

文章编号: 1007 4619 (2007) 02 0193 08

融合形状和光谱的高空间分辨率遥感影像分类

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, 湖北 武汉 430079)

摘 要: 提出了一种像元形状指数及基于形状和光谱特征融合的高(空间)分辨率遥感影像分类方法。形状和光谱是遥感影像纹理的具体表现形式,尤其在高分辨率影像中地物细节得到充分表达,相邻像元的关系及其共同表征的形状特性成为分类的重要因素。本文用像元及其邻域的关系来描述其空间结构,同时为了更全面地利用影像特征,提出了基于支持向量机的形状和光谱融合分类方法。实验证明,该方法计算简便且能有效表达高分辨率影像的地物特征,提高分类精度。

关键词: 像元形状指数; 光谱; 支持向量机; 融合; 高空间分辨率

中图分类号: TP751.1 文献标识码: A

Classification of High Spatial Resolution Remotely Sensed Imagery Based on the Fusion of Spectral and Shape Features

HUANG Xin, ZHANG Liang pei, LI Ping xiang

(National Key Laboratory for Information Engineering in Surveying, Mapping and Remote Sensing,

Wuhan University, Hubei Wuhan 430079, China)

Abstract: Classification of multispectral data with high spatial resolution is investigated. High spatial resolution remotely sensed (HSRRS) images with multispectral bands such as QuickBird and IKONOS provide a large amount of information, thus opening up avenues for new remote sensing applications. However, their availability poses challenges to image classification. Due to the complex spatial arrangement and spectral heterogeneity even within the same class, conventional spectral classification methods are grossly inadequate for HSRRS imagery. In order to overcome this inadequacy, spectral features must evidently be complemented by one or the other means. Shape is an important feature of high spatial resolution remotely sensed (HSRRS) imagery, and it is the manifestation of textures on such imagery. In this paper, a spatial feature index, pixel shape index (PSI), is proposed in order to describe the shape feature in a local area surrounding a pixel. PSI is a pixel based feature, which measures the gray similarity distance in every direction. As merely the shape feature is inadequate for classification of HSRRS imagery, the spectral bands are added to the input vectors of our classifier. And then a fast fusion algorithm which integrates both shape and spectral features using the support vector machine (SVM) has been developed to interpret the complex input vectors. To test the effectiveness of PSI, some spatial features extracted by wavelet transform (WT), gray level co occurrence matrix (GLCM) are utilized for comparison. Experimental results demonstrate that PSI is capable of describing the shape features effectively and leads to more accurate classifications than other methods, meanwhile the classification algorithm fusing spectral and shape features by SVM is feasible. It is also found that spectral and

收稿日期: 2006 02 28; 修订日期: 2006 07 28

基金项目: 国家自然科学基金(编号: 40471088, 40523005), 973 项目(编号: 2006CB701302)及测绘遥感信息工程国家重点实验室开放基金

项目(编号: 904150695) © 2021 China Academic Journal Electronic Publishing House. All rights reserved. <http://www.cnki.net>

作者简介: 黄昕(1982—), 男, 博士研究生。现主要从事遥感影像模式识别、神经网络原理、遥感应用等方面的研究。E-mail:

xhuang6143@mars.whu.edu.cn

shape features can complement each other and their integration can result in enhanced accuracy.

Key words: PSI; spectrum; SVM; fusion; high spatial resolution

1 引 言

高(空间)分辨率遥感影像能够提供大量的地表特征,同一地物类别内部组成要素丰富的细节信息得到表征,空间信息更加丰富,地物的尺寸、形状及相邻地物的关系得到更好的反映。然而这类新型遥感影像的光谱统计特征不如低分辨率影像稳定,地物空间分布复杂,同类物体呈现出很大的光谱异质性,具体表现为类内方差变大,类间方差减小,不同地物的光谱相互重叠,使得传统的光谱分类方法不能得到满意的结果。因此近年来遥感应用人员提出了很多空间特征算子,以弥补光谱特征的不足。Zhang^[1]利用灰度共生矩阵(GLCM)提取城市的结构信息,取得了比光谱特征更好的效果;Myint^[2]比较了灰度共生矩阵、小波变换、分形特征以及空间自相关在高分辨率影像特征提取中的效果,结果小波变换(Wavelet Transform)取得了最高的精度;李厚强等^[3]用分形理论构造了航空影像的纹理特征,把光谱特征和纹理特征输入BP神经网络,较好解决了具有相似光谱特征地物的区分问题;Benediktsson^[4]用数学形态学构造了多尺度的空间特征剖面,并用神经网络融合空间特征和光谱特征,取得了较高的精度;Segi^[5]用种子点填充和迭代的方式,结合不同地物的形状模板提取高分辨率影像目标的形状特征,取得了较好的形状分类效果。

