰度：445 990nm 多光谱：244厘米到288厘米 蓝：450 520nm (分辨率取决于成像角度) 绿：520 600 nm 红：630 690nm 近红外：760 900nm
成像幅宽	16.5公里 × 16.5公里
图像数据编码方式	11bits/s
定位精度	圆误差23m；线性误差17m（无地面控制点）

表 A-1 Quickbird卫星图像参数表

1.2 图像等级划分

根据后续处理程度的不同，Quickbird 图像大致可以划分为基本级、标准级、正射级三类图像 [14]

- ① 基本级图像：基本级图像在 Quickbird 图像中所经处理最少，它主要适于自身拥有高级图像处理设备或能力的用户。基本级图像与经纬度信息、星历表、照相机模型结合起来可用于高级影像处理（如正射纠正）。基本级图像经过了辐射校正与传感器校正，但未进行几何校正。其中辐射校正包括：不同传感器间相对辐射响应校正、对传感器未收集数据的区域充零以及相对辐射值到绝对辐射值的转换；传感器校正包括：内在传感器几何结构校正、光学校正、扫描校正、多光谱带之间的配准等。基本级全色图像在星下点的分辨率为 61cm，而在 25 度俯视角处大约为 72cm；基本级多光谱图像在星下点的分辨率为 2.44m，而在 25 度俯视角处大约为 2.88m。由于它是处于参考坐标系下而非地面坐标系，因而它在几何上属于无确定精度的裸数据。单幅全色基本图像大小为 27552×27424 ；单幅多光谱图像大小为 6856×6888 。所覆盖的面积大致为 272km。
- ② 标准级图像：标准级图像用于需要较高定位精度或较大覆盖面积的场合。这种场合下的用户一般能够使用比较充足的图像处理工具将该级别卫星图像应用到各种场合去。标准级图像经过了辐射校正、传感器校正、几何校正三个层次的处理，且已投影到定制图坐标系中去。标准级图像的辐射校正与传感器校正跟基本级图像的一样，它的几何校正工作包括移除飞行器轨道位置与高度的不确定成分、地球自转、地表不均衡及全景失真等。其全色图像在星下点的分辨率为 60cm，而在 25 度俯视角处大约为 70cm；多光谱图像在星下点的分辨率为 2.4m，而在 25 度俯视角处大约为 2.8m。标准级图像的几何定位精度大约为 14m。其单幅图像大小及所覆盖地区的面积与基本级图像大致相仿。
- ③ 正射级图像：正射级图像已经被投影到地理信息系统坐标系中，可以作为基准图像进行广泛的应用。正射校正后的图像是进行地图或 GIS 数据的更新工作、现有特征层匹配的理想参考数据源。它也可用于变化检测及其他要求较高精度的分析应用场合。正射级图像除了进行标准级图像所要求的辐射、传感器、几何校正以外，还需要使用数字高程模型

(DEM) 与地面控制点 (GCP) 将图像上的每个像素都准确投影到区域地理坐标系中去。它与标准级图像的根本区别在于标准级图像使用一个粗略的 DEM 实现地图投影，而它使用的 DEM 精度很高。正射级图像的分辨率与标准级大致相同，但是其地理定位精度大大高于标准级图像定位精度且依赖于图像的最后尺寸。

参考文献

- [1] A. Agarwal and B. Triggs. Hyperfeatures-multilevel local coding for visual recognition. In Proc. British Machine Vision Conference, 2006.
- [2] P. Agouris, K. Beard, G. Mountrakis, et al. Capturing and modeling geographic object change: A spatiotemporal gazetteer framework. ISPRS Journal of Photogrammetry and Remote Sensing, 55(10):1241–1250, Oct. 2000.
- [3] C. Benedek and T. Sziranyi. Markovian framework for structural change detection with application on detecting built-in changes in airborne images. In Proc. (554) Signal Processing, Pattern Recognition, and Applications, Innsbruck, Austria, Feb. 2007.
- [4] J. Besag. On the statistical analysis of dirty pictures. Journal of the Royal Statistical Society, B48:259–302, 1986.
- [5] Y. Boykov and V. Kolmogorov. An experimental comparison of min-cut/max-flow algorithms for energy minimization in vision. IEEE Trans. Pattern Analysis and Machine Intelligence, 26(9):1124–1137, Sep. 2004.
- [6] Y. Boykov, O. Veksler, and R. Zabih. Fast approximate energy minimization via graph cuts. IEEE Trans. Pattern Analysis and Machine Intelligence, 23(11):1222–1239, Nov. 2001.
- [7] L. Bruzzone. Automatic analysis of the difference image for unsupervised change detection. IEEE Trans. Geoscience and Remote Sensing, 38(3):1171–1182, 2000.
- [8] L. Bruzzone and D. Fernandez. An adaptive parcel-based technique for unsupervised change detection. International Journal of Remote Sensing, 21(4):817–822, 2000.
- [9] L. Bruzzone and D. Fernandez Prieto. An mrf approach to unsupervised change detection. In Proc. International Conference on Image Processing, pages I:143–147, 1999.

