

高空间分辨率遥感图像分类的 SSMC 方法

黄 昕 张良培 李平湘

(武汉大学测绘遥感信息工程国家重点实验室, 武汉 430079)

摘 要 近年来随着高空间分辨率遥感的发展, 影像的空间细节描述能力得到提高, 像元之间的空间相关性得到增强, 使传统的遥感影像光谱分类方法面临着巨大的挑战。基于此背景, 提出了高分辨率遥感影像分类的 SSMC (spatial and spectral mixed classifier) 方法, 旨在同时采用光谱和空间特征进行遥感影像分类。本文是基于 SSMC 方法的一个具体的实验, 通过多尺度的空间金字塔构造每个像元的空间参数, 整合影像的光谱信号和空间信息进行高分辨率遥感影像分类。实验结果证明, SSMC 方法对于提高高分辨率遥感影像的分类精度具有积极的意义。

关键词 光谱信息 空间参数 高空间分辨率 SSMC 方法

中图分类号: TP391.41 文献标识码: A 文章编号: 1006-8961(2006)04-0529-06

SSMC Method for the Classification of High Spatial Resolution Remotely Sensed Images

HUANG Xin, ZHANG Liang-pei, LI Ping-xiang

(National Laboratory for Information Engineering in Surveying, Mapping and Remote Sensing, Wuhan University, Wuhan 430079)

Abstract Traditional spectral-based methods have proven inadequate for the classification of high spatial resolution remotely sensed images, due to the lack of consideration of the spatial features of the data. In order to improve the classification effect of high spatial resolution remotely sensed data, the author presented a new method called SSMC (Spatial and Spectral Mixed Classifier) driven by integrated spatial and spectral features. In this algorithm, we use twofold pyramids to extract the spatial information of images, one is the background pyramid composed of a set of windows, such as 64×64 , 32×32 , 16×16 and 8×8 , which can mimic human perception in identifying objects of different scales; and the other is mallat pyramid, which is used here to make a multiresolution analysis for every level of the background pyramid. The new algorithm is constructed for the classification of high resolution multispectral images, whose typical cases are IKONOS, Quick Bird etc. And in the experiments, the presented method can achieve better accuracy than the conventional ones, so we can conclude that the SSMC method is active and encouraging.

Keywords spectral information, spatial parameter, high spatial resolution, SSMC method

1 引言

近年来, 空间技术的发展使我们可以获得甚高空间分辨率的遥感数据, 该影像的特点在于: (1) 相邻像元具有高度的相关性; (2) 类内的光谱差异增大, 类间的光谱差异减小; (3) 影像的空间关系变得更加复杂, 同谱异质、同质异谱的现象广泛存在。所以, 不同类别地物的光谱信息存在较大重叠, 传统的

光谱方法在高分辨率影像的解译上面临困难。

要解决这个问题必须利用影像的空间信息, 从基于像元的特征提取转向基于区域的特征提取。近年来, 有很多学者从事这方面的研究, Myint 利用小波变换提取高分辨率影像的纹理特征, 用不同的测度分析小波子影像的特征, 并比较了不同的窗口大小对于纹理信息提取的差异^[1,2], 但该算法受限于 window size 效应^[3], 分类结果易产生“带状边缘”; Zhang 用灰度共生矩阵进行房屋提取, 把频率值进

收稿日期: 2005-03-29; 改回日期: 2005-06-13

第一作者简介: 黄昕(1982~), 男, 2004年毕业于武汉大学遥感信息工程学院, 现为武汉大学测绘遥感信息工程国家重点实验室博士研究生。主要从事高空间分辨率遥感影像模式识别、神经网络原理等方面的研究。E-mail: huangxin1982420@163.com

行归一化映射得到共生矩阵图像,再用 ISODATA 算法对该图像进行分类,最后用目视解译的方法通过人工试验提取目标^[4];Franco 利用 Markov 随机场构造的纹理参数对光谱混合的类别进行再分类^[5],该算法的再分类过程是基于阈值,必须通过目视解译进行试验和调整;Barnsley 提出核重分类,利用地物的空间排列特点对分类结果进行后处理以提高解译的准确性^[6];Zhang 把高分辨率影像上的线状特征以辅助波段的形式参与分类,增强了分类结果的结构性^[7];Gong 把高分辨率影像边缘检测的结果进行平滑,作为伪波段以增强光谱分类的结果^[8];Guindon 用高分辨率商业化软件 eCognition 对 Ottawa 地区的 Ikonos 影像分类^[9],该软件充分考虑了地物的光谱、形状和分布,用户可获得多尺度的分类结果,只是需要过多的人机交互。