本文提出一种像元形状指数(Pixel Shape Index, PSD),通过像元及其邻域的光谱相似性描述其上下文的形状分布,然后把归一化后的形状和光谱特征输入支持向量机(SVM)进行分类。文章详细讨论了PSI的构造及其三个参数对分类结果的影响和作用,并用QuickBird多光谱影像实验证明了算法的有效性。

2 算 法

2.1 像元形状指数(PSD)

PSI的设计原则是:(1)利用相邻像元的光谱相似性,目的在于考虑像元的空间上下文特征;(2)使处于相同形状区域内的像元具有相同或相近的特征值,这是为了增强高分辨率影像的同质性,在一定程

度上平滑噪声;(3)尽量拉大不同形状区域像元之间的特征值,这是为了充分利用高分辨率影像的细节特性。

首先定义方向线为穿过中心像元的一系列线段,它们的长度各不相同,其长度由相邻像元间的光谱同质性测度和阈值来确定。图1表示中心像元(Centric pixel)及其邻域像元(Surrounding pixel)所构成的方向线,图中相同灰度的像素处在同一方向线上。




图 1 PSI的方向线

Fig 1 Direction lines of PSI algorithm

形状指数的计算就是基于这一系列方向线的长度,其计算步骤如下,计算流程如图2所示。

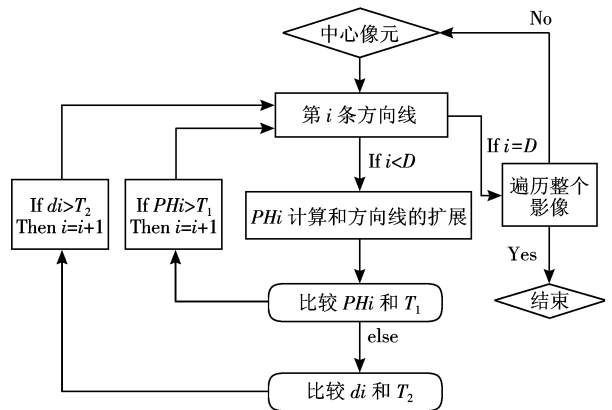


图 2 PSI算法流程图

Fig 2 The flow chart of PSI algorithm

(1) 同质性测度:

$$PH_i(x, y) = \sum_{s=1}^n |p_s^{cen} - p_s^{sur}| \quad (1)$$

式中, $PH_i(x, y)$ 表示当前的邻域像元 (x, y) 在第 i 条方向线上的同质性测度值, p_s^{cen} 表示中心像元在波段 s 上的光谱值, p_s^{sur} 表示当前邻域像元在波段 s 上的光谱值, n 代表波段数。

(2) 方向线的扩展:每条方向线都按照特定的规则从中心像元出发朝两边同时扩展,第 i 条方向线扩展的条件是:(a)当前像元的 $PH_1(x, y)$ 小于阈值 T_1 ;(b)该方向线的总长度小于阈值 T_2 。

(3) 设 D 为一个像元的方向线总数,遍历整个影像,按照 (1) 和 (2) 两步可以分别跟踪得到每个像元的所有 D 条方向线。

(4) 按式 (2) 计算第 i 条方向线的长度:

$$d_i = \max\{|m^{e1} - m^{e2}|, |n^{e1} - n^{e2}|\} \quad (2)$$

式中, (m^{e1}, n^{e1}) 表示该方向线一端的像元坐标行列号, (m^{e2}, n^{e2}) 表示另一端点的行列号。因此得到任意像元 (i, j) 的方向线长度序列: $d(i, j) = [d_1, d_2, \dots, d_D]$ 。

