

基于 SSLPP 算法对高光谱遥感影像分类

潘银松 王攀峰 黄 鸿 刘 艳

(重庆大学光电技术及系统教育部重点实验室 重庆 400044)

摘 要 局部保持投影算法为非监督维数约简算法,没有有效利用样本数据的类别信息,不能有效提取鉴别特征。针对此问题,提出一种半监督局部保持投影(SSLPP)算法。该算法以少量有标记数据和无标记数据作为训练样本集构造出本征图 G_i ,并有区别地对待标记样本与无标记样本,增大同类样本点之间的权重,更有利于鉴别特征提取。在 AVIRIS KSC 和 Botswana 高光谱遥感影像数据集上的实验结果表明,SSLPP 算法能够较为有效地发现高维空间中数据的内蕴结构,使得总体分类精度得到较为明显的改善。

关键词 高光谱影像,维数约简,半监督学习,半监督局部保持投影

中图分类号 TP751.1,TP391.4 **文献标识码** A

Hyperspectral Remote Sensing Image Classification Based on SSLPP

PAN Yin-song WANG Pan-feng HUANG Hong LIU Yan

(Key Laboratory on Opto-electronic Technique and Systems, Ministry of Education, Chongqing University, Chongqing 400044, China)

Abstract Without using the data category information, Locality Preserving Projection algorithm is an unsupervised algorithm in the dimension reduction of hyperspectral images, so it has not a very good performance in the aspect of feature extraction. To resolve this problem, an algorithm based on semi-supervised locality preserving projection (SSLPP) is proposed in this paper. A graph G_i is constructed by SSLPP combined with the information of unlabeled samples and labeled samples whose are treated in different ways, therefore increasing the weights of congener samples and being beneficial to feature extraction. Experiments on the AVIRIS KSC set and Botswana data set show that the algorithm proposed in the paper can find the high dimensional space data intrinsic structure, effectively improving the overall accuracy of the classification.

Keywords Hyperspectral images, Dimension reduction, Semi-supervised learning, Semi-supervised locality preserving projection

1 引言

高光谱遥感技术是 20 世纪末遥感领域的重大成就之一,目前该技术已被广泛应用于环境监测、海洋遥感、地质矿岩识别等诸多领域^[1,2]。然而,高光谱数据相邻波段的相关性强^[3,4],且光谱维数高,使得传统的分类识别方法易陷入维数灾难^[5]现象而无法获得理想的分类结果。因此,如何对高光谱数据实现有效的维数约简^[6],成为高光谱遥感影像分类^[7]的关键。

经过国内外诸多学者的研究,已产生了一系列算法,经典的降维算法分为线性降维算法和非线性降维算法^[8]。线性降维算法包括:主成分分析(Principal Component Analysis, PCA)^[9]、线性鉴别分析(Linear Discriminant Analysis, LDA)^[10]等。这一类算法都是建立在“全局线性”这一基本假设基础上的,不能发现隐藏在高维数据中的低维流形^[11,12],无法揭示高光谱数据的内蕴结构。非线性降维算法包括:局部线性嵌入(Local Linear Embedding, LLE)^[13]、拉普拉斯特

征映射(Laplacian Eigenmap, LE)^[14]等。但是 LLE 和 LE 算法只能得到训练样本的低维嵌入,没有明晰的投影矩阵,不能直接处理新样本。He 等提出的局部保持投影算法(Locality Preserving Projection, LPP)^[15]可以有效解决新样本问题。然而 LPP 属于非监督学习算法^[16,17],没有利用类别信息,致使分类精度较低。监督学习方法 SLPP(Supervised Locality Preserving Projection)分类精度较高,可是要求标记所有训练样本^[18],成本过高,有时是不能实现的。在实际问题中,研究者常常面对的情况是大量的未标记数据以及相对较少的标记数据。由此,半监督学习应运而生,它同时利用无标记数据和有标记数据,只需较少的人工参与就能获得更高的学习精度,半监督学习成为解决此类问题的发展趋势。

