

doi: 10.3788/gzxb20144306.0630001

基于核映射多光谱特征融合的高光谱遥感 图像分类法

樊利恒¹, 吕俊伟¹, 于振涛¹, 曹亮杰²

(1 海军航空工程学院 控制工程系, 山东 烟台 264001)

(2 中国人民解放军 91245 部队, 辽宁 葫芦岛 125001)

摘 要: 多光谱遥感图像的波段设定在理论和实践上都极具地物针对性, 在更有效的数据挖掘方法帮助下可以提取足够的光谱特征以区分地物, 本文将光谱匹配技术用于相似性度量, 以提高分类准确度. 首先选定光谱角制图、光谱相关制图、Mahalanobis 距离、光谱相似度和光谱信息差异做为光谱度量; 随后选择高斯核函数, 在选定核函数之后, 得到了核映射下的光谱特征度量来挖掘高光谱遥感数据的光谱特征. 最后采用核映射多光谱特征融合法对多光谱遥感图像光谱特征的相似性进行描述, 得到基于核映射多光谱特征融合的高光谱遥感图像分类算法. 使用 MATLAB 中的 LIBSVM 工具箱对 AVIRIS 高光谱遥感数据进行分类实验, 并与已有算法进行对比, 结果表明本文提出的算法具有较高的分类准确度和性能.

关键词: 高光谱; 核映射; 遥感图像; 分类; 相似性度量; 光谱度量

中图分类号: TP391

文献标识码: A

文章编号: 1004-4213(2014)06-0630001-6

Classification of Hyperspectral Images by Fusion of Multifeature Under Kernel Mapping

FAN Li-heng¹, LV Jun-wei¹, YU Zhen-tao¹, CAO Liang-jie²

(1 Department of Control Engineering, Naval Aeronautical Engineering Institute, Yantai, Shandong 264001, China)

(2 The 91245st Unit of PLA, Huludao, Liaoning 125001, China)

Abstract: The spectral bands have strong relation with land covers both partially and theoretically. Thus it is possible to extract enough spectral features with the help of more efficient data represent methods to distinguish land covers. More pertinent spectral matching methods can be taken to improve the similarity and dissimilarity metric and to improve the performance of the classifiers. A couple of classic and efficient spectral measures, such as spectral angle mapper, spectral correlation mapper, mahalanobis distance, spectral similarity value and spectral information divergence, were selected. Then the RBF Gaussian function was used and the spectral measure under the kernel mapping were obtained. A new method based on the fusion of multifeatures under kernel mapping was taken to dig the features of hyperspectral remote sensing data. Profile the similarity between different classes and thus a new classification algorithm was proposed. At last, this method was applied to a hyperspectral remotely sensing AVIRIS dataset named 92AV3C using the LIBSVM toolbox of MATLAB. The results show that the classification method of hyperspectral images by fusion of multifeatures under kernel mapping can significantly improve the accuracy of the classification. Experimental comparison shows the proposed algorithm can provide better performance for the pixel classification of hyperspectral image than many other wellknown techniques.

基金项目: 国家自然科学基金(Nos. 61032001, 60801049)和国家高技术研究发展计划创新基金(No. 2010AAJ140)资助

第一作者: 樊利恒(1986-), 男, 博士研究生, 主要研究方向为高光谱遥感图像分类与典型目标识别. Email: fan_li_heng@126.com

导师(通讯作者): 吕俊伟(1960-), 男, 教授, 博士, 博导, 主要研究方向为机器视觉、目标识别与跟踪. Email: ljwei369@yahoo.com.cn

收稿日期: 2013-10-14; 录用日期: 2013-12-24

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

Key words: Hyperspectral; Kernel mapping; Remotely sensing image; Classification; Similarity metric; Spectral measures

