

DOI:10.3969/j.issn.1673-4785.201410040
网络出版地址: <http://www.cnki.net/kcms/detail/23.1538.TP.20150317.1025.001.html>

基于谱域-空域结合特征和图割原理的高光谱图像分类

尤雅萍^{1,3}, 成运², 苏松志^{1,3}, 曹冬林^{1,3}, 李绍滋^{1,3}

(1. 厦门大学 信息科学与技术学院, 福建 厦门 361005; 2. 湖南人文科技学院 信息科学与工程系, 湖南 娄底 417000; 3. 福建省仿脑智能系统重点实验室, 福建 厦门 361005)

摘 要: 高光谱图像中存在着特征维度高而训练集小的问题。为解决该问题, 提出了一种 2 步走的分类方法: 1) 通过支持向量机对图像进行初步分类, 根据分类结果计算出每个类别的均值特征; 2) 使用 1) 计算出来的均值特征作为能量函数的数据项, 然后利用图割原理对图像做二次分类。实验中发现: 空间上相近的像素点往往具有相似的特征, 且属于同一个类别。针对这种现象, 提取一个将谱域特征和空域特征相结合的新特征。该特征既包含了光谱信息也包含了空间信息, 具有较好的分类性能和鲁棒性。在 Indian Pine 数据集和 Pavia University 数据集进行实验, 实验结果表明了本文提出方法的有效性。

关键词: 高光谱; 图像分类; 谱域特征; 空域特征; 谱域-空域结合特征; 均值特征; 支持向量机; 图割原理
中图分类号: TP391.4 **文献标志码:** A **文章编号:** 1673-4785(2015)02-0201-08

中文引用格式: 尤雅萍, 成运, 苏松志, 等. 基于谱域-空域结合特征和图割原理的高光谱图像分类[J]. 智能系统学报, 2015, 10(2): 201-208.

英文引用格式: YOU Yaping, CHENG Yun, SU Songzhi, et al. Hyperspectral image classification based on spectral-spatial combination features and graph cut[J]. CAAI Transactions on Intelligent Systems, 2015, 10(2): 201-208.

Hyperspectral image classification based on spectral-spatial combination features and graph cut

YOU Yaping^{1,3}, CHENG Yun², SU Songzhi^{1,3}, CAO Donglin^{1,3}, LI Shaozi^{1,3}

(1. School of Information Science and Technology, Xiamen University, Xiamen 361005, China; 2. Department of Information Science and Engineering, Hunan University of Humanities, Science and Technology, Loudi 417000, China; 3. Fujian Key Laboratory of the Brain-Like Intelligent Systems, Xiamen 361005, China)

Abstract: The high-dimension of the feature vs. small-size of training set is an unsolved problem in the hyperspectral image classification task. To solve this problem a two-step classification method is proposed. Firstly, a preliminary classification is performed by the support vector machine (SVM) and the classification results are used to calculate the mean feature (MF) of each class. Secondly, a classification based on the graph cut theory is applied with the MFs as an input of the energy function. The experimental results showed that spatially nearby pixels have large possibilities of having the same label and similar features. Therefore, a new feature called spectral-spatial combination (SSC) is extracted that combines the spectral-based feature and spatial-based feature. The SSC feature contains the related spectral and spatial information of each pixel and provides better classification performance and robustness. Experiment results on the Indian Pine dataset and the Pavia University dataset demonstrated the effectiveness of the proposed method.

Keywords: hyperspectral; image classification; spectral feature; spatial feature; spectral-spatial combination feature; mean features; support vector machines; graph cut

收稿日期: 2014-10-29. 网络出版日期: 2015-03-17.
基金项目: 国家自然科学基金资助项目(61202143); 福建省自然科学基金资助项目(2013J05100, 2010J01345, 2011J01367); 湖南省自然科学基金资助项目(12JJ2040).
通信作者: 李绍滋. E-mail: szlig@xmu.edu.cn.

自 20 世纪 80 年代以来, 高光谱遥感图像的光谱分辨率已达到纳米级别, 设备获取到的光谱信息比较准确和丰富。因此, 人们开创了高光谱遥感对

地观测技术来识别地物类别,这是传统 RGB 图像和多光谱图像所不能完成的。虽然高光谱遥感图像分类技术目前已经取得了一定进展,但依然存在着一些挑战:1) 特征维度高而训练集小,高光谱图像上每个像素点的原始光谱特征多达百维,而且,高光谱图像的样本标注往往需要有技巧的专家人工地进行分类,代价昂贵,使得获取一个足够大的训练样本集变得不可行,从而影响分类器模型的性能;2) 以像素为单位的分类具有空间相似特性。所谓的空间相似特性指的是:空间上相邻的像素点属于同一个类别的概率更大。如何更好地利用空间信息,将这一特性应用到高光谱图像分类当中,以提高分类结果的准确率,是当前一个研究方向。目前国内外对高光谱图像分类技术的研究方法可以归纳为特征研究的方法和空间信息利用的方法。