针对上述问题,本文提出了一种基于半监督局部保持投影(Semi-Supervised Locality Preserving Projection, SSLPP)算法,该方法将高光谱数据从高维观测空间投影到低维空间,以提取高光谱数据的鉴别特征,然后对低维空间的数据实现分类。在 AVIRIS KSC 和 Botswana 高光谱影像数据集上的

本文受国家自然科学基金(61101168),中国博士后科学基金项目(2012M511906)资助。

潘银松(1963—),男,博士,副教授,硕士生导师,主要研究方向为 CMOS 图像传感器及微电子, E-mail:panys@cqu.edu.cn;王攀峰(1986—),男,硕士,主要研究方向为图像处理、模式识别、流形学习、遥感影像智能处理等。

实验结果表明本文算法能够较为有效地解决高光谱遥感影像的分类问题。

2 算法介绍

2.1 局部保持投影算法(LPP)

假设高维欧氏空间 R^D 中一组含 N 个样本的数据集为 $X = \{x_1, x_2, \dots, x_N\}$, LPP 算法旨在保持数据的局部结构, 其目标函数试图确保在高维空间中的近邻点 x_i 和 x_j , 在投影到低维数据空间后, 对应低维空间的映射数据点 y_i 和 y_j 同样保持近邻关系。LPP 按线性映射 $y_i = a^T x_i$ 将样本数据从高维空间向低维空间映射, 进而将函数的最小化问题转化成为一个广义特征值分解问题。

LPP 的目标函数如下:

$$\min \sum_{ij} (y_i - y_j)^2 W_{ij} \quad (1)$$

其中

$$W_{ij} = \begin{cases} e^{-\frac{\|x_i - x_j\|^2}{\sigma}}, & \text{if } x_i \in N_k(x_j) \text{ or } x_j \in N_k(x_i) \\ 0, & \text{otherwise} \end{cases}$$

$N_k(x_i)$ 与 $N_k(x_j)$ 分别表示 x_i 和 x_j 的 k 近邻, 利用 $y_i = a^T x_i$, 经过简单变换之后目标函数变为:

$$\begin{cases} \arg \min a^T X L X^T a \\ \text{s. t. } a^T X D X^T a = 1 \end{cases} \quad (2)$$

式中, D 是对角矩阵, 且 $D_{ii} = \sum_j W_{ij}$, L 是拉普拉斯矩阵, $L = D - W$; 约束条件是为了避免退化解。这样就可以转换为求解一个广义特征值问题:

$$X L X^T a = \lambda X D X^T a \quad (3)$$

最小化目标函数(2)的解就由上述广义特征值问题的最小特征值对应的特征向量 a 给出。

然而, 从本质上讲 LPP 是一种无监督的降维方法, 其缺点可以简单描述为: 原高维空间中, 若存在两个相近甚至重合但不同类的数据点, LPP 降维之后这两个数据点依旧投影在一起, 使得分类结果不理想。

2.2 监督局部保持投影算法(SLPP)

区别于 LPP 算法, SLPP 算法利用训练样本数据集的类别信息构造类内图 G_w , 即当第 i 个样本点和第 j 个样本点属于同一类时, 则在点 x_i 和 x_j 之间添加一条边, 得到图 G_w 。

$$W'_{ij} = \begin{cases} W_{ij}, & x_i \text{ 与 } x_j \text{ 属于同一类} \\ 0, & \text{其他} \end{cases} \quad (4)$$

由于该算法利用了训练样本的类别信息, 改善了权重矩阵 W'_{ij} , 从而使得分类精度有明显的提高。

SLPP 算法虽然可以改善 LPP 自身的缺点改善分类效果, 但是需要大量的人力、物力及时间来对数据进行标记类别标签, 使得准备工作繁重复杂, 未能达到事半功倍的效果。

2.3 半监督局部保持投影算法(SSLPP)

基于对 LPP 与 SLPP 两种算法各自的优缺点分析, 并同时考虑局部保留特征和利用数据类别信息, 本文提出一种半监督局部保持投影(Semi-Supervised Locality Preserving Projection, SSLPP)的降维算法, 其特性为保持数据局部结构的同时充分利用同类数据的信息。SSLPP 算法是将无监督的 LPP 算法向有监督方向的一种扩展, 并同时解决在监督学习

