

doi: 10. 6046/zrzyyg. 2022304

引用格式: 李雷,孙希延,纪元法,等. 融合超像素和多属性形态学轮廓方法的高光谱图像分类[J]. 自然资源遥感,2023,35(4):114–121. (Li L, Sun X Y, Ji Y F, et al. Hyperspectral image classification based on superpixel segmentation and extended multi-attribute profiles[J]. Remote Sensing for Natural Resources,2023,35(4):114–121.)

融合超像素和多属性形态学轮廓方法的高光谱图像分类

李 雷¹, 孙希延², 纪元法², 付文涛³

(1. 桂林电子科技大学精密导航技术及应用广西重点实验室, 桂林 541004; 2. 桂林电子科技大学信息与通信学院, 桂林 541004; 3. 卫星导航定位与位置服务国家地方联合工程研究中心, 桂林 541004)

摘要: 基于超像素分割的图像处理方法近年来被广泛应用于高光谱遥感图像(hyperspectral image, HSI)分类过程中,但是其单一尺度下无法充分提取 HSI 的丰富信息,且分类过程受参数依赖严重。因此针对基于超像素分割的 HSI 分类技术利用空间信息不足的问题,提出一种超像素分割方法和扩展多属性轮廓(extended multi-attribute profile, EMAP)方法相结合的 HSI 图像分类方法。该方法首先采用超像素分割方法提取超像素级特征,同时利用 EMAP 方法提取像素级 HSI 特征,融合 2 种特征后的图像具有完整的 HSI 结构特性,考虑到融合之后的信息冗余,采用递归滤波的方法进行光谱学滤波,最后将特征输入到支持向量机(support vector machine, SVM)分类器中,确定像素的标签。在 Indian Pines 和 University of Pavia 这 2 个数据集上实验,分析了参数的变化对分类精度的影响,并与其他同类算法相比较,分类精度和 Kappa 系数较 S3-PCA 方法分别提高了 3.55 个百分点和 2.88 百分点。

关键词: 高光谱图像分类; 信息融合; 特征提取; 超像素分割

中图法分类号: TP 751.1 **文献标志码:** A **文章编号:** 2097-034X(2023)04-0114-08

0 引言

高光谱传感器集成了传感技术和光谱技术,采集的图像包含几十到几百个波段,具有很高的光谱分辨率,能够从不同角度反映地物的材料特性^[1],因此在资源勘探^[2]、目标检测^[3-5]、土地分类^[6]等众多领域都有广泛应用^[7],然而,由于成像光谱仪距离地面较远,加上大气传输过程中的多次散射以及表面微观物质的复杂分布,因此在高光谱图像(hyperspectral image, HSI)中经常出现混合像素,即一个图像像素可能覆盖几种不同的物质,因此其分类技术也是众多学者研究的重点。

由于 HSI 的丰富的光谱特性,在以往的分类方法中,产生了众多光谱信息的特征提取和分类方法,基于光谱信息的稀疏表示方法^[8],寻找最优超平面的支持向量机(support vector machine, SVM)分类后处理方法^[9],此外,空间信息同样不可忽视,在发现仅使用光谱信息的分类效率有限时,针对空间特征提取的 HSI 分类方法也被提出,例如利用扩展多属性轮廓(extended multi-attribute profile, EMAP)方

法提取空间纹理信息^[10-11]。Liao 等^[12]利用双边滤波提取 HSI 中的空间信息;Feng 等^[13]叠加了从原始图像中提取的 EMAP 和 Gabor 空间信息,构建 HSI 单个场景的多视图数据集。

