

DOI:10.13203/j.whugis20140952



文章编号:1671-8860(2017)03-0362-07

傅里叶谱纹理和光谱信息结合的高分辨率 遥感影像地表覆盖分类

佃袁勇¹ 杨光² 方圣辉²

1 华中农业大学园艺林学学院,湖北 武汉,430070

2 武汉大学遥感信息工程学院,湖北 武汉,430079

摘要:以高空间分辨率遥感影像为研究对象,将纹理特征与影像的光谱特征结合起来,用于地表覆盖类型分类。设计了一种基于傅里叶谱纹理的分类策略,对主成分分析后的第 1、2 主分量特征影像,利用径向谱(*r*-spectrum)提取纹理特征,并将纹理与光谱特征结合起来,构建了不同的分类特征用于支持向量机分类模型。以 Salinas 数据集和 QuickBird 影像为例,验证该算法。结果表明,纹理与光谱信息的结合可以明显提高高分辨率遥感影像的分类精度;由傅里叶径向谱提取的纹理特征可以很好的应用到高分辨率遥感影像的分类问题中,分类精度高于基于傅里叶总能量谱和灰度共生矩阵的分类精度;利用该算法对 PCA 变换后的第 1 和第 2 分量提取的纹理特征具有一定的互补性,并且结合多特征图像的纹理特征提取优于单特征图像的纹理特征提取。

关键词:高空间分辨率;径向谱;纹理特征;主成分分析

中图法分类号:TP751; P237 **文献标志码:**A

卫星遥感对地观测技术的“三高”(高时间分辨率、高空间分辨率、高光谱分辨率)发展,尤其是高空间分辨率商业卫星的成功发射,使遥感影像信息量更丰富、便于影像解译,极大地推进了遥感技术的应用。高分辨率遥感影像中,地物的几何结构和信息更加明显,空间信息更加丰富,影像地物尺寸、形状、领域地物的关系得到更好的反映^[1]。

遥感影像的纹理特征常被应用于分类问题。纹理特征提取方法主要包括:以灰度共生矩阵^[2]为代表的统计方法;基于马尔科夫随机场^[3]模型的方法;基于自相关函数的方法;基于频域的傅里叶变换的方法^[4]、小波变换法^[5]等。傅里叶变换是图像变换中应用最为广泛的一种方法,已被广泛应用于遥感影像的纹理信息提取。傅里叶谱分解利用图像二维傅里叶变换技术,对傅里叶功率谱进行量化和分解。该方法多被用来对特定环境下的地物类型做定性分析和比较,Mugglestone 和 Renshaw 利用傅里叶谱分解的方法提取冰川地貌信息^[6];Couteron 利用该方法描述半干旱地区植被的变化^[7];Proisy 等利用高分辨率影像估

计红树林的生物量信息^[8,9]。基于以上方法的纹理特征提取多基于单特征图像或单张相片^[10-12],很少利用多波段或多个变化后的特征提取纹理特征,这样导致多光谱或高光谱的大多数波段的纹理信息没有被充分利用。

本文基于高空间分辨率遥感影像,采用傅里叶谱分解算法提取纹理特征,并将纹理特征与光谱特征结合起来,用于分类。首先进行主成分分析(principal components analysis, PCA),利用变换后的第 1、2 分量分别提取纹理特征,并与光谱特征结合。最后利用支持向量机(support vector machine, SVM)分类器进行分类。本文设计了不同的分类方案,并对各方案进行了比较分析。

1 方法和实验

1.1 实验数据

Salinas 数据集:该数据集(图 1)由机载可见光/红外成像光谱仪(airborne visible infrared imaging spectrometer, AVIRIS)在加利福尼亚萨利

收稿日期:2015-10-23

项目资助:国家 863 计划(2012AA12A304, 2013AA102401);中央高校基本科研业务费专项基金(2014QC018);地理国情监测国家测绘地理信息局重点实验室开放研究基金(2013NGC05)。