中需要数据全部标注的问题。

设高维欧氏空间 R^D 中一数据集 $X_{all} = \{x_1, x_2, \dots\}$, 从中根据先验知识标注少量不同地物类样本的类别标签, 同时随机选取部分样本数据作为无标记数据, 组成样本训练集 X , 即 $X = \{(x_1, l_1), \dots, (x_c, l_c), x_{c+1}, x_{c+2}, \dots, x_N\}$, $x_i \in R^D$, l_i 为对数据点 x_i 标注的地物类别标签, 前 c 个样本点具有地物类别信息, 其余 $N-c$ 个为无类别标记样本。依据部分标记地物信息的样本, SSLPP 算法中构建了本征图 G_l , 即在邻域内如果两个样本点属于同类或近邻则连接起来。其可行性准则为将同类或近邻的数据点拉近, 从而达到提高分类精度的目的。

SSLPP 算法如下:

1) 构建本征图 G_l

首先构建一个含有 N 个样本点的图 G_l 。具体方法是当第 i 个样本点和第 j 个样本点相距较近时, 则在点 x_i 和 x_j 之间添加一条边。对于样本点间的距离较近有两种定义方法: ϵ -近邻方法和 k -近邻方法。本文采用 k -近邻方法对每个数据点 x_i ($i=1, 2, \dots, N$) 计算其 k 近邻 $x_1^i, x_2^i, \dots, x_k^i$ 。

2) 计算图 G_l 中边的权重矩阵 W^l

$$W^l_{ij} = \begin{cases} \beta \times W_{ij}, & x_i \text{ 与 } x_j \text{ 属于同一类} \\ W_{ij}, & x_i \text{ 与 } x_j \text{ 互为近邻点} \\ 0, & \text{其他} \end{cases} \quad (5)$$

式中, $W_{ij} = e^{-\frac{\|x_i - x_j\|^2}{\sigma}}$, $\sigma \in R$, 为一可调参数; 系数 β (实验中 β 取值 10) 为大于 1 的常数。

3) 计算映射矩阵 A

SSLPP 算法的目标函数定义为:

$$\begin{cases} \arg \min \sum_{ij} (y_i - y_j)^2 W^l_{ij} \\ \text{s. t. } a^T X D^l X^T a = 1 \end{cases} \quad (6)$$

通过目标函数式(6)使得同类或近邻数据点保持紧密:

$$\begin{aligned} \arg \min \sum_{ij} (y_i - y_j)^2 W^l_{ij} &= \arg \min \sum_{ij} (y_i^2 + y_j^2 - 2y_i y_j) W^l_{ij} \\ &= \arg \min \sum_i y_i^2 D^l_{ii} + \sum_j y_j^2 D^l_{jj} - 2 \sum_{ij} y_i y_j W^l_{ij} \\ &= \arg \min 2 \left(\sum_i y_i^2 D^l_{ii} - \sum_{ij} y_i y_j W^l_{ij} \right) \\ &= \arg \min 2(Y^T D^l Y - Y^T W^l Y) \\ &= \arg \min 2Y^T L^l Y \\ &= \arg \min 2a^T X L^l X^T a \end{aligned}$$

推导式中 W^l 是本征图 G_l 对应的权重矩阵; D^l 是对角矩阵, $D^l_{ii} = \sum_j W^l_{ij}$; L^l 是 Laplacian 矩阵, $L^l = D^l - W^l$; a 为待求的投影向量。经过简单的变换之后, 目标函数变为:

$$\begin{cases} \arg \min a^T X L^l X^T a \\ \text{s. t. } a^T X D^l X^T a = 1 \end{cases} \quad (7)$$

利用 Lagrange 乘子法, 上述最优化问题转化为广义的特征值求解问题:

$$X L^l X^T a = \lambda X D^l X^T a \quad (8)$$

解式(8)对应 d 个最小特征值 $\lambda = [\lambda_0, \lambda_1, \dots, \lambda_{d-1}]$ 所对应的特征向量 $[a_0, a_1, \dots, a_{d-1}]$, 即为所求的从高维空间到低维空间的映射矩阵 $A = [a_0, a_1, \dots, a_{d-1}]$ 。

