

文章编号:1671-8860(2013)07-0799-06

文献标志码:A

# 面向灾害应急土地覆被分类的样本 自动选择方法研究

温奇<sup>1,2</sup> 夏列钢<sup>3</sup> 李苓苓<sup>1,2</sup> 吴玮<sup>1,2</sup>

(1 民政部国家减灾中心,北京市朝阳区广百东路6号院,100124)

(2 民政部减灾与应急工程重点实验室,北京市朝阳区广百东路6号院,100124)

(3 中国科学院遥感应用研究所,北京市海淀区邓庄南路9号,100101)

**摘要:**通过对自动化样本选择方法进行研究,实现了局部区域内面向对象的土地覆被自动分类。首先通过模糊聚类获得影像中的候选对象样本,分别提取影像特征和先验知识中的地类特征,通过预设阈值完成样本初步筛选,然后根据先验知识进行半监督距离度量学习,完成样本的自动选择,并为最终的监督分类提供度量依据。应用舟曲泥石流灾区影像进行了实验,结果表明,本文方法与基于人工选择样本的分类结果精度非常接近,同时在多次实验中表现出较高的稳定性,相对人工方法更加客观,适合批量自动化处理。

**关键词:**灾害应急;土地覆被分类;样本自动选择;特征提取;特征匹配

中图法分类号:P237.3

在重大自然灾害发生后,利用高空间分辨率遥感影像进行灾情解译和判读已成为应急救灾和灾后评估的有效手段。在汶川地震、玉树地震、舟曲泥石流灾害的灾后评估工作中,高空间分辨率遥感影像都发挥了很大的作用<sup>[1-2]</sup>。但对于影响范围较大的灾害,高空间分辨率遥感数据量大,人工目视解译往往需要花费较长的时间,而且解译结果一般具有较大的主观性,影响了灾情综合评估工作的时效性和精确度。采用面向对象的监督分类方法进行土地覆被自动分类,不但可以在很大程度上省时省力,还可以保证结果的客观性。尽管面向对象的监督分类效果较好,但典型样本人工选择的过程却制约了灾情解译的自动化应用,因此灾情评估应用中,土地覆被自动分类的关键是实现样本选择的自动化。

为了实现土地覆被自动分类,提高分类精度,很多学者在结合多源信息、改进分类方法等方面进行了深入研究<sup>[3-8]</sup>。从这些研究来看,大部分学者通过研究分类方法、地物特征等致力于提高分类精度,但很大程度上受人工选择样本的制约,很少能做到完全自动化。

在局部生态地理区域内,主要的土地覆被类

型具有较强的时空连贯性,地物特征基本保持不变,因此有可能主动学习这些不变的特征并加以利用,从待分类影像中自动选择合适的样本用于土地覆被监督分类<sup>[9]</sup>。本文基于以上考虑,提出了面向对象的样本自动选择方法,以满足面向灾害应急的土地覆被自动分类需求。

## 1 样本自动选择

针对高分辨率遥感影像灾情评估应用的实际需求,整体上采用面向对象的分类技术流程,其中核心内容为本文的样本自动选择方法,其流程如图1所示。

首先对待分类影像进行模糊聚类,将聚类结果对象块作为分类单元;然后从遥感影像及辅助数据中提取光谱、形状等地物特征,作为分类样本选择的依据,同时像素对于聚类块的模糊隶属度也是选择样本的依据;接着依据加权的特征隶属度关系进行样本筛选,并执行改进的距离度量学习方法,确定最后的分类样本;最后用该组分类样本执行SVM分类,得到分类结果图。其中,特征计算-样本筛选-距离度量学习的过程是本文样本