(5) 形状指数的计算是基于像元的方向线序列,PSI 用如下 3 个指标作为像元 (i, j) 的形状指数:

$$\begin{aligned} PSI_1(i, j) &= \sum_{i=1}^D d_i \\ PSI_2(i, j) &= \max(d_1, d_2, \dots, d_D) \\ PSI_3(i, j) &= \min(d_1, d_2, \dots, d_D) \end{aligned} \quad (3)$$

这样,每个像元可得 3 维形状指数特征向量。PSI 共有 3 个参数:光谱相似性阈值 T_1 、空间扩展阈值 T_2 和方向线总数 D 。它们在影像特征提取中承担不同的功能: D 控制方向线的疏密程度和夹角,它表示 PSI 对空间特征描述能力, D 越大,方向线越密集,夹角越小,对邻域形状的探测越准确; T_1 是同质性阈值,它与同一形状区域内像元灰度的变化程度有关; T_2 是空间扩展阈值,表示方向线的最大长度限制,它和影像目标的大小有关。可以预计, D 越大越好,而 T_1 和 T_2 需要结合具体的影像特点灵活设置。式 (1) 是为了简便的探测邻域的光谱相似性,符合 PSI 设计原则的条件 1;式 (2) 用垂直和水平距离计算长度是为了避免欧式距离的浮点计算,且有助于减少同质像元间的特征值差别,符合设计条件 2;式 (3) 用方向线长度的最值和总和作为形状特征向量,是为了体现不同形状区域像元的特征值之差,符合条件 3。

PSI 的出发点是利用邻域灰度相似性来度量上下文的结构信息,这一点和灰度共生矩阵的思想很相似,两者都对光谱空间进行变换,GLCM 把光谱空间变换到共生矩阵空间,PSI 则把光谱空间变换到方向线距离空间,它们的区别在于:(1) GLCM 采用固定窗口操作,而 PSI 取消了窗口设置,且每条方向线的长度都不一样,算法根据不同的结构分布灵活处理,能有效利用影像的各向异性;(2) GLCM 首先

降低影像的灰度级,然后计算灰度值相同的像元个数,PSI 则保留了原始影像的灰度特征,然后用同质性阈值计算灰度值相似的像元个数;(3) GLCM 探测 4 个方向,而 PSI 探测 20 个方向。以上特性使 PSI 在高分辨率影像分类中能比 GLCM 获得更好的效果。

2.2 基于 SVM 的光谱和形状特征融合

近年来遥感学者们提出了很多空间和光谱特征融合的分类方法,主要分为两种:一是多分类器算法^[6],二是单分类器多特征算法^[3,4]。前者主要利用多种分类器的决策层融合,并行处理多元特征,在决策层根据不同特征和分类器的功能进行融合;后者的处理方法是先把不同特征归一化,然后用一个分类器处理混合特征向量。两者各有特点,算法一是特征在决策层融合,能最大限度地利用每个特征的单一处理能力;算法二是在特征层的融合,有效特征的加入使特征空间的维数扩展,也使可分性加强。算法一需要更多的 CPU 时间,算法二对特征的依赖性更强。考虑到高分辨率的海量数据,本文选择单分类器多特征方法。

已有研究利用极大似然, BP, Fisher, ECHO, ARTMAP^[3,6] 等分类器进行多特征融合分类,本文则利用支持向量机 (SVM) 处理多元特征向量。选择 SVM 是考虑到它在小样本、非线性和复杂的高维模式识别问题上表现出的独特优势^[7]。关于 SVM 的原理详见文献 [7]。基于 SVM 的形状和光谱特征融合分类要进行以下设置:

(1) 形状和光谱特征的归一化,其步骤如下,其中 d_{ij} 和 d'_{ij} 分别表示归一化前后的特征值。

$$\begin{aligned} \text{step1:} & \begin{cases} d'_{ij} = \frac{d_{ij} - d_{\min}}{d_{\max} - d_{\min}} \cdot 255 & \text{光谱特征} \\ \text{直方图均衡化} & \text{PSI 特征} \end{cases} \\ \text{step2:} & d''_{ij} = \frac{d'_{ij} - d'_{\max}}{d'_{\max} - d'_{\min}} \cdot 1 \quad \text{所有特征} \end{aligned}$$