2.4 SSLPP 算法步骤

本文所提出的 SSLPP 算法如表 1 所列。

表1 SSLPP算法


输入:	N 个训练样本的数据集,其中含有 c 个标记类别的训练样本 $X = \{(x_1, l_1), (x_2, l_2), \dots, (x_c, l_c), x_{c+1}, x_{c+2}, \dots, x_N\}, x_i \in \mathbb{R}^D$
输出:	投影矩阵 A ,低维空间的构造点 Y
Step1	从数据集中随机选取一定量的训练样本和测试样本;
Step2	利用部分已知地物类别标记的训练样本集 X 构建类内图 G_i ;
Step3	构造 G_i 的权重矩阵 W_i ;
Step4	求解式(8)特征方程中的 d 个最小特征值对应的特征向量,得到投影矩阵 A ;
Step5	计算嵌入特征 $Y = A^T X$ 。

3 实验与分析


为了验证本文算法的有效性,采用了 AVIRIS KSC 数据和 Botswana 数据进行实验,并将本文 SSLPP 算法与 PCA、LPP、SLPP 算法进行比较。

3.1 AVIRIS KSC 数据集

1996年3月23日,NASA的成像光谱仪(AVIRIS)获取佛罗里达州肯尼迪空间中心(Kennedy Space Center, KSC)附近的高光谱影像,该实验数据由 KSC 遥感研究组提供。该数据从海拔 20km 左右航空飞行获得,地面分辨率为 18m,大小为 614×512 ,光谱范围为 $400 \sim 2500\text{nm}$,波段个数为 224。本实验进一步去除大气水分吸收及低信噪比波段,选用原数据的 176 个波段进行研究。根据肯尼迪空间中心地面覆盖图和 Landsat 专题制图仪(TM)影像,获得 13 类典型地物样本点 5211 个。图 1 给出了 AVIRIS KSC 高光谱遥感影像和各地物光谱曲线,表 2 给出了 KSC 高光谱遥感图像类别信息。



(a) AVIRIS KSC 高光谱遥感影像



(b) 各类地物光谱曲线

图1 AVIRIS KSC 高光谱遥感影像和各地物光谱曲线

表2 KSC 高光谱遥感图像类别信息

Category	Name	Sum
C1	Scrub	761
C2	Willow swamp	243
C3	Cabbage palm hammock	256
C4	Cabbage palm/oak hammock	252
C5	Slash pine	161
C6	Oak/broadleaf hammock	229
C7	Hardwood swamp	105
C8	Graminoid marsh	431
C9	Spartina marsh	520
C10	Cattail marsh	404
C11	Salt marsh	419
C12	Mud flats	503
C13	Water	927

实验设置如下:选取 AVIRIS KSC 数据中的 C1—C10,共 10 类数据,从这 10 类地物中随机选取 14(其中有 4 个类别标记,10 个未标记),16(其中有 6 个类别标记,10 个未标记),18(其中有 8 个类别标记,10 个未标记)个数据点作为训练样本,100 个数据点作为测试样本。首先分别用 PCA、LPP、SLPP 以及本文所提算法 SSLPP(其中 $\beta=10$)对训练样本进行处理得到投影矩阵 A ,然后通过投影矩阵 A 把训练样本和测试样本分别进行维数约简,最后由最近邻分类器判断出每个测试样本的类别,并与真实类别对比,判断是否正确,同时计算出总体分类精度。重复实验 10 次,最终分类精度取 10 次实验的平均值。

图 2 给出了采用不同算法在不同维数下对 AVIRIS KSC 数据集进行分类的总体分类精度。表 3 给出了不同算法在各维数下总体精度的最高值。




图2 不同算法在不同维数下对 AVIRIS KSC 数据集进行分类的总体分类精度

表3 不同算法对 AVIRIS KSC 数据集分类在各维数下的最高总体精度(平均值+方差(%))