第一作者:佃袁勇,博士,主要从事遥感技术在资源环境中的应用研究。dianyuanrong@126.com

纳斯山谷获得,共 224 个波段,去掉噪声影响的波段,保留剩下的 204 个波段。该影像空间分辨率为 3.7 m,大小 512 像素×217 像素,带有地表覆盖类型标记的数据点共 54 129 个,实验中训练样本个数为标记数据点的 10%,数据主要覆盖农业用地,被分为 16 个类别,包括葡萄园、玉米地、休耕地等(编号 0 为背景),具体分布见表 1。

表 1 Salinas 数据集样本分布情况

Tab.1 Sample Distribution of Salinas Dataset

编号	类别	个数	编号	类别	个数
1	椰菜 1	2 009	9	葡萄地 2	6 203
2	椰菜 2	3 726	10	玉米地	3 278
3	休耕地 1	1 976	11	苜苳 1	1 068
4	休耕地 2	1 394	12	苜苳 2	1 927
5	休耕地 3	2 678	13	苜苳 3	916
6	残梗地	3 959	14	苜苳 4	1 070
7	芹菜地	3 579	15	葡萄地 3	7 268
8	葡萄地 1	11 271	16	葡萄地 4	1 807

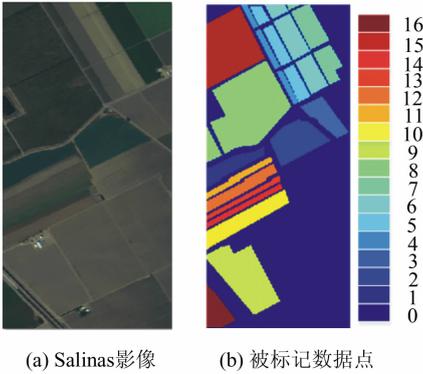


图 1 Salinas 数据集
Fig. 1 Salinas Dataset

九峰高分辨率数据集:该数据集由 Quick-Bird 卫星成像,成像区域为武汉市九峰森林公园。该影像分辨率为 2.44 m,具有 4 个多光谱通道,实验区影像大小 800 像素×800 像素,如图 2。根据地面调查,研究区主要覆盖 6 类地物,包括水体、针叶林、阔叶林、混交林、耕地以及裸地。训练和测试样本列如表 2 所示。

表 2 九峰数据集样本分布

Tab.2 Sample Distribution of Jiufeng Dataset

类别		样本数		
编号	名称	训练	测试	总数
1	水体	41	369	410
2	针叶林	39	351	390
3	阔叶林	48	432	480
4	混交林	46	414	460
5	耕地	38	342	380
6	裸地	12	108	120
	合计	224	2 016	2 240



图 2 九峰地区彩色合成快鸟影像

Fig. 2 QuickBird Image with Color Composition in Jiufeng Region

1.2 纹理信息提取

本文采用傅里叶谱分解的方法进行纹理信息提取。傅里叶变换的作用是实现空间域到频率域的转换,由于图像是二维的离散数据,故对于 n 行、 n 列的图像,二维离散傅里叶变换公式为:

$$F(p, q) = \sum_{j=1}^n \sum_{k=1}^n f(j, k) \exp[-i2\pi(\frac{pj}{n} + \frac{qk}{n})] \quad (1)$$

式中, $f(j, k)$ 为数字图像, j, k 为空间域中的纵横坐标; p, q 为频率变量, $|p| \leq p_{\max}, |q| \leq q_{\max}, p_{\max} = q_{\max} = n/2$ (奈奎斯特频率), 本文 p, q 取离散整数。

令 $F(p, q)$ 的实部与虚部分别为 a_{pq} 与 b_{pq} :

$$a_{pq} = n^{-2} \sum_{j=1}^n \sum_{k=1}^n x_{jk} \cos\left\{2\pi\left(\frac{pj}{n} + \frac{qk}{n}\right)\right\} \quad (2)$$

$$b_{pq} = n^{-2} \sum_{j=1}^n \sum_{k=1}^n x_{jk} \sin\left\{2\pi\left(\frac{pj}{n} + \frac{qk}{n}\right)\right\} \quad (3)$$

式中, $x_{jk} = f(j, k) - \overline{f(j, k)}$ 为均值修正后的空间域的观测值。这里忽略相位信息(因为相位信息在纹理信息识别方面被认为是一个有争议的问题^[13])。