所有特征都归一化到 $[0, 1]$ 范围内,以便输入 SVM。

(2) 多类问题:处理多类支持向量机大多通过构造一系列 SVM,每个 SVM 用于识别其中两个类别并将其判别结果组合起来实现多类。本文采用 OAO (One Against One) 策略^[8],该方法在每两类间构建一个分类面,当对一个未知样本分类时,每个 SVM 都要对其进行判别并投票,得票最多的类别即为未知样本的类别。

(3) 核函数的选择,即在多项式核和 RBF 核间

作出选择。由于高分辨率影像地物的类间方差较大,同类地物样本的光谱特征较分散,并非紧紧围绕着某些中心,光谱样本没有明显的中心,样本并无权重大小,而对于 RBF核来说,其对于远离节点中心的输入样本的输出几乎为零,样本根据离中心距离的远近有不同的权重和响应值,然而多项式核却不具有局域性,所以它更适合作为高分辨率影像特征的核函数。

(4) 参数优化:设 C 是正则化参数, p 是多项式核函数的次数,在特征空间中 C 控制着待分模式对决策面的可偏离程度, C 增大时,这种偏离程度增大, C 减小时,可偏离程度减小。本文采用 LOOMS (Leave One Out Model Selection) 算法^[8]自动对 SVM 进行参数优化计。

3 实 验

实验数据选自北京某地 QuickBird 影像的 3 个

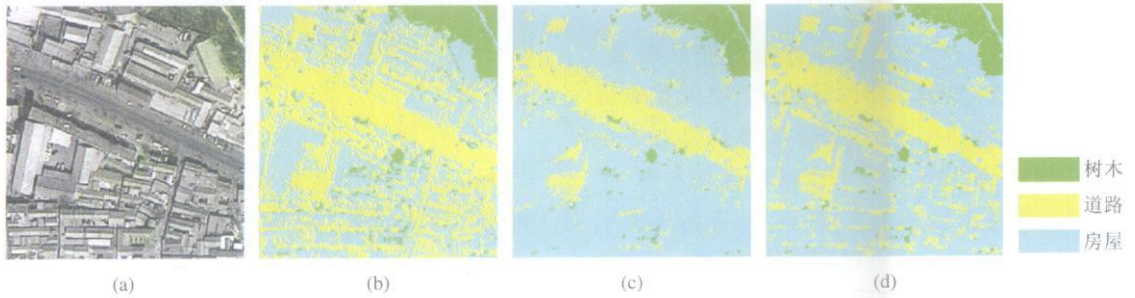


图 3 PSI参数测试影像

(a) RGB 影像; (b) 光谱分类; (c) $D=20, T_1=100, T_2=30$; (d) $D=20, T_1=100, T_2=5$

Fig 3 Testing images for PSI parameters

(a) RGB image (b) Spectral classification (c) classification map of PSI with $D=20, T_1=100, T_2=30$;

(d) classification map of PSI with $D=20, T_1=100, T_2=5$

(1) D 代表方向线的总数,表示 PSI对邻域信息描述的程度。 D 越大,相邻方向线的夹角越小,PSI对邻域形状探测能力更强。图 4 为分类精度 Kappa 系数 (纵轴)和 D (横轴)的关系曲线, D 分别取值 8, 12, 16 和 20,该图说明了 D 在分类中的作用,当它增加时 Kappa 系数的提高很明显。

(2) T_1 表示同质性区域里中心和邻域像元的最大光谱差异,由于高分辨率影像中地物的类内方差较大,且存在光照、阴影和噪声的影响,所以较大的 T_1 在实验中能取得较好的效果,图 5 说明了随着 T_1 的增大, Kappa 系数呈直线上升趋势。

(3) T_2 表示同质性区域里中心和邻域像元的最大空间距离,它的设置对于区分不同形状的地物

可见光多光谱波段,空间分辨率 2 44m。实验目的:一是用来检测 PSI的参数在分类中的作用和影响,二是测试 PSI对传统光谱分类的改进,以及它和其他空间特征算子的比较。

