

# 基于特征加权的高光谱图像融合分类<sup>①</sup>

汪超永<sup>1</sup>, 孙丙宇<sup>2</sup>, 李文波<sup>2</sup>

<sup>1</sup>(中国科学技术大学 自动化系, 合肥 230036)

<sup>2</sup>(中国科学院 合肥智能机械研究所, 合肥 230031)

**摘要:** 在对高光谱图像监督分类中, 传统的监督学习方法对高光谱数据进行分类时需要获取足够的有标记样本作为训练样本, 这样可以有效的避免 Hughes 效应. 实际情况下的高光谱数据拥有较多的波段和相对较小的训练样本集给传统的遥感图像分类方法带来了挑战. 因此, 提出了一种基于特征组合以及特征加权的高光谱图像分类算法, 针对纹理特征分析难度较大的现实, 利用一阶直方图的统计特征描述图像纹理特征, 通过类内散度矩阵的逆矩阵作为特征加权矩阵构造组合核函数将高光谱光谱特征和空间特征融合起来, 同时利用特征加权的方法用于提高小训练样本的监督分类精度. 实验结果表明, 本文所提的方法对小样本的高光谱数据分类具有良好的效果.

**关键词:** 支持向量机; 高光谱图像; 特征加权; 一阶直方图; 组合核函数

## Fusion Hyperspectral Image Classification Based on Feature Weighting

WANG Chao-Yong<sup>1</sup>, SUN Bing-Yu<sup>2</sup>, LI Wen-Bo<sup>2</sup>

<sup>1</sup>(Department of Automation, University of Science and Technology of China, Hefei 230026, China)

<sup>2</sup>(Institute of Intelligent machine, Chinese Academy of Sciences, Hefei 230031, China)

**Abstract:** When supervised classification of hyperspectral images, the traditional supervised learning method for hyperspectral data classification needs to obtain enough samples marked as training samples, which can effectively avoid Hughes effects. Hyperspectral data under actual conditions with more bands and relatively small training set a challenge to the traditional remote sensing image classification. Therefore, this paper presents an approach based on a weighted combination of features and characteristics of hyperspectral image classification algorithm for texture analysis more difficult reality, the use of a first-order statistical characteristics describe the image histogram texture features within class scatter matrix by inverse matrix method as a feature weighting matrix structure combined kernel function hyperspectral spectral characteristics and spatial characteristics integrate, while taking advantage of features to improve the small weighted training samples for supervised classification accuracy. Experimental results show that the method proposed in this paper for a small sample of hyperspectral data classification with good results.

**Key words:** support vector machines(SVM); hyperspectral image; first order histogram; feature weighting; combined kernel function

## 1 引言

高光谱遥感技术兴起于上个世纪 80 年代, 随着美国宇航局喷气推进实验室研制出航空可见光和红外光成像光谱仪, 给高光谱遥感技术全面发展提供了契机. 遥感图像分类技术在现实情况下有着非常广泛的应

用<sup>[1]</sup>, 当前高光谱图像分类技术是高光谱遥感领域的基础问题也是研究热点. 遥感图像记录遥感卫星观察地区一定时间段以内的地物电磁波幅, 包含了丰富的空间、光谱和辐射信息. 虽然理论上高光谱图像携带大量信息, 但是其数据存在很大的冗余且数据量剧增,

① 基金项目: 国家科技支撑计划(2014BAD10B08)

收稿时间: 2015-01-07; 收到修改稿时间: 2015-03-12

给我们技术上的处理带来了困难. 在不损失信息量的前提下, 国内外学者提出的所有算法和方法中都会通过降维来提取有效数据. 在分类方法中, SVM(Support vector machines)在解决高维模式识别以及小样本、非线性中具有它独特的一些优势.

传统的支持向量机方法并没有充分利用高光谱遥感图像所提供的空间信息, 也并没有区分不同的样本特征对于最后分类精度的不同重要性. 文献[2-4]提出将空间信息和光谱信息融合的算法, 利用融合机制将高光谱图像空间特征和光谱特征融合起来, 改善高光谱图像分类精度. 在文献[2]中作者提出通过滤波器提取高光谱图像空间纹理特征并将其与光谱特征融合应用到最小二乘支持向量机分类模型中, 从而提高高光谱图像分类精度. 在文献[3]中提出总共三种不同的加权方法以体现出不同样本、特征、类别对于最终分类的不同的重要性. 虽然传统的滤波器虽然可以实现分类图像的平滑, 但是往往会应为信息量损失较大而导致分类精度下降, 同时以上几种方法都是仅仅考虑其中一项问题, 并没有将传统SVM应用于高光谱图像分类所欠缺考虑的地方综合起来. 因此本文提出了基于特征加权的高光谱图像融合分类方法(Fusion Hyperspectral Image Classification based on Feature Weighting), 利用一阶直方图简明描述高光谱图像纹理特征, 并与光谱特征融合起来, 与此同时考虑不同特征对于图像分类的不同重要性, 最终有效的提高了分类效果.