则傅里叶变换的功率谱表示为:

$$|F(p, q)|^2 = a_{pq}^2 + b_{pq}^2 \quad (4)$$

傅里叶谱纹理含有大量的信息,而且包含很多成分。不过仅利用总能量谱一个特征作为纹理特征可能是不充分的,若把每个采样谱都作为纹理特征又会造成信息的冗余,实际上,它可以被分解和量化,作为新的纹理特征。

令 $I_{pq} = (a_{pq}^2) + a_{pq}^2/n^2$ 。本文中把 p, q 由笛卡尔坐标系转到极坐标系中,令 $r = \sqrt{p^2 + q^2}, \theta = \sin(p/q)$, 对于每一个半径 r 的取值范围(如 $0 < r \leq 1, 1 < r \leq 2, \dots$) 内的所有方向 θ 来求

I_{pq} , 即 $I_{r\theta}$ ($I_{r\theta} = I_{pq}$) 的平均值, 就是得到了所谓的径向谱 (r-spectra), 计算公式如下:

$$I(r) = (k\sigma^2)^{-1} \sum_{\theta} I_{r\theta} \quad (5)$$

式中, k 为半径 r 范围内采样谱的个数; σ^2 为方差。本文每一个 r 的取值范围为 $(\sqrt{2}(t-1), \sqrt{2}t]$ (t 的范围是 $[1, n/2]$), 且 t 为整数, 利用单特征图像提取的径向谱纹理特征数目固定为 $n/2$ 。实际上, 也可以对每一个角度 (θ) 范围, 求该范围内的所有半径长度对应的平均谱值, 称作周向谱 (angle-spectrum), 本文采用径向谱, 径向谱精炼了功率谱的信息量, 而且反应了粗糙和细腻的地表纹理特征^[14]。

径向谱提取了一定窗口内的整体信息, 而在分类问题中, 为了使每一个像素得到准确的分类结果, 本文通过移动窗口来弥补这种缺陷。具体过程如下: 选取固定窗口尺寸, 从第一个窗口开始提取纹理特征, 然后逐像素移动窗口, 逐个窗口提取纹理特征, 对于被多个窗口覆盖的像素, 最终的纹理特征由覆盖窗口的径向谱向量的平均值来确定。

本文提出先对高光谱/多光谱影像进行主成分分析, 由于 PCA 的前两主分量含有大量的信息量, 故利用 PCA 的第 1、2 主分量, 作为纹理提取的对象。最终将光谱特征与纹理特征串联起来作为分类器的输入。本文尝试不同大小的窗口, 发现采用了逐像素移动窗口的方法后对不同窗口分类精度的影响不大, 而且选用较小的窗口在计算效率和精度上都有一定优势, 最终选择 4×4 的窗口, 算法流程如图 3。

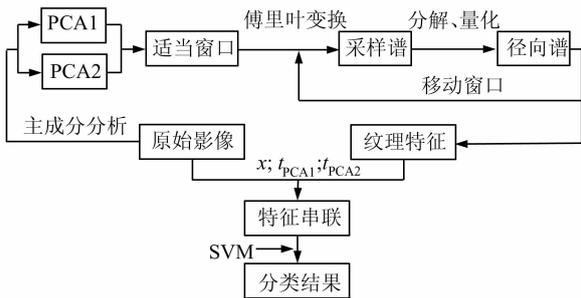


图3 傅里叶谱纹理与光谱结合的分类算法

Fig. 3 Classification Algorithm Based on Fourier Spectrum Texture Combined with Spectral Information

1.3 特征权重自适应调整

本文采用基于距离测度的方法自动对光谱特征和纹理特征赋予权重, 并作为分类器的输入。

- 1) 将光谱特征与纹理特征串联, 归一化处理。
- 2) 分别利用各个特征的值, 统计各类别的均

值和方差, 计算每两个类别的标准化距离, 标准化距离计算公式如下:

$$d_{\text{norm}} = \frac{|\eta_i - \eta_j|}{\sigma_i + \sigma_j} \quad (6)$$

式中, d_{norm} 为标准化距离; η_i, η_j 分别为类别 i 和类别 j 的均值; σ_i 和 σ_j 为类别 i 和类别 j 的标准差。

3) 计算每个特征所有类别间的标准化距离之和, 并对光谱特征和纹理特征的总体按比例分配权重因子, 具体过程如下:

设参与分类的特征表达为 $X = [x_{(1)1}, x_{(1)2}, \dots, x_{(1)m}, x_{(2)1}, x_{(2)2}, \dots, x_{(2)n}]$, m, n 分别表示光谱特征和纹理特征的个数, 令 ω_1, ω_2 分别为光谱特征和纹理特征的权重因子, 可由以下计算得到:

$$\omega_1 = \frac{\sum_{k=1}^m d_k / m}{\sum_{k=1}^{m+n} d_k / (m+n)} \quad (7)$$

$$\omega_2 = \frac{\sum_{k=m+1}^{m+n} d_k / n}{\sum_{k=1}^{m+n} d_k / (m+n)} \quad (8)$$

其中,

$$d_k = \sum_{i=1}^l \sum_{j=1}^l d_{ijk} \quad (9)$$

式中, d_{ijk} 为第 k 个特征在类别 i, j 间的标准化距离, 见式(6)。

4) 更新参与分类的特征, 特征表达为:

$$X = [\omega_1 x_{(1)1}, \omega_1 x_{(1)2}, \dots, \omega_1 x_{(1)m}, \omega_2 x_{(2)1}, \omega_2 x_{(2)2}, \dots, \omega_2 x_{(2)n}]$$

1.4 分类器及参数

SVM^[15] 是一种建立在结构风险最小化原则 (structural risk minimization, SRM)^[16] 和 VC 维 (vapnik-chervonenkis dimension)^[15,17,18] 理论基础上的学习机, 它在解决小样本、非线性和高维模式识别问题中有较大优势。

本文分类算法均采用 SVM 分类器, 选用径向基核函数, 利用 k 折交叉验证^[19] 的方法确定分类器参数 (k 取 5)。实验中固定径向基核函数中的伽马系数 g 的值为 0.01, 对惩罚因子 C 进行估计, 估计范围 1 到 100, 步长取 1, 即在 C 从 1 到 100 变化过程中, 对于每一个 C 值, 将训练集平均分成 5 份, 每一份轮流作为测试样本, 其余作为训练样本, 得到 5 次的平均分类精度 (交叉验证精度), 在参数变化过程中, 选择最高精度对应的参数 C 为分类器的参数。

2 实验方案与结果

2.1 实验方案

为比较傅里叶谱分解方法提取的纹理特征与其他方法的差异,本文设计了不同输入特征用于分类。具体实验方案如下:

- 方案 1 光谱特征;
- 方案 2 光谱+PCA1、2 径向谱;
- 方案 3 光谱+PCA1、2 总能量谱(所有频率下的采样谱的和,不对其进行分解);
- 方案 4 光谱+PCA1、2 GLCM(gray-level

co-occurrence matrix) 各 4 个统计特征,包括角二阶矩、对比度、逆差矩、熵(具体的计算过程参见文献[2]);

方案 5 光谱+PCA1 径向谱;

方案 6 光谱+PCA2 径向谱。

2.2 分类结果浅析

Salinas 数据集:表 3 比较了该数据集各方案的分类结果,图 4 为对应方案所有采样点的分类结果图。需要说明的是,该数据集为高光谱影像,通常在分类前进行降维,本文采用流形学习中的等距特征映射(isometric mapping, ISOMAP)^[20]算法提取 10 个特征,作为光谱特征。

表 3 Salinas 数据集各方案分类概况

Tab. 3 Classification Results of Salinas Dataset by Different Scenarios

	方案 1	方案 2	方案 3	方案 4	方案 5	方案 6
特征数	10	14	12	18	12	12
总体精度	86.34% (46 735/54 129)	88.23% (47 759/54 129)	86.89% (47 032/54 129)	87.04% (47 116/54 129)	88.15% (47 717/54 129)	88.16% (47 724/54 129)
Kappa 系数	0.848	0.869	0.854	0.856	0.867	0.868