算法	最高总体分类识别精度(%)		
	4 labels	6 labels	8 labels
PCA	68.18±1.62	68.51±1.52	71.41±1.31
LPP	66.54±4.94	68.70±2.08	70.70±3.94
SLPP	69.07±3.67	71.96±2.78	74.85±1.78
SSLPP	73.69±3.79	76.06±2.46	78.90±2.43

由图 2、表 3 可得,所有算法随着训练样本数量的增加,其总体分类精度有所提高。原因是训练样本数越多,提供的具有代表性的先验信息就越多,各种算法得到的样本鉴别特征就更有效,进而提高了分类精度。实验中 PCA 算法的分类效果优于 LPP,其原因是 LPP 只利用了训练样本的局部近邻结构信息,忽略了数据的整体结构信息,而 PCA 算法则利用了所有训练样本的整体分布信息,所以相对于 LPP 算法 PCA 略显优势。本文算法 SSLPP 相对于 LPP 算法,依靠标记样本的作用,使得总体分类精度有明显提高,弥补了 LPP 非监督的缺陷,提高了分类精度。

在 4 个标记训练样本、10 个未标记训练样本的条件下,SSLPP 算法比 LPP 算法总体分类精度提高约 7.15%,比 PCA 算法提高约 5.51%;在 6 个标记训练样本、10 个未标记训练样本的条件下,SSLPP 算法比 LPP 算法总体分类精度提高约 7.36%,比 PCA 算法提高约 7.55%;在 8 个标记训练样本

本、10 个未标记训练样本的条件下,SSLPP 算法比 LPP 算法总体分类精度提高约 8.20%,比 PCA 算法提高约 7.49%。

3.2 Botswana 数据集

Botswana 数据集是美国宇航局在 2001 年通过 EO-1 卫星上 3000 万像素分辨率的高光谱传感器获取的高光谱影像,其覆盖了博茨瓦纳奥卡万戈三角洲地区长 7.7km 的带状地带。该影像共有 242 个波段,将第 120 至 133、第 165 至 186 以及第 221 波段至 242 等 97 个波段剔除,以消除大气吸收的影响,剩下的 145 个波段用于实验研究。图 3 给出了实验所使用的高光谱影像和各地物光谱曲线,表 4 给出了 Botswana 高光谱遥感图像类别信息。




图 3 Botswana 高光谱遥感影像和各地物光谱曲线

表 4 Botswana 高光谱遥感图像类别信息

Category	Name	Sum
C1	Water	270
C2	Hippo Grass	101
C3	Floodplain Grasses	1251
C4	Floodplain Grasses	2215
C5	Reeds 1	269
C6	Riparian	269
C7	Firescar2	259
C8	Island Interior	203
C9	Acacia Woodlands	314
C10	Acacia Scrublands	248
C11	Acacia Grasslands	305
C12	Short Mopane	181
C13	Mixed Mopane	268
C14	Exposed Soils	95

实验设置如下:选取 Botswana 数据集中较易区分的 Mixed Mopane、Short Mopane、Acacia Woodlands、Firescar2、Floodplain Grasses 2、Riparian,共 6 类,从这 6 类地物中随机选取 14(其中有 4 个类别标记,10 个未标记),16(其中有 6 个类别标记,10 个未标记),18(其中有 8 个类别标记,10 个未标记)个数数据点作为训练样本,100 个数数据点作为测试样本。首先分别用 PCA、LPP、SLPP 以及本文所提算法 SSLPP(其中 $\beta = 10$)对训练样本进行处理得到投影矩阵 A,然后通过投影矩阵 A 把训练样本和测试样本分别进行维数约简,最后由最近邻分类器判断出每个测试样本的类别,并与真实类别对比,判断是否正确,并计算出总体分类精度。重复实验 10 次,最终的分

图 4 给出了采用不同算法在不同维数下对 Botswana 数据集进行分类的总体分类精度。表 5 给出了不同算法在各维数下总体精度的最高值。




图 4 不同算法在不同维度下对 Botswana 数据集进行分类的总体分类精度

表 5 不同算法对 Botswana 数据集分类在各维度下的最高总体分类精度(平均值+方差(%))