一般来说,上述所提方法皆是从像素级层面对 HSI 进行信息提取,即直接对 HSI 进行纹理、光谱等特征提取,除此之外,HSI 的另外一种表征方式是超像素分割,其考虑到了空间邻域弱假设,从超像素级层面对 HSI 进行表征,提高了对 HSI 的辨识度。Ren 等^[14]利用超像素改进了异常检测算法 RX 的自适应内窗;Sellars 等^[15]采用超像素生成收缩加权图表示,加速了 HSI 的图形分类器;Jiang 等^[16]通过多尺度超像素方法与传统的主成分分析(principal component analysis, PCA)方法相结合来学习 HSI 固有的低维特征,提出了 SuperPCA 方法;Zhang 等^[17]改进了 SuperPCA 方法,将全局 PCA 方法结合了局部 PCA,重建降维 HSI;Beirami 等^[18]采用波段分组技术改进了 SuperPCA 方法,总体精度比传统 SuperPCA 提高了 8 百分点;Jia 等^[19]建立了超像素之间的相似度矩阵,在超像素特征层面传播样本标签。

但是上述方法均建立在超像素分割方法能够完

收稿日期: 2022-07-27; 修订日期: 2022-10-04

基金项目: 广西科技厅项目“基于北斗的境内外地质勘查监测空间信息服务及应用示范”(编号: AA17202033)资助。

第一作者: 李 雷(1998-),男,硕士研究生,研究方向为高光谱遥感图像处理。Email: 921427610@qq.com。

通信作者: 纪元法(1975-),男,博士,教授,研究方向为卫星导航与接收机。Email: jiyuanfa@163.com。

全提取信息的基础上,其他处理方案诸如波段分组、线性判别分析 (linear discriminant analysis, LDA)、PCA 等只是辅助,因此分类的结果极度依赖分割方法的参数设置。本文受 SuperPCA 方法的启发,从超像素方面来表示 HSI,然而,并没有一种最佳的方式能够完整无缺地利用 HSI 的丰富信息,同样地,也没有任何单独的一种表达方式能够完整地表达 HSI,性能较好的超像素分割方法也是比较依赖参数设置,需要进行多次重复实验才能取得令人满意的效果。因此,本文介绍了一种 HSI 分类方法,重点在于解决超像素分割方法依赖参数严重以及单一方法提取信息不充分的问题。该方法建立在超像素分割方法基础上,分别从超像素级和像素级层面提取 HSI 特征并相结合。采用熵率超像素分割方法 (entropy rate superpixel segmentation, ERS) 将 HSI 分割为一个

个单独的区域,然后对每一个同质区域进行 PCA 分析,并重新组合,提取了 HSI 的低维固有的局部特征;采用 EMAP 方法提取纹理特征,之后将 2 种信息进行融合,并采用递归滤波 (recursive filtering, RF) 方法去除信息融合后的冗余,最后进行分类。该方法将提高分类精度,减少对超像素数目设置的依赖性,提高单一方法对 HSI 的信息提取程度。

1 理论模型

本文提出的分类框架如图 1 所示,主要包括 4 个主要部分: ①超像素级特征生成; ②生成 EMAP 特征; ③分别融合这些特征并采用 RF 方法滤波; ④进行 SVM 分类,确定最后的分类标签。




图 1 分类框架示意图

Fig.1 Schematic diagram of classification framework

1.1 超像素级特征生成

超像素分割方法基于相邻像素具有相似结构的假设,将整个图像精细划分为多个彼此不重叠的同质子区域,小尺度分割的超像素在强度和纹理特征上都具有较高的一致性,由于其简单、高效和鲁棒性,被广泛应用于图像处理的预处理过程。由于原始的 HSI 波段众多,因此分割之前需要对 HSI 进行 PCA 处理,获得贡献率最大的第一主成分 I_f ,然后使用 ERS 对图像的第一主成分进行分割^[11],描述为:

$$I_f = \bigcup_{k=1}^S Y_{k,g}, \text{ s. t. } Y_k \cap Y_g = \emptyset, (k \neq g), \quad (1)$$

式中: Y_k 和 Y_g 分别为互不重叠的同质区域; S 为总的超像素数目。

传统的降维方法多是在全局层面对整个 HSI 进行 PCA 分析,忽视了 HSI 的局部特征。受到 SuperPCA 方法^[16]的启发,为了提高对 HSI 的信息挖掘程度,本文采用一种“分而治之”的策略:在生成同质区域后,对每一个同质区域进行单独的 PCA 分析,然后再将它们组合起来形成新的降维 HSI,如图 2 所示。图 2 中首先将超像素分割后的图像作为目标