本文提出的 SSMC (spatial and spectral mixed classifier) 方法,是对同一像元的不同背景进行小波分解来提取该像元的多尺度空间信息,结合光谱信息对高空间分辨率多光谱影像进行分类,以弥补传统方法的不足,提高解译的自动化程度和精度。

2 算法

2.1 空间特征参数的构造

用小波变换构造像元的空间参数。2 维影像 $f(x, y)$ 在分辨率 2^j 下的小波系数可按下式计算:



图 1 多背景的 Mallat 分析

Fig. 1 Mallat analysis for multi-backgrounds

设原始窗口为 I , I 经过第 i 阶小波变换得到低频、垂直、水平和对角方向子影像分别为 AP_i , VD_i , HD_i , DD_i , $i = 1, 2, 3$ 。用熵 Entropy (简记为 E) 作为每个子影像的特征值

$$E = - \sum \sum Q(i, j) \log(Q(i, j))$$

$$Q(i, j) = \frac{|P(i, j)|^2}{\sqrt{\sum_{i,j} |P(i, j)|^2}} \quad (2)$$

$$c_{m,n}^{(j)} = \sum_{l,k} \phi_{k-2m} \phi_{l-2n} f_{k,l}^{j-1}$$

$$w_{m,n}^{(j,h)} = \sum_{l,k} \phi_{k-2m} \psi_{l-2n} f_{k,l}^{j-1}$$

$$w_{m,n}^{(j,v)} = \sum_{l,k} \psi_{k-2m} \phi_{l-2n} f_{k,l}^{j-1}$$

$$w_{m,n}^{(j,d)} = \sum_{l,k} \psi_{k-2m} \psi_{l-2n} f_{k,l}^{j-1} \quad (1)$$

$c_{m,n}^{(j)}$ 、 $w_{m,n}^{(j,h)}$ 、 $w_{m,n}^{(j,v)}$ 和 $w_{m,n}^{(j,d)}$ 分别表示低频、水平高频、垂直高频和对角高频子影像的小波系数, j 为分解阶数, $\psi(x)$ 为 1 维小波函数, 具有高通滤波的作用; $\phi(x)$ 为 1 维尺度函数, 具有低通滤波的作用。本文选用 db4 小波基, 求出各个子影像的小波系数, 经过线性映射便可得到小波分解的各个子图像。

以往用小波变换提取像元的空间特征, 往往局限于固定的窗口和尺度^[1,10], 研究人员关心的是各种尺度对特征提取的差异和比较^[1]。事实上, 人的大脑和视觉对物体的观察和理解是基于连续的长度, 用连续且不断扩大的背景来确定被观察物体的空间位置和关系。为了模拟人类识别目标的特性, 对一系列不同中心窗口进行小波变换, 构造像元的空间特征参数, 把单一的窗口和尺度扩展为多窗口和多尺度, 提取像元的多尺度空间信息。图 1 表示了空间信息提取特点, 用两种金字塔分析目标像元的空间特征, 一种是目标像元所处的不同尺度的背景, 如多窗口 64×64 、 32×32 、 16×16 和 8×8 ; 另一种是对每个背景窗口采用 Mallat 金字塔, 如图 1(a) 是利用该金字塔对同一窗口的不同尺度描述。

其中, $P(i, j)$ 为小波系数。

设子影像 AP_i , VD_i , HD_i , DD_i 的特征值分别为 $E(AP_i)$ 、 $E(VD_i)$ 、 $E(HD_i)$ 和 $E(DD_i)$ 。Myint^[1]、Zhu^[10] 用每个子影像的特征值组合成一个 n 维的特征向量, $n = 3i + 1$, 但过多的空间参数会减少分类特征中的光谱含量, 而且空间特征和光谱特征的评价尺度不同, 会造成混合分类特征的扭曲。所以这里将同一阶小波分解的子影像特征值进行组