OCIS Codes: 100.0100; 100.2960; 100.4145; 100.5010; 300.0300

0 引言

高光谱遥感从诞生到现在已经走过了 30 多年的历程,多光谱遥感成像技术已经初步展示了其优于普通遥感技术的性能,并已在很多领域得到应用.高光谱遥感数据具有图谱合一的特点,在提供丰富信息的同时波段之间具有较强的相关性和冗余性,降低了数据处理的效率,甚至会影响分类准确度.特征提取为上述问题提供了有效的技术手段,主要的特征提取方法有 KPCA^[1]、MNF^[2]、ICA^[3]等.然而由于外界环境时时刻刻都在发生变化,导致光谱特征也随之发生变化,从而导致特征选择和提取技术并不总是能够提取出有效特征.文献[4]建立了一个光谱随四季变换的 3D 模型,但该模型不能检测出所有物体的每个变换.因此,基于特征选择和提取的有效的分类器在不同数据集上往往产生不同效果.与光谱特征相比,光谱相似性度量简单并具有较小的计算量,可以作为重要的分类判据.而作为度量光谱相似性的重要方法,光谱匹配技术得到了广泛的应用与研究.

在多光谱遥感图像分类中,由于数据本身的光谱特征较少,直接进行匹配难以有效表征地物波谱间的差异,导致分类准确度下降.通过引入辅助信息可以提高地物类之间的可区分度,并取得了较好的准确度改进,但通过挖掘多光谱影像本身信息来改善分类效果的技术仍然很少.由于多光谱卫星遥感图像的波段设定无论从理论上还是实践上都极具地物针对性,在更有效的数据挖掘方法辅助下有可能提取足够的光谱特征以区分关键地物,因此可以采用更有针对性的光谱匹配技术用于改进相似性度量的准确性,提高分类准确度.从机器学习的角度来看,支持向量机能够有效利用源问题中隐含的特殊信息以实现智能理解.

核函数方法通过非线性映射能够较好地分辨、提取并放大有用的特征,提高特征空间的非线性处理能力,近些年有不少学者将核方法引入高光谱遥感图像的分类应用中^[5-7],并在一定程度上提高了分类准确度,文献[8]对核函数对高光谱多类分类问题的影响进行了评估.本文提出的基于核映射的多光谱特征融合算法一方面结合多光谱特征融合技术增加数据的信息量,另一方面又以核函数将多维空间映射至高维空间,在高维空间实现了多光谱遥感图像的精确分类.对 AVIRIS 的高光谱遥感数据 92AV3C 进行分类试验,并与当前一些其他著名算法进行了对比,实验和对比结果表明,基于核映射多光谱特征融合技术的分类方法可以更准确地地区分地物,提高分类准确度.

1 方法描述

1.1 光谱度量

本文采用多光谱特征融合法来对多光谱遥感图像的光谱特征的相似性进行描述.所采用的的光谱度量有:光谱角制图(Spectral Angle Mapper, SAM)^[9]、光谱相关制图(Spectral Correlation Mapper, SCM)、Mahalanobis 距离(Mahalanobis Distance, MD)^[10]、光谱相似度(Spectral Similarity Value, SSV)^[11-12]、光谱信息差异(Spectral Information Divergence, SID)^[10].

1) SAM

光谱角制图将像元的 N 个波段的光谱响应作为 N 维空间的矢量,通过计算两个矢量的夹角来定量表征两个像元之间的匹配程度.

$$\text{SAM}(\mathbf{x}_i, \mathbf{x}_j) = \arccos\left(\frac{\mathbf{x}_i \cdot \mathbf{x}_j}{\|\mathbf{x}_i\| \|\mathbf{x}_j\|}\right) \quad (1)$$

\mathbf{x}_i 和 \mathbf{x}_j 为两个不同的像元, N 为光谱波段数.

