

# 面向高光谱影像分类的空间正则化 流形鉴别分析方法

黄鸿\*, 王丽华, 石光耀

重庆大学光电技术及系统教育部重点实验室, 重庆 400044

**摘要** 针对传统高光谱影像特征提取算法大多仅考虑光谱信息或提取空间信息不够精细的问题,提出了一种监督空间正则化流形鉴别分析(SSRMDA)算法,以提高遥感地物的分类性能。该算法首先利用样本数据的标签信息构建谱域类内图和类间图,以揭示高光谱数据潜在的非线性流形结构;然后构建空域类内图,并将空间信息以正则化方式与光谱信息融合,实现谱-空信息的有效融合,并可在低维空间内使类内数据更加聚集,增强嵌入数据的可分性。在 Indian Pines 和 Washington DC Mall 数据集上的实验表明,所提算法的总体分类精度分别为 91.58% 和 96.67%,说明所提算法有效提升了地物分类能力,尤其在小样本下的优势更为明显,更有利于实际应用。

**关键词** 遥感; 高光谱影像分类; 特征提取; 图嵌入; 流形学习; 空间正则化

中图分类号 TP751.1

文献标志码 A

doi: 10.3788/AOS202040.0228001

## Spatially-Regularized Manifold Discriminant Analysis Algorithm for Hyperspectral Image Classification

Huang Hong\*, Wang Lihua, Shi Guangyao

Key Laboratory of Optoelectronic Technique System of the Ministry of Education,  
Chongqing University, Chongqing 400044, China

**Abstract** Traditional feature extraction algorithms consider only spectral information in the hyperspectral image (HSI) and cannot extract fine spatial information. To solve this problem, this paper proposes a supervised spatially-regularized manifold discriminant analysis (SSRMDA) algorithm to improve the classification performance of ground objects in the HSI. The SSRMDA algorithm firstly constructs a spectral-domain intraclass image and an interclass image by using the label information of training samples, which reveals the potential nonlinear manifold structure of hyperspectral data. Based on that, a spatial-domain intraclass image is constructed, and it combines the spectral information of HSI by regularization to realize the effective fusion of spectral-spatial information. In low-dimensional space, the intraclass data in low dimensional space becomes more clustered and the separability of embedded features is enhanced. Experiments on the Indian Pines and Washington DC Mall datasets show that the overall classification accuracy of the SSRMDA algorithm reaches 91.58% and 96.67%, respectively, which denotes that the proposed algorithm effectively improves the classification ability of ground objects. Compared with other feature extraction algorithms, the proposed algorithm is effective in practical applications, especially when a small number of training samples are available.

**Key words** remote sensing; hyperspectral image classification; feature extraction; image embedding; manifold learning; spatial regularization

**OCIS codes** 280.4750; 100.3008; 110.2960

## 1 引 言

高光谱遥感影像将反映目标辐射特性的光谱信

息与反映目标几何空间信息的图像信息有机结合起来,实现了“图谱合一”,已被广泛应用于农业规划、环境监测及资源勘查等领域<sup>[1-3]</sup>。但是,由于高光谱

收稿日期: 2019-07-18; 修回日期: 2019-08-23; 录用日期: 2019-09-06

基金项目: 重庆市基础研究与前沿探索项目(cstc2018jcyjAX0093, cstc2018jcyjAX0633)、重庆市研究生科研创新项目(CYB19039)

\* E-mail: hhuang@cqu.edu.cn

影像的光谱分辨率较高,波段众多,波段间的相关性强,易造成“维数灾难”问题<sup>[4]</sup>。特征提取是解决上述问题的有效途径,它通过减小数据冗余度来提取有效的鉴别信息,降低维度,进而有效地提升地物分类性能<sup>[5-7]</sup>。

近年来,国内外学者提出了一系列特征提取算法,其中的主成分分析(PCA)<sup>[8]</sup>和线性判别分析(LDA)<sup>[9]</sup>是两种经典的子空间线性变换算法,但它们不能有效揭示数据的内在非线性结构。为此,学者们提出了流形学习方法,以更好地发现高维数据潜在的低维流形结构,如局部线性嵌入(LLE)<sup>[10]</sup>、邻域保持嵌入(NPE)<sup>[11]</sup>和局部保持投影(LPP)<sup>[12]</sup>等。随后,Xu等<sup>[13]</sup>提出了一种图嵌入(GE)框架,上述算法均可统一到该框架下,其区别在于如何构建本征图和惩罚图。在此框架下,学者们通过引入样本数据的先验信息,提出了边界Fisher分析(MFA)<sup>[13]</sup>、局部Fisher判别分析(LFDA)<sup>[14]</sup>等监督学习方法,以进一步提升分类性能。