合,构造新的空间特征参数, $C_1, C_2, C_3, C_4, \dots, C_m$, 其中, m 为空间特征的维数。对于某个窗口而言, 每进行一次小波分解将产生 4 个新的特征值, 用这 4 个值构造 1 个新的归一化特征值 C_j , 这样, 该窗口每进行一次小波分解就得到 1 个新的空间参数 C_j , 其计算方法为

$$C_j = \frac{E(AP_i)}{E(VD_i) + E(HD_i) + E(DD_i)} \quad (3)$$

式中, $j=1, 2, 3, \dots, m, i$ 为小波分解阶数。

该空间参数一是降低了空间特征向量的维数, 保持了分类信息中光谱含量和空间含量的平衡, 解决了空间特征参数的归一化问题; 二是有效补充了光谱信息在高分辨率遥感解译中的缺陷; 三是用金字塔式的背景窗口模拟人的视觉, 避免了传统的单窗口小波方法的弊端; 四是对每个背景窗口采用多分辨率分析, 提取地物的多尺度空间特征。

考虑到算法的通用性, 在分类时只需选择背景窗口的配置, 可供选择的背景窗口为 $64 \times 64, 32 \times 32, 16 \times 16, 8 \times 8$ 。对 $64 \times 64, 32 \times 32$ 的背景窗口进行 3 阶小波变换, 即每个窗口提取 3 个特征值; 对 16×16 窗口进行 2 阶小波变换, 提取 2 个特征值; 对 8×8 背景窗口只进行 1 阶小波变换, 提取 1 个特征值。小波分解阶数并非越多越好^[10], 如果对以上窗口进一步分解会得到 2×2 窗口的子影像, 这么小的窗口实际上已无法对地物的空间信息进行有效描述, 所以采取背景窗口和小波分解阶数一一对应的策略。当背景窗口确定以后, 空间特征维数 m 也就确定了。

2.2 SSMC 的实现

为了说明 SSMC 方法的分类性能, 采用最小距离分类器 (MDTM) 作为空间特征和光谱特征的载体。传统的最小距离分类器为

$$d_{wi} = \sum_{j=1}^P \|i_j - l_{w,j}\| \quad (4)$$

其中, d_{wi} 指的是像元 i 到 w 类的光谱距离, i_j 表示像元 i 在波段 j 的光谱值, P 为传感器的波段数, $l_w = [l_{w,1}, l_{w,2}, l_{w,3}, \dots, l_{w,p}]$, 其中 $l_{w,j}$ 为第 w 类地物样本在波段 j 上的平均光谱值, $j=1, 2, 3, \dots, p$ 。像元 i 的类别为

$$w^* = \min_w (d_{wi}) \quad (5)$$

以 SSMC 思想修改上述分类器, 考虑到 2.1 节中的空间特征参数, 可得

$$d_{wi}^s = \sum_{k=1}^m h_{w,i,k} \times \|s_{i,k} - s_{w,k}\| \quad (6)$$

其中, d_{wi}^s 表示像元 i 到 w 类地物的空间距离, $h_{w,i,k}$ 是像元 i 相对于 w 类地物的第 k 个空间参数的权重, 即对每一个空间特征分量自适应加权, 设像元 i 与 w 类地物相应的权值向量为 $h_{w,i} = [h_{w,i,1}, h_{w,i,2}, h_{w,i,3}, \dots, h_{w,i,m}]$, 用样本最基本的两个统计量——方差和均值来确定每个特征分量的权 $h_{w,i,k}$, 其计算涉及 5 个向量: 像元 i 的空间特征向量 $s_i = [s_{i,1}, s_{i,2}, s_{i,3}, \dots, s_{i,m}]$, 其中 m 为空间特征维数; 假设第 w 类地物有 n 个训练样本, $q=1, 2, 3, \dots, n$, 其第 q 个样本的空间特征向量为 $s_{w,q} = [s_{w,q,1}, s_{w,q,2}, s_{w,q,3}, \dots, s_{w,q,m}]$; 由第 w 类地物的训练样本可得该类空间特征向量的均值向量 $s_w = [s_{w,1}, s_{w,2}, s_{w,3}, \dots, s_{w,m}]$; 由第 w 类地物样本可得该类空间特征向量的方差向量为 $v_w = [v_{w,1}, v_{w,2}, v_{w,3}, \dots, v_{w,m}]$; 由以上 4 个向量计算得到 x_i 相对于 w 类地物的偏离矢量 $t_{w,i} = [t_{w,i,1}, t_{w,i,2}, t_{w,i,3}, \dots, t_{w,i,m}]$, 其中