由于光谱通道数量的剧增,高光谱图像中存在着冗余现象,因此可通过特征提取^[1-5]来获取有用特征,将原始高维数据映射到低维空间,构建新的特征,降低数据的维度。其中,无监督学习的方法包括经典的 PCA^[1]、IDA^[2]等。有监督方法包括 LDA^[3]以及针对 LDA 在高光谱图像中的应用的几种改进方法,如 NDA、NWFE 和 DNP^[3],这几种方法都是根据最大化类间距、最小化类内距原理来实现的。半监督方法是当前高光谱图像分类技术当中比较适用的一种方法,在一定程度上缓解了小训练集带来的问题。浙江大学的钱云涛教授提出了一种三维离散小波变换纹理特征^[6],从多个不同的尺度、频域、方向对高光谱图像数据立方体进行分解。文献[7]提出了基于谱聚类的波段选择技术,以波段图像为样本点生成相似度矩阵,通过谱聚类,将所有数据分成 k 类,从中选择 k 个有代表性的波段参与后续分类工作。

不管是特征选取,还是特征提取,都没有考虑到像素空间之间的相关性。通过对高光谱图像伪成像图的分析观察,发现空间位置相邻的像素点有很大的概率是同一类别。基于这个特性,谱域-空域结合的高光谱图像分类技术开始发展^[8-11]。比如文献[10]中构建超图,图中有 2 种超边,一种是基于特征的超边,通过在特征空间中,寻找距离最近的 k 个像素点来生成的;另一种是基于空间的超边,通过连接空间位置上 k 个相邻的像素点来生成的。文献[11]首先利用最大噪声分量方法和虚拟维数估计算法对高维图像进行特征提取和主分量数目计算,并且用数学形态学操作方法提取主分量图像的目标

形态信息,根据得到的空域特征,与原始光谱特征相结合得到最终的组合特征。

以上的方法更多的是将原始光谱特征信息和空间信息分成 2 个独立的部分,本文提出一种将两者相结合的方法,将空间信息加入到原始光谱特征当中,提取一个新的基于谱域-空域相结合的特征(spectral-spatial combination feature, SSC),通过 SVM 训练分类器模型,对图像进行初步分类;然后,基于图割(graph cut, GC)原理对初步分类结果进行修改,做一个二次分类,进一步考虑空间相似特性,提高分类性能。

1 谱域-空域结合的特征提取

1.1 基于谱域的特征

高光谱图像是通过遥感设备在一条连续的光谱窄波段上抓取光谱信息成像而得,图像上的每个像素点在各个波段上都会有一个对应的光谱强度值,由此可以构成一条具有上百个波段光谱值的光谱曲线。通过早期的实验发现,现实生活当中相同的物质,光谱曲线相同或相近;不同的物质,则光谱曲线有所区别。因此,使用光谱曲线上的光谱强度值作为特征,可以用来描述不同类别标签,作为目标分类的一个判断依据,将这种特征称为基于谱域的特征。本文为了避免特征选取和特征提取过程中可能造成的信息丢失,将使用所有波段的光谱强度值来构成基于谱域的特征。假设有像素点 A ,那么它的谱域特征可以表示为 $\mathbf{x}_{\text{spe}_A}$,且被归一化到 $[-1, 1]$ 。

1.2 基于空域的特征

本文中空域特征描述的是空间邻域像素点的总体加权特征。首先定义一个空间邻域,然后根据邻域点与中心像素点的距离设定权值,最后计算整个空间邻域像素点的加权特征和,所得结果即为中心像素点的空域特征。空间邻域范围可包括一阶邻域、二阶邻域、 3×3 、 5×5 等,如图 1 所示。本文采用 3×3 的空间邻域范围。




图 1 4 种不同空间邻域

Fig.1 Four types of spatial neighbors for centroid pixel

对于像素点 A , $N(A)$ 表示其空间邻域点的集合,那么,基于空域的特征 $\mathbf{x}_{\text{spa}_A}$ 计算公式为

$$\mathbf{x}_{\text{spa}_A} = \sum_{x \in N(A)} w(x) \times \mathbf{x}_{\text{spe}} \quad (1)$$