然而,上述算法都仅考虑了高光谱数据的光谱域信息,却忽视了数据的空间属性。有研究表明,空-谱结合有利于克服单一光谱不能有效区分地物类别的问题<sup>[15]</sup>。文献[16]通过优化高光谱影像边缘来揭示数据的空-谱局部结构,进而提取更多的鉴别特征,其提出的鉴别空-谱边缘算法(DSSM)有效地改善了地物分类性能;文献[17]提出的局部像素邻域保留投影(LPNPE)方法通过最小化局部像素散度矩阵和最大化整体散度矩阵来保持空间局部像素邻域结构在低维空间的不变性,进而提取有效鉴别信息,实现地物分类;文献[18]提出的半监督空谱全局与局部判别分析(S<sup>3</sup>GLDA)通过半监督与无监督方式将光谱信息和空间信息进行融合,保留了谱域全局判别结构和空域局部判别结构在低维空间的不变性,进而提取鉴别特征,提高分类精度。上述算法均采用开窗方式对空间信息进行提取,窗口大小易影响信息提取的准确度,从而影响高光谱地物分类性能。

针对以上问题,本文提出了一种面向高光谱遥感影像分类的监督空间正则化流形鉴别分析算法(SSRMDA)。该算法首先将训练样本中的每个点作为顶点,每个点用其对应的光谱特征描述,从而构造光谱域上的类内图和类间图;然后,通过熵率超像素(ERS)<sup>[19]</sup>方法将原始高光谱图像划分为大小不一的超像素块,以超像素块内的每个像素点为顶点,选择对应的空间近邻点构造空间域类内图,以表征高光谱影像内部的空间信息,同时将得到的空间信

息作为光谱域目标函数的正则项,以融合高光谱影像的空间-光谱信息,进而增强类内数据的聚集性。最后,采用正则化参数来平衡光谱特征和空间特征的融合度,使用图嵌入模型求取低维嵌入矩阵,保持高维空间中的低维流形结构不变,从而提取鉴别特征,实现地物分类。

## 2 本文方法

假设一高维数据为  $\mathbf{X} = [x_1, x_2, \dots, x_M] \in \mathbf{R}^{D \times M}$ ,  $D$  为波段数,  $M$  为样本总数,类别标签  $l_i \in \{1, 2, \dots, c\}$ ,  $c$  为类别数,则  $\mathbf{X}$  在低维空间通过线性变换  $\mathbf{Y} = \mathbf{Z}^T \mathbf{X}$  后可以得到数据  $\mathbf{Y} = [y_1, y_2, \dots, y_M] \in \mathbf{R}^{d \times M}$ ,  $d$  ( $d \ll D$ ) 为嵌入维数,  $\mathbf{Z}$  为嵌入矩阵,  $\mathbf{Z} = [z_1, z_2, \dots, z_d] \in \mathbf{R}^{D \times d}$ 。

### 2.1 熵率超像素

超像素是由一系列具有相似特征(颜色、纹理、亮度等)且空间位置相邻的像素构成的局部图像块区域,其大小和形状可以根据图像不同的局部空间结构自适应地调整,从而尽可能地保留有用信息。

ERS是一种将图像映射到图  $\mathbf{G}(\mathbf{X}, E)$  的基于图论的分割方法,每个像素表示图的一个顶点,记为  $x_i \in X$  ( $x_i$  为第  $i$  个样本);  $E$  为边集,  $e_{ij}$  为连接顶点  $x_i$  与  $x_j$  ( $x_j$  为第  $j$  个样本)之间的边,边权值为  $w_{ij}$ ,表示顶点  $x_i$  与  $x_j$  之间的相似度。ERS的目标是选择边缘子集  $A \in E$ ,将原图分割为  $S_A = \{s_1, s_2, \dots, s_N\}$ ,则可以得到包含  $N$  个超像素的图  $\mathbf{G}(\mathbf{X}, A)$ 。ERS的目标函数如下:

$$\max F(A) = H(A) + \lambda B(A), \quad (1)$$

式中:  $\lambda$  为平衡因子,  $\lambda \geq 0$ ;  $H(A)$  为熵率,用来产生紧凑的超像素区域;  $B(A)$  为平衡项,使形成的超像素区域具有合适的尺寸。

