

doi:10.3788/gzxb20144308.0810002

基于纹理特征和形态学特征融合的高光谱影像分类法

王增茂^a,杜博^b,张良培^a,张乐飞^b

(武汉大学 a 测绘遥感信息工程国家重点实验室; b 计算机学院,武汉 430079)

摘要:针对传统融合空间和光谱特征方法仅使用单一空间特征,并未充分利用其双高分辨率的特点,提出了一种基于纹理特征和形态学特征融合的高光谱影像分类方法。首先利用传统主成份分析变换降低高光谱影像的维数,消除空间相关性,然后对每一主成分采用灰度共生矩阵提取纹理特征,获得扩展纹理特征,最后结合形态学特征和部分光谱特征进行高光谱影像的分类。实验证明,本文提出的方法能更好地克服传统光谱特征分类的局限性,提高高光谱影像的分类准确度。

关键词:主成分分析; 形态学特征; 纹理特征; 高光谱; 灰度共生矩阵

中图分类号:TP751 文献标识码:A

文章编号:1004-4213(2014)08-0810002-8

Based on Texture Feature and Extend Morphological Profile Fusion for Hyperspectral Image Classification

WANG Zeng-mao^a, DU Bo^b, ZHANG Liang-pei^a, ZHANG Le-fei^b

(a. State Key Laboratory of Information Engineering in Surveying, Mapping and Remote Sensing,

b. School of Computer Science, Wuhan University, Wuhan 430079, China)

Abstract: Single spatial feature is used in the traditional spectral and spatial feature fusion, which does not make full use of the advantage of high spectral and spatial resolution. In order to overcome the shortage, a method based on texture feature and extend morphological profile fusion for hyperspectral image classification was proposed. Firstly, with the principle component analysis, the hyperspectral image dimension was reduced and the spatial correlation was eliminated, then using the gray level co-occurrence matrix the texture features for each principle component were extracted and the extend texture features were got, lastly combined the extend morphological profile and part spectral features hyperspectral image is classified. The experiments show that the proposed method can overcome the limitation of traditional spectral feature classification and improve the accuracy of hyperspectral images classification.

Key words: Principle component analysis; Extend morphological profile; Texture feature; Hyperspectral; Gray level co-occurrence matrix

OCIS Codes: 100.2000; 100.5010; 110.4234; 100.2960; 110.2960

基金项目:国家重点基础研究发展计划(Nos. 2012CB719905, 2011CB707105)、国家自然科学基金(No. 61102128)、中国博士后科学基金(No. 211-180788)和湖北省自然科学基金(No. 2011CDB455)资助

第一作者:王增茂(1990—),男,硕士研究生,主要研究方向为高光谱遥感影像分类. Email: 862464835@qq.com

导师(通讯作者):杜博(1983—),男,副教授,博士后,主要研究方向为光学影像与信息处理、高光谱遥感、模式识别. Email: gunspace@163.com

收稿日期:2013-11-19; **录用日期:**2014-03-06

<http://www.photon.ac.cn>

0 引言

相对于普通的遥感影像,高光谱影像光谱分辨率很高,能提供更多的光谱信息、具有“图谱合一”的特点。随着传感器和成像技术的发展,高光谱分辨率和高空间分辨率的双高影像日益丰富。双高遥感数据包含了丰富的空间和光谱等信息,为遥感影像分类提供了多类型特征。双高影像的分类研究已经成为高光谱遥感影像处理领域的研究热点。

高空间分辨率高光谱影像的分类方法有:1)对高光谱影像先降维再进行分类^[1-5]。主要包括特征提取和特征选择,如 Bor-Chen Kuo 和 David A. Landgrebe 提出非参数权重特征提取(Nonparametric Weighted Feature Extraction,NWFE)法,先进行特征选择,然后进行影像分类^[4]; Hsiao-Yun 等提出了双最近比例法(Double Nearest Proportion,DNP)进行特征提取,然后进行分类^[6]; B. Du, L. Zhang, L. Zhang 等基于流形学习对高光谱影像进行降维和分类^[7-8]; Mustafa Teke 等提出了增强 Fisher 判别准则(Enhanced Fisher Discriminant Criterion, EFDC)进行特征提取和分类^[9]; Md. Ali Hossain 等提出了归一化互信息(Mutual Information, NMI)方法进行特征选择和分类^[10]。特征提取和选择可以有效的降低高光谱数据的维数,避免了“Huge”现象,但是损失了部分的光谱信息而且没有其它新的特征形成。2)基于核函数方法^[11]。首先将高光谱数据通过核函数(如线性核函数,多项式核函数,高斯核函数等)映射到高维空间,然后在高维空间进行特征提取再进行分类。如 Kuo Bor-Chen 等使用基于核函数的非参数权重(Kernel Nonparametric Weighted Feature Extraction, KNWFE)进行高光谱分类^[12]; G. Licciardi 等使用基于核的主成分分析(Kernel Principle Component Analysis, KPCA)进行了高光谱影像的分类^[13]等。基于核函数的方法提高了分类准确度,但是进行核变换时核矩阵的大小等于像元的个数,运算效率比较低。3)基于空间和光谱特征融合的高光谱影像分类方法。形态学特征与光谱特征融合取得了较好的分类结果^[14-16]。Gabor 纹理等空间特征与光谱信息融合在高光谱影像的分类结果中也取得了较高的准确度^[17-18]。Mathieu Fauvel 等提出了扩展形态特征(Extend Morphological Profile, EMP)和光谱特征融合用于双高影像分类,结果优于传统分类方法^[19]。Aytekin Orsan 等提取了差分形态轮廓(Differential Morphological Profiles, DMPs)与光谱特征融合用于双高影像分类^[20]。Rongrong Ji 等提出了空间光谱约束的方法进行高光谱影像的分类^[21]。综上可知,空间和光谱特征融合方法是双高影像分类中的研究热点。但是,现有方法主要集中于光谱特征的提取和选择,对空间