自动选择方法的核心内容,解决了从人工选择样本到自动筛选样本这一关键问题,其中还融入了针对

待分类区域的特点设计的类别库以及各地类的主要判别特征,这些设计依赖于少量的先验知识。

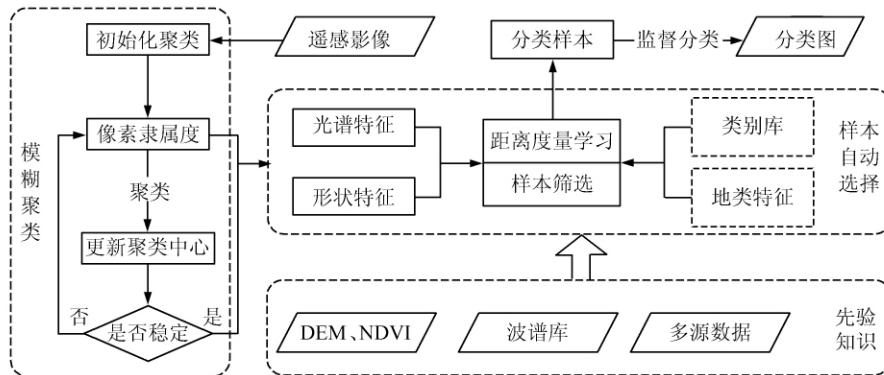


图1 基于自动样本选择的土地覆被分类流程

Fig. 1 Flowchart of Land Cover Classification Based on Automatically Samples Selection

### 1.1 模糊聚类

本文采用模糊聚类方法从影像中提取分类对象,而不是通常所用的多尺度分割方法,主要基于以下考虑:首先是候选样本的自动选取,自动选择的候选样本对象应在一定程度上代表所有对象,而模糊聚类的隶属度直接提供了较好的参考依据;其次,多尺度分割得到的对象在计算空间包含等关系时具有较大优势,但在面向减灾应用的土地覆被分类中,这些关系并非决定性因素。此外,一般情况下,聚类的效率高于多尺度分割,更适合处理覆盖范围较大的影像<sup>[10]</sup>。

本文采用经典的模糊  $K$  均值聚类算法,并针对实际应用需求进行了相应的修改。与经典算法类似,聚类的主要目标仍然为最小化如下函数:

$$J_m = \sum_{j=1}^n \sum_{k=1}^K u_{kj}^m d^2(z_k, x_j), \quad 1 \leq m \leq \infty \quad (1)$$

通过聚类确定像素的隶属度,并形成稳定类簇(本文将其表达为对象块)。

在聚类结束后,根据各对象块中像素的平均隶属度来计算其整体隶属度。对不同类别地物设定不同的隶属度阈值,阈值设定目前以比例形式确定,亦即隶属度在各自类别的对象中相比较大的部分(实验中设置为 1/3)被选定。自动选择的样本将从这些候选的对象块中产生。

### 1.2 特征提取

人工选择样本的主要依据是地物样本在影像中表现的光谱、空间等特征,许多特征对后续分类同样起着重要作用<sup>[11-12]</sup>,因此,特征提取是样本自动选择的先决条件。它包括两方面的内容:一是影像特征的提取,即根据一定规则对从待分类影像中提取的候选对象块进行特征计算,如形状指数、水体指数等,这些特征是随影像不同而变化

的;二是地类特征的提取,即从先验知识中提取地类的主要特征,如道路的形状指数、河流的水体指数,这些特征属于地物的本质特征,在相同尺度下基本不变。

#### 1.2.1 影像特征

光谱特征是地物在影像中的直观表现,对于判别大多数地物具有重要作用,通常的光谱平均值、方差等特征还不足以完整地反映地物对象的光谱特征<sup>[13]</sup>,在实际应用中,通过计算对象中像素的各种指数(水体指数、植被指数等)加以弥补,这些特征是学习新距离度量的主要依据。

在面向对象的特征计算中,形状特征具有不可忽视的作用,是当前解决异物同谱及同物异谱等现象的有效手段<sup>[14-15]</sup>,除了计算对象的一般形状特征(如周长、面积、长宽比等)等,本文还引入了边界矩特征<sup>[16]</sup>来描述对象。

#### 1.2.2 地类特征

从先验知识中提取地类特征一般先于分类过程进行,主要用作距离度量学习的输入,为自动判定样本服务。假设根据应用需求及数据源确定  $m$  个类别,  $n$  种特征,此时需要确定  $l$  个参考特征集  $\langle x_i, y_i \rangle, i \in \{1, \dots, l\}$ , 其中,  $x_i \in R^n$  为各种地类特征值组成的向量;  $y_i \in \{1, \dots, m\}$  为类别标签。地类特征的确定还无法完全自动化,特别是类别的确定、特征值的调整等工作需要运用大量的先验知识,这是机器学习难以独立完成的。然而这部分工作可以在设计分类系统时完成,因此在具体针对局部区域自动分类时并不会造成影响。