## 2 SVM基本原理

支持向量机的核心内容是 Vapnik 等人在 1992~1995 年提出来的. SVM 算法最初设计是为了解决二分类问题的, 当我们遇到多分类的问题时, 我们就需要对二分类的 SVM 进行推广. 对于多分类 SVM 来说, 构造多分类构造器主要有二种方法: 一种是直接法. 所谓直接法就是直接在目标函数上修改, 但是这种方法计算复杂度高, 实现起来比较困难. 另一种是间接法, 主要通过组合多个二分类分类器来构造多分类分类器, 主要有一对一(one-versus-one, 简称 1-v-1 SVMs)以及一对余(one-versus-rest, 简称 1-v-r SVMs)法二种.

其中一对一法每个 SVM 分类器只考虑多类别中的某二类样本, 不会出现一对余法中容易出现的二类训练样本间的不均衡问题而导致的分类精度较低的情

况, 此方法分类精度相对较高. 一对一法就是在任意二个样本之间设计一个分类器, 因此  $n$  个类别总共需要  $n(n-1)/2$  个分类器. 本文所采用的改进版 libsvm<sup>[5]</sup>也是基于一对一的多分类决策方法进行实验.

## 3 基于特征融合的高光谱图像融合分类

### 3.1 问题描述

为了尽可能的提高高光谱图像分类精度, 我们需要充分挖掘高光谱图像所蕴含的信息, 与此同时我们要体现出样本特征对于分类的不同重要性. 本文所提的方法根据特征加权以及空间域光谱域融合以此来充分挖掘高光谱图像所能提供的信息, 并且能够有效体现样本不同特征对于分类效果的影响, 从而改进传统 SVM 方法的不足, 提高高光谱图像分类的精度. 传统的 SVM 并没有体现训练样本, 样本特征对于分类结果的区别性, 对于分类结果有一定的影响. 现有的文献提出的方法都是针对训练样本进行加权, 仅仅指出了不同样本对分类精度的影响, 并没有指出不同的样本特征(如波段)对分类精度的影响, 因此我们在构建分类器的过程中将对分类结果产生不同影响的特征分别对待, 以此来提高最后的分类效果.

### 3.2 FHICFW 方法

#### 3.2.1 特征加权

假设对于一个  $c$  空间有  $n$  个样本分别为  $x_1, x_2, \dots, x_n$ , 其中  $n_i$  ( $i=1, 2, \dots, c$ ) 表示属于类别  $i$  的样本个数. 则有  $n_1 + n_2 + \dots + n_c = n$ . 类内离散度矩阵定义为:

$$S_w = \sum_{i=1}^c \sum_{x_k \in i} (\mu_i - x_k)(\mu_i - x_k)^T$$

文献[6]指出类内离散度矩阵的逆矩阵可以很好的体现出不同特征对于分类效果的不同作用. 因为  $S_w$  为实对称矩阵, 因此存在正交矩阵将其转化为对角矩阵  $\Lambda$ , 我们设正交矩阵为  $Q$ , 则可以推出类内离散度矩阵的逆矩阵:

$$Q^T S_w Q = \Lambda$$

$$S_w^{-1} = (QBQ^T)^{-1} = (QB^{-\frac{1}{2}})(QB^{-\frac{1}{2}})^T$$

我们设  $G = (QB^{-\frac{1}{2}})$ , 因此我们可以把  $G$  作为分类问题中的特征加权矩阵用于高光谱图像分类的特征加权之中.

### 3.2.2 空间特征提取<sup>[7]</sup>

在图像分析中纹理特征处于十分重要的位置. 对于高光谱图像来说, 针对高光谱图像的纹理分析是一件十分困难的事情. 文献[8]提出的 Gabor 纹理特征它是由某个频率和方向的正弦波调制的一个二维 Gabor 函数. 针对每幅 Gabor 滤波器输入的高光谱图像, 将其输出利用 Sigmoid 函数进行非线性变换, 最后得到一组纹理输出图. 虽然 Gabor 纹理特征是一种很常见的纹理特征, 但是滤波参数对结果影响很大, 同时计算量也较大. 本文提出的灰度直方图分析法是最简单的纹理提取算法, 可以通过简单计算一些统计特征来表示纹理特征. 直方图简明反映了图像中的一些统计信息, 两块纹理区域一阶直方图的接近程度和这两块区域的纹理相似程度成正相关. 我们假设图像的一阶直方图  $\rho(x)$ ,  $x = 1, 2, \dots, G$  ( $G$  代表最大灰度级), 那么我们可以用直方图均值 ( $\mu = -\sum_{x=1}^G x\rho(x)$ )、方差 ( $\delta^2 = (\sum_{x=1}^G (x-\mu)^3 \rho(x)) / \delta^4 - 3$ )、偏度 ( $(\sum_{x=1}^G (x-\mu)^3 \rho(x))$ )、峰度 ( $(\sum_{x=1}^G (x-\mu)^3 \rho(x)) / \delta^4 - 3$ )、能量 ( $\sum_{x=1}^G (\rho(x))^2$ )、熵 ( $-\sum_{x=1}^G \rho(x) \log_2 \rho(x)$ ) 这些纹理指数来大致描述此区域的纹理特征.