$$s_{w,k} = \frac{1}{n} \sum_{q=1}^n s_{w,q,k} \quad v_{w,k} = \frac{1}{n-1} \sum_{q=1}^n (s_{w,q,k} - s_{w,k})^2 \quad (7)$$

n 为 w 类的样本数, $k=1, 2, 3, \dots, m$, 且

$$t_{w,i,k} = \frac{1}{v_{w,k} \times |s_{i,k} - s_{w,k}|} \quad (8)$$

把 $t_{w,i,k}$ 归一化得到

$$h_{w,i,k} = \frac{d_{w,i,k}}{\sum_{i=1}^m d_{w,i,k}} \quad (9)$$

$h_{w,i,k}$ 的设置是为了减弱偏离度较高的特征参数对分类的影响, 因为偏离度较高意味着该特征值对地物空间特征描述能力不强, 导致空间参数的不稳定, 因此需要用 $h_{w,i,k}$ 削弱这种参数对分类的影响。于是, 最小距离分类器可按 SSMC 方法修改为

$$w^* = \min_w (d_{wi}^s \times (1-a) + d_{wi}^s \times a \times b) \quad (10)$$

其中, a 是调节参数, 控制分类器中空间参数和光谱信息之间的比例, b 是位移参数, 它对分类的结果不会造成影响, 但 b 的设置会影响具有最佳分类效果的 a 值, 使具有最好分类效果的 a 值产生偏移。

3 实验

实验数据选用北京地区的 Quick Bird 多光谱影像, 数据包括 3 个可见光波段, 分别是 R: 630 ~ 690nm; G: 520 ~ 600nm; B: 450 ~ 520nm, 其空间分辨率为 2.44m, 如图版 I 图 1(a) 所示。

3.1 实验 1

用 SSMC 方法对样区分类, 并比较 SSMC 方法

和以往算法的分类效果。由于有 3 个多光谱波段, 所以 $p=3$; 背景窗口配置为 $64 \times 64, 32 \times 32, 16 \times 16$, 背景窗口的设置和影像空间分辨率以及地物的尺度特征有关, 可根据实际情况进行选择; 实验中取 $a=0.38, b=0.3$, 图版 I 图 1(b) 是传统的光谱聚类法 ISODATA 的分类结果, 采用文献[4]的方法, 先分 7 类, 然后根据目视解译归为 4 类; 图版 I 图 1(c) ~ (e) 是用文献[1]的方法提取纹理特征进行分类的结果, 图版 I 图 1(f) 是 SSMC 方法分类的结果。

(1) 对比图版 I 图 1(b) ~ (e), 从图版 I 图 1(c) 可以看到大窗口在边缘处存在明显的误分, 随着窗口的减小, window size 效应也随之减小, 图版 I 图 1(d)、(e) 在边缘处的分类得到改善, 但又出现逐像素分类的椒盐效果。window size 效应产生的本质在于尺度单一, 如果把逐像素 (per-pixel) 分类看作 1×1 窗口分类的话, 那么所有窗口运算都将出现椒盐效果, 只是椒盐颗粒的大小不同, 因为单一背景尺寸提取的空间信息尺度也是单一的, 这一点在图版 I 图 1(b) ~ (e) 中表现得非常明显, 这是传统的空间特征提取算法的不足。

(2) 对比图版 I 图 1(c) ~ (f) 和图版 I 图 1(b), 可以发现光谱方法无法提取出光谱特征相近的农田和树木, 只有通过空间信息的介入才能加以区分。

(3) 对比图版 I 图 1(c) ~ (f), 从目视解译可以观察到本文算法对不同尺度地物的适应性, 对于大

面积地物的植被, 图版 I 图 1(f) 的结果表现出很均匀的效果, 对于小尺度的, 有时甚至是零星的树木, 图版 I 图 1(f) 的结果也比图版 I 图 1(e) 要好。为了进一步对比, 把图版 I 图 1 的左上角区域放大 (图版 I 图 2)。