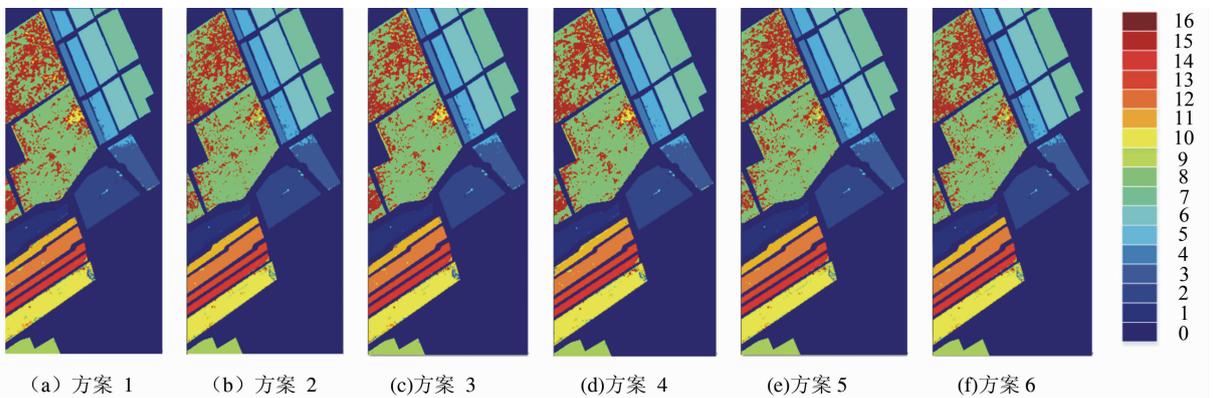


图 4 Salinas 数据集分类结果图

Fig. 4 Classification Maps of Salinas Dataset

由表 3 可以看出,加入纹理的分类结果(方案 2~方案 6)优于仅利用光谱的分类结果(方案 1);本文采用的径向谱纹理(方案 2)分类精度最高,高于总能量谱纹理(方案 3)和 GLCM 纹理(方案 4),结合 PCA1、2 主分量提取的径向谱纹理(方案 2)的分类精度略高于基于单一分量提取纹理的分类精度。由图 4 仍可以看出,方案 2 在最相似的

类别 8 和类别 15 之间(如中间和左上相邻的两片较大的区域)的分类效果优于其他方案。

表 4 统计了九峰数据集各方案的分类结果,具体的分类情况如表 5。

由表 4 同样可以看出,加入纹理特征的分类(方案 2~方案 6)精度和 Kappa 系数明显高于仅利用光谱信息的分类(方案 1);结合径向谱纹理

表 4 九峰数据集各方案分类概况

Tab. 4 Classification Results of Jiufeng Dataset by Different Scenarios

	方案 1	方案 2	方案 3	方案 4	方案 5	方案 6
特征数	4	8	6	12	6	6
总体精度	82.59% (1 665/2 016)	89.88% (1 812/2 016)	84.67% (1 707/2 016)	89.19% (1 798/2 016)	89.63% (1 807/2 016)	88.74% (1 789/2 016)
Kappa 系数	0.785	0.876	0.811	0.867	0.873	0.862

表5 方案2 分类情况
Tab.5 Classification Results by Scenario 2

预测类别	参考类别						总数	用户精度/%
	水体	针叶林	阔叶林	混交林	耕地	裸地		
水体	369	0	0	0	0	0	369	100
针叶林	0	308	0	2	0	0	310	99.35
阔叶林	0	0	428	58	4	0	490	87.34
混交林	0	43	4	354	88	0	489	72.39
耕地	0	0	0	0	250	5	255	98.04
裸地	0	0	0	0	0	103	103	100
总数	369	351	432	414	342	108	2 016	-
生产者精度/%	100	87.75	99.07	85.51	73.10	95.37	-	-
总体精度:89.88%(1 812/2 016) Kappa 系数:0.876								

(方案2)的分类精度高于总能量谱纹理(方案3)和 GLCM 纹理(方案4)的分类精度,虽然方案4的分类精度接近方案2,但参与分类的特征数较多;结合 PCA 前两主分量提取纹理特征的分类结果(方案2)优于基于单一分量提取纹理特征的分类结果(方案5、方案6)。由图5(a)~5(f)反