### 3.2.3 特征融合

高光谱图像反映地物的光谱信息以及地物空间和几何关系的图像信息. 为了将空间特征引入高光谱图像分类, 提高分类器的性能, 本文提出了利用组合核函数的方法将光谱特征和空间特征有效的融合在一起<sup>[9]</sup>. SVM 通过核函数实现在原空间非线性分类的样本, 通过映射在高维特征空间中样本的线性分类. 用核函数取代原空间的内积运算, 即通过映射, 将输入数据映射到高维特征空间, 当我们选定了一个核函数, 也就定义了一个特征空间.

本文在 Hilbert 空间中定义样本点的特征矢量为  $x_i = \{x_i^s, x_i^w\}$ , 它由样本点相应的空间域特征  $x_i^s \in \mathfrak{R}^N$  和光谱域特征  $x_i^w \in \mathfrak{R}^N$  组成并且相应的空间域的核矩阵为  $K_s$ , 光谱域的核矩阵为  $K_w$ . 现在我们设非线性变换  $\xi_1$  和  $\xi_2$ , 我们可以得到样本点  $x_i$  特征域如下变换:

$$\Phi(x_i) = \{\xi_1(x_i^s), \xi_2(x_i^w)\}$$

由于空间域和光谱域的核函数对于组合核函数的影响是不同的, 因此我们加入变量  $\alpha$  ( $0 \leq \alpha \leq 1$ ) 作为

调节因子, 因此我们有:

$$K = \alpha K_s(x_i^s, x_j^s) + (1-\alpha)K_w(x_i^w, x_j^w)$$

接下来我们来验证该组合核函数是否满足 Mercer 条件:

我们设  $g(x) \in \Phi(\mathfrak{R}^N)$ ,  $K \in \Phi(\mathfrak{R}^N * \mathfrak{R}^N)$ , 显然有  $\iint K(x, y)g(x)g(y)dx dy \geq 0$ , 即组合核函数满足 Mercer 条件, 我们可以用来作为 SVM 的核函数. 利用上述方法融合空间域与光谱域信息构造组合核函数.

## 4 实验以及结果分析

### 4.1 实验环境

本文实验环境: CPU Intel(R) Core(TM) i5-3230M 2.60GHZ, 内存 4GB, 64 位 Win7 操作系统, 软件平台 R2012a.

### 4.2 实验数据集

本文实验所用的数据是 Indian pines<sup>[10]</sup>. Indian pines 是标准的高光谱数据, 广泛应用于特征提取以及分类算法实验中.

本实验所用数据是由位于印第安纳州西北部的 Indian Pines 实验基地的 Aviris 传感器所收集的, 该遥感图像大小为 145\*145 像素, 波长范围在 0.4-2.4\*10<sup>-6</sup> 米之间的 224 条光谱反射谱带组成. 我们通过删除覆盖吸水区域的谱带最终得到 200 个谱带. 图像总共包括 16 种不同的地物信息, 但是其中 7 种由于样本量太小不予采用. 9 个其他的类别总共包含 8489 个样本, 如(图 1 和表 1)所示. (图 2)显示了真实的地物分布信息, 其中各种不同的类别分别由不同的颜色来表示. 本次实验总共选取 9 个类别共 8489 个样本, 在每一个类别中随机抽取 10% 的样本作为训练样本(各个类别名称及相应类别样本总数如表 1 所示).




图 1 伪彩色合成图像 图 2 真实的地物分布图

表 1 Indian Pine 数据集信息表

类别标签	类别名称	样本总数
C1	Corn-notill	1428
C2	Corn-mintill	830
C3	Grass-pasture	483
C4	Gras-trees	730
C5	Hay-windrowed	478
C6	Soybean-notill	972
C7	Soybean-mintill	2455
C8	Soybean-clean	593
C9	woods	1265

4.3 结果分析

4.3.1 本文方法与特征融合方法, 特征组合比较

从整体分类精度以及各个地物类别的分类精度 2 个方面比较本次实验将本文所提的特征融合与特征组合的方法与表现比较优秀的 SVM 改进算法. 表 2 中的所有算法都是在每一个地物类别中随机抽取 10% 的样本(总共 0.1\*8489 个样本)作为训练集, 其中方法 1 是融合空间特征和光谱特征的分类方法, 方法二是把样本特征加权的方法.