对比以上分类结果, 可以进一步观察到本文的空间特征提取方法对于多尺度地物分类的良好效果, 既保持了地物的细节信息, 又保持了大片区域的整体性, 同时具备了逐像素 (per-pixel) 分类和区域 (per-area) 分类的优点, 这是因为采用 $64 \times 64, 32 \times 32, 16 \times 16$ 和 8×8 的 4 层背景空间金字塔, 实现了对高空间分辨率影像多尺度地物分类的适应性。还有一点值得注意的是, 从图版 I 图 1(b) 和图版 I 图 2(a) 可以看到由于水体的富营养化使得光谱方法的分类结果将部分水体归为植被类, 而所有的空间方法都没有产生这种效果, 可见空间信息对于土地利用的分类比对土地覆盖的分类更为有效。

3.2 实验 2

从图版 I 图 1(a) 中选择了 4 类地物的样本, 以说明分类器参数 a 和 b 对于分类结果的影响。分类器的配置为多光谱波段数 $p=3$, 用 $64 \times 64, 32 \times 32, 16 \times 16$ 和 8×8 为背景窗口提取空间特征, 空间特征维数 $m=9$ 。首先考察在 b 值一定的情况下, 不同 a 值对于分类精度的影响, 图 2 为 $b=0.3$ 时 3 个不同 a 值的测试结果。 $a=0$, 即是传统的光谱监督分类方法。




图 2 分类精度测试

Fig. 2 Accuracy of classification test

表 1 所示为定量统计结果, 比较 $a=0$ 和 $a=0.4$ 的测试结果, 后者对水体的测试精度略微有一点提高, 但幅度很小, 这是因为水体为非纹理区域, 而且其光谱特征已经非常明显, 对它的提升空间很小; 城区的精度有所下降, 这是因为 SSMC 方法对城区识别的峰值精度对应于 $a=0.2$ 而不是 $a=0.4$ (见图 3(c)); SSMC 对农田和树木的分类效果则有


明显改善, 因为二者在光谱上的混淆, 必须借助空间信息才能进行有效的区分。

不同 b 值对分类结果的影响, 如图 3 所示。


从图 3 可以看到每条曲线 (对应于一个 b) 都存在一个精度的最大值, 在最值的左边, 曲线为单调递增, 最值的右边, 曲线为单调递减, 这说明对于每一类地物都存在一个最佳的 a 值 (记为 a^*), 即存在

表 1 测试精度统计
Tab.1 Statistics of testing accuracy


| 精度评定 | 水体 | | | 城区(不含阴影) | | | 农田 | | | 树木 | | |
|----------------|--------|-----|----------|----------|-------|----------|--------|-----|----------|--------|-----|----------|
| | 测试像元总数 | 错分 | 测试精度 (%) | 测试像元总数 | 错分 | 测试精度 (%) | 测试像元总数 | 错分 | 测试精度 (%) | 测试像元总数 | 错分 | 测试精度 (%) |
| $\alpha = 0.0$ | 8 496 | 26 | 99.69 | 6 225 | 994 | 84.04 | 4 200 | 650 | 84.54 | 1 512 | 628 | 58.50 |
| $\alpha = 0.4$ | 8 496 | 24 | 99.72 | 6 225 | 1 025 | 83.53 | 4 200 | 431 | 89.73 | 1 512 | 410 | 72.88 |
| $\alpha = 0.7$ | 8 496 | 968 | 88.61 | 6 225 | 1 707 | 72.57 | 4 200 | 463 | 88.97 | 1 512 | 486 | 67.85 |