2) SCM

光谱相关制图主要考虑了光谱之间在形状和亮度的差异.定义为

$$\text{SCM}(\mathbf{x}_i, \mathbf{x}_j) = \frac{N \sum_{k=1}^N x_{ik} x_{jk} - \sum_{k=1}^N x_{ik} \sum_{k=1}^N x_{jk}}{\sqrt{(N \sum_{k=1}^N x_{ik}^2 - (\sum_{k=1}^N x_{ik})^2)(N \sum_{k=1}^N x_{jk}^2 - (\sum_{k=1}^N x_{jk})^2)}} \quad (2)$$

3) MD

Mahalanobis 距离主要用于在计算光谱特征的统计距离时的相关性.定义为

$$\text{MD}(\mathbf{x}_i, \mathbf{x}_j) = \sqrt{(\mathbf{x}_i - \mathbf{x}_j)^T \Sigma^{-1} (\mathbf{x}_i - \mathbf{x}_j)} \quad (3)$$

Σ 是用 n 个训练样本估计的协方差矩阵.

$$\Sigma = \frac{1}{n-1} \sum_{i=1}^n (\mathbf{x}_i - \bar{\mathbf{x}}) (\mathbf{x}_i - \bar{\mathbf{x}})^T, \bar{\mathbf{x}} = \frac{1}{n} \sum_{i=1}^n \mathbf{x}_i$$

4) SSV

光谱相似度综合考虑光谱间的形状和距离关系.定义为

$$\text{SSV} = \sqrt{\text{ED}^2 + (1 - \text{PC})^2} \quad (4)$$

ED 为欧式距离

$$\text{ED}(\mathbf{x}_i, \mathbf{x}_j) = 2 \sqrt{1 - \cos(\text{SAM}(\mathbf{x}_i, \mathbf{x}_j))}$$

PC 为皮尔逊相关系数

$$\text{PC}(\mathbf{x}_i, \mathbf{x}_j) = \frac{\sum_{k=1}^N (x_{ik} - \mu_i) (x_{jk} - \mu_j)}{[\sum_{k=1}^N (x_{ik} - \mu_i)^2 \sum_{k=1}^N (x_{jk} - \mu_j)^2]^{1/2}}$$

$$\mu_l = \frac{1}{N} \sum_{k=1}^N x_{lk}, l = i, j$$

5) SID

SID 计算由两个光谱特征产生的概率分布之间的

距离. 定义为

$$\text{SID}(\mathbf{x}_i, \mathbf{x}_j) = D(\mathbf{x}_i \parallel \mathbf{x}_j) + D(\mathbf{x}_j \parallel \mathbf{x}_i) \quad (5)$$

$$D(\mathbf{x}_i \parallel \mathbf{x}_j) = \sum_{k=1}^N q_k D_k(\mathbf{x}_i \parallel \mathbf{x}_j) =$$

$$\sum_{k=1}^N q_k (I_k(\mathbf{x}_i) - I_k(\mathbf{x}_j)),$$

$$D(\mathbf{x}_j \parallel \mathbf{x}_i) = \sum_{k=1}^N p_k D_k(\mathbf{x}_j \parallel \mathbf{x}_i) =$$

$$\sum_{k=1}^N p_k (I_k(\mathbf{x}_j) - I_k(\mathbf{x}_i)),$$

$$p_k = \frac{x_{jk}}{\sum_{l=1}^N x_{jl}}, q_k = \frac{x_{ik}}{\sum_{l=1}^N x_{il}},$$

$$I_k(\mathbf{x}_i) = -\log p_k, I_k(\mathbf{x}_j) = -\log q_k.$$

1.2 核映射下的光谱度量

假设输入空间的样本 $\mathbf{x}_k \in R^N (k=1, 2, \dots, n)$ 被某种非线性映射 Φ 映射到某一特征空间 H 得到 $\Phi(\mathbf{x}_k) (k=1, 2, \dots, n)$, 即 $\Phi: R^N \rightarrow H$, 那么 $\mathbf{x}_i, \mathbf{x}_j$ 在特征空间的点积形式就可以通过 Mercer 核以输入空间的样本来表示. 即

$$K(\mathbf{x}_i, \mathbf{x}_j) = \Phi(\mathbf{x}_i) \Phi(\mathbf{x}_j) \quad (6)$$