特征的提取融合主要集中于 Gabor、EMP 等单一特征^[17-22],并未充分利用其丰富的空间信息。

针对上述问题,本文提出了一种融合纹理特征和形态学特征(Extend Morphological Profile, EMP)的双高影像分类算法,充分利用纹理信息和形态学特征的互补性提高影像的分类准确度。由于高光谱波段数众多,波段间的空间相关性很大,因此本文对原始的高光谱影像进行主成分分析,降低波段维数,得到空间无关的主成分,每一主成分作为新的影像波段,分别提取形态学特征和纹理特征,将每一主成分提取的形态学特征和纹理特征融合作为分类器的输入特征,使用 C-SVM 进行分类。实验证明本文的方法提高了分类准确度。

1 基于纹理特征和形态学特征融合的高光谱影像分类

1.1 主成分分析

主成分分析(Principal Component Analysis, PCA),又称 K-L 变换,是寻求有效的线性变换的经典方法之一。其目的是在最小均方意义上寻找最能代表原始数据的投影方向,从而达到对特征空间降维的目的^[23]。主成份分析是影像在低维空间优化的表达。

假设 $\mathbf{X}_1, \mathbf{X}_2, \dots, \mathbf{X}_n$, ($\mathbf{X}_i = [x_1, x_2, \dots, x_p]^T, i=1, 2, \dots, n$) 为输入样本点,则其协方差矩阵

$$\mathbf{C} = \frac{1}{n} \sum_{i=1}^n \mathbf{X}_i \mathbf{X}_i^T \quad (1)$$

主成份分析的主要问题就是求解特征值

$$\lambda_i \mathbf{\mu}_i = \mathbf{C} \mathbf{\mu}_i, i=1, 2, \dots, n \quad (2)$$

式中, \mathbf{C} 为样本协方差矩阵, λ_i 为 \mathbf{C} 的一个特征值, $\mathbf{\mu}_i$ 为相应的特征向量。由上式计算 \mathbf{C} 的非零特征值 λ_i 和特征向量 $\mathbf{\mu}_i$,选取求得的 λ 对应的特征向量 $\mathbf{\mu}$ 。依据下式对原始数据进行重建。

$$\mathbf{S} = \mathbf{\mu}^T \mathbf{X} \quad (3)$$

主成分分析是影像降维中常用的方法之一,经过主成分变换后的影像,其绝大部分的信息集中在特征值 λ 较大的映射方向上,因此将特征值按照从大到小排列,选取贡献率大于 95% 的前几个特征值对应的特征向量,依据上式获取变换后的主成分,一般前两个或前三个特征值的贡献率大于 95%,本文实验选取的是前三个主成分。

1.2 基于数学形态学特征提取

数学形态学是一种非线性的影像处理理论^[24-25],主要是以一个已知大小和形状的结构元素^[26]来分析影像中象元间的空间关系。其基本运算包括腐蚀、膨胀、开运算、比运算,而其他的运算都是基于这四种运算。

腐蚀的定义为

$$\gamma_B(I) = \delta_B \circ \epsilon_B(I) \quad (4)$$

膨胀的定义为

$$\varphi_B(I) = \epsilon_B \circ \delta_B(I) \quad (5)$$

开运算的定义为

$$\epsilon_B(I(x)) = \min_{x_i} (I(x_i) \in B_X) \quad (6)$$

闭运算的定义

$$\delta_B(I(x)) = \max_{x_i} (I(x_i) \in B_X) \quad (7)$$

式中: I 为待处理的影像, B 为结构元素, B_X 为结构元素 B 在象元 x 处的中心值.

从式(4)~(7)可以看出腐蚀即为结构元素中的最小值,膨胀与腐蚀相反为结构元素中的最大值.而开运算是先腐蚀后膨胀、闭运算是先膨胀后腐蚀的过程.使用这些基本形态运算提取空间特征,在文献[14]中提出了形态轮廓的概念

$$MP^{(n)}(I) = [\varphi^{(n)}(I), \dots, \varphi_r^{(n)}(I), I, \gamma_r^{(n)}(I), \dots, \gamma_r^{(n)}(I)] \quad (8)$$

式中: n 为开运算和闭运算的次数, I 为待处理的全波段影像, φ 为闭运算, γ 为开运算.