- [10] J. Burns, A. Hanson, and E. Riseman. Extracting straight lines. *IEEE Trans. Pattern Analysis and Machine Intelligence*, 8(4):425–455, Jul. 1986.
- [11] M. Carlotto. Detection and analysis of change in remotely sensed imagery with application to wide area surveillance. *IEEE Trans. Geoscience and Remote Sensing*, 6(1):189–202, 1997.
- [12] L. Carvalho and L. Fonseca. Digital change detection with the aid of multiresolution wavelet analysis. *International Journal of Remote Sensing*, 22(18):3871–3876, 2001.
- [13] C. Dance, J. Willamowski, L. Fan, et al. Visual categorization with bags of keypoints. In *ECCV International Workshop on Statistical Learning in Computer Vision*, 2004.
- [14] Digital Global Inc. QuickBird Imagery Products—Product Guide, Dec. 2002.
- [15] S. Geman and D. Geman. Stochastic relaxation, gibbs distributions, and the bayesian restoration of images. *IEEE Trans. Pattern Analysis and Machine Intelligence*, 6:721–741, 1984.
- [16] L. Grady and E. Schwartz. Isoperimetric graph partitioning for image segmentation. *IEEE Trans. Pattern Analysis and Machine Intelligence*, 28(3):469–475, Mar. 2006.
- [17] J. Hammersley and P. Clifford. Markov field on finite graphs and lattices. Unpublished, 1971.
- [18] C. Harris and M. Stephens. A combined corner and edge detector. In *Alevy Vision Conference*, 1988.
- [19] G. Hazel. Object-level change detection in spectral imagery. *IEEE Trans. Geoscience and Remote Sensing*, 39(3):553–561, Mar. 2001.
- [20] F. Jurie and B. Triggs. Creating efficient codebooks for visual recognition. In *Proc. International Conference on Computer Vision*, pages 604–610, 2005.

- [21] T. Kasetkasem and P. Varshney. An image change detection algorithm based on markov random field models. *IEEE Trans. Geoscience and Remote Sensing*, 40(8):1815–1823, 2002.
- [22] Y. Kita. Change detection using joint intensity histogram. In Proc. International Conference on Pattern Recognition, pages 351–356, Washington, DC, USA, 2006.
- [23] V. Kolmogorov and R. Zabih. What energy functions can be minimized via graph cuts? *IEEE Trans. Pattern Analysis and Machine Intelligence*, 26(2):147–159, Feb. 2001.
- [24] S. Kumar and M. Hebert. Discriminative random fields: A discriminative framework for contextual interaction in classification. In Proc. International Conference on Computer Vision, 1988.
- [25] S. Li. *Markov Random Field Modeling in Computer Vision*. Springer-Verlag, London, UK, 1995.
- [26] S. Li. *Markov Random Field Modeling in Image Analysis*. Springer-Verlag New York, Inc., Secaucus, NJ, USA, 2001.
- [27] W. Li, X. Li, Y. Wu, et al. A novel framework for urban change detection using vhr satellite images. In Proc. International Conference on Pattern Recognition, 2006.
- [28] D. Lowe. Distinctive image features from scale-invariant keypoints. *International Journal of Computer Vision*, 60(2):91–110, 2004.
- [29] J. Malik, S. Belongie, T. Leung, et al. Contour and texture analysis for image segmentation. *International Journal of Computer Vision*, 43(1):7–27, Jun. 2001.
- [30] K. Mikolajczyk and C. Schmid. A performance evaluation of local descriptors. *IEEE Trans. Pattern Analysis and Machine Intelligence*, 27(10), Oct. 2005.
- [31] D. Nistér and H. Stewénius. Scalable recognition with a vocabulary tree. In Proc. International Conference on Computer Vision and Pattern Recognition, 2006.