常见的核函数有^[13-14]: $K(\mathbf{x}, \mathbf{y}) = \mathbf{x} \cdot \mathbf{y}$ (线性核函数), $K(\mathbf{x}, \mathbf{y}) = (\mathbf{x} \cdot \mathbf{y} + 1)^d, d \in N$ (多项式核函数), $K(\mathbf{x}, \mathbf{y}) = \exp(-\gamma \|\mathbf{x} - \mathbf{y}\|_2^2), (\mathbf{x} \neq \mathbf{y})$ (RBF 核函数), $K(\mathbf{x}, \mathbf{y}) = \tanh(b(\mathbf{x} \cdot \mathbf{y}) - c)$ (Sigmoid 核函数). 与 Sigmoid 核函数、多项式核函数及线性核函数相比, 高斯 RBF 核函数涉及较少的数字复杂性, 并且只需估计一个参量, 因此本文选择高斯 RBF 核函数. 选定核函数之后, 可以得到核映射下的光谱特征, 分别为

1) KSAM

$$K_{\text{SAM}}(\mathbf{x}_i, \mathbf{x}_j) = \exp(-\gamma(\text{SAM}(\mathbf{x}_i, \mathbf{x}_j))^2) \quad (7)$$

2) KSCM

$$K_{\text{SCM}}(\mathbf{x}_i, \mathbf{x}_j) = \exp(-\gamma(\text{SCM}(\mathbf{x}_i, \mathbf{x}_j))^2) \quad (8)$$

3) KMD

$$K_{\text{MD}}(\mathbf{x}_i, \mathbf{x}_j) = \exp(-\gamma(\text{MD}(\mathbf{x}_i, \mathbf{x}_j))^2) \quad (9)$$

4) KSSV

$$K_{\text{SSV}}(\mathbf{x}_i, \mathbf{x}_j) = \exp(-\gamma(\text{SSV}(\mathbf{x}_i, \mathbf{x}_j))^2) \quad (10)$$

5) KSID

$$K_{\text{SID}}(\mathbf{x}_i, \mathbf{x}_j) = \exp(-\gamma(\text{SID}(\mathbf{x}_i, \mathbf{x}_j))^2) \quad (11)$$

1.3 类均值向量的计算

假设一共有 M 个训练样本和 K 个类别, 每一类的训练样本数目为 $M_i (i=1, 2, \dots, K)$, 则有 $M = \sum_{i=1}^K M_i$, 而每一类的均值向量为

$$\boldsymbol{\mu}_i = \left[\sum_{j=1}^{M_i} \frac{x_{j1}}{M_i}, \sum_{j=1}^{M_i} \frac{x_{j2}}{M_i}, \dots, \sum_{j=1}^{M_i} \frac{x_{jN}}{M_i} \right] \quad (12)$$

式中, x_{jl} 表示第 i 类的第 j 个样本在波段 l 的值, N 是波段数.

1.4 相似性度量

一个样本与类均值向量之间的相似性定义为

$$\text{Sim}(\mathbf{x}, \boldsymbol{\mu}_i) = \frac{\mathbf{x} \cdot \boldsymbol{\mu}_i}{\|\mathbf{x}\| \|\boldsymbol{\mu}_i\|} \quad (13)$$

对类 $C_k (k=1, 2, \dots, K)$, 计算各个属于类 C_k 的训练样本与该类均值向量 $\boldsymbol{\mu}_k (k=1, 2, \dots, K)$ 之间的光谱相似性度量, 并分别计算类 $C_j (j \neq k)$ 的训练样本与类 C_j 均值向量 $\boldsymbol{\mu}_k$ 之间的光谱差异性度量.