3.1 PSI参数测试

实验区如图 3 (a)所示,由于该实验的目的是测试 PSI的参数,所以实验影像的地物较简单,主要包括房屋、道路和树木。图 3 (b)是采用 RGB三个波段作为输入的 SVM分类结果,图 3 (c)和图 3 (d)是 RGB波段加上 3维 PSI特征输入 SVM的分类结果。

从图 3 (b)可以看出,单独使用光谱特征不能有效区分道路和房屋。受太阳高度角影响,屋顶(人字形)的朝阳面比背光面反射更强,在影像上具有更高的灰度值,而屋顶的阴暗部分和道路的灰度值较接近,因此造成光谱特征的误分。在 PSI形状特征引入到特征空间后,分类得到明显改善。下面分别对 PSI三个参数的功能进行测试。

非常重要, T_2 和 Kappa 的关系如图 6 所示。

当 T_2 从 110 到 30 时,精度曲线缓缓上升到最

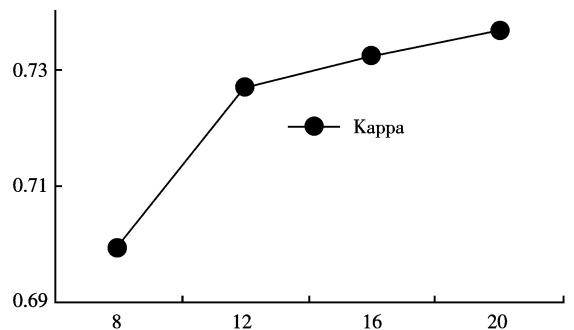


图 4 D 和 Kappa 的关系曲线

Fig 4 Relationship between Kappa coefficient and D

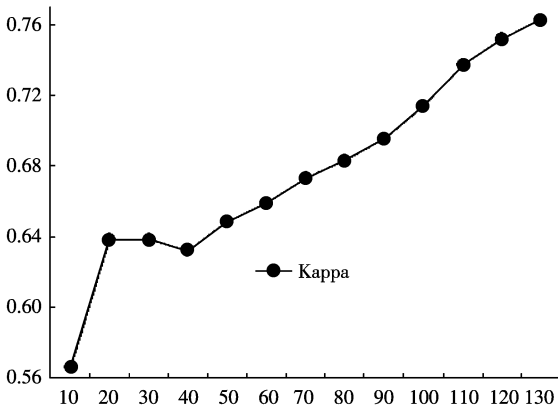


图 5 T₁ 和 Kappa 的关系曲线

Fig 5 Relationship between Kappa coefficient and T₁




图 6 T₂ 和 Kappa 的关系曲线

Fig 6 Relationship between Kappa coefficient and T₂

大值,然后随 T₂ 的减小, Kappa 系数出现很快的衰减。T₂ = 30 和 T₂ = 5 的分类图如图 3 (c) 和图 3 (d) 所示,从图中可以看出,较大的 T₂ 检测出较大范围的地物,如房屋;较小 T₂ 检测出较小尺寸的地物,如房屋间的小路。可见 T₂ 是 PSI 算法的尺度因子,它的设置反映形状检测的目标尺寸。

总的来看, D 一般取 20—24 即可,更大的 D 值不能明显提高精度,但会增加计算时间; T₁ 的理论值应该是取各类样本的类内均方差的平均值,但在实验中可以根据具体情况进行调节; T₂ 是尺度因子,应根据感兴趣地物的大小来确定,也可以利用 T₂ 的变化提取多尺度信息。

3.2 分类比较实验 (1)