#### 1.2.3 样本筛选

影像特征和地物与当前影像中的表征有关,而地类特征由先验知识决定,与影像无关,这两种特征的综合比较即是样本筛选的过程。假设以  $\Phi$

$=[\varphi_1, \varphi_2, \dots, \varphi_n]$ 代表上述影像特征所组成的特征集,以 $\Psi=[\psi_1, \psi_2, \dots, \psi_m]$ 代表某种地物的地类特征集,则对于当前影像特定地物可确定特征权重 $P=[p_1, p_2, \dots, p_n]$ 。对于每个候选样本,首先需要计算n维影像特征向量,然后针对单个特征分别计算其与地物的相似度 $\mu_i$ (主要通过特征值与阈值的差值、比值进行计算,不同特征的具体算法不同),最终参考式(2)综合评判其作为这种地物样本的可能性:

$$\mu = p_1\mu_1 + \dots + p_n\mu_n \quad (2)$$

$\mu$ 值越接近1,表明候选样本越有可能成为样本。

### 1.3 距离度量学习

由于遥感对象的特征复杂,传统的欧氏距离或光谱角已难以满足对象间的度量需求,因此引进距离度量学习的方法判别候选样本与各种地类之间的相似度,在确定最终分类样本的同时,还可以为基于距离的监督分类提供特征依据。距离度量学习的目标是根据数据特点学习一个适合当前数据的距离度量,使得数据的结构更加明晰,样本确立与分类也将变得更加简单<sup>[17-18]</sup>。在本文的应用中,训练数据就是从先验知识中提取的地类特征以及无标签的候选样本,最重要的学习目标就是使具有相似特征的对象或样本之间的距离更小,而特征差异明显的对象或样本之间的距离更大。

首先定义相似集合S与非相似集合D,具体可表示为:

$$\begin{cases} (\mathbf{x}_i, \mathbf{x}_j) \in S, y_i = y_j \\ (\mathbf{x}_i, \mathbf{x}_j) \in D, y_i \neq y_j \end{cases} \quad (3)$$

定义对象 $\mathbf{x}_i$ 与 $\mathbf{x}_j$ 之间的距离形式如下:

$$d^2(\mathbf{x}_i, \mathbf{x}_j) = \|\mathbf{x}_i - \mathbf{x}_j\|_A^2 = (\mathbf{x}_i - \mathbf{x}_j)^T \mathbf{A} (\mathbf{x}_i - \mathbf{x}_j) \quad (4)$$

其中为使距离非负,且满足三角不等式,要求 $\mathbf{A}$ 为半正定。显然,当 $\mathbf{A}$ 为单位阵时,式(4)简化为欧氏距离。通过最优化方法对上述问题可以描述为:

$$\begin{cases} \min_{\mathbf{A} \in \mathbb{R}^{n \times n}} \sum_{(\mathbf{x}_i, \mathbf{x}_j) \in S} \|\mathbf{x}_i - \mathbf{x}_j\|_A^2 \\ \text{s. t. } \mathbf{A} \geq 0, \sum_{(\mathbf{x}_i, \mathbf{x}_j) \in D} \|\mathbf{x}_i - \mathbf{x}_j\|_A^2 \geq 1 \end{cases} \quad (5)$$

进一步考虑当前影像的候选样本,采用半监督方法学习新的距离度量,既能保证先验知识的准确应用,又能兼顾待分类影像的具体特点。这里先验知识主要用于上述S与D集合的确定,亦即类别之间、像素之间的相似度将通过地类特征、影像特征共同加以确定。

设 $\mu_{ik}, \mu_{jk}$ 为候选样本 $\mathbf{x}_i, \mathbf{x}_j$ 与 $y_k$ ( $k=1, \dots, m$ )类的相似度,则当且仅当 $\mu_{ik}$ 与 $\mu_{jk}$ 均大于 $s_k$ 时,认为样本 $\mathbf{x}_i$ 与 $\mathbf{x}_j$ 相似;均小于 $d_k$ 时,认为两者不相似,其中 $s_k, d_k$ 为关于类别 $i$ 的相似阈值和非相似阈值。