2 算法步骤

1) 对光谱特征进行平滑滤波

使用均值滤波器对光谱特征进行平滑滤波. 主要目的是最小化随机噪声. 高光谱图像中的均值滤波器定义为

$$\text{Med}x_{ik} = \frac{1}{n} \sum_{x_j \in B(x_i)} x_{jk}, k=1, 2, \dots, N \quad (14)$$

x_{ik} 是像元 x_i 的第 k 个波段的值, $B(x_i)$ 表示 x_i 的一个邻域, n 是该邻域的像元数目.

2) 计算光谱度量

根据 1.3 节分别计算核映射下的 5 个光谱特征.

3) 计算类均值向量

在经过平滑滤波的高光谱遥感图像上利用训练样本估计每一类的均值向量.

4) 利用 SVM 进行分类

在计算核映射下的 5 个光谱特征之后, 根据 1.4 节计算相似性度量和差异性度量, 利用 SVM 算法使不同类的光谱度量在更高维空间有较好的可分性, 得出阈值, 利用阈值可以判断新的样本属于哪一类.

3 实验与分析

3.1 实验数据

实验所选用的数据是美国 AVIRIS (Airborne Visible InfraRed Imaging Spectrometer) 高光谱遥感数据 92AV3C.tif. 数据采集自美国印第安纳州西北部的一块印度松树测试地, 该高光谱遥感数据是公开的基准高光谱图像数据, 目前的学术文章中, 已有大量的国内外学者在高光谱图像处理的研究上采用了该数据, 因此有利于重复实验和不同的算法之间的比较. 该图像大小为 145×145 , 波长范围为 $0.4 \sim 2.5 \mu\text{m}$, 原始波段数为 220 个, 移除水吸收波段 (水吸收波段为 104 ~ 108 和 150 ~ 162) 后的波段数一共有 200 个, 图像的空间分辨率约为 20 m, 数据采集于 1992 年 6 月. 将该数据的第 50 个波段作为红色, 第 27 个波段作为绿色, 第 17 个波段作为蓝色的 RGB 显示如图 1(a) 所示. 可以看出图像的大约 2/3 被农作物覆盖, 大约 1/3 被森林和其他多年生植被覆盖, 由于拍摄的季节的原因, 耕地上的农作物没能较好的覆盖土地, 此外还有几条公路. 其地面真实数据如图 1(b). 从图 1(b) 可以看出该数据包括 16 个地物类别, 数据的地物类别情况如表 1. 高光谱数据图和地面观测数据图来源于网站: <http://dynamo.ecn.purdue.edu/~biehl/MultiSpec>.



(a) Data set 92AV3C displayed in simulated color infrared form



(b) A generalized reconnaissance map of the dataset

图 1 92AV3C 图像示意图

Fig. 1 The map about the hyperspectral dataset 92AV3C

表 1 实验所用高光谱遥感数据的地物类别及样本数目

Table 1 The classes and number of samples used in the experiments

No.	Landcover types	Number of samples
1	Alfalfa	54
2	Corn-no till	1 434
3	Corn-min till	834
4	Corn	234
5	Grass/Pasture	497
6	Grass/Trees	747
7	Grass/pasture-mowed	26
8	Hay-windrowed	489
9	Oats	20
10	Soybean-no till	968
11	Soybean-min till	2 468
12	Soybean-clean till	614
13	Wheat	212
14	Woods	1 294
15	Bldg-Grass-Tree-Drives	380
16	Stone-steel towers	95

由于类别 1、4、7、9、13、15 和 16 的可用样本数小于波段数的 2 倍,有些文献只考虑了类别 2、3、5、6、8、10、11、12 和 14,在从这 9 类的样本中随机选择一部分作为训练样本,剩下的一部分则作为测试样本。