由于高光谱影像波段众多,文献[19]中提出了扩展形态特征(Extend Morphological Profile,EMP),即通过降维来提取部分主要成分的形态轮廓特征

$$EMP_m^{(n)}(I) = [MP_1^{(n)}(I), \dots, MP_m^{(n)}(I)] \quad (9)$$

式中, m 为降维后的维数.

形态特征中既包含了原有的光谱信息,也含有通过形态学运算提取的空间特征.数学形态学是形态学特征提取的理论依据,它主要是利用结构元素的几何模板探测影像中的形状信息.结构元素有大小和形状等属性,如圆形、方形等,因此结构元素的选取对特征提取的结果也有影响.定义一个结构元素,对某一波段每进行一次开运算或闭运算即得到一种形态特征.本文依据文献[19]建立半径为 2 的圆形结构元素,对式(3)得到的某一主成分进行四次开运算和四次闭运算得到这一主成分的形态特征(Morphological Profile,MP),对每一主成分进行同样的形态运算,得到最后的扩展形态特征.

1.3 基于灰度共生矩阵的理特征提取

高光谱影像不仅含有丰富的光谱和空间信息,同样也含有丰富的纹理信息.纹理特征提取的方法有很多,有基于统计特征、基于空间频率、基于结构、基于模型等方法^[27].基于统计的纹理方法中,纹理被视为相邻像元或相邻区域内几何位置等相互关系的表征.灰度共生矩阵通过计算影像各像元灰度级之间的联合条件概率密度表示纹理,反映了图像中任意两点灰度的相关性和纹理特征的统计性质.

灰度共生矩阵(Gray Level Co-occurrence Matrix,GLCM)描述了图像域范围内,两个距离为 d ,方向为 θ ($0^\circ, 45^\circ, 90^\circ, 135^\circ$) 的像元在图像中出现的概率,通过 (d, θ) 值可以组合许多的共生灰度矩阵来分析图像灰度级别的空间分布格局^[28].灰度共生矩阵为一对称矩

阵,如果 $\Delta x, \Delta y$ 相对纹理的粗糙度很小,则矩阵中元素值集结在对角线附近.反之,元素值将离开主对角线向外扩散.其意义是,细纹理灰度空间变化很快,粗纹理随距离增大仅有细微变化. Haralick 等人由灰度共生矩阵提取了近 14 种特征,常见的描述影像纹理特征的统计属性有

二阶矩

$$f_1 = \sum_{i=0}^{L-1} \sum_{j=0}^{L-1} p^2(i, j) \quad (10)$$

二阶矩反映了图像灰度分布均匀程度和纹理粗细程度.它是灰度共生矩阵各元素的平方和,又被称为能量. f_1 越大,纹理越粗,能量越大,反之,纹理则越细,能量则小.

对比度

$$f_2 = \sum_{n=0}^{L-1} n^2 \{ \sum_{i=0}^{L-1} \sum_{j=0}^{L-1} p(i, j) \} \quad (11)$$

对比度反映了图像的清晰度和纹理沟纹深浅的程度.对比度大,纹理的沟纹深,效果清晰;反之,对比度小,则沟纹浅,效果模糊.

均值

$$f_3 = \sum_{i=0}^{L-1} \sum_{j=0}^{L-1} p(i, j) * i \quad (12)$$

均值反映了纹理的规则程度,纹理杂乱无章难以描述的值越小;规律性强、易于描述的,值越大.

熵

$$f_4 = - \sum_{i=0}^{L-1} \sum_{j=0}^{L-1} p(i, j) \log_2 p(i, j) \quad (13)$$

熵是图像具有信息量的度量,纹理信息也属于图像的信息,是一个随机性的度量,当灰度共生矩阵中所有元素有最大的随机性、灰度共生矩阵中所有值几乎相等时,共生矩阵中元素分散分布时,熵较大.它表示图像中纹理的非均匀程度或复杂程度.若图像没有任何纹理,则灰度共生矩阵几乎为零阵.它反映图像中纹理的复杂程度或非均匀度.若纹理复杂,则说明纹理信息多,熵值大;反之,若图像中灰度均匀,则熵值小.则第 m 波段影像的四种纹理属性可表示为

$$f_m^{(n)} = [f_1, f_2, f_3, f_4] \quad (14)$$

传统使用灰度共生矩阵提取纹理更多的是针对全色波段影像或者多光谱影像降维后的第一主成分^[28-29],但是对于双高影像而言更多的是 Gabor 纹理等^[17-18],本文将灰度共生矩阵应用于双高影像的纹理特征提取.对于高光谱影像空间相关性很大,信息量也大,做主成分分析后,其大量的结构信息并不能完全在第一主成分得到表达,为了弥补光谱信息的不足,充分的提取纹理特征,本文提出了扩展纹理特征,即对主成份分析降维后的每一维进行纹理特征的提取.假设主成份分析降维后的维数为 m ,得到扩展纹理特征为

$$F = [f_1^{(n)}, f_2^{(n)}, \dots, f_m^{(n)}] \quad (15)$$

式中: F 为扩展纹理特征, m 为降维后的维数, n 为纹理特征的属性个数, $f_m^{(n)}$ 为第 m 维的纹理特征.本文对影

像降维后的每一主成分提取常用的四种纹理信息即二阶距、对比度、均值、熵，获取扩展纹理特征。由于本文选取的是前三个主成分，因此其纹理的维数为 12。

1.4 特征融合

双高影像含有丰富的光谱信息和空间信息，仅使用光谱信息或空间信息都会造成信息损失。为此，本文提出的方法需要将光谱信息和空间信息进行融合。文献[19]提出了数据融合的方法，将空间特征和光谱特征结合起来作为分类器的输入量。特征融合的方式有堆叠融合和复合核函数融合^[25]。