### 2.2 图嵌入

图嵌入模型旨在构造本征图  $\mathbf{G}(\mathbf{X}, \mathbf{W})$  和惩罚图  $\mathbf{G}^p(\mathbf{X}, \mathbf{W}^p)$  来保持数据间的几何特性,  $\mathbf{W}$  和  $\mathbf{W}^p$  分别为本征图和惩罚图的相似度权值矩阵。本征图揭示同类数据间的相似性,惩罚图反映异类数据间的近似性。图嵌入的目的是将图的顶点映射为低维向量,采用边权值度量原则保留顶点之间的相似程度,目标函数定义为

$$\min \frac{1}{2} \sum_{i,j=1}^M \|\mathbf{Z}^T x_i - \mathbf{Z}^T x_j\|^2 w_{ij} = \min \text{tr}(\mathbf{Z}^T \mathbf{X} \mathbf{L} \mathbf{X} \mathbf{Z}^T), \quad (2)$$

式中:  $\mathbf{L}$  为图拉普拉斯矩阵,且  $\mathbf{L} = \mathbf{D} - \mathbf{W}$ ,

$$\mathbf{D} = \text{diag}\left(\sum_{j=1}^M \tau_{1j}, \sum_{j=1}^M \tau_{2j}, \dots, \sum_{j=1}^M \tau_{Mj}\right), \mathbf{W} = [\tau_{ij}]_{i,j=1}^M.$$

### 2.3 监督空间正则化流形鉴别分析

本文算法首先利用谱域信息构造类内图和类间

图,然后利用空域信息构造类内图,并将其作为正则项,以表征图像的空间结构。低维嵌入空间使类内数据聚集且类间数据分散,以提取鉴别特征,改善地物分类性能。本文算法流程图如图 1 所示。

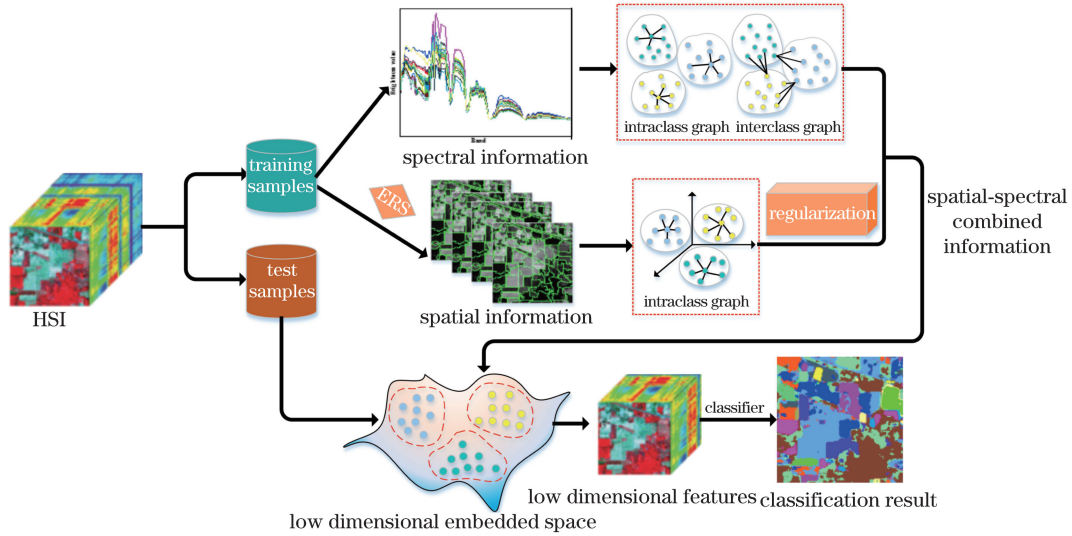


图 1 SSRMDA 算法流程图

Fig. 1 Flow chart of SSRMDA algorithm

下面对该算法进行具体介绍。

#### 1) 谱域表达

构造类内图  $\mathbf{G}^w(\mathbf{X}, \mathbf{W}^w)$ ,  $\mathbf{W}^w$  为类内图的相似权重矩阵,若顶点  $x_i$  与  $x_j$  来自同类数据,且  $x_j$

为  $x_i$  的  $K_w$  近邻( $K_w$  近邻表示光谱类内近邻),则可在两点之间连一条边,否则  $x_i$  与  $x_j$  无连接边。边权值为  $\tau_{ij}^w$ ,用于描述两点之间的相似关系,定义为

$$\tau_{ij}^w = \begin{cases} \exp\left(-\frac{\|x_i - x_j\|^2}{2\sigma_{i,w}^2}\right), & x_i \in N_{K_w}(x_j) \text{ or } x_j \in N_{K_w}(x_i) \ \& \ l_i = l_j, \\ 0, & \text{otherwise} \end{cases}, \quad (3)$$

式中: $\sigma_{i,w} = \frac{1}{M} \sum_{j=1}^M \|x_i - x_j\|$ ;  $N_{K_w}