图 2 测试区域的谷歌图像

Fig. 2 Google image for the test area

3.2 实验

实验目的:1)验证本文算法的性能;2)比较本文算法与相关文献[15-19]所提出的算法。

实验方法:首先在全波段对数据进行平滑滤波;利用训练样本估计每一类的均值向量,这一步是在经过平滑滤波之后的图像上进行;根据 1.3 节分别计算训练样本与类均值向量之间核映射下的 5 个光谱特征, RBF 的参量 γ 的取值范围为 $\{10^{-3}, \dots, 10^3\}$, 据 1.4 节计算相似性度量和差异性度量,并用 SVM 算法估计阈值;计算测试样本与各类均值向量之间的光谱度量,共可以得到 45 个特征,将这 45 个特征组成一个向量,用 SVM 分类方法将其分类. 实验软件环境为: Matlab 2008a、Windows XP, 硬件环境为: Intel Celeron E3300 CPU 2.51 GHz/1.99 GB RAM. 采用 MATLAB 的 LIBSVM 工具箱来处理多类的 SVM 问题,根据文献[20]的研究,对于 SVM 算法的核函数选用高斯 RBF 函数, γ 的取值范围为 $\{10^{-3}, \dots, 10^3\}$, 惩罚因子 C 的取值范围为 $\{0, \dots, 10^3\}$.

分类准确度检验是分类技术中一个不可或缺的环节,准确度检验一方面可以有效地对分类器进行评价从而改造分类器,另一方面也是对分类成果的最终评价,实际上对分类准确度进行精确的分析是一件非常困难而又难以使不同学者信服的事情. 目前广泛使用的表示分类准确度的方法是首先构造一个大小为 $K \times K$ 混淆矩阵(Confusion Matrix, CM)或误差矩阵(Error Matrix, EM) $A(K$ 是类别数), $a_{i,j}$ 表示分类结果中第 j 类数据被分为第 i 类的的数据点数目,然后依据混淆矩阵分别计算总体分类准确度和 kappa 系数. Montserud 等^[21]认为 kappa 系数的值大于 0.75 时表示分类器的分类性能良好,而当 kappa 系数小于 0.4 时性能很差.

3.3 实验验证与结果分析

由于对训练样本的选择与分割准确度有一定的联系,实验中随机选择一半的样本作为训练样本,分别实验 10 次,取平均作为结果显示,算法结果如图 3,图 3(a)是在整幅图像上进行分类的结果,图 3(b)是只在类别确定的区域上进行分类的结果,由图 3(b)得到的混

淆矩阵如表 2. 可以发现对于类别 7 和 9 而言分类准确度较差,分别为 0.576 9 和 0.55,可能是由于它们样本数目太少,对它们的样本均值估计与真实均值相差较大所致,而其他类别都有较高的分类准确度,包括了 1、4、13、15 和 16,可以看出本文算法对样本数目的要

求并不是太高,很多算法都要求样本数目是波段数的 2 倍左右. 从表 2 中可以计算得到总体准确度为 0.976 9,kappa 系数为 0.973 7. 可以得出结论,本文算法具有优异的性能.

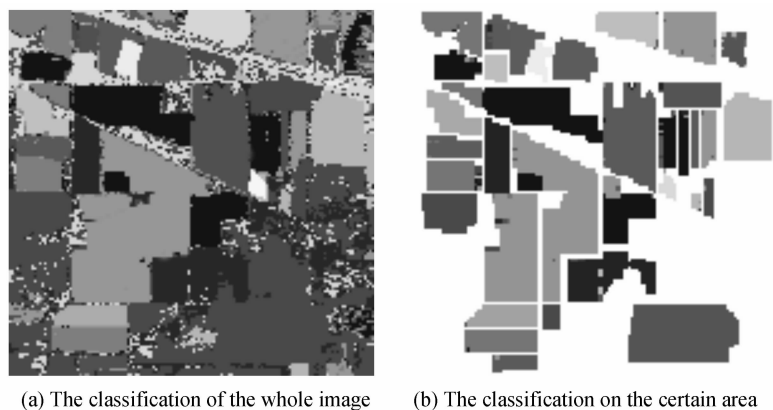


图 3 本文算法分类结果图
Fig. 3 The classification result by the Method proposed in this article