映了各方案的分类结果细节。图5(b)(方案2)显示了较好的分类效果,但耕地和林地之间有少量错分;此外,由图5(e)、5(f)的比较可以看出该纹理提取方法对 PCA 的前两分量提取的纹理特征具有一定的互补性,主要体现在裸地、耕地以及林地。

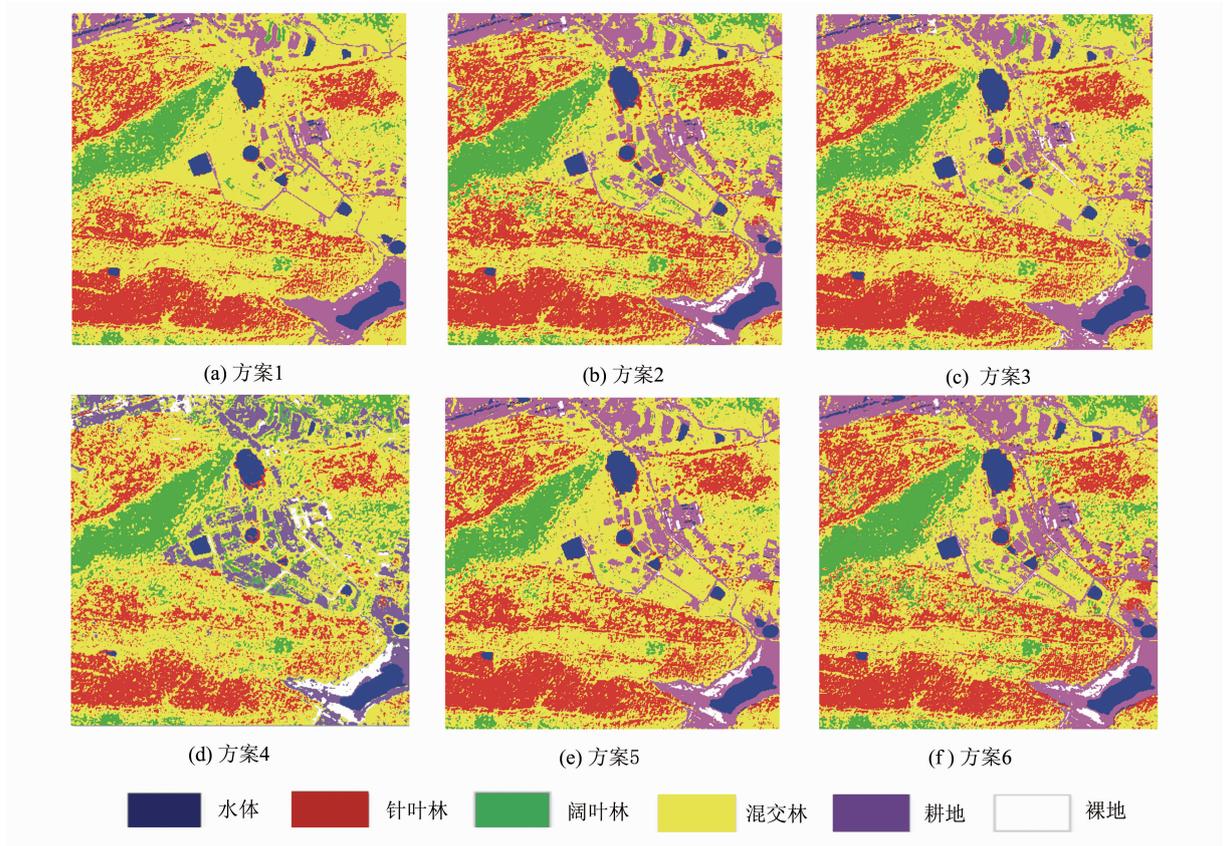


图5 九峰数据集分类结果图

Fig.5 Classification Maps of Jiufeng Dataset

由以上实验结果及对比分析,可以得到以下结论:

- (1) 纹理信息与光谱信息的结合可以明显提高高分辨率影像的分类精度;
- (2) 径向谱纹理特征优于总能量谱特征和

GLCM 纹理特征;

- (3) 利用多特征图像提取的纹理特征优于单特征图像提取的纹理特征,且利用该算法对 PCA 前两分量提取的纹理特征具有一定的互补性;
- (4) 采用逐像素移动窗口的方法和自适应特

征加权的方法基本弥补了基于窗口的纹理提取方法的缺陷;

(5) 基于 SVM 分类模型,将傅里叶径向谱纹理特征与光谱特征结合,在针对以农、林为主体的高分辨率遥感影像的分类问题中具有很大的潜力。

3 结 语

本文以 Salinas 数据集和武汉九峰地区 QuickBird 影像为研究对象,采用 SVM 分类模型将傅里叶谱分解算法与光谱信息结合并应用到高分辨率遥感影像的地表覆盖分类中。研究中采用逐像素移动窗口的策略避免窗口化纹理提取的缺陷;采用自适应特征加权的方法解决光谱特征和纹理特征的差异问题。利用本文的算法和策略,针对高光谱和多光谱遥感影像,采用多种方案做分类实验,对几种方案做了比较,其中径向谱纹理与光谱信息结合的分类结果显示出较高精度和良好效果。此外,本文考虑了光谱特征和纹理特征,并没有加入其他特征如形状特征、植被指数、DEM 等。结合多特征的分类问题值得进一步研究。

参 考 文 献

[1] Wan Youchuan, Song Yang. Application of Maps Revision Based on Classification of High Resolution Satellite Images[J]. *Geomatics and Information Science of Wuhan University*, 2005, 30(2):105-109(万幼川,宋杨. 基于高分辨率遥感影像分类的地图更新方法[J]. 武汉大学学报·信息科学版, 2005, 30(2):105-109)

[2] Hanta-Kasari M, Parkkinen J, Jaaskelainen T, et al. Generalized Co-occurrence Matrix for Multispectral Texture Analysis[C]. The 13th International Conference on Pattern Recognition, Piscataway, USA, 1996

[3] Wang Keqi, Bai Xuebing. Classification of Wood Surface Texture Based on Gauss-MRF Model[J]. *Journal of Forestry Research*, 2006, 17(1): 57-61

[4] Kumaresan R. Spectral Analysis[M]. Boca Raton, USA: CNC Press, 1993:1 143-1 169

[5] Fanelli A, Leo A, Ferri M. Remote Sensing Images Data Fusion: A Wavelet Transform Approach for Urban Analysis[C]. IEEE/ ISPRS Joint Workshop on Remote Sensing and Data Fusion over Urban Areas, Piscataway, USA, 2002

[6] Mugglestone M A, Renshaw E. Detection of Geo-

logical Lineations on Aerial Photographs Using Two-dimensional Spectral Analysis[J]. *Computers & Geosciences*, 1998,24(8): 771-784

[7] Couteron P. Quantifying Change in Patterned Semi-arid Vegetation by Fourier Analysis of Digitised Aerial Photographs[J]. *International Journal of Remote Sensing*, 2002, 23(17):3 407-3 425

[8] Proisy C, Couteron P, Fromard F. Predicting and Mapping Mangrove Biomass from Canopy Grain Analysis Using Fourier-based Ordination of IKONOS Images[J]. *Remote Sensing of Environment*, 2007, 109(3):379-392

[9] Proisy C, Mougin E, Fromard F, et al. On the Influence of Canopy Structure on the Polarimetric Radar Response from Mangrove Forest[J]. *International Journal of Remote Sensing*, 2002, 23(20): 4 197-4 210

[10] Yu Hao, Qi Zhihong, Zhang Xiaoping, et al. Extraction of Terraced Field Texture Features Based on Fourier Transformation[J]. *Remote Sensing for Land and Resources*, 2008, 20(2): 39-41(于浩,齐志红,张晓萍,等. 基于傅里叶变换的梯田纹理特征提取[J]. 国土资源遥感, 2008, 20(2): 39-41)