表 2 本文方法与特征融合方法分类, 加权方法结果

分类方法	FHICFW	方法 1	方法 2	
各个类别分类精度	C1	0.95	0.94	0.95
	C2	0.94	0.93	0.93
	C3	0.97	0.98	0.97
	C4	0.99	0.98	0.99
	C5	0.99	0.98	0.99
	C6	0.94	0.93	0.95
	C7	0.96	0.95	0.96
	C8	0.95	0.93	0.94
	C9	0.98	0.98	0.98
总体分类精度	0.96	0.954	0.959	

通过表一分析可以说明在同样大小的训练样本总数下, 本文所提实验方法可以有效的提高高光谱图像小样本分类的精度, 最后得到的分类精度无论是整体精度还是各个地物类别的分类精度相较于表一另外 2 种改进 SVM 方法都有明显的提高.

4.3.2 本文和传统的 SVM 比较

本次实验以整体分类精度、各地物类别分类精度为标准, 将本文方法和传统的 SVM 方法进行比较. 传统的 SVM 方法是在每一个地物类别中随机抽取 50% 的样本(总共 0.5\*8489 个样本)作为训练集, 本文所提方法仍然是在每一个地物类别中随机 10%(总

0.1\*8489 个样本)作为训练样本.

表 3 本文方法和传统的 SVM 方法比较

分类方法	FHICFW	SVM	
各个类别分类精度	C1	0.95	0.93
	C2	0.94	0.93
	C3	0.97	0.99
	C4	0.99	1
	C5	0.99	1
	C6	0.94	0.9
	C7	0.96	0.92
	C8	0.95	0.96
	C9	0.98	0.99
整体分类精度	0.96	0.95	

表 3 直观的可以说明, 本文所提方法在整体分类精度和各地物类别分类精度均出色于传统的 SVM 算法.

5 结论

本文中我们提出了将高光谱图像空间特征和光谱特征融合以及利用类内离散度矩阵逆矩阵应用于特征加权用于高光谱图像的地物分类. 其中特种融合基于组合核函数实现的, 特征加权是针对所有的样本数据进行的操作. 核函数是 SVM 的核心内容, 正确的选择核函数以及参数是分类的基本功. 当前对核函数的研究基本都是如何选择合适的 SVM 核函数提高分类的性能. 本文结果证明, 较之传统的 SVM, 本文方法能有效区分各特征对于分类结果的不同重要性, 降低特征维度, 通过组合核函数有效融合空间特征和光谱特征, 对于小样本集合能够取得很好的分类效果. 随着高光谱技术的发展, 空间分辨率越来越高, 在往后的工作当中, 我们将进一步研究更加高效的组合核函数来融合空间特征和光谱特征.

参考文献

- 1 浦瑞良, 宫鹏. 高光谱遥感及其应用. 北京: 高等教育出版社, 2000.
- 2 李吉明, 贾森, 彭艳斌. 基于光谱特征和纹理特征协同学习的高光谱图像数据分类. 光电工程, 2012, 39(11): 88-94.
- 3 肖倩. 结合空间信息与光谱信息的高光谱图像分类研究[硕士学位论文]. 哈尔滨: 哈尔滨工程大学, 2013.
- 4 高恒振, 万建伟, 粘永健, 王力宝, 徐湛. 组合核函数支持向量机高光谱图像融合分类. 光学精密工程, 2011, 4: 878-883.

- 5 Chang CC, Lin CJ. LIBSVM: a library for support vector machines. *ACM Trans. on Intelligent Systems and Technology (TIST)*, 2011, 2(3): 27.
- 6 Ji B, Chang CI, Jensen JL, et al. Unsupervised constrained linear Fisher's discriminant analysis for hyperspectral image classification. *Optical Science and Technology, the SPIE 49th Annual Meeting. International Society for Optics and Photonics*. 2004. 344-353.
- 7 许存禄. 图像纹理分析的新方法及其应用[博士学位论文]. 上海: 复旦大学, 2005.
- 8 Jain AK, Farrokhnia F. Unsupervised texture segmentation using Gabor filters. *Proc. of IEEE International Conference on Systems, Man and Cybernetics 1990. IEEE*. 1990. 14-19.
- 9 张冰, 孔锐. 一种支持向量机的组合核函数. *计算机应用*, 2007, 27(1): 44-46.
- 10 Landgrebe D. AVIRIS NW Indiana's Indian Pines 1992 data set. 1992.

[www.c-s-a.org.cn](http://www.c-s-a.org.cn)

[www.c-s-a.org.cn](http://www.c-s-a.org.cn)