1.4.1 向量堆叠融合

假设 x_{spec} 为光谱特征， x_{spat} 为与扩展纹理特征和扩展形态特征相关的特征，则有特征融合表达式为

$$\gamma = [\varphi_{\text{spec}}^T x_{\text{spec}}, \varphi_{\text{spat}}^T x_{\text{spat}}] \quad (16)$$

式中， γ 为融合特征， φ 为提取特征线性映射矩阵。

1.4.2 复合核函数融合

与堆叠融合方式不同，复合核函数融合借助核函数将光谱特征和空间特征融合起来。其表达式为

$$K_{\sigma, \mu}(x, z) = (1 - \mu)k_{\sigma}^{\text{spat}}(\gamma_x, \gamma_z) + \mu k_{\sigma}^{\text{spect}}(x, z) \quad (17)$$

式中， σ 为高斯核函数中的参数， μ 为空间特征权重，可以通过交叉检验的方法获取。

$$K_{\sigma}(X, Z) = \exp\left(-\frac{\|X - Z\|^2}{2\sigma^2}\right) \quad (18)$$

本文采用的是式(16)的方式进行特征融合，将式(3)主成分分析结果与形态学特征和纹理特征融合，得到分类的融合特征 γ 。对于影像中的每一点象元，以象元的融合特征代替光谱特征作为分类特征，输入到分类器。本文使用的是 C-SVM 分类器，核函数为常用的高斯核函数，C-SVM 是多类分类器，其中 C 是正则系数， C 的取值范围是 $[0, \infty]$ ，C-SVM 对于多类的分类有很好的区分效果和容错率。C-SVM 中有两个参数 C 和 g ， g 为核函数参数，本文 C 和 g 的最优选择是使用 10 倍交叉检验的方法获取的，即选取训练样本通过组合不同的 C 和 g 比较其分类准确度，准确度最大时即为 C 和 g 的最优值。最后选用最优的模型参数得到最优的模型对高光谱影像进行分类。

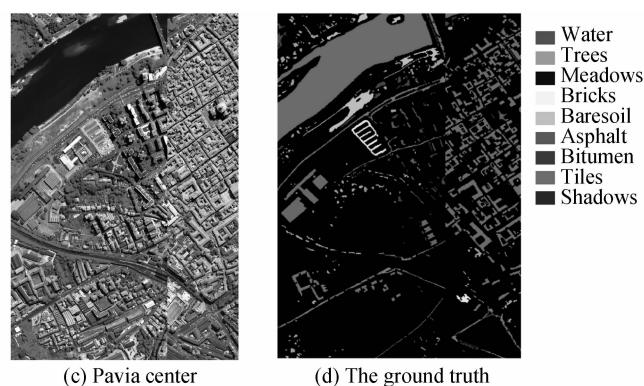
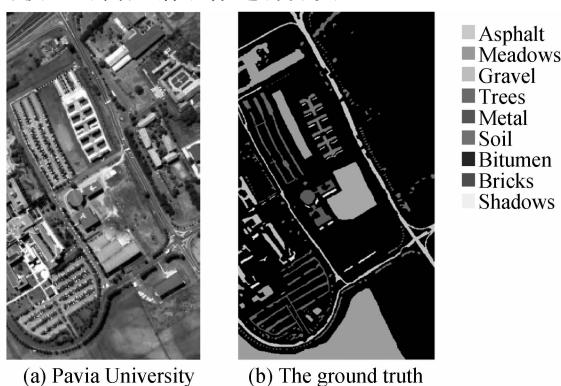