式中: \mathbf{x}_{spe} 是 A 的邻域点 x 的基于谱域的特征, $w(x)$ 是权值,该值的大小与两像素点间的欧拉距离 $d(A,x)$ 成反比:

$$w(x) = \frac{1}{d(A,x)}, \quad \text{s.t.} \quad \sum_{x \in N(A)} w(x) = 1 \quad (2)$$

1.3 基于谱域-空域结合的特征

目前在大部分的高光谱图像分类技术方法当中,普遍使用的是原始光谱特征,或者基于原始特征的一个特征提取。由于高光谱图像具有空间相似特性,可以利用空间邻域像素点的特征来平滑噪点特征。当中心像素点为噪点,周围空间邻域点都属于同一个类别的时候,那么加入空域特征,可以一定程度上改变噪点的特征,趋于同类化,使其正确分类。因此,本文提出了 SSC,该特征由 2 部分特征组成:中心像素点自身的谱域特征及其空间邻域点权值计算得到的空域特征。由于自身的谱域特征和周围空间特征的重要性并不是同等的,所以通过特征权值修正量的设置来实现对两部分特征在组合当中的贡献率的调整。对于像素点 A ,最终提取得到的 SSC 特征为 $\mathbf{x}_{\text{SSC}_A}$,计算公式为

$$\begin{aligned} \mathbf{x}_{\text{SSC}_A} &= k_{\text{spe}} \mathbf{x}_{\text{spe}_A} + k_{\text{spa}} \mathbf{x}_{\text{spa}_A} \\ \text{s.t.} \quad k_{\text{spe}} + k_{\text{spa}} &= 1 \end{aligned} \quad (3)$$

式中: k_{spe} 和 k_{spa} 都是非负整数,取值范围为 $[0,1]$ 。

2 图像分类

2.1 SVM 初步分类

通常情况下,支持向量机在多分类问题上有优势^[12-16]。而高光谱图像分类技术正好是多类别的分类问题,因此本文采用 SVM 来训练分类器模型。分类结果是通过决策函数 $f(\mathbf{x})$ 来判断,如式(4):

$$f(\mathbf{x}) = \sum_{i \in S} a_i y_i K(\mathbf{x}_i, \mathbf{x}) + b \quad (4)$$

在训练阶段,本文先通过一个有限大小的训练样本集得到 SVM 分类器模型。由于训练样本是离散存在的,没有空间邻域,并且样本本身是由人工精确标注,噪点的可能性很低,所以将训练样本基于谱域的特征 \mathbf{x}_{spe} 直接作为训练的输入特征,采用基于 RBF 核函数的支持向量机训练出分类器模型,如式(5)所示:

$$\begin{aligned} K(\mathbf{x}_i, \mathbf{x}_j) &= \langle \varphi(\mathbf{x}_i) \cdot \varphi(\mathbf{x}_j) \rangle = \\ &\exp\left(-\frac{\|\mathbf{x}_i - \mathbf{x}_j\|^2}{2\sigma^2}\right) \end{aligned} \quad (5)$$

在测试阶段,对高光谱图像上的每个像素点依次提取基于谱域-空域相结合的特征作为输入,通

过训练得到的分类器模型,对像素点进行分类,最终得到一个 SVM 初步分类结果 \mathbf{Y}_{test} 。

2.2 类别均值特征

已知同一类别的样本具有相同或相近的光谱特征,那么可以通过将同一类别的样本的特征进行求和取平均,得到一个特征向量,作为这个类别的均值特征。有了这个均值特征,就可以计算测试样本与各个类别的特征相似度,作为基于 GC 原理进行二次分类的一个分类代价判断依据。

高光谱图像分类技术当中现存的小训练集因素,导致了样本集存在信息不足等问题,本文利用整个高光谱图像的 SVM 初步分类结果来计算类别均值特征 \mathbf{m} 。

$$\mathbf{m}_j = \frac{\sum_{i=1}^n \mathbf{x}_{\text{SSC}_i} \cdot I\{l_i = j\}}{\sum_{i=1}^n I\{l_i = j\}} \quad (6)$$

式中: \mathbf{m}_j 是标签为 j 的像素点的均值特征, n 为高光谱图像的像素点总数, l_i 为像素点 i 的 SVM 分类结果, $I\{l_i = j\}$ 是指示函数,表示 l_i 等于标签 j 。

2.3 基于 GC 的二次分类

在以像素为单位的图像分类当中,空间位置上相近的像素直观上更可能是属于同一类的,所以无论是基于光谱信息还是空间信息的分类代价在分类的过程中都应该被考虑进去。根据 MRF 可知,一个像素的分类仅仅依赖于像素本身以及空间上相邻的像素。而 GC 算法的基本原理就是受 MRF 启发而来。因此,在 SVM 初步分类的结果上,本文使用 GC 算法来进行第 2 次的分类,目的在于修正自身分类标签和空间邻域像素标签差别很大的像素点。