处理图像,可见图像被划分为多个均匀区域,每个区域由矩阵表示,矩阵列为像素的谱向量, B 为原始的波段数, S_i , S_j 和 S_k 是均匀区域的位置标识,将 PCA 应用到每个区域中,使波段数目由 B 减少到 d ,按照原来的位置重新组合 S_i , S_j 和 S_k ,即可得到新的特征集合 H_{sp} 。




图 2 获取超像素级特征

Fig.2 Obtaining super pixel level features

相对于全局意义上的 PCA 分析,针对每一个同质区域进行 PCA 固然是增加了计算量,但由于 PCA 的高效性,两者的计算量差距可以忽略不计。而带来的好处是可以显著提高第一特征向量方向的偏心

率,即有效在低维空间中保存基本数据信息,经过重组后的图像 H_{sp} 视为超像素的特征图像。

1.2 像素级特征生成及融合

像素级特征的提取采用 EMAP 方法,作为传统形态学剖面纹理特征提取方法的改进,EMAP 级联了多种属性原则的形态学滤波器^[20],其做法是首先对 HSI 进行 PCA 分析,然后根据面积、标准差、形状等准则,分别生成不同的属性文件(attribute profile, AP),然后级联起来形成扩展属性文件(extended attribute profile, EAP),公式为:

$$EAP = \{AP_1, AP_2, \dots, AP_n\}, \quad (2)$$

式中: $AP_i (i = 1, 2, \dots, n)$ 为对分量 i 的属性滤波; n 为主成分个数。EMAP 是将不同属性特性向量级联成单一向量(图 3),公式为:

$$EMAP = \{EAP'_a, EAP'_s, EAP'_d, EAP'_i\}, \quad (3)$$

式中 $EAP'_a, EAP'_s, EAP'_d, EAP'_i$ 分别为面积准则向量、像素标准差向量、形状原则向量和惯性矩准则向量。可以看出, EAP 只使用了一个属性, EMAP 应用了多个属性,通过不同的属性滤波全面有效地描述 HSI 丰富的地物特性。




图 3 获取像素级特征

Fig.3 Obtaining pixel-level features

EMAP 方法的像素级特征提取采用阈值参数计算,该参数相当于单个特征的平均值为 2.5% ~ 10%,标准偏差为 2.5%,面积属性为 200 和 500 的阈值,由于 EMAP 特征生成要增加众多的维度,因此本文基于 HSI 的前 3 个主成分分量生成 EMAP 特征 H_{EMAP} 。

1.3 融合特征及分类

EMAP 方法集中考虑了图像的全局特征,基于超像素级的分割方法生成的特征 H_{sp} 是基于局部的 PCA 来学习固有的低维特征,这 2 种特征形成了信息互补,重要的是,EMAP 特征弥补了分割方法提取边缘信息的不足的缺陷。因此采用一种简单的融合方法,将 2 种特征沿着光谱维度叠加起来,计算公式为:

$$H = [H_{sp}, H_{EMAP}] \in R. \quad (4)$$

在分类之前,由于融合了多个特征,新特征的维度会变大,因此需要对新的特征再次进行 PCA 分析,提取 HSI 的光谱-空间特征,方法是对融合后的图像进行域变换 RF, 获得特征图像,公式为:

$$O = RF(H)_{\delta_s, \delta_r}, \quad (5)$$

式中: RF 为域变换递归滤波操作; δ_r 和 δ_s 分别为空间和范围标准差参数; O 为产生的特征图像。

最后,采用 SVM 分类器来获得最后的分类标签图 $label$,其中,分类器的核函数选用高斯核函数(radial basis function, RBF)。

$$label = SVM(O)_{RBF}. \quad (6)$$

2 实验及分析

为了验证所提方法的可行性和有效性,本文选择 2 个数据集作为试验场景,同时以 SVM, PCA, LDA, SuperPCA^[16], S3-PCA^[17], BG-SuperPCA^[18] 几种方法作为对照试验,均在一台 2.5 GHz CPU 和 12 GB 内存的笔记本电脑上使用 MATLAB 进行实验,同时为了评估总体分类性能,使用 3 种常用的分类指标,即总体精度(overall accuracy, OA)、平均精度(average accuracy, AA)和 Kappa 系数。OA 是正确分类的像素的比例,AA 是每个类别中正确分类的特征的比例,Kappa 系数则基于混淆矩阵,综合了 OA 和 AA 这 2 种精度指标,取值越靠近 1,表明其分类效果越好,其中,Kappa 系数是图像分类精度的最有价值的评价指标^[21]。

2.1 实验数据集

实验选择 2 个经典的高光谱数据集: Indian Pines 数据集和 University of Pavia 数据集^[22]。

Indian Pines 数据集是位于美国印第安纳州西北部的印第安松树试验场景。该场景尺寸为 145 像元 $\times$ 145 像元,空间分辨率为 20 m^[22]。该图像删除了 20 个多余的吸水波段,共包含 220 个波段,并包含 16 种地物。真实地物图以及伪彩色图如图 4 所示。University of Pavia 数据集为拍摄于意大利帕维亚大学周围的城区场景,尺寸为 610 像元 $\times$ 340 像元,空间分辨率为 1.3 m,为了消除噪声影响,将原始拍摄图像制作成数据集时,去除了被冗余的被水体吸收的波段,共 115 个波段^[22]。图 5 显示了图像的波段合成图,以及真实的特征图。




图 4 Indian Pines 数据集
Fig.4 Indian Pines data set




图 5 University of Pavia 数据集
Fig.5 University of Pavia data set

2.2 数据集实验

对于 2 个数据集,随机从样本总含量中选择

10% 标记样本作为训练样本,剩余的作为测试样本。RF 的参数分别为 $\delta_s = 200$, $\delta_r = 0.3$; SVM 分类器采用 RBF 核,参数选择默认的参数;超像素数目设置为 $S = 100$ 。每个数据均重复 10 次取平均值为最后结果。

2.2.1 Indian Pines 数据集测试

图 6 所示为几种对照算法和本文算法在 Indian Pines 数据集的分类结果,从图 6(b)中可以看出 SVM 方法错分、误分类现象严重,出现了很多的噪点,说明了在本文算法中进行滤波处理的必要性,其好处是在减少数据量的同时,也降低了误分类现象出现的概率,本文算法中的分类结果(图 6(h))中误分类的情况大大减少,整体分类效果优于其他同类算法。




图 6 Indian Pines 数据集分类结果
Fig.6 classification results of Indian Pines dataset

表 1 中给出了 6 种对照算法分别在 3 种分类精度评价指标上的数据对比,其中,PCA 和 LDA 方法仅仅提取了光谱信息,因此在分类精度有限,S3 -

PCA 由于是在 SuperPCA 方法的基础上提取了全局特征,因此精度有所提升。BG - superPCA 方法是在 superPCA 基础上将初始图像的波段进行分组,原因

是考虑到相邻波段之间拥有相似的信息,聚合波段在一定程度上减少了冗余小噪声的干扰,但其精度依赖超像素数目,随机超像素数目下表现略差。本文提出的方法在增加了纹理特征的同时,采用 RF

方法去除了细小的噪声,因此在 3 个精度评价指标上较其他算法均有明显提升。其中,Kappa 系数较高的 S3 - PCA 方法提高了 3.55 百分点,AA 提高了 2.24 百分点。

表 1 Indian Pines 数据集分类精度对比

Tab.1 Comparison of classification accuracy of Indian Pines data set								(%)
指标	SVM	PCA	LDA	BG - SuperPCA	S3 - PCA	SuperPCA	本文算法	
OA	85.23	83.52	84.74	87.35	94.62	93.56	98.26	
AA	83.51	84.69	82.34	88.10	95.39	94.37	97.63	
Kappa 系数	83.62	82.69	83.08	87.96	95.10	94.50	98.65	