图 2 实验数据

Fig. 2 Experiment dataset

本文方法分类完整流程图为

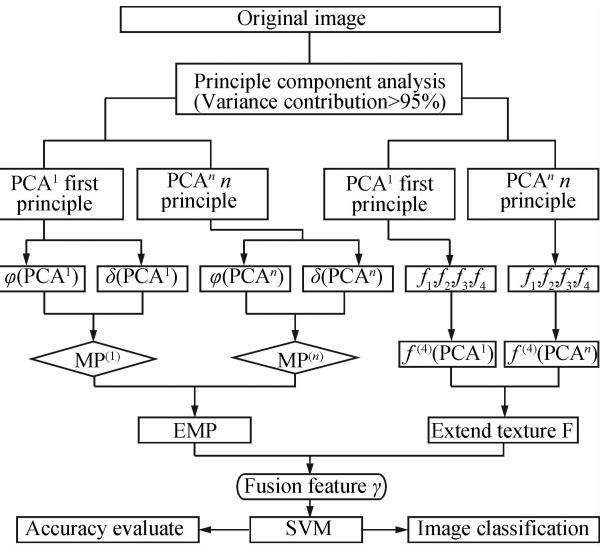


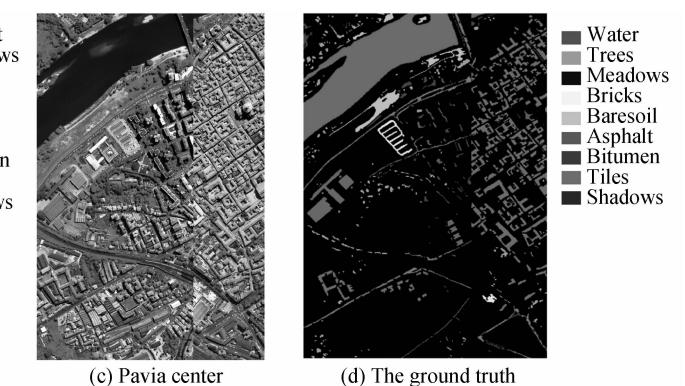
图 1 本文算法流程

Fig. 1 Flow Chat of Algorithm

2 实验与讨论

2.1 实验数据

为验证本文的方法，选取了同时由 ROSIS-3 (Reflective Optics System Imaging Spectrometer) 获得的 Italy Pavia 大学的高光谱影像和 Pavia Center 的高光谱影像作为实验区，ROESIS-3 是航空光学成像光谱仪，波段范围涵盖了可见光和近红外频道：0.43 ~ 0.86 μm，空间分辨率为 1.3 m，光谱分辨率为 10 nm。ROESIS-3 获取的 Pavia 大学的原始波段数为 115，由于其中 12 个波段的噪声大，最终选择其中的 103 个波段，大小为 610 × 340。Pavia Center 的原始数据大小为 1 096 × 1 096，中间有一段 381 像素宽的条带被删除，因此产生了一个 1 096 × 715 的两部分影像的组合。ROESIS-3 获取的 Pavia Center 数据集的波段数为 102。图 2 给出了两幅影像的彩色影像，(a) 为 Pavia 大学的彩色数据，(b) 为 Pavia 大学的地面参考数据，(c) 为 Pavia Center 的彩色影像，(d) 为 Pavia Center 的地面参考数据。



(c) Pavia center: A grayscale aerial photograph showing a residential and industrial area of Pavia. To its right is a corresponding binary ground truth map.

(d) The ground truth: A binary map showing the segmented land cover categories for the Pavia center area.

Legend:

- Water
- Trees
- Meadows
- Bricks
- Baresoil
- Asphalt
- Bitumen
- Tiles
- Shadows

2.2 实验结果及讨论

2.2.1 Pavia 大学数据

对 Pavia 大学 103 个波段进行主成份分析,选取前三个主成份(方差贡献率大于 95%),对每一主成份进行形态学空间特征提取和纹理特征提取,使用 LibSVM 进行分类。形态学特征提取选取的结构元素为半径为 2 的圆形区域,纹理特征提取方法为灰度共生矩阵,选取的统计量为常用的均值、熵、对比度及二阶矩等属性。对于 C-SVM 中核函数的参数 C 和 g , C 为 SVM 的惩罚因子, g 为 SVM 中高斯核函数的参数值,本文使用了 10 倍交叉检验方法得到了参数最优值,其最优参数值如表 2。表 1 给出了影像的训练样本个数、检验个数及分类数量。图 3 中给出了训练区域的分类准确度对比。

表 1 Pavia University 高光谱影像的类别和样本

Table 1 Train and Test samples of Pavia University

No	Name	Train	Test
1	Asphalt	248	6 206
2	Meadow	240	16 123
3	Gravel	192	1 880
4	Tree	224	2 933
5	Metal sheet	265	1 345
6	Bare Soil	232	5 029
7	Bitumen	175	1 330
8	Brick	214	3 682
9	Shadow	131	947
Total		1921	39 475

表 2 Pavia University C 和 g 参数最优值

Table 2 Optimal parameters of C & g

	C	g
Spectral	48.502 9	1
Spectral+EMP	16	1
Spectral+Texture	256	0.006 8
PCA-EMP+Texture	256	0.006 8

为了验证本文方法,进行了四组不同特征融合的实验。图 3 显示了分类的准确度,其中 AA(Average Accuracy)为平均准确度,OA(Over All)为总的分类准确度,Kappa 为分类 Kappa 准确度。图 4 显示了 Pavia 大学数据的四组实验结果,(a)为光谱特征的分类结果,(b)为光谱特征结合形态学特征的分类结果,(c)为光谱特征和纹理特征结合的分类结果,(d)为本文的主成份分析结合形态特征和纹理特征的分类结果。从图 4 中可以看出,传统特征的分类中,对噪声比较敏感,分类结果中有很多细小斑点,导致被分类区域较为破碎。与之相对照,本文的融合特征分类结果中每类地物的斑块则比较完整,具有很强的抗噪能力。草地、道路、房屋等面状地物具有明显的纹理特征,纹理特征和形态学特征的融合使这些同质区域在分类中取得了很好的分类效果。传统分类注重的是单像元的分类或其单