## 2 实验及结果分析

在上述样本自动选择方法的基础上,开发了自动分类原型系统,选择典型灾害监测评估应用中的遥感影像进行土地覆被分类实验,并对实验结果进行了分析。

### 2.1 实验区域概况

2010年8月8日,甘肃省甘南藏族自治州舟曲县发生特大山洪泥石流灾害,灾害造成甘南藏族自治州舟曲县城及周边地区巨大的人员伤亡和财产损失。舟曲县地处南秦岭山地,岷山山系呈东南-西北走向,贯穿全境。地势西北高,东南低,县境内山峦重叠,沟壑纵横,地形复杂,是典型的高山峡谷区。

### 2.2 实验方法

#### 2.2.1 数据准备

本文选取了2008年7月与2010年8月9日获取的舟曲县城1m分辨率航空遥感影像<sup>[19]</sup>、典型地物波谱、DEM高程数据、中分辨率土地利用分类图等数据作为先验知识参考,并从2010年8月15日获取的舟曲2.5m的Quickbird影像中裁取覆盖研究区域大小为1100×850的图像子区进行分类实验(见插页II彩图2(a))。在数据准备过程中,根据实验区域地物的分布情况与实际应用需求确立的重点地物及相应的地类特征如表1所示。

表1 实验区主要地类及特征

Tab. 1 Land Cover Types and Features in Study Area

类别	光谱特征	地形特征	形状特征
植被	植被指数(0.8)	山体阴影(0.1)	
河流	水体指数(0.7)	汇流区(0.1)	形状指数(0.1)
建筑	光谱平均值(0.5)	高程(0.1)	面积(0.2)
道路	光谱平均值(0.5)		形状指数(0.3)
裸地	光谱平均值(0.6)	粗糙度(0.1)	
泥石流	光谱平均值(0.6)	坡度(0.3)	

表1所列为权重较大的一些特征,其余通用的特征还有平均亮度、坡向、矩特征、对比度、熵等,根据§1.2.3的计算需求预设了每个地物类别对各个特征的权重(括号内所列)。

#### 2.2.2 自动分类

以上完成了数据预处理和先验知识的准备,然后通过执行如下步骤实现自动分类。

1) 首先对实验影像进行模糊聚类,选择初始聚类数为15,从聚类结果(见插页Ⅱ彩图2(b))中获取对象并矢量化。为了表明模糊聚类对于获取对象及确定其隶属度的作用,在聚类结果图中的灰度级别反映了类簇及隶属度的共同作用。

2) 计算影像中每个矢量对象的影像特征,以属性的形式保存于矢量文件中。

3) 以§1.2.3中所述方法对矢量对象进行初步筛选,根据经验将综合阈值设为0.6,超过阈值的对象作为候选样本进入下一步。

4) 以所有候选样本为基本数据进行距离度量学习,约束条件 $S, D$ 根据§1.3所述由影像特征与地类特征间的相似性比较得到,具体将相似阈值调整为0.8,非相似阈值设为0.7,学习得到的A将用于全局数据进一步进行非监督学习。

5) 用前述得到的度量方式计算候选样本与各地类的实际距离,最终根据阈值(也可用比率控制样本数量)从中筛选用于分类的训练样本。

6) 根据样本训练SVM模型,完成整个实验影像的监督分类(见插页Ⅱ彩图2(d))。

与上述自动分类相对应地从影像中根据矢量化对象进行人工选择样本,同样采用SVM监督分类(相同参数设置)完成分类过程(见插页Ⅱ彩图2(c))。

### 2.2.3 精度验证

为了提高精度统计的客观性,人工选择样本的过程由三位专家分别独立地进行,根据这三批样本共进行三次监督分类,分类算法及参数设置与自动分类相同。自动分类通过调整样本选择过程中的部分阈值同样进行三次分类。参考实地考察数据以及其他高分辨率航空影像,在实验影像中选择了500个像素点作为精度验证数据,两种分类结果精度的平均值如表2所示。