2.2.2 University of Pavia 数据集测试

图 7 为在 University of Pavia 数据集上的实验分布结果,可以看到虽然该数据集包含的细节较多,本文提出算法的分类精度仍优于其他算法,这是因为与其他方法相比,本文算法综合考虑了 HSI 中固有

的低维特征,使用 EMAP 方法保留了边缘地物的轮廓细节信息,对比算法中的各个分类精度也在表 2 中给出。由表 2 可见,本文方法在此数据集中 3 种分类评价指标上依然保持优势,Kappa 系数较 SVM 方法提高了 14.23 百分点。




图 7 University of Pavia 数据集分类结果

Fig.7 Classification results of data set of University of Pavia

表 2 University of Pavia 数据集分类精度对比

Tab.2 Comparison of classification accuracy of University of Pavia data set								(%)
指标	SVM	PCA	LDA	BG - SuperPCA	S3 - PCA	SuperPCA	本文算法	
OA	86.39	84.45	86.75	89.35	96.34	95.20	97.68	
AA	85.78	86.12	86.10	88.36	95.56	94.85	98.45	
Kappa 系数	84.23	84.55	85.19	88.67	95.78	94.03	98.66	

2.3 参数变化对比

本节实验测试不同训练集比例对 3 种分类精度的影响,测试分别在 2 个数据集上进行,数据集比例分别设置从 5% ~40%,间隔 5 百分点,测试 3 个分




图 8 分类精度随训练集变化图
Fig. 8 Classification accuracy changes with training set

图 9 为在 2 个数据集中,以 10% 训练集,进行测试 Kappa 系数随超像素的数目变化,可以看出,超像素数目的增加会对 Kappa 系数造成一定的影响,即有轻微下降趋势,但总体来看,在超像素数目很高时,2 个数据集中的 Kappa 系数依然有令人满意的表现,这是因为 EMAP 方法弥补了由于超像素过高导致图像过分解时的缺陷,说明了本文算法能够很好地减少对超像素参数的依赖性。




图 9 Kappa 系数随超像素数目变化图
Fig. 9 Kappa coefficient versus the number of superpixels

2.4 消融实验分析

为了全方位验证本文方法的有效性,在本节中,分别在 Indian Pines 数据集中将 EMAP 特征、光谱学 RF、超像素特征这 3 种步骤去除,将训练集逐渐增加至 40%,观察 Kappa 精度的变化,来测试每一个步骤的必要性。

图 10 可以看出,当去掉超像素特征时获得的 Kappa 精度最低,精度较完整方法下降了约 10 百分点,可见对高光谱图像进行局部特征提取的必要性。不叠加 EMAP 特征时获得较高的精度,去掉 RF 步

类精度的变化。图 8 为在 2 个数据集中,3 种分类精度随训练集比例增加的变化图。当训练集比例均从 1% 逐渐增加至 40% 时,3 种分类精度均在提高,验证了本文方法的有效性。

骤的效果次之。但是均未达到完整方法的效果,验证了叠加 EMAP 特征为提取纹理特征时起到了积极的效果。综合来看,去掉任何一个步骤时,都不能达到完整算法所达到的效果,本文提出算法的每一个步骤均对特征提取过程起到了积极作用,每一个步骤都缺一不可。




图 10 Indian Pines 数据集消融试验分析
Fig. 10 Ablation test analysis in Indian Pines data set

3 结论

本文提出了一种基于像素和超像素互补信息自适应融合的 HSI 分类框架。基于超像素的降维方法,采用分而治之的策略,提取了 HSI 固有的低维特征;使用 EMAP 方法从像素级层面提取特征,达到像素级和超像素级信息的互补;同时使用了 RF 方法去除融合信息的冗余;最后采用 SVM 方法确定最后的分类标签。