在将 GC 算法应用到高光谱图像的过程中, V 是高光谱图像的像素集, E 是上述像素集中空间相邻的像素点之间的边集合。二次分类目标在于找到一个分类结果 $l: V \rightarrow L$, 使损失函数(7)的值最小。

$$C(l) = \sum_{i \in V} C_{\text{spe}_i, l_i} + \sum_{(i,j) \in E} C_{\text{spa}_i, l_i, j, l_j} \quad (7)$$

式中: $C(l)$ 表示对全部像素进行分类的损失函数,它是光谱分类代价和空间分割代价之和。其中 C_{spe} 是每个像素点基于光谱信息进行分类的光谱分类代价; C_{spa} 是每个像素点基于空间信息进行分类的空间分割代价。

式(7)是一个 NP 困难问题,本文采用 Boykov^[17]提出的方法来求解这个方程,式(8)~(11)是式(7)当中各个项的详细展开解释。

$$C_{\text{spe}_{i,l_i}} = \begin{cases} d(\mathbf{x}_{\text{SSC}_i}, \mathbf{m}_{l_i}), l_i \neq y_i \\ 0, l_i = y_i \end{cases} \quad (8)$$

$$d(\mathbf{x}_{\text{SSC}_i}, \mathbf{m}_{l_i}) = \sqrt{\|\mathbf{x}_{\text{SSC}_i} - \mathbf{m}_{l_i}\|^2} \quad (9)$$

式中对于像素 i , l_i 是它在 GC 二次分类中的分类结果标签。当二次分类结果与 SVM 初步分类结果一样时,光谱分类代价 $C_{\text{spe}_{i,l_i}}$ 为 0;当 2 次分类结果不一样,通过计算像素点 i 与类别 l_i 的标准特征之间的相似度来决定光谱分类代价 $C_{\text{spe}_{i,l_i}}$ 大小,相似度由欧拉距离公式计算得到。

$C_{\text{spa}_{i,l_i,j,l_j}}$ 表示将 2 个相邻的像素分为 2 个类的空间分割代价。在现实的应用中,有 2 个问题必须考虑。1) 当 2 个相邻的像素点被分为同类的时候,不存在分割,所以分割代价应该为 0;2) 当 2 个处在同质区的相邻像素点被分为不同类的时候,分割代价应该较大;而当处在非同质区的相邻像素点被分为不同类的时候,分割代价应该趋于 0。于是式(7)中的第 2 个项就可以展开成式(10)、(11):

$$C_{\text{spa}_{i,l_i,j,l_j}} = w_{ij}d(l_i, l_j) \quad (10)$$

$$d(l_i, l_j) = \begin{cases} 1, & l_i \neq l_j \\ 0, & l_i = l_j \end{cases} \quad (11)$$

式中对于任意一个像素点对 (i, j) , w_{ij} 可以被看做是像素点 i, j 之间的边缘权重。根据 MRF 可知当 i 和 j 空间相邻的时候,边的权重是一个非 0 值。同时权重 w_{ij} 也负比于 i 和 j 的特征相似度。同时又可以通过计算 SSC 的特征欧式距离来衡量像素点间的相似性。于是得到权重 w_{ij} 的表达式:

$$w_{ij} = \begin{cases} \frac{1}{d(\mathbf{x}_i, \mathbf{x}_j)}, i, j \text{ 相邻} \\ 0, \text{其他} \end{cases} \quad (12)$$

3 实验结果及分析

3.1 数据集

实验采用了高光谱图像的 2 个典型数据集,一是用 AVIRIS 遥感设备抓取的 Indian Pine 数据集,图像的宽度和高度均为 145 像素,波段数为 220。该数据集中包含 16 个类别和 10 366 个已标注的样本点,除去一些样本数很少的类别,留下 9 个类别用于实验。表 1 给出了 Indian Pine 数据集的信息。另一个数据集是用 ROSIS-03 遥感设备在帕维亚上空拍摄的 Pavia University 数据集。它包含有 610×340 个像素点和 115 个波段,去除 12 个噪声波段后,剩下 103 个波段用于实验。数据集中包含 9 个类别和 42 776 个标注样本点。表 2 给出了 Pavia University 数据集的相关信息。

表 1 Indian Pine 数据集信息
Table 1 Information about the Indian Pine data set

标签	类别	颜色
1	Corn-notill	255, 255, 0
2	Com-mintill	0, 255, 0
3	Grass-pasture	184, 92, 0
4	Grass-trees	192, 192, 192
5	Hay-windowed	255, 102, 0
6	Soybean-notill	255, 0, 0
7	Soybean-mintill	200, 100, 200
8	Soybean-clean	0, 255, 255
9	Woods	85, 100, 255