表2 分类精度比较

Tab. 2 Comparison of Classification Accuracy

	样本数/个	总体精度/%	Kappa系数
人工1	60	81.2	0.788
人工2	60	77.2	0.722
人工3	60	84.6	0.813
自动1	138	79.4	0.749
自动2	179	78.6	0.737
自动3	237	79.2	0.743

### 2.3 实验结果分析

从目视效果来看,人工样本的分类效果稍好于自动样本的分类效果。从表2的精度比较来看,人工样本与自动样本的平均分类精度分别为81.0%和79.7%,但后者的分类精度稳定性较

高,而且分类的样本数也能通过调整阈值加以控制。总体来讲,自动选择样本基本上能达到一般人工样本的效果。考虑到本文方法在提高分类精度上未做较大改进,因此有可能使其精度最终达到甚至超过当前人工选择样本的分类精度。另外,自动选择样本较人工选择更具客观性,如图2所示,自动分类方法在多次实验中保持了更稳定的精度,有利于整体质量控制以及后期有针对性的改进。考虑到自动样本选择在运行速度、批处理等方面的优势,其在土地覆盖分类特别是应急处理中将具有较大的应用潜力。

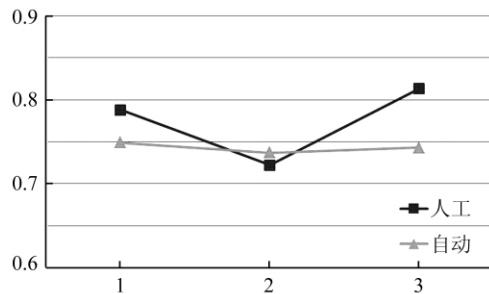


图2 两种分类方法Kappa系数比较

Fig. 2 Comparison of Kappa Coefficient of Two Methods

从两种样本的分类结果来看,道路的分类精度较低,这主要与聚类获得的对象有关,由于实验影像的空间分辨率原因,道路对象与邻接建筑的分割效果较差,而且道路本身的光谱变化较大,导致对象块破碎,这些使得影像中道路特征的提取效果较差,即使人工样本也难以选择。

两种分类结果的目视效果及混淆矩阵的比较表明,自动样本分类对建筑的分类较差,多误分为裸地,主要是由于裸地与建筑的光谱特征比较近似,而且由于建筑分布复杂且分割精度不高,建筑物的形状特征无法完全利用。

## 3 结语

针对高分辨率遥感减灾应用中对土地覆被分类的时效性、精确度等要求的不断提高,本文提出以自动样本选择为核心的监督分类方法实现面向对象的遥感影像自动分类,通过模糊聚类、特征提取、距离学习等步骤完成分类样本的自动选择。与基于人工选择样本的分类效果的比较结果显示,自动样本基本可以满足分类需求,而且分类结果更具客观性。

1) 样本自动选择方法在效率、客观性等方面明显优于传统的人工选择方法,预计通过调整分

类算法能使最终的分类精度有进一步的提高,从而基本满足灾情监测评估应用的需求。由于面向对象分析方法可以提取多种特征精细表征影像中的特定地物,因此在一定的先验知识的辅助下,比较容易实现样本的自动选择,从影像分辨率角度考虑,也更符合实际应用情况。

2) 从分类实验的分析中可以看出,进一步改进分割效果对于面向对象分类具有重要意义,特别是对道路、建筑等人工建设的规则目标,一种比较自然的改进思路就是在分割过程中考虑先验知识,亦即以本文所述的地类特征控制各种分割参数,达到合理提取对象的目的。

尽管现阶段已初步实现基于自动选择样本的分类,但总体上本文还是较多地采用传统的技术手段,样本选择及分类过程中的算法离稳健性和高精度的目标还有较大的改进余地。后期将从自动分类的全局考虑,在特征提取、选择、应用等多方面做进一步改进,从理论和方法上继续为自动分类的实用化努力。