为了验证 PSI 算法的有效性,该实验把 PSI 算法和几种常用的空间特征算子进行比较。实验影像如图 7 (a) 所示,该图是一幅典型的北京城区高分辨率影像,老居民区房屋较矮较密集,新社区房屋较高且有草地、树木、花园点缀,道路既有较宽阔的公路,又有花园、房屋间的小路。实验采用的光谱特征是 QuickBird 的 RGB 三个可见光波段,空间特征为 PSI (D = 20, T₁ = 100, T₂ = 50)、小波纹理特征 (WT) 和灰度共生矩阵 (GLCM),为了使空间特征之间具有可比性,实验采用文献 [9] 的算法为每个像元提取 3 维小波纹理特征,用文献 [1] 的算法提取 mean, variance 和 contrast 3 维灰度共生矩阵特征,所有的特征都经过归一化后输入 SVM。图 7 (b) 是经地面调查和全色影像识别后的地面参考数据,其中少量用来训练 SVM,其余的用来测试算法的精度,训练样本和测试样本的数据对比见表 1。图 7 (c) 是输入特征为 3 维光谱波段的分类结果,图 7 (d) 是光谱特征加入 3 维 WT 纹理特征分类的结果,图 7 (e) 是加入 GLCM 特征后的结果,图 7 (f) 是光谱加上 PSI 特征的分类结果,精度评定采用混淆矩阵的 Overall 精度 (OA),见表 2。

表 1 训练和测试像元的个数

Table 1 The number of training and testing pixels

类别	训练样本数	测试像元数
水体	394	18538
树木	362	15492
草地	242	1598
房屋	468	2215
裸地	306	11971
道路	448	2714
阴影	241	22648

表 2 不同特征的分类精度对比

Table 2 The classification accuracies of spatial features with RGB bands

特征	水体	树木	草地	房屋	裸地	道路	阴影	OA
RGB	0.925	0.576	0.576	0.153	0.854	0.879	0.973	0.605
RGB+WT	0.925	0.665	0.586	0.376	0.760	0.857	0.964	0.685
RGB+GLCM	0.926	0.815	0.593	0.701	0.706	0.867	0.980	0.814
RGB+PSI	0.926	0.849	0.606	0.889	0.752	0.847	0.975	0.876