表 2 Pavia University 数据集信息
Table 2 Information about the PaviaU data set

标签	类别	颜色
1	Asphalt	192, 192, 192
2	Meadows	0, 255, 0
3	Gravel	0, 255, 255
4	Trees	0, 128, 0
5	Metal Sheets	255, 0, 255
6	Soil	165, 82, 41
7	Bitumen	128, 0, 128
8	Bricks	255, 0, 0
9	Shadow	255, 255, 0

3.2 评价指标

在高光谱图像分类技术研究中有 4 个常用的评价指标^[18]:生产者精度(producer's accuracy, PA),用户精度(user's accuracy, UA),总体精度(overall accuracy, OA)和 κ 统计值(Kappa coefficient)。其中 OA 和 κ 属于综合指标。

3.3 参数设定

实验过程中,衡量空域和谱域特征贡献率的参数 k_{spe} 的取值,可以使用自适应算法进行计算,本文只是通过简单的步长设定,在 $[0, 1]$ 循环调参,找出分类准确率最高的较优值。SVM 分类器的惩罚因子 C 在 $[10^{-3}, 10^3]$ 上通过对数等分函数,寻找较优值。

3.4 对比方法

为了证明所提出方法的有效性,将本文最终的方法(SSC/SVMGC)与其他 3 种方法进行对比。第 1 种是原始特征的简单 SVM 分类方法(SVM),第 2 种是本文提出的 SSC 特征加上 SVM 分类器(SSC/SVM),第 3 种是文献[18]中提出的方法,该方法首先采用原始光谱特征加 SVM 分类,然后用 GC 算法进行优化(SVM/GC^[18])。

3.5 实验对比结果

3.5.1 不同大小的训练集

该组实验主要是通过对多组大小不同的训练样

本的分类效果进行对比,选取合适的训练集。在 Indian Pine 数据集中每个类别的训练样本数为:3、5、10、20、50 和 100, $k_{spe} = 0.8$ 。在 Pavia University 数据集中,每个类别的训练样本数为:25、50、100、200、300 和 400, $k_{spe} = 0.1$ 。图 2 给出了实验结果。