## 参 考 文 献

- [1] 范一大,杨思全,王磊,等.汶川地震应急监测评估方法研究[J].遥感学报,2008,12(6):858-864
- [2] 杨思全,刘三超,吴玮,等.青海玉树地震遥感监测应用研究[J].航天器工程,2011,20(2):90-96
- [3] Keuchel J, Naumann S, Heiler M, et al. Automatic Land Cover Analysis for Tenerife by Supervised Classification Using Remotely Sensed Data[J]. Remote Sensing of Environment, 2003, 86(4): 530-541
- [4] Jordi I. Automatic Recognition of Man-made Objects in High Resolution Optical Remote Sensing Images by SVM Classification of Geometric Image Features[J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2007, 62(3): 236-248
- [5] 刘璞,张远,周斌,等.基于SAM和多源信息的土地利用/覆盖自动分类[J].浙江大学学报(工学版),2009,43(9):1574-1579
- [6] 谭衡霖.高分辨率多光谱影像城区建筑物提取研究[J].测绘学报,2010,39(6):618-623
- [7] 骆剑承,王钦敏,周成虎,等.基于自适应共振模型的遥感影像分类方法研究[J].测绘学报,2002,31(2):145-150
- [8] 王卫红,夏列钢,骆剑承,等.面向对象的遥感影像多层次迭代分类方法研究[J].武汉大学学报·信  
息科学版,2011,36(10):1154-1158
- [9] Kuemmerle T, Radeloff V C, Perzanowski K, et al. Cross-border Comparison of Land Cover and Landscape Pattern in Eastern Europe Using a Hybrid Classification Technique[J]. Remote Sensing of Environment, 2006, 103(4): 449-464
- [10] Ghosh A, Mishra N S, Ghosh S. Fuzzy Clustering Algorithms for Unsupervised Change Detection in Remote Sensing Images[J]. Information Sciences, 2011, 181(4): 699-715
- [11] Mennis J, Guo D. Spatial Data Mining and Geographic Knowledge Discovery—An Introduction[J]. Computers, Environment and Urban Systems, 2009, 33(6): 403-408
- [12] Li J, Narayanan R M. Integrated Spectral and Spatial Information Mining in Remote Sensing Imagery [J]. IEEE Transactions on Geoscience and Remote Sensing, 2004, 42(3): 673-685
- [13] Tang Hong, Fang Tao, Shi Pengfei. Spectral Similarity Measure Based on Fuzzy Feature Contrast Model[J]. Optics Communications, 2004, 238(1/3): 123-137
- [14] van der Werff, van der Meer. Shape-based Classification of Spectrally Identical Objects [J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2008, 63(2): 251-258
- [15] Atkinson P M, Lewis P. Geostatistical Classification for Remote Sensing: An Introduction[J]. Computers & Geosciences, 2000, 26(4): 361-371
- [16] 吴一全,武燕燕.利用NSCT和Krawtchouk矩进行图像检索[J].武汉大学学报·信息科学版,2011,36(6):691-694
- [17] Xing E P, Ng A Y, Jordan M I, et al. Distance Metric Learning with Application to Clustering with Side-information[J]. Advances in Neural Information Processing Systems, 2003, 15: 521-528
- [18] Weinberger K Q, Saul L K. Distance Metric Learning for Large Margin Nearest Neighbor Classification[J]. Journal of Machine Learning Research, 2009, 10: 207-244
- [19] 国家测绘地理信息局.舟曲县灾前灾后权威高清影像对比图[EB/OL].<http://www.sbsm.gov.cn/article/chyw/201008/20100800071142.shtml>, 2010

第一作者简介:温奇,博士,主要从事空间技术减灾和高分辨率遥感灾情评估方面的研究。

E-mail:wenqi@ndrcc.gov.cn

## Automatically Samples Selection in Disaster Emergency Oriented Land-Cover Classification

WEN Qi<sup>1,2</sup> XIA Liegang<sup>3</sup> LI Lingling<sup>1,2</sup> WU Wei<sup>1,2</sup>

(1) National Disaster Reduction Center of China, 6 East Guangbai Road, Chaoyang District, Beijing 100124, China  
(2) Key Laboratory of Disaster Reduction and Emergency Response Engineering, 6 East Guangbai Road,

Chaoyang District, Beijing 100124, China

(3) Institute of Remote Sensing Application, Chinese Academy of Sciences, 9 South Dengzhuang Road,  
Haidian District, Beijing 100101, China