算法	最高总体分类识别精度 (%)		
	4 labels	6 labels	8 labels
PCA	80.72±1.78	81.20±1.77	81.97±1.30
LPP	84.62±3.44	85.42±1.20	86.92±1.52
SLPP	85.00±2.75	85.77±2.21	87.01±1.76
SSLPP	90.05±1.28	91.13±1.60	91.56±0.89

由图 4、表 5 可得,与 AVIRIS KSC 数据的实验结果类似,随着训练样本数量的增加,各类算法其总体分类精度也随之有所提高。本文算法 SSLPP 相对于 LPP 算法,因标记样本的作用,使得总体分类精度明显提高,弥补了 LPP 非监督的缺陷;并且随着训练样本的增加,SSLPP 算法相对于 LPP 算法的分类精度的提高度也有所扩大。

在 4 个标记训练样本、10 个未标记训练样本的条件下,SSLPP 算法比 LPP 算法总体分类精度提高约 5.43%,比 PCA 算法提高约 9.33%;在 6 个标记训练样本、10 个未标记训练样本的条件下,SSLPP 算法比 LPP 算法总体分类精度提高约 5.71%,比 PCA 算法提高约 9.93%;在 8 个标记训练样本、10 个未标记训练样本的条件下,SSLPP 算法比 LPP 算法总体分类精度提高约 4.64%,比 PCA 算法提高约 9.59%。

结束语 本文提出了一种基于 SSLPP 高光谱遥感影像分类算法。该方法的核心内容是将高维数据投影到低维空间中,且利用已标记数据的类别信息,使得属于同类数据点更加紧密,继而提高数据的总体分类精度。通过在 AVIRIS KSC 数据集和 Botswana 数据集做分类实验,实验中随机选取了 4、6、8 个有类别标记的样本点及 10 个无类别标记的样本点作为实验算法的训练样本,经过不同降维算法实验结果的比较,SSLPP 算法的总体分类精度比 LPP 算法提高 4.64%~8.20%,比 PCA 算法提高 5.51%~9.59%。证实本文所提 SSLPP 算法可以较为有效地改善高光谱遥感影像分类的问题。

研究和实现:1)集成通用 CAD 软件的模型用于分析仿真,并实现 CAD 几何模型可视化显示或隐藏;2)支持基于多项式回归模型、Kriging 模型、径向基函数模型、基于支持向量回归模型、样条响应面模型的响应面分析;3)支持基于经典算法、启发式算法、响应面算法、全局优化算法的优化设计;4)丰富数据可视化工具,提供交互可视化处理权衡研究数据结果工具集,为设计人员分析数据提供辅助。

参考文献

- [1] Chen Z, Siddique Z. A cooperative-collaborative design system for concurrent multi-disciplinary mechanical design[C]// Proceedings of the ASME International Design Engineering Technical Conferences and Computers and Information in Engineering Conference. California: DIPTeM University of Genoa, 2005: 779-787
- [2] Weatherill N P, Turner-Smith E A, John J, et al. An integrated software environment for multi-disciplinary computational engi-

neering[J]. Engineering Computations, 1996, 16(8)

- [3] 赵顺华, 吴义忠, 沈博. 基于 Web 的多领域可视化建模系统设计与实现 [J]. 计算机科学, 2013, 40(6): 138-141
- [4] Vittorio C, Bruna D S, Vito I, et al. Evaluation and optimization of manufacturing system using simulation modeling and design of experiment[C]// Proceedings of the 20th European Modeling and Simulation Symposium (EMSS 2008). Italy: DIPTeM University of Genoa, 2008: 224-230
- [5] PHX ModelCenter-Phoenix Integration [EB/OL]. <http://www.phoenix-int.com/software/phx-modelcenter.php>, 2013-06-24
- [6] Dassault Engineous Software [EB/OL]. <http://www.3ds.com/products/simulia/portfolio/isight-simulia-execution-engine/isight-see-portfolio/>, 2013-07-19
- [7] 赵勇, 颜力, 陈小前, 等. 基于 MDO 方法的月球探测卫星总体设计[J]. 上海航天, 2006(2): 37-41
- [8] 韩明红, 邓家祺. 复杂工程系统多学科设计优化集成环境研究[J]. 机械工程学报, 2004, 40(9): 100-105