- [32] E. Nowak, F. Jurie, and B. Triggs. Sampling strategies for bag-of-features image classification. In Proc. European Conference on Computer Vision, 2006.
- [33] F. O’Gorman and M. Clowes. Finding picture edges through collinearity of feature points. IEEE Trans. Computers, 25(4):449–456, 1976.
- [34] R. Radke, O. Andra, O. Al-Kofahi, et al. Image change detection algorithm: A systematic survey. IEEE Trans. Image Processing, 14(3):294–307, Mar. 2005.
- [35] J. Rogan and S. Yool. Mapping fire-induced vegetation depletion in the peloncillo mountains. International Journal of Remote Sensing, 22:3101–3121, 2001.
- [36] Y. Rubner, C. Tomasi, and L. Guibas. The earth mover’s distance as a metric for image retrieval. International Journal of Computer Vision, 40(2):99–121, 2000.
- [37] S. Sarkar and K. Boyer. Quantitative measures of change based on feature organisation: Eigenvalues and eigenvectors. Computer Vision and Image Understanding, 71(1):110–136, 1998.
- [38] S. Sarkar and P. Soundararajan. Supervised learning of large perceptual organization: Graph spectral partitioning and learning automata. IEEE Trans. Pattern Analysis and Machine Intelligence, 22(5):504–525, May 2000.
- [39] J. Shi and J. Malik. Normalized cuts and image segmentation. IEEE Trans. Pattern Analysis and Machine Intelligence, 22(8):888–905, 2000.
- [40] A. Singh. Digital change detection techniques using remotely-sensed data. International Journal of Remote Sensing, 10(6):989–1003, 1989.
- [41] J. Sivic and A. Zisserman. Video Google: A text retrieval approach to object matching in videos. In Proc. International Conference on Computer Vision, volume 2, pages 1470–1477, Oct. 2003.
- [42] W. Tldd. Urban and regional land use change detected by using landsat data. Journal of Research U.S.G.S, 5(5):529–534, 1997.
- [43] C. Unsalan and K. Boyer. Classifying land development in high-resolution panchromatic satellite images using straight-line statistics. IEEE Trans. Geoscience and Remote Sensing, 42:907–919, Apr. 2004.

- [44] C. Unsalan and K. Boyer. A theoretical and experimental investigation of graph theoretical measures for land development in satellite imagery. *IEEE Trans. Pattern Analysis and Machine Intelligence*, 27(4):575–589, Apr. 2005.
- [45] M. Varma and A. Zisserman. Classifying images of materials: Achieving viewpoint and illumination independence. In Proc. European Conference on Computer Vision, pages 255–271, 2002.
- [46] J. Zhang, M. Marszalek, S. Lazebnik, et al. Local features and kernels for classification of texture and object categories: An in-depth study. Technical report, Inria Research Report RR-5737, Oct. 2005.
- [47] 白笛暮. 基于先验知识和活动轮廓的变化分析：使用高分辨率遥感图像更新城区建筑数字地图的应用（英文）：[博士学位论文]. 北京：中国科学院自动化研究所, 2005.
- [48] 边肇祺、张学工等. 模式识别. 清华大学出版社, 北京, 2000.
- [49] 戴昌达, 姜小光, 唐伶俐. 遥感图像处理与应用. 清华大学出版社, 2004.
- [50] 李晓明, 郑链, 胡占义. 基于sift特征的遥感影像自动配准. *遥感学报*, 10(6):885–892, 2006.
- [51] 刘炜. 基于概率模型的高分辨率卫星图像建筑物识别及变化检测：[硕士学位论文]. 北京：中国科学院自动化研究所, 2005.
- [52] 彭文辉. 基于信息熵的合成孔径雷达图像水体变化检测：[硕士学位论文]. 北京：中国科学院自动化研究所, 2004.

个人简历及攻读硕士期间发表的论文

汤峰峰，男，汉族，中共党员，1982年10月17日出生于湖南衡阳，2000年毕业于湖北浠水第一中学，同年9月进入南京邮电学院电子工程系学习，并于2004年6月毕业，获工学学士学位。2004年9月至2005年6月，在中国科学院研究生院学习研究生基础课程。2005年6月至2007年6月在中国科学院自动化研究所模式识别国家重点实验室攻读硕士学位，主要研究方向为高分辨率遥感图像的变化检测与理解。

攻读硕士期间发表的论文：

1. V. Prinet, C. Cassisa, **FF Tang**, "MRF Modeling for Optical Flow Computation from Multi-structure Objects", In Proc. ICIP2006, Atlanta, oct. 2006.
2. **F. Tang**, V. Prinet, "Computing Invariants for Structural Change Detection in Urban Areas", In Proc. Urban2007, Paris, April 2007.

致 谢

在攻读硕士学位的三年里，自动化研究所和模式识别国家重点实验室、中法联合实验室为我的学习和科研工作提供了良好的环境和资助。在各位老师和同学的帮助下，研究工作得以顺利展开。在完成论文之际，我向研究所、实验室，向指导我和帮助我的老师和同学们致以最衷心的感谢。

首先感谢我的导师普林特。感谢她在研究生三年的学习和工作中，对我的指导、关怀和帮助。她对学术研究的严谨执着，对工作的认真负责都深深地影响了我。从她那我不仅获得了科学知识，还领悟了生活、工作的意义。总之她对我的教导将令我终生受益。

感谢马颂德研究员，卢汉清研究员，王蕴红教授，唐明副研究员对我论文的指导与帮助。

感谢我们组的段静辉、彭婷、白笛暮、何亮亮，尤其感谢毕胜和喜力，感谢他们对我的程序的贡献。

感谢模式识别国家重点实验室和中法联合实验室的各位老师和同学，是他们共同创造了一个良好的科研、学习氛围。

感谢自动化所的各位领导，感谢研究生部的各位老师，为我们提供学习、生活上的帮助。

最后我要感谢我的爸爸、妈妈和我的女朋友，感谢他们一直在背后支持着我，鼓励我前进。

2007年6月