**Abstract:** The automation level of classification for remote sensing image need to be improved to satisfy the timeliness and high-precision requirements in disaster emergency monitoring and assessment. But, the artificial selection of typical samples restricts the automatic interpretation of disaster information, a problem particularly acute for the development of business operation systems. This paper implements a totally automatic object-oriented land cover classification system based on automatic sample selection. First, the candidate object samples are acquired by fuzzy clustering. Second, image features and land type features are extracted from imagery and prior knowledge, respectively. Afterward, samples can be selected by applying preset thresholds on these features. Distance metric learning is then used not only for further sample selection, but also for more accurate supervised classification. Zhouqu Debris flow disaster images are computed by this method. Results show that the classification outcomes with samples selected automatically are very close to those samples selected by hand. Our results are more stable and objective than those produced manually. Moreover, it is more convenient to batch process images automatically.

**Key words:** disaster emergency; land cover classification; automatically samples selection; feature extraction; feature matching

---

**About the first author:** WEN Qi, Ph.D. His research interests are in spatial technology disaster reduction and high resolution remote sensing disaster assessment.

E-mail: wenqi@ndrcc.gov.cn

+++++

(上接第 773 页)

descriptor has a lower discriminating ability when compared with SIFT. Experimental results demonstrate that the modified descriptor has a better discriminating ability compared with SURF descriptor.

**Key words:** Haar-like features; SURF; remote sensing images; image matching

---

**About the first author:** YAN Li, professor, Ph. D, Ph. D supervisor. His research interests include photogrammetry, remote sensing image processing and 3D laser imaging radar data processing.