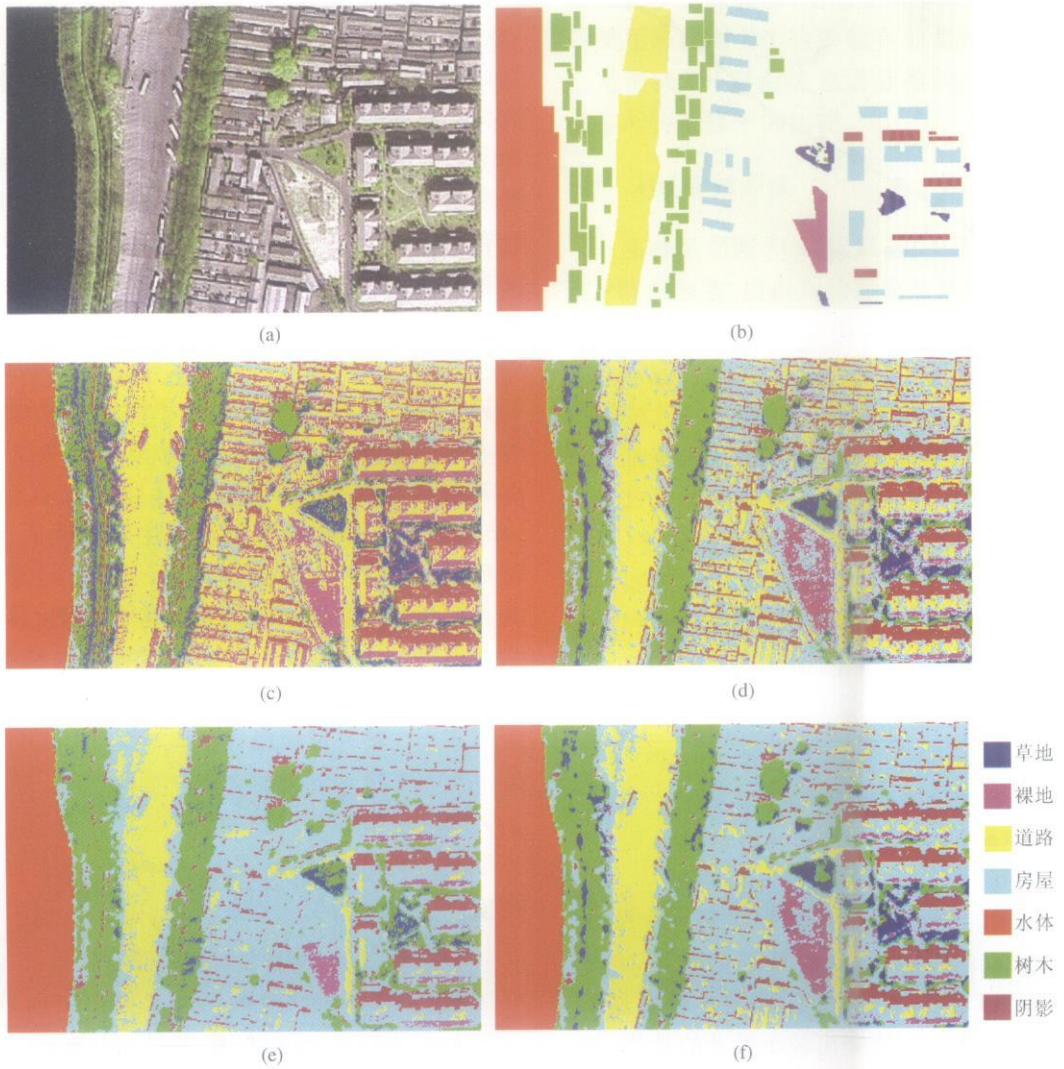


图 7 不同输入特征的分类图比较

(a) 实验区域 RGB 影像; (b) 地面参考数据; (c) 光谱特征分类; (d) WT 特征分类 (文献 [8])
(e) GLCM 特征分类 (文献 [1]); (f) PSI 特征分类

Fig 7 Comparison of classification maps for different input features

(a) RGB image in the experimental area; (b) the reference data; (c) The classification map using spectral features;
(d) The classification map using WT features; (e) The classification map using GLCM; (f) The classification map for PSI

从图 7 (c) — (f) 来看, 光谱特征存在较大的误分现象, 几乎无法区分道路和房屋, 树木和草地, 这是由于其光谱特性很相似, 所以必须引入合适的空间特征。从图 7 和表 2 的结果可知, 空间特征对于高分辨率影像解译是必须的, 各种空间特征都能一定程度地改进分类结果。从表 2 列出的各种地物的分类精度可知, PSI 特征得到的精度最高, 其次是共生矩阵 (GLCM) 和小波变换 (WT)。

3.3 分类比较实验 (2)

为了进一步验证 PSI 算法的适应性, 该实验用另一景 QuickBird 图像进行了测试。

图 8 (a) 为原始影像, 大小 1420×460 像素, 分类结果如图 8 (b) — (d) 所示, 由于小波特征未能取得良好效果, 故没有列出其结果。PSI 的参数设置为: $D = 20$, $T_1 = 130$, $T_2 = 100$, GLCM 仍然采用 mean, variance 和 contrast 3 维灰度共生矩阵特征, 所有的特征都经过归一化后输入 SVM。表 3 是各个地物类别的精度评定, 从该表可知: 光谱分类的结果仍然未能有效区分光谱特征相似的草地—树木和道路—房屋, GLCM 和 PSI 方法能有效改善光谱分类的精度, 而后者的效果更为显著, 草地—树木的平均分类精度: GLCM 比光谱分类提高了 0.003, PSI 则为 0.027; 道路的分类精度提高: GLCM 为 0.025,




图 8 实验 2 的分类特征与结果比较

(a) RGB 影像; (b) 光谱分类结果; (c) GLCM 分类结果; (d) PSI 分类结果

Fig 8 Comparisons of classification features and results for experiment (2)

(a) RGB image (b) classification map for spectral features (c) classification map for GLCM; (d) classification map for PSI

表 3 实验 (2) 的分类精度统计

Table 3 Accuracies statistics for the experiment 2

特征	水体	树木	草地	房屋	裸地	道路	阴影	OA	Kappa
RGB	0.9989	0.7506	0.8122	0.5364	0.9921	0.7955	0.9528	0.7457	0.6818
GLCM	0.9989	0.8358	0.7335	0.5555	0.9862	0.8201	0.9527	0.7864	0.7393
PSI	0.9989	0.8355	0.7820	0.9778	0.9882	0.8216	0.9528	0.8566	0.8234