表 2 混淆矩阵

Table 2 The confusion matrix

	C ₁	C ₂	C ₃	C ₄	C ₅	C ₆	C ₇	C ₈	C ₉	C ₁₀	C ₁₁	C ₁₂	C ₁₃	C ₁₄	C ₁₅	C ₁₆
C ₁	49	0	0	3	0	0	0	2	0	0	0	0	0	0	0	0
C ₂	0	1 380	2	0	1	2	0	0	0	18	28	2	0	0	1	0
C ₃	0	4	827	0	0	0	0	0	0	0	0	3	0	0	0	0
C ₄	0	0	2	230	0	2	0	0	0	0	0	0	0	0	0	0
C ₅	0	0	0	0	480	4	0	0	0	0	12	1	0	0	0	0
C ₆	0	0	0	0	0	746	0	0	0	0	0	0	0	0	1	0
C ₇	0	0	0	0	1	1	15	8	0	0	1	0	0	0	0	0
C ₈	0	3	0	9	0	0	0	474	0	0	0	0	3	0	0	0
C ₉	0	4	0	0	2	0	0	0	11	0	1	0	0	0	2	0
C ₁₀	0	3	0	0	2	2	0	0	0	957	4	0	0	0	0	0
C ₁₁	0	9	7	0	10	6	0	0	0	12	2 411	11	0	0	2	0
C ₁₂	0	0	4	0	0	0	0	0	0	0	2	607	0	0	0	1
C ₁₃	0	0	0	0	0	0	0	0	0	0	0	0	211	1	0	0
C ₁₄	0	0	0	0	1	0	0	0	0	0	0	0	0	1 274	19	0
C ₁₅	0	0	0	1	0	0	0	6	0	3	0	0	0	4	366	0
C ₁₆	9	0	5	0	0	0	0	2	0	0	0	0	0	0	0	79

文献[16]使用多个光谱特征,并在整个波段和波段的某个子集分别进行了分类,得到的总体分类准确度分别为 0.902 0 和 0.916 0. 文献[17]提出了采用 ADL+TPCA+SVM 组合的方法,只用了 5 个训练样本,得到的总体准确度和 kappa 系数分别为 0.733 9 和 0.69. 文献[18]提出了基于监督-非监督的分类方法,得到了 0.915 0 的总体分类准确度. Landgrebe[19]提出了使用 DBFE 特征的 ECHO 分类器,得到 0.944 的总体分类准确度. 对此发现,本文提出的基于核映射的多光谱特征融合算法比文献[15-19]使用的算法度量准确度高.

4 结论

采用核映射多光谱特征融合法对多光谱遥感图像光谱特征的相似性进行度量,得到基于核映射多光谱特征融合的高光谱遥感图像,运用分类算法实现了多光谱遥感图像的准确分类. 对 AVIRIS 高光谱遥感数据 92AV3C 进行分类试验,验证了该算法具有较高的分类准确度,可以更准确地地区分地物,并且对通常意义上的小样本类别也有比较可靠的分类准确度,但当样本特别小的时候分类准确度受到较大的影响.