(上接第 336 页)

其中本文算法是采用欧氏距离来判定近邻域的,但是欧氏距离不能很好地反映非线性数据间的分布情况,影响近邻域的确定及后续的降维工作。对于如何解决这个问题,需要进一步的研究。

参考文献

- [1] 王立志, 黄鸿, 冯海亮. 基于 MFA 与 kNNS 算法的高光谱遥感影像分类[J]. 计算机科学, 2012, 39(6): 261-265
- [2] Yang Guo-peng, Zhou xin, Yu Xu-chu, et al. Relevance vector machine for hyperspectral imagery unmixing [J]. Acta Electronica Sinica, 2010, 38(12): 2751-2756
- [3] Yin Ji-hao, Wang Yan, Wang Yi-song. A revised multi-target detection approach in hyperspectral image [J]. Acta Electronica Sinica, 2010, 38(9): 1975-1978
- [4] Luo Si-wei, Zhao Lian-wei. Manifold learning algorithms based on spectral graph theory [J]. Journal of Computer Research and Development, 2006, 43(7): 1173-1179
- [5] He Lin, Pan Quan, et al. Research Advance on Target Detection for Hyperspectral Imagery [J]. Acta Electronica Sinica, 2009, 37(9): 2016-2024
- [6] Wang Li-zhi, Huang Hong, Feng Hai-liang. Hyperspectral Remote Sensing Image Classification Based on SSMFA and kNNS [J]. Acta Electronica Sinica, 2012, 40(4): 780-787
- [7] Ma Li, Crawford M M, Tian Jin-wen. Local manifold learning-based k-nearest-neighbor for hyperspectral image classification [J]. IEEE Transactions on Geoscience and Remote Sensing, 2010, 48(11): 4099-4109
- [8] Huang H, Li J W, Feng H L. Subspaces versus Submanifolds: A comparative study in small sample size problem [J]. International Journal of Pattern Recognition And Artificial Intelligence, 2009, 23(3): 463-490
- [9] Turk M, Pentland A. Eigenfaces for recognition [J]. Journal of

Cognitive Neuroscience, 1991, 3(1): 71-86

- [10] Belhumeur P, Hespanha J, Kriegman D. Eigenfaces vs. Fisherfaces: Recognition using class specific linear projection [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 1997, 20(7): 711-720
- [11] He Xiao-fei, Cai Deng, Yan Shui-cheng, et al. Neighborhood preserving embedding [A]// Proceedings of the 10th IEEE International Conference Computer Vision (ICCV'05) [C]. Beijing, 2005: 1208-1213
- [12] He Xiao-fei, Yan Shui-cheng, Hu Yu-xiao, et al. Face recognition using Laplacianfaces [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2005, 27(3): 328-340
- [13] Yan Shui-cheng, Xu Dong, Zhang Ben-yu, et al. Graph embedding and extensions: A general framework for dimensionality reduction [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2007, 29(1): 40-51
- [14] Fu Yun, Yan Shui-cheng, Huang T S. Classification and feature extraction by simplexization [J]. IEEE Transactions on Information Forensics and Security, 2008, 3(1): 91-100
- [15] Fu Yun, Yan Shui-cheng, Huang T S. Discriminant simplex analysis [A]// Proceedings of the IEEE Conference ICASSP[C]. Las Vegas, NV, 2008: 3333-3336
- [16] Bau T C, Sarkar S, Healey G. Hyperspectral region classification using a three-dimensional gabor filterbank [J]. IEEE Transactions on Geoscience and Remote Sensing, 2010, 48(9): 3457-3464
- [17] Acito N, Diani M, Corsini G. Hyperspectral signal subspace identification in the presence of rare signal components [J]. IEEE Transactions on Geoscience and Remote Sensing, 2010, 48(4): 1940-1954
- [18] Yang J M, Kuo B C, Yu P T, et al. Adaptive subspace method for hyperspectral image classification [J]. IEEE Transactions on Geoscience and Remote Sensing, 2010, 48(7): 2840-2853