在 2 个公开的高光谱数据集上进行了实验验证,与现有的几种分类方法相比,该分类方法在 3 种分类精度上均有明显的优势。更重要的是,该方法

可以分别从像素级和超像素级层面提取特征,充分提取 HSI 的内部信息,在保留局部特征的同时联系全局特征。减少了在基于超像素分割方法中对分割参数的依赖性。

在今后的研究工作中,笔者将着眼于更适合超像素级特征和像素级特征的融合方法,从而更好地适应实际应用。

参考文献 (References) :

[1] Camps – Valls G, Tuia D, Bruzzone L, et al. Advances in hyper-spectral image classification; Earth monitoring with statistical learning methods[J]. IEEE Signal Processing Magazine, 2014, 31 (1) : 45 – 54.

[2] Yan L, Zhu R, Mo N, et al. Cross – domain distance metric learning framework with limited target samples for scene classification of aerial images[J]. IEEE Transactions on Geoscience and Remote Sensing, 2019, 57 (6) : 3840 – 3857.

[3] Lu X, Zhang W, Li X. A hybrid sparsity and distance – based discrimination detector for hyperspectral images[J]. IEEE Transactions on Geoscience and Remote Sensing, 2018, 56 (3) : 1704 – 1717.

[4] Horstrand P, Diaz M, Guerra R, et al. A novel hyperspectral anomaly detection algorithm for real – time applications with push – broom sensors[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2019, 12 (12) : 4787 – 4797.

[5] Shimoni M, Haelterman R, Perneel C. Hypersectral imaging for military and security applications; Combining myriad processing and sensing techniques[J]. IEEE Geoscience and Remote Sensing Magazine, 2019, 7 (2) : 101 – 117.

[6] Tong X Y, Xia G S, Lu Q, et al. Land – cover classification with high – resolution remote sensing images using transferable deep models[J/OL]. arXiv, 2018 (2018 – 07 – 16) [2022 – 10 – 04]. <https://arxiv.org/abs/1807.05713v2>.

[7] Krupnik D, Khan S – D. Close – range, ground – based hyperspectral imaging for mining applications at various scales; Review and case studies[J]. Earth – Science Reviews, 2019, 198 : 102952.

[8] Li W, Du Q, Zhang F, et al. Hyperspectral image classification by fusing collaborative and sparse representations[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2016, 9 (9) : 4178 – 4187.

[9] Kang X, Li S, Benediktsson J A. Spectral – spatial hyperspectral image classification with edge – preserving filtering[J]. IEEE Transactions on Geoscience and Remote Sensing, 2014, 52 (5) : 2666 – 2677.

[10] Liang J, Zhou J, Gao Y. Tensor morphological profile for hyperspectral image classification[C]//IEEE International Conference on Image Processing. IEEE, 2016, 20 (6) : 25 – 39

[11] 付 航, 孙根云, 赵云华, 等. 多尺度超像素分割和奇异谱分析

的高光谱影像分类[J]. 中国图象图形学报, 2021, 26 (8) : 1978 – 1993.

Fu H, Sun G Y, Zhao Y H, et al. Combining multiscale superpixel segmentation and singular spectral analysis for hyperspectral image classification[J]. Journal of Image and Graphics, 2021, 26 (8) : 1978 – 1993.

[12] Liao J, Wang L, Zhao G, et al. Hyperspectral image classification based on bilateral filter with linear spatial correlation information[J]. International Journal of Remote Sensing, 2019, 40 (17) : 6861 – 6883.

[13] Feng J, Zhang J, Zhang Y. A multiview spectral – spatial feature extraction and fusion framework for hyperspectral image classification[J]. IEEE Geoscience and Remote Sensing Letters, 2021, 19 : 5504805.

[14] Ren L, Zhao L, Wang Y. A superpixel – based dual window RX for hyperspectral anomaly detection[J]. IEEE Geoscience and Remote Sensing Letters, 2020, 17 (7) : 1233 – 1237.

[15] Sellars P, Aviles – Rivero A, Schonlieb C B. Superpixel contracted graph – based learning for hyperspectral image classification[J]. IEEE Transactions on Geoscience and Remote Sensing, 2020, 58 (6) : 4180 – 4193.