[11] Wang Huanping, Liu Yong. The Study on Classification of High Resolution Remote Sensing Image in Saline Area Based on Window Fourier Transform Power Spectrum Analysis [J]. *Remote Sensing Technology and Application*, 2011, 26(2):233-238 (王焕平,刘勇. 基于窗口傅里叶变换功率谱分析的盐田地区高分辨率遥感影像分割分类方法探讨[J]. 遥感技术与应用, 2011, 26(2):233-238)

[12] Zhang Lefei, Zhang Liangpei, Tao Dacheng. On Combining Multiple Features for Hyperspectral Remote Sensing Image Classification[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2012, 50(3):879-893

[13] Tang Xiaou, Stewart W K. Optical and Sonar Image Classification; Wavelet Packet Transform vs Fourier Transform[J]. *Computer Vision and Image Understanding*, 2000, 79(1): 25-46

[14] Couteron P. Textural Ordination Based on Fourier Spectral Decomposition: A Method to Analyze and Compare Landscape Patterns[J]. *Landscape Ecology*, 2006, 21(4):555-567

[15] Cortes C, Vapnik V. Support Vector Networks[J]. *Machine Learning*, 1995, 20(3): 273-297

[16] Vapnik V. Statistical Learning Theory[M]. New York: Springer Press, 1998: 732-739

[17] Vapnik V, Levin E. Measuring the VC Dimension of a Learning Machiric[J]. *Neural Computation*, 1994,6(5):811-876

- [18] Sontag E. VC Dimension of Neural Networks[M]. New York: Springer Press, 1998
- [19] Stone M. Cross-validatory Choice and Assessment of Statistical Predictions[J]. *Journal of Royal Statistical Soc (Series B)*, 1974, 36(2):111-147
- [20] Tenenbaum J, Silva V, Langford J. A Global Geometric Framework for Nonlinear Dimensionality Reduction[J]. *Science*, 2000, 290(5 500):2 319-2 323

Combining Fourier Spectrum Texture and Spectral Information for Land Cover Classification with High Resolution Remote Sensing Images

DIAN Yuanyong¹ YANG Guang² FANG Shenghui²

1 Institute of Garden Forestry, Huazhong Agriculture University, Wuhan 430070, China

2 School of Remote Sensing and Information Engineering, Wuhan University, Wuhan 430079, China

Abstract: The extraction of textural features gives more information in many pattern recognition issues. The textural features are widely exploited in the classification problems. In this study, the high resolution images were employed as the research object. Textural features and spectral features were combined to solve the problems of land cover classification. The paper designed a classification strategy based on Fourier spectrum texture. The spectral image was submitted to the principal components analysis (PCA) and r -spectrum was extracted from the first two principal components as the textural features. The common power spectrum might be insufficient because of the lack of the feature number. However, it would bring redundancy when taking into account each sample spectrum associated with each frequency. In fact, it could be divided and quantified flexibly. Consequently, new features were yielded through the method. In this study, different scenarios associated with different input features were designed. Support vector machine (SVM) was employed as the classifier. The algorithm was tested on hyperspectral dataset acquired in Salinas area and QuickBird images acquired in Jiufeng area. Results showed that the combination of textural features and spectral features could obviously improve the accuracy; the textural features extracted by Fourier r -spectrum could be applied well to the classification problems of high resolution remote sensing images; the classification accuracy was higher than the one that is based on the whole sample spectrum and the commongray-level co-occurrence matrix (GLCM); it was suitable to move the window pixel by pixel when extracting the textural features; adaptive weight would better deal with the problems of multiple features; the textural features extracted from the first and second principle components had complementary properties. In addition, the extraction of textural information from multi-feature pictures was superior to single feature picture.

Key words: high resolution; r -spectrum; textural feature; principal component analysis

First author: DIAN Yuanyong, PhD, specializes in remote sensing technology on resource environment. E-mail: dianyuanyong@126.com

Foundation support: The National High Technology Research and Development Program of China (863 Program), Nos. 2012AA12A304, 2013AA102401; the Fundamental Research Funds for the Central Universities, No. 2014QC018; the Open Fund of Major Laboratory Program of Geography National Condition Monitoring National Administration of Surveying, Mapping and Geo-information, No. 2013NGC05.