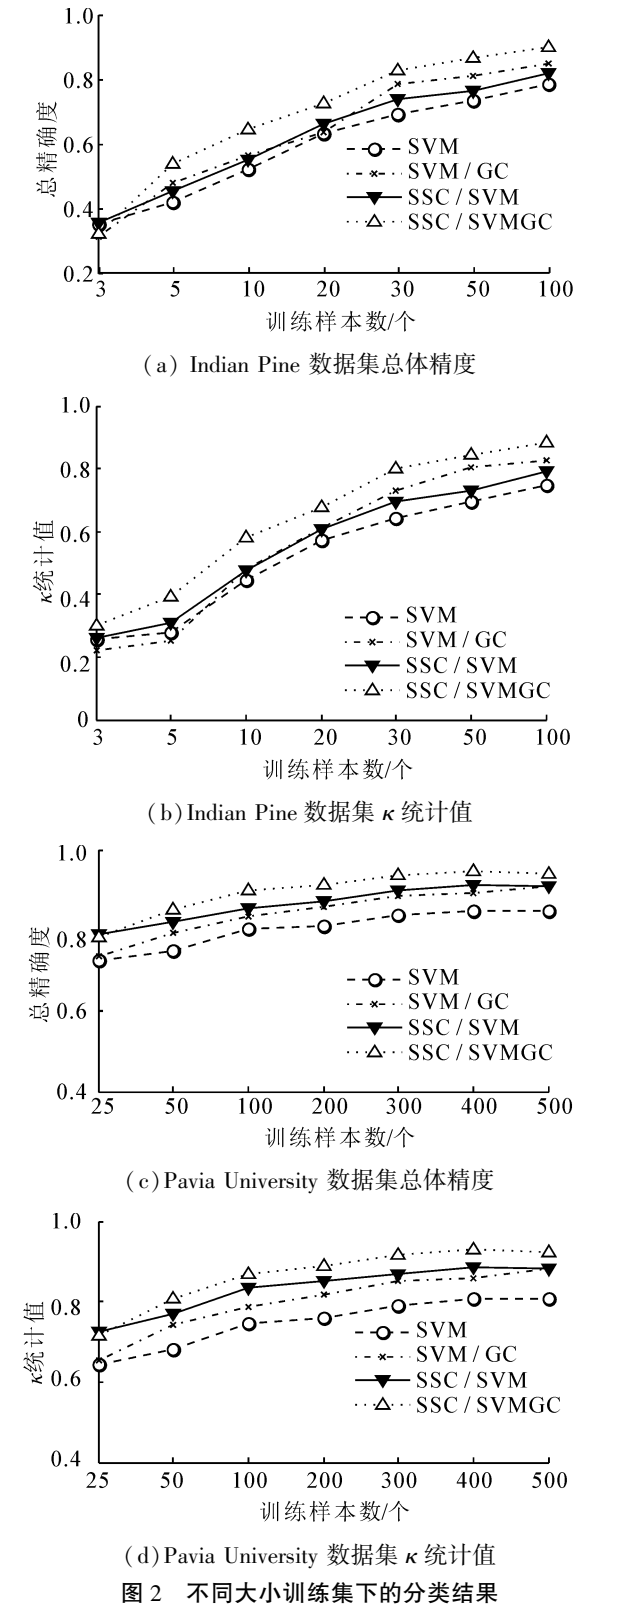


图 2 不同大小训练集下的分类结果

Fig.2 Classification results with different training sizes

从实验结果中可以发现:当训练集相对较小时,分类效果会相对较差。随着训练数据集的增大,准确率会相应提高,直到接近一个饱和点。当有足够的训练样本数时,分类效果会趋于稳定。因此本文之后的实验,都是在 50×9 个训练样本的 Indian Pine 数据集和 300×9 个训练样例的 Pavia University 数据集上进行。

可以看到在不同大小的训练集情况下,本文提出的方法效果通常都比别的方法好,证实了所提出方法的有效性和鲁棒性。

3.5.2 参数 k_{spe} 和 k_{spa}

参数 k_{spe} 和 k_{spa} 用于调节谱域特征和空域特征在 SSC 特征中所占的比例。实验发现通过调整光谱特征和空间特征的贡献率,可以有效优化分类结果,如图 3 所示。Indian Pine 数据集的最佳 k_{spe} 是 0.8, Pavia University 数据集是 0.1。




Fig.3 Classification results with different k_{spe}

3.5.3 不同方法的对比

该组实验对 4 种方法的分类结果进行了详细的比较。图 4~5 和表 3~6 表明,在 50×9 个训练样本的 Indian Pine 数据集和 300×9 个训练样例的 Pavia University 数据集上,所有的方法都取得了不错的效果。然而相比于简单 SVM 分类的方法,SSC/SVM 在 Indian Pine 和 Pavia University 数据集上准确率分别提升了 1.77%和 7.16%。这说明 SSC 特征胜过原始光谱特征。而方法 SSC/SVMGC 相比 SSC/SVM,其准确率在 Indian Pine 和 Pavia University 数据集上分别提升了 11.85%和 6.08%。这表明将 GC 理论应用于高光谱图像分类中是有效的。在 Indian Pine 数据集上,本文最终所提出的 SSC/SVMGC 方法的总体精度相对于 SVM、SSC/SVM 和 SVM/GC^[18] 分别提升了 13.62%、11.85%和 6.33%,而在 Pavia University 数据集中分别提升了 13.24%、6.08%和 8.09%。




图 4 不同分类方法下的 Indian Pine 数据集分类结果
Fig.4 Classification results of the Indian Pine data set by different methods





图 5 不同分类方法下的 Pavia University 数据集分类结果
Fig.5 Classification results of the Pavia University data set by different methods

表 3 Indian Pine 数据集的总体精度和 κ 统计值

Table 3 Overall accuracy and Kappa coefficient of the Indian Pine

指标	SVM	SSC/SVM	SVM/GC	SSC/SVMGC
总体精度	0.732 9	0.750 6	0.805 8	0.869 1
κ 统计值	0.693 0	0.713 8	0.772 6	0.847 9

表 4 Pavia University 数据集的总体精度和 κ 统计值

Table 4 Overall accuracy and Kappa coefficient of the Pavia University

指标	SVM	SSC/SVM	SVM/GC	SSC/SVMGC
总体精度	0.834 8	0.906 4	0.886 3	0.967 2
κ 统计值	0.787 3	0.878 4	0.851 7	0.956 6

使用 GC 算法进行二次分类需要增加一定的时间,其中,大小为 610×340 的 Pavia University 数据集在 SVM 测试分类阶段所需分类时间为 28.91 s,GC 二分类阶段所需时间为 6.03 s,准确率提高了 6%,这在高光谱图像分类非实时应用领域是可以接受的。

表 5 训练样本集大小为 50×9 的 Indian Pine 数据集的生产者精度和用户精度($k_{spe}=0.8$)