[16] Jiang J, Ma J, Chen C, et al. SuperPCA: A superpixelwise PCA approach for unsupervised feature extraction of hyperspectral imagery[J]. IEEE Transactions on Geoscience and Remote Sensing, 2018, 56 (8) : 4581 – 4593.

[17] Zhang X, Jiang X, Jiang J, et al. Spectral – spatial and superpixel-wise PCA for unsupervised feature extraction of hyperspectral imagery[J]. IEEE Transactions on Geoscience and Remote Sensing, 2021, 60 : 552210.

[18] Beirami A B, Mokhtarzade M. Band grouping SuperPCA for feature extraction and extended morphological profile production from hyperspectral images[J]. IEEE Geoscience and Remote Sensing Letters, 2020, 17 (11) : 1953 – 1957.

[19] Jia S, Deng X, Xu M, et al. Superpixel – level weighted label propagation for hyperspectral image classification[J]. IEEE Transactions on Geoscience and Remote Sensing, 2020, 58 (7) : 5077 – 5091.

[20] 王扣准, 黄 睿. 利用多属性剖面与双边滤波的高光谱影像分类[J]. 遥感信息, 2016, 31 (6) : 104 – 109.

Wang K Z, Huang R. Hyperspectral image classification using extended multi – attribute profiles and guide bilateral filter[J]. Remote Sensing Information, 2016, 31 (6) : 104 – 109.

[21] 罗建华, 李明奇, 郑泽忠, 等. 基于深度卷积神经网络的高光谱遥感图像分类[J]. 西华大学学报 (自然科学版), 2017, 36 (4) : 13 – 20.

Luo J H, Li M Q, Zheng Z Z, et al. Hyperspectral remote sensing images classification using a deep convolutional neural network model[J]. Journal of Xihua University (Natural Science Edition), 2017, 36 (4) : 13 – 20.

[22] 付光远, 辜弘扬, 汪洪桥. 基于加权 K 近邻和卷积神经网络的

高光谱图像分类[J]. 计算机应用研究,2018,35(8):2540 – 2543.

based on weighted KNN and CNN [J]. Application Research of Computers. 2018,35(8):2540 – 2543.

Fu G Y, Gu H Y, Wang H Q. Hyperspectral image classification

Hyperspectral image classification based on superpixel segmentation and extended multi – attribute profiles

LI Lei¹, SUN Xiyan², JI Yuanfa², FU Wentao³

(1. Guangxi Key Laboratory of Precision Navigation Technology and Application, Guilin University of Electronic Technology, Guilin 541004, China; 2. Information and Communication School, Guilin University of Electronic Technology, Guilin 541004, China; 3. National & Local Joint Engineering Research Center of Satellite Navigation Positioning and Location Service, Guilin 541004, China)

Abstract: Superpixel segmentation – based image processing has been extensively used for the classification of hyperspectral images (HSI) in recent years. However, it fails to fully extract the HSI information at a single scale, and its classification process highly depends on parameters. Given the insufficient spatial information utilization by the superpixel segmentation – based HSI classification technology, this study proposed an HSI classification method that combines the superpixel segmentation method and the extended multi – attribute profile (EMAP) method. First, the superpixel segmentation and EMAP methods were employed to extract superpixel – level and pixel – level HSI features, respectively. By fusing the two types of features, the resulting images displayed complete HSI structural characteristics. To eliminate information redundancy, the fused images were subjected to spectral filtering through the recursive filtering method. Finally, the features were input to the support vector machine (SVM) for pixel tag determination. Experiments on the Indian Pines and University of Pavia datasets analyzed the effects of parameter variations on classification accuracy. Compared with the S3 – PCA algorithm, the method proposed in this study exhibited superior classification accuracy and Kappa coefficient, which were improved by 3.55 and 2.88 percentage points, respectively.

Keywords: hyperspectral image classification; information fusion; feature extraction; superpixel segmentation
(责任编辑: 张 仙)