一的空间特征,这使得同质区域在特征空间上有很小的相似度,容易产生噪声。可见,增加融入空间特征的数量可以提高分类准确度。

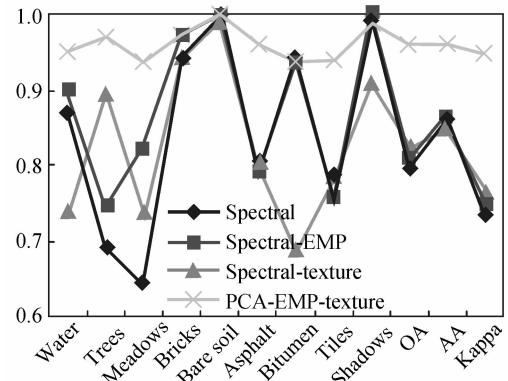


图 3 不同特征融合的分类准确度对比

Fig. 3 The classification of the different characteristics of fusion accuracy

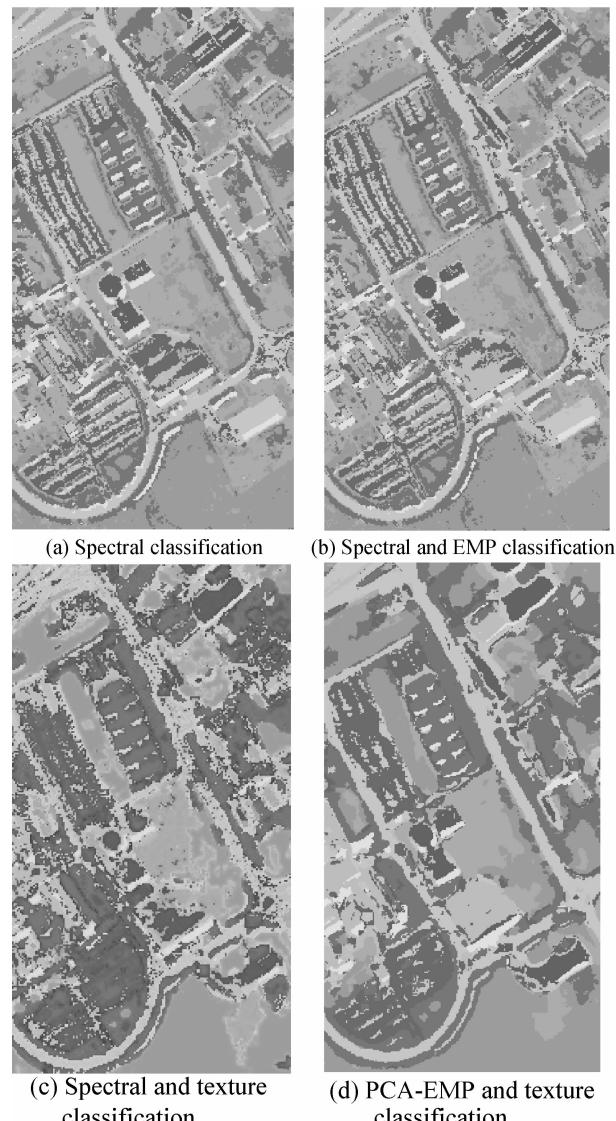


图 4 Pavia University 分类结果

Fig. 4 The classification results of Pavia University

3.2.2 Pavia Center 数据

为了进一步说明本文方法的可靠性,对Pavia Center数据同样进行主成份分析,取前三个主成份为降维后数据(方差贡献率大于95%).采用同样的方法提取影像形态学特征和纹理特征,以及分类器的最优参数,其最优参数值如表4,使用Lib-SVM进行分类.表3为Pavia Center数据的类别数量以及训练/测试样本数.表5为分类结果的准确度评价,图5为不同融合特征的准确度对比.图6显示了影像的分类结果.

表3 Pavia Center高光谱影像类别和样本

Table 3 Train and Test samples of Pavia Center

No	Name	Train	Test
1	Water	248	64 215
2	Trees	240	7 332
3	Meadows	192	2 712
4	Bricks	224	2 685
5	Bare Soil	265	6 559
6	Asphalt	210	9 064
7	Bitumen	150	7 287
8	Tiles	180	41 717
9	Shadows	240	2 842
Total		1 949	144 413

表4 Pavia Center C 和 g 参数最优值

Table 4 Optimal parameters of C & g

	C	g
Spectral	48.502 9	1
Spectral+EMP	16	1
Spectral+Texture	256	0.006 8
PCA-EMP+Texture	256	0.006 8