参考文献

[1] WANG Ying, GUO Lei, LIANG Nan. A dimensionality

- reduction method based on KPCA with optimized sample set for hyperspectral image[J]. *Acta Photonica Sinica*, 2011, **40**(6): 847-851.
- 王赢, 郭雷, 梁楠. 基于优选样本的 KPCA 高光谱图像降维方法[J]. 光子学报, 2011, **40**(6): 847-851.
- [2] ZHANG Deng-hui, YU Le. Support vector machine based classification for hyperspectral remote sensing images after minimum noise fraction rotation transformation[C]. Proceeding of internet computing and information services conference, September, 2011.
- [3] SU Ling-hua, YI Tong-sheng, WAN Jian-wei. Compression of hyperspectral image based on independent component analysis [J]. *Acta Photonica Sinica*, 2008, **37**(5): 973-976.
- 苏令华, 衣同胜, 万建伟. 基于独立分量分析的高光谱图像压缩[J]. 光子学报, 2008, **37**(5): 973-976.
- [4] HEMISSI S, ETTABAA K, FARAH I, *et al.* Towards multitemporal hyperspectral images classification based on 3D signature model and matching [C]. In Proceedings of the Hyperspectral 2010 Workshop.
- [5] MURAT D, DAVID L. A cost-effective semi-supervised classifier approach with kernels[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2004, **42**(1): 264-270.
- [6] GUSTAVO C V, BRUZZONE L. Kernel-based methods for hyperspectral image classification[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2005, **43**(6): 1-12.
- [7] CANTY M J, NIELSEN A A. Linear and kernel methods for multivariate change detection [J]. *Computers&Geosciences*, 2012, **38**: 107-114.
- [8] FAUVEL M, CHANUSSOT J, BENEDIKTSSON J A. Evaluation of kernels for multiclass classification of hyperspectral remote sensing data[C]. Acoustics, Speech and Signal Processing, 2006, ICASSP 2006 Proceedings. 2006 IEEE International Conference on (Vol. 2, pp ii-ii). IEEE.
- [9] XIA Lie-gang, WANG Wei-hong, HU Xiao-dong, *et al.* An improved spectral similarity measure based on kernel mapping for classification of remotely sensed image [J]. *Acta Geodaeticaet Cartographica Sinica*, 2012, **41**(4): 591-604.
- 夏列钢, 王卫红, 胡晓东, 等. 图像分类中基于核映射的光谱匹配度量方法[J]. 测绘学报, 2012, **41**(4): 591-604.
- [10] MATHUR M, KOCH M. Computer processing of remotely-sensed images(fourth edition)[M]. New York: A John Wiley & Sons, Ltd., Publication, 2011, 229-284.
- [11] FREEK V M. The effectiveness of spectral similarity measures for the analysis of hyperspectral imagery [J]. *International Journal of Applied Earth Observation and Geoinformation*, 2006, **8**(1): 3-17.
- [12] FARIFTEH J, FREEK V M, CARRANZA E. Similarity measures for spectral discrimination of saline soils[J]. *International Journal of Remote Sensing*, 2007, **28**(23): 5273-5293.
- [13] GESTEL T V, SUYKENS J A K, LANCKRIET G, *et al.* Bayesian framework for least squares support vector machine classifiers, gaussian processes and kernel fisher discriminant analysis[J]. *Neural Computation*, 2002, **14**(5): 1115-1147.
- [14] WANG Feng, ZHANG Hong-bin. Optimal double-kernel combination method for classification[J]. *Acta Electronica Sinica*, 2012, **40**(2): 260-265.
- 王峰, 张鸿宾. 最优双核复合分类算法的构造[J]. 电子学报, 2012, **40**(2): 260-265.
- [15] 高恒振. 高光谱遥感图像分类技术研究[D]. 长沙: 国防科学技术大学, 2011.
- [16] GALAL A, HASAN H, IMAM I F. Learnable hyperspectral measures[J]. *Egyptian Informatics Journal*, 2012, **13**(2): 85-94.
- [17] FORERO S V, ANGULO J. Classification of hyperspectral images by tensor modeling and additive morphological decomposition[J]. *Pattern Recognition*, 2013, **46**(2): 566-577.
- [18] ALAJLAN N, BAZI Y, FARID M, *et al.* Fusion of supervised and unsupervised learning for improved classification of hyperspectral images [J]. *Information Sciences*, 2012, **217**(12): 39-55.
- [19] DAVID L. Hyperspectral image data analysis [J]. *Signal Processing Magazine*, 2002, **19**(1): 17-28.
- [20] WIDODO A, YANG B S. Support vector machine in machine condition monitoring and fault diagnosis [J]. *Mechanical Systems and Signal Processing*, 2007, **21**(6): 2560-2574.
- [21] MONTSERUD R A, LEAMANS R. Comparing global vegetation maps with the kappa statistic [J]. *Ecological Modeling*, 1992, **62**(4): 275-293.