PSI为 0.04; 对于房屋的分类: GLCM 为 0.191, PSI 则是 0.442。

4 结 论

(1) 本文提出一种像元形状指数 PSI 提取高分辨率影像的结构形状特征。PSI 利用像元邻域的光谱相似性探测其空间形状特征, 用 20 条不同长度的方向线描述中心像元的上下文信息, 并依据这些方向线的长度构造了 3 维 PSI 特征。文中对 PSI 的 3 个参数 D , T_1 和 T_2 进行了测试, 结果表明: 参数 D 和 T_1 的增加有助于分类精度的提高, 而 T_2 则是 PSI 的尺度因子, 它表示 PSI 对目标探测的感兴趣尺度。实验把

PSI 和另两种常用的空间算子灰度共生矩阵 (GLCM) 和小波纹理特征 (WT) 进行了比较, 结果表明 PSI 在高分辨率影像分类上具有一定的优势, 获得了较好的结果。PSI 计算简单, 易于实现, 考虑到高分辨率影像数据量大, 其存储和处理需要更大的空间和更多的时间, 所以 PSI 算法具有较强的实用性。

(2) 本文试验了基于 SVM 的光谱和形状特征融合分类算法, 把形状特征和光谱特征归一化后输入 SVM。实验证明单分类器多特征的方法是可行的, SVM 能有效利用特征空间中的光谱和空间特征, 提高高分辨率影像的分类精度。

(3) PSI 有很多不足之处有待改进: ① 当方向线很长时, 20 条方向线并不能很好地描述像元邻域

的形状特征;② PSI 3 维特征之间的关系需进一步实验;③ 如果每次使用一个 T_2 值,那么 PSI 无法表达多尺度地物,通过采用多个 T_2 设置增加特征空间维度的方式可以弥补 PSI 在尺度表达上的不足,这一点也需要进一步实验。

参 考 文 献 (References)

- [1] Zhang Y. Optimisation of Building Detection in Satellite Images By Combining Multispectral Classification and Texture Filtering [J]. ISPRS Journal of Photogrammetry and Remote Sensing, 1999, 54: 50—60.
- [2] Myint SW, Lan 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.
- [3] Li H Q, Liu Z K, Lin F. Aerial Image Classification Method Based on Fractal Theory [J]. Journal of Remote Sensing, 2001, 5 (5): 353—357. [李厚强,刘政凯,林峰.基于分形理论的航空图像分类方法 [J]. 遥感学报, 2001, 5 (5): 353—357.]
- [4] Benediktsson J A, Palmason J A, Sveinsson J R. Classification of Hyperspectral Data from Urban Areas Based on Extended Morphological Profiles [J]. IEEE Transactions on Geoscience and Remote Sensing, 2005, 43 (3): 480—491.
- [5] Segl K, Reusser S, Heiden U, et al. Fusion of Spectral and Shape Features for Identification of Urban Surface Cover Types Using Reflective and Thermal Hyperspectral Data [J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2003, 58: 99—112.
- [6] Acqua F D, Gamba P, Ferrari A, et al. Exploiting Spectral and Spatial Information in Hyperspectral Urban Data With High Resolution [J]. IEEE Transactions on Geoscience and Remote Sensing Letters, 2004, 1 (4): 322—326.
- [7] Luo J C, Zhou C H, Leung Y, et al. Support Vector Machine for Spatial Feature Extraction and Classification of Remotely Sensed Imagery [J]. Journal of Remote Sensing, 2002, 6 (1): 50—55. 路剑承,周成虎,梁怡等.支持向量机及其遥感影像空间特征提取和分类的应用研究 [J]. 遥感学报, 2002, 6 (1): 50—55.]
- [8] Foody G M, Mathur A. A Relative Evaluation of Multiclass Image Classification by Support Vector Machines [J]. IEEE Transactions on Geoscience and Remote Sensing, 2004, 42 (6): 1335—1343.
- [9] Chen S Q in Q M. The Classification of Texture and Structure in the High Resolution Imagery Based on Wavelet Transform [J]. Geography and Geo-Information Science, 2003, 19 (3): 6—9. 陈杉,秦其明.基于小波变换的高分辨率影像纹理结构分类方法 [J]. 地理与地理信息科学, 2003, 19 (3): 6—9.]