Table 5 Producer's Accuracy and User's Accuracy of the Indian Pine with 50 training samples per class($k_{spe}=0.8$)

Class	生产者精度				用户精度			
	SVM	SSC/SVM	SVM/GC	SSC/SVMGC	SVM	SSC/SVM	SVM/GC	SSC/SVMGC
1	0.567 9	0.581 2	0.748 6	0.601 5	0.689 6	0.713 7	0.592 2	0.937 8
2	0.713 3	0.788 0	0.637 3	0.991 6	0.381 4	0.390 4	0.763 3	0.543 6
3	0.933 7	0.954 5	0.940 0	0.944 1	0.874 0	0.893 4	0.968 0	0.932 5
4	0.987 7	0.990 4	1.000 0	0.983 6	0.941 3	0.952 6	0.973 3	0.969 0
5	1.000 0	1.000 0	1.000 0	1.000 0	0.981 5	0.983 5	0.965 7	0.995 8
6	0.699 6	0.723 3	0.759 3	0.805 6	0.619 9	0.660 1	0.852 2	0.750 7
7	0.536 9	0.540 9	0.733 2	0.839 1	0.812 6	0.855 7	0.811 9	0.959 0
8	0.807 8	0.851 6	0.640 8	0.984 8	0.623 7	0.662 7	0.569 7	0.945 0
9	0.978 7	0.987 4	0.998 4	0.999 2	0.990 4	0.994 4	0.992 9	0.983 7

表 6 训练样本集大小为 300×9 的 Pavia University 数据集的生产者精度和用户精度 ($k_{spe} = 0.1$)

Class	生产者精度				用户精度			
	SVM	SSC/SVM	SVM/GC	SSC/SVMGC	SVM	SSC/SVM	SVM/GC	SSC/SVMGC
1	0.815 3	0.965 5	0.817 1	0.970 0	0.952 8	0.929 6	0.961 0	0.942 3
2	0.813 7	0.875 5	0.900 0	0.989 0	0.939 0	0.983 0	0.960 2	0.997 6
3	0.805 6	0.824 2	0.834 7	0.848 0	0.713 8	0.921 2	0.761 7	0.965 8
4	0.955 6	0.921 7	0.982 4	0.930 8	0.799 6	0.854 5	0.777 2	0.936 0
5	0.997 8	1.000 0	0.997 8	1.000 0	0.994 8	1.000 0	0.994 8	1.000 0
6	0.802 9	0.940 5	0.848 5	0.985 3	0.589 0	0.698 6	0.803 9	0.962 3
7	0.908 3	0.934 6	0.914 3	0.945 1	0.712 3	0.995 2	0.716 1	0.995 2
8	0.812 6	0.883 5	0.866 6	0.917 4	0.760 7	0.855 8	0.787 1	0.872 0
9	0.983 1	0.971 5	0.983 1	0.982 0	0.865 2	0.988 2	0.865 2	0.988 3

4 结 论

为了解决高光谱图像分类特征维度高、训练集小的问题,并且合理利用像素类别标签空间相似性高的特性,提出了谱域和空域相结合的特征 SSC,并应用 GC 原理对 SVM 的初步分类结果进行二次优化。通过对实验结果的分析,可以得出以下结论:

1) 基于谱域和空域相结合的 SSC 特征分类效果好于基于原始光谱特征,SSC 特征较好地利用空间邻域信息,减少了噪点数量;

2) 将高光谱图像分类看做是一个机器学习问题,然后用 GC 算法来解决,是一种非常有效的方法。GC 算法的使用对处于边缘轮廓的像素点的分类起到较好的作用,对边缘点除了考虑光谱分类代价,还实际性地考虑了分割代价。

本文提出的方法虽然已经取得了很好的实验效果,但是仍有一些有待解决的问题。首先,文中参数 k_{spe} 是通过一个简单的循环实验来设置的,在未来工作中要思考怎样通过机器学习算法来寻求其最优值。其次,各个类别的标准特征作为 GC 的一个参数,它的准确率是非常重要的。之后的实验当中可以考虑加入主动学习方法,从 SVM 初步分类结果中选出具有价值的样本,作为新样本加入到样本集中,扩充样本集,提升 SVM 分类器性能。

参考文献:

[1] FONG M. Dimension reduction on hyperspectral images[R]. Los Angeles: University of California, 2007.

[2] WANG J, CHANG C I. Independent component analysis based dimensionality reduction with applications in hyperspectral image analysis[J]. IEEE Transactions on Geosci-

ence and Remote Sensing, 2006, 44(6): 1586-1600.

[3] 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.

[4] 苏红军,杜培军,盛业华. 高光谱遥感数据光谱特征提取算法与分类研究[J]. 计算机应用研究, 2008, 25(2): 390-394.