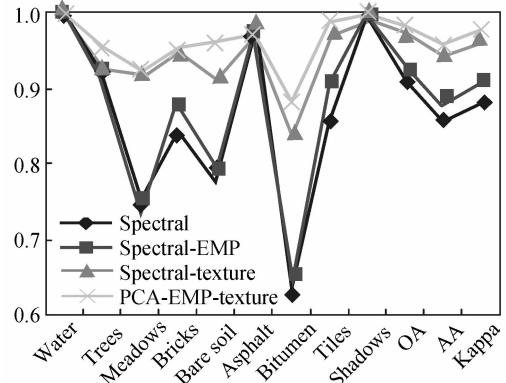


图5 不同特征融合的分类准确度对比

Fig. 5 The classification accuracy of different features fusion

表5 Pavia Center高光谱影像分类结果

Table 5 The classification results of Pavia Center

	Spectral	Spectral-EMP	Spectral-Texture	PCA-EMP-Texture
Water	0.993 0	0.993 2	0.992 8	1.000 0
Trees	0.913 3	0.922 2	0.922 2	0.953 6
Meadows	0.756 7	0.759 9	0.922 7	0.912 9
Bricks	0.836 5	0.879 0	0.950 8	0.939 3
Bare Soil	0.772 7	0.798 4	0.905 2	0.958 5
Asphalt	0.975 4	0.979 9	0.958 4	0.966 8
Bitumen	0.627 7	0.665 6	0.837 2	0.884 3
Tiles	0.853 1	0.901 4	0.972 6	0.983 5
Shadows	0.995 5	0.989 5	0.989 2	0.992 0
OA	0.911 9	0.930 4	0.967 3	0.980 1
AA	0.858 2	0.876 6	0.939 0	0.954 5
Kappa	0.877 2	0.902 5	0.954 0	0.971 9



(a) Spectral classification



(b) Spectral and EMP classification



(c) Spectral and texture classification



(d) PCA-EMP and texture classification

图6 Pavia Center分类结果

Fig. 6 The classification results of Pavia Center

如图 6 所示,(a)为光谱特征分类结果,(b)为光谱结合形态学特征的分类结果,(c)为光谱结合纹理特征的分类结果,(d)为本文的主成分分析结合形态学特征和纹理特征的分类结果.从直观上可以看出(d)中的房屋分类效果明显优于传统特征的分类结果.如图 6 中圆形标记区域,在原始影像上,此处有少量云覆盖,在传统特征的分类将其错误分离出来.而在(d)中得到正确的分类.又如三角标记区域在传统特征分类中,都将其错误的归为同一类.而在(d)中其分类结果与地面参考区域保持一致.(d)中道路结果有很好的细化,纹理相对比较清晰.从图 3 准确度对比中可以看出,空间信息的融入提高了分类准确度.这是由于“同物异谱,异物同谱”现象的影响,单一的光谱分类不能很好地区分地物类别.空间特征的融入是对光谱特征的约束.从表 5 可以看出,融入空间特征后其分类准确度有很大程度的提高.可见,更多空间特征融入对光谱特征有很好的约束,可以提高分类准确度.

3 结论

本文在双高影像传统特征分类方法分析的基础上,提出了一种基于纹理特征和形态学特征的高光谱影像分类方法.算法上,首先对高光谱影像降维处理,本文使用的是目前在高光谱影像降维中常用的主成分分析,消除波段间的相关性,得到空间无关的主成分.然后对每个主成分提取形态特征和纹理特征,由于每个主成分之间没有相关性,因此提取的特征之间无相关性,得到扩展纹理特征和扩展形态特征.然后将这些空间无关的特征融合,得到分类融合特征.再使用交叉检验的方法获取 C-SVM 的最优参数,最后采用最优的分类模型对双高影像进行分类.实验表明:1)与传统的光谱特征方法相比,本文方法具有很好的抗噪能力,分类结果噪声小,对同质地物有很好的分类效果.2)与传统的融合单一空间特征方法相比,本文方法提高了空间约束,很大的提高了分类准确度.3)光谱空间中融合多种空间特征能够有效的克服光谱空间在分类中的不足,可以提高分类准确度.