E-mail: lyan@sgg.whu.edu.cn

插页Ⅱ

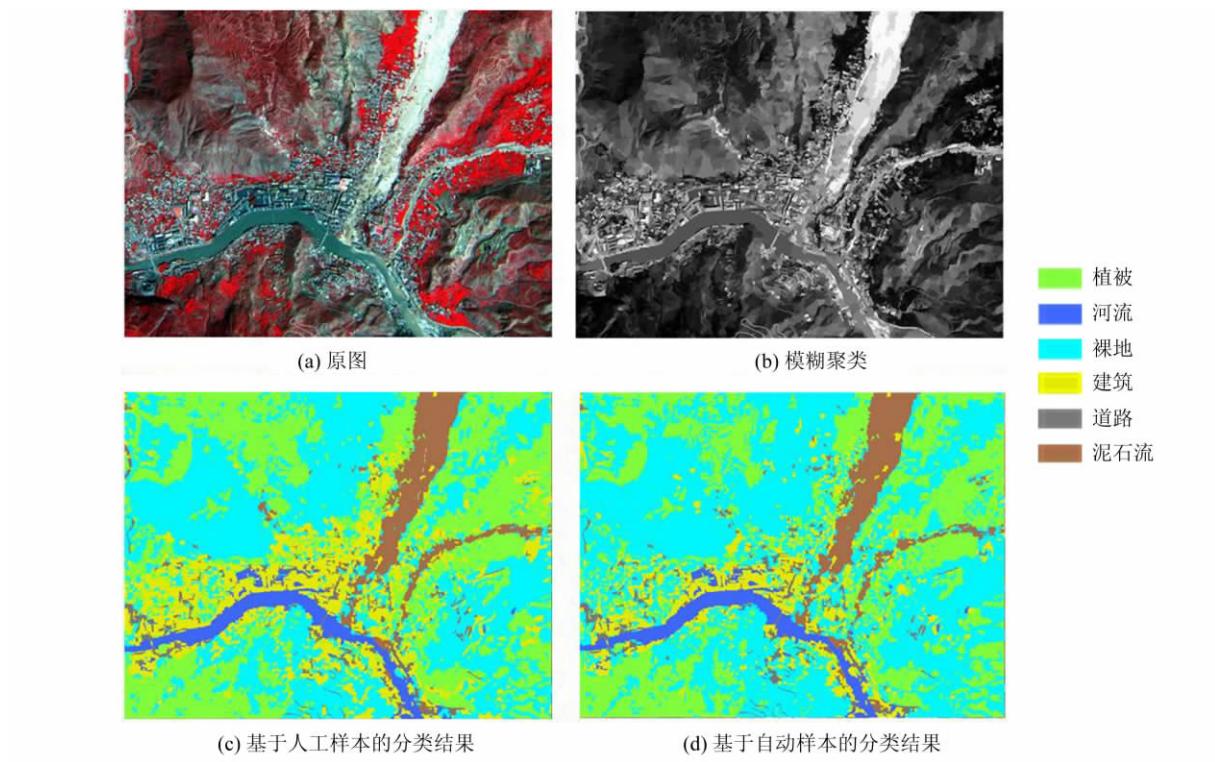


图 1 基于两种样本的分类结果比较

Fig. 1 Comparison of Classification Results Based on Two Kinds of Samples

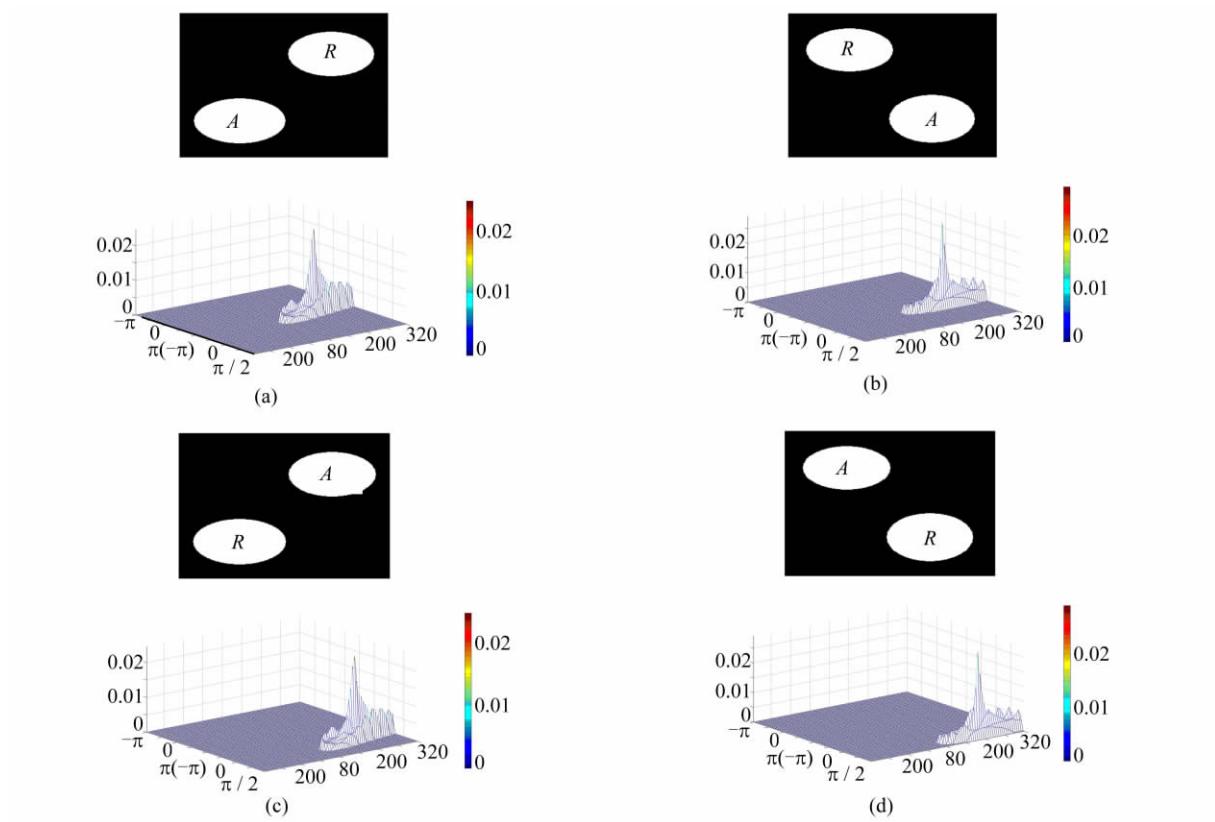


图 2 空间关系直方图实例

Fig. 2 Examples of the Histogram of Spatial Relationships