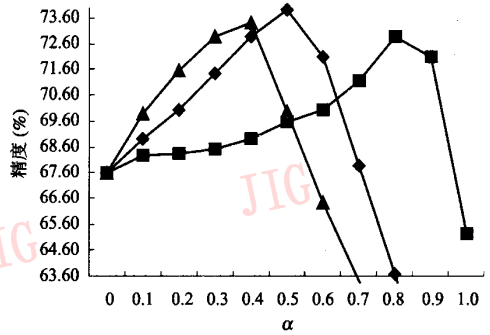
(a) 农田精度曲线



(b) 水体精度曲线



(c) 城区精度曲线



(d) 树木精度曲线

◆ $b = 0.3$ ■ $b = 0.05$ ▲ $b = 0.55$

图 3 分类精度曲线

Fig. 3 Accuracy curves of classification

最佳的空间特征和光谱特征的比例。同时可以观察到:每类地物的 α^* 值是不同的,所以对于不同类型的地物,需要不同的空间和光谱特征的比例,例如:图 3(a),在最值的两边曲线基本呈轴对称,这说明空间特征和光谱特征对于农田分类的贡献是基本相同的;而在图 3(b)和(c)中,精度曲线在到达最值后便迅速下降,这说明空间特征在到达其最佳的辅助分类效果后便迅速失效,空间特征的比例在上升

到一定程度后不仅不能提高精度,反而使得精度迅速下降,这说明了空间特征区分水体和城区的能力大大弱于光谱特征,也说明了纯粹利用空间信息进行分类不会得到理想的结果。还可以观察到,在图 3 的每一幅子图中,3 条曲线(对应于 3 个 b 值)精度的最值几乎完全相同,这说明 b 对分类结果是没有影响的,只是使得 α^* 产生偏移,从图 3(a)~(d)可以明显看到这个偏移的趋势。

4 结 论

针对传统的光谱分类方法以及现有的空间特征方法的不足,提出了 SSMC 方法,并用小波变换构造的空间特征参数结合光谱信息为 SSMC 的实现举出了一个示例,实验结果证明,SSMC 方法对于解译以 Quick Bird 和 IKONOS 为代表的高空间分辨率多光谱传感器影像具有积极的意义。

SSMC 方法的主要特点在于:

(1) 用 64×64 、 32×32 、 16×16 和 8×8 的多窗口模拟人的视觉认知,构造 4 层背景金字塔,并用 Mallat 金字塔对每一个背景层进行空间特征提取,对于每一个背景窗口的每一次小波分解,将产生 1 个空间参数,在压缩空间特征维数的同时实现空间特征归一化;

(2) 将光谱信息和空间信息整合用于高分辨率影像分类,取得显著效果;

(3) 算法具有通用性和实用性,用户只需确定背景窗口,以及根据先验知识选定样区,在 CPU 主频 633MHz、内存 128M 的硬件环境下,对一幅 179×221 的影像进行分类的时间为 216s。

本文是 SSMC 方法实现的一个例子,属于混合分类器的初探性研究,下一步的研究主要是:

(1) 各种分类器对于空间和光谱混和特征の利用能力是不同的,所以需要根据特征组合的特点对传统的分类器进行改进,构造适合 SSMC 方法的分类器;

(2) 特征是多元化的,还可以构造如共生矩阵、Markov 随机场、分形等多种空间特征,以及主成分、独立成分、生物量指标等多种光谱特征,如何利用这些特征,如何保持空间特征与光谱特征的平衡,以及如何用人工智能的方法让机器对这些特征进行自动

选择或组合,是很值得研究的。

参考文献 (References)

- 1 Myint S W, Lam N S N, Tylor J. An evaluation of four different wavelet decomposition procedures for spatial feature discrimination within and around urban areas [J]. *Transactions in GIS*, 2002, 6(4):403~429.
- 2 Myint S W. Fractal approaches texture analysis and classification of remotely sensed data [J]. *International Journal of Remote Sensing*, 2003, 24(9):1925~1947.
- 3 Hodgson M E. What size window for image classification? A cognitive perspective [J]. *Photogrammetric Engineering and Remote Sensing*, 1998, 64(8):797~807.
- 4 Zhang Yun. Optimisation of building detection in satellite images by combining multispectral classification and texture filtering [J]. *ISPRS Journal of Photogrammetry and Remote Sensing*, 1999, 54(8):50~60.
- 5 Franco J A, Moctezuma M, Parmiggiani F. Remote sensing images segmentation; a mixed approach adapted for fine structure detection [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2003, 41(10):2807~2822.
- 6 Barnsley M J, Rarr S L. Inferring urban land use from satellite sensor using kernel-based spatial reclassification [J]. *Photogrammetric Engineering and Remote Sensing*, 1996, 62(7):949~958.
- 7 Zhang Q, Wang J, Peng X, et al. Urban built-up land change detection with road density and spectral information from multi-temporal landsat TM data [J]. *International Journal of Remote Sensing*, 2003, 23(7):3057~3078.
- 8 Gong P, Howarth P. The use of structural information for improving land-coverclassification accuracies at the rural-urban fringe [J]. *Photogrammetric Engineering and Remote Sensing*, 1990, 56(8):67~73.
- 9 Guindon B, Zhang Y. Landsat urban mapping based on a combined spectral-spatial methodology [J]. *Remote Sensing of Environment*, 2004, 92(6):218~232.
- 10 Zhu C, Yang X. Study of remote sensing image texture analysis and classification using wavelet [J]. *International Journal of Remote Sensing*, 1998, 13(6):3167~3187.