参考文献

- [1] JOLLIFFE I. Principal component analysis [M]. New York: Springer-Verlag, 1986.
- [2] ZUBKO V, KAUFMAN Y J, BURG R I, et al. Principal component analysis of remote sensing of aerosols over oceans [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2007, **45**(3):730-745.
- [3] BANDOS T V, BRUZZONE L, CAMPS-VALLS G. Classification of hyperspectral images with regularized linear discriminant analysis[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2009, **47**(3):862-873.
- [4] KUO B C, LANDGREBE D A. Nonparametric weighted feature extraction for classification[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2004, **42**(5):1096-1105.
- [5] LANDGREBE D A . Signal theory methods in multispectral remote sensing[M]. Hoboken,NJ:Wiley,2003.
- [6] HUANG H Y, KUO B C. Double nearest proportion feature extraction for hyperspectral-image classification [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2010, **48**(11): 4034-4046.
- [7] DU Bo, ZHANG Liang-pei, ZHANG Le-fei. A discriminative manifold learning based dimension reduction method for hyperspectral classification [J]. *International Journal of Fuzzy Systems*, 2012, **14**(2), 272-277.
- [8] DU Bo, ZHANG Le-fei, ZHANG Liang-pei . Discriminnt manifold learning approach for hyperspectral image dimention reduction[J]. *Atca Photonica Sinica*, 2013, **42**(3):320-325. 杜博,张乐飞,张良培,等.高光谱图像降维的判别流形学习方法,光子学报,2013,**42**(3):320-325.
- [9] MUSTAFA T, UFUK S. Classification on hyperspectral images using enhanced fisher discriminant criterion[C]. 2013 21st Signal Processing and Communications Applications Conference,2013.
- [10] HOSSAIN M, JIA X, PICKERING M. Improved feature selection based on a mutual information measure for hyperspectral image classification [C]. 2012 IEEE International Geoscience and Remote Sensing Symposium. 2012:3058-3061.
- [11] JIA X, KUO B C, CRAWFORD M M. Feature mining for hyperspectral image classification [J]. *Proceedings of the IEEE*, 2013, **101**(3) ,676-697.
- [12] KUO B C, LI C H, YANG J M. Kernel nonparametric weighted feature extraction for hyperspectral image classification [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2009, **47**(4):1139-1155.
- [13] LICCIARDI G, MARPU P R, CHANUSSOT J, et al. Linear versus nonlinear PCA for the classification of hyperspectral data based on the extended morphological profiles [J]. *Geoscience and Remote Sensing Letters, IEEE*, 2012, **9**(3): 447-451.
- [14] PESARESI M, BENEDIKTSSON J A. A new approach for the morphological segmentation of high-resolution satellite imagery[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2001, **39**(2):309-320.
- [15] PALMASON J A, BENEDIKTSSON J A, SVEINSSON J R, et al. Fusion of morphological and spectral information for classification of hyperspectral urban remote sensing data[C]. Proceedings of the Geoscience and Remote Sensing , Symposium2006(IGARSS'06),2006:2506-2509.
- [16] PALMASON J A, BENEDIKTSSON J A, SVEINSSON J R, et al. Classification of hyperspectral data from urban areas using morpholgical preprocessing and independent component analysis[C]. *International Geoscience And Remote Sensing Symposium*. 2005, **1**: 176.
- [17] SHEN Lin-lin , JIA Sen. Three-dimensional gabor wavelets for pixel-based hyperspectral imagery classification[J]. *IEEE Transactions on Geoscience and Remote Sensing* ,2011, **49**(12) ,5039-5046.
- [18] ZHU Ze-xuan, SHEN Lin-lin, SUN Yi-wei, et al. Memetic three-dimensional gabor feature extraction for hyperspectral imagery classification[M]. Advances in Swarm Intelligence. Springer Berlin Heidelberg,2012:479-488.
- [19] FAUVEL M, BENEDIKTSSON J A, CHANUSSOT J, et al. Spectral and spatial classification of hyperspectral data using SVMs and morphological profiles[J]. *IEEE Transactions on Geoscience and Remote Sensing* ,2008, **46**(11):3804-3814.

- [20] AYTEKIN O, MURA M D, ULUSOY I, *et al.* Classification of hyperspectral images based on weighted DMPS [C]. Geoscience and Remote Sensing Symposium (IGARSS), 2012 IEEE International, 2012:4154-4157.
- [21] JI Rong-rong, GAO Yue, HONG Ri-chang, *et al.* Spectral-spatial constraint hyperspectral image classification[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2014, **52**(3): 1811-1824.
- [22] FAUVEL M. Advances in spectral-spatial classification of hyperspectral images[J]. *Proceedings of the IEEE*, 2013, **101**(3), 652-675.
- [23] DUDA R O, HART P E. Pattern classification and scene analysis[M]. New York: Wiley, 1973.
- [24] SERRA J. Image analysis and mathematical morphology[M]. Volume 2: Theoretical Advances. London, U. K. : Academic, 1988.
- [25] SERRA J. Image analysis and mathematical morphology[M]. London, U. K. : Academic, 1982.
- [26] SOILLE P. Morphological image analysis: principles and applications[M]. Springer-Verlag New York, Inc. , 2003.
- [27] HU Hai-xu, WANG Wen. Based on texture feature and mathematical morphology for high-resolution images of city road extraction[J]. *Geography and Geo-Information Science*, 2008, **6**(24), 47-49.
胡海旭,王文,何厚军. 基于纹理特征与数学形态学的高分辨率影像城市道路提取[J]. 地理与地理信息学, 2008, **6**(24), 47-49.
- [28] LI Jin-lian, LIU Xiao-mei, LI Heng-peng. Texture extraction and the land using information recognition methods for spot-5 image[J]. *Journal of Remote Sensing*, 2006, **10**(6), 927-931.
李金莲,刘晓玲,李恒鹏. Spot5 影像纹理特征提取与土地利用信息识别方法[J]. 遥感学报, 2006, **10**(6), 927-931.
- [29] JIANG Qing-xiang, LIU Hui-ping. Extract information from TM image with texture analysis methods [J]. *Journal of Remote Sensing*, 2004, **8**(5), 459-464.
姜清香,刘慧平. 利用纹理分析方法提取 TM 图像信息[J]. 遥感学报, 2004, **8**(5), 459-464.