SU Hongjun, DU Peijun, SHENG Yesheng. Study on feature extraction and experiment of hyperspectral data[J]. Application Research of Computers, 2008, 25(2): 390-394.

[5] 赵春晖,齐滨, YOUN E. 基于蒙特卡罗特征降维算法的小样本高光谱图像分类[J]. 红外与毫米波学报, 2013, 32(1): 62-67.

ZHAO Chun Hui, QI Bin, YOUN E. Hyperspectral image classification based on Monte Carlo feature reduction method[J]. J Infrared Millim Waves, 2013, 32(1): 62-67.

[6] QIAN Y T, YE M, ZHOU J. Hyperspectral image classification based structured sparse logistic regression and three-dimensional wavelet texture features[J]. IEEE Transactions on Geoscience and Remote Sensing, 2013, 51(4): 2276-2291.

[7] 彭艳斌,艾解清. 基于谱聚类波段选择的高光谱图像分类[J]. 光电工程, 2012, 39(2): 63-67.

PENG Yanbin, AI Jieqing. Hyperspectral imagery classification based on spectral clustering band selection[J]. Opto-Electronic Engineering, 2012, 39(2): 63-67.

[8] 王国立,孙杰,肖倩. 结合空-谱信息的高光谱图像分类方法[J]. 黑龙江大学自然科学学报, 2010, 27(6): 788-791.

WANG Guoli, SUN Jie, XIAO Qian. Combination of spatial information and spectral information for hyperspectral imagery classification[J]. Journal of Natural Science of Hei-LongJiang University, 2010, 27(6): 788-791.


- [9] 吴见, 彭道黎. 基于空间信息的高光谱遥感植被分类技术[J]. 农业工程学报, 2012, 28(5): 150-153.
WU Jian, PENG Daoli. Vegetation classification technology of hyperspectral remote sensing based on spatial information [J]. Transactions of the Chinese Society of Agricultural Engineering, 2012, 28(5): 150-153.
- [10] JI R R, GAO Y, HONG R, et al. Spectral-spatial constraint hyperspectral image classification[J]. IEEE Transactions on Geoscience and Remote Sensing, 2014, 52(3): 1811-1824.
- [11] 高恒振, 万建伟, 粘永健, 等. 一种基于谱域-空域组合特征支持向量机的高光谱图像分类算法[J]. 宇航学报, 2011, 32(4): 917-921.
GAO Hengzhen, WAN Jianwei, NIAN Yongjian, et al. Hyperspectral image classification algorithm based on spectral-spatial hybrid features and SVM[J]. Journal of Astronautics, 2011, 32(4): 917-921.
- [12] BENEDIKTSSON 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.
- [13] FREUND Y and SCHAPIRE R E. A decision theoretic generalization of online learning and an application to boosting [J]. Journal of Computer and System Sciences, 1997, 55(1): 119-139.
- [14] MARCONCINI M, CAMPS-VALLS G, BRUZZONE L. A composite semisupervised SVM for classification of hyperspectral images[J]. IEEE Geoscience Remote and Sensing Letters, 2009, 6(2): 234-238.
- [15] ARCHIBALD R, FANN G. Feature selection and classification of hyperspectral images with support vector machines [J]. IEEE Geoscience Remote and Sensing Letters, 2007, 4(4): 674-677.

- [16] BRUZZONE L, CHI M, MARCONCINI M. A novel transductive SVM for semisupervised classification of remote sensing images[J]. IEEE Geoscience Remote and Sensing Letters, 2006, 44(11): 3363-3373.
- [17] BOYKOV Y, VEKSLER O, ZABIH R. Fast approximate energy minimization via graph cuts[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2001, 23(11): 1222-1239.
- [18] BAI J, XIANG S M, PAN C H. A graph based classification method for hyperspectral images[J]. IEEE Transactions on Geoscience and Remote Sensing, 2012, 51(2): 803-817.


作者简介:



尤雅萍, 女, 1990 年生, 硕士研究生, 主要研究方向为高光谱图像分类技术。



苏松志, 1982 年生, 男, 博士, 助理教授, 主要研究方向为人体行为分析与理解。主持国家青年基金一项, 主持省青年基金一项, 参与多项国家级基金项目, 发表学术论文多篇, 其中被 SCI 检索 7 篇。



李绍滋, 1963 年生, 男, 教授, 博士生导师, 博士, 福建省人工智能学会副理事长, 主要研究方向为运动目标检测与识别、自然语言处理与多媒体信息检索等。发表学术论文 200 余篇, 其中被 SCI 检索 26 篇、被 EI 检索 170 篇。