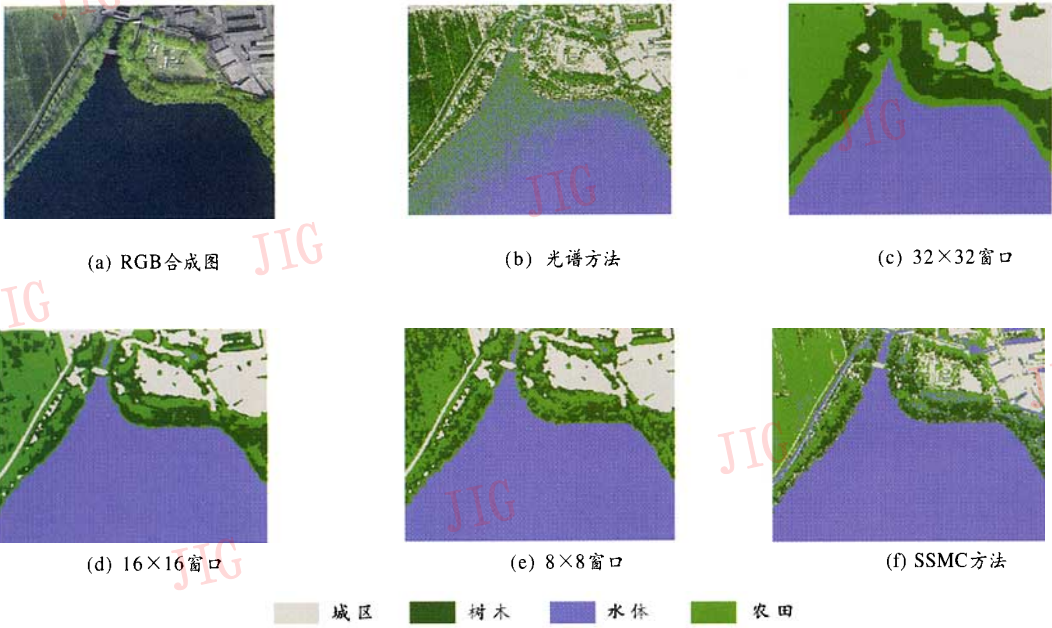


图1 分类结果的比较
Fig.1 Comparison of different classification results

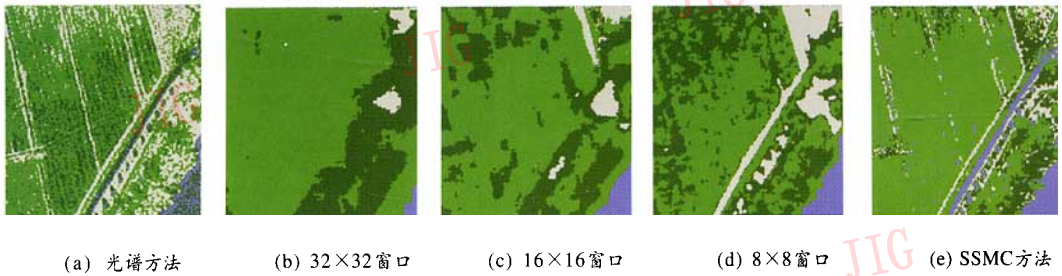


图2 实验区左上部分分类结果比较
Fig.2 Comparison of classification results for the left-upper part of the experimental area

邹 阳等:一种自动立体显示器立体对比度和视区检测方法




图1 图4(a)中右边图像的R、G、B值
Fig.1 R、G、B value of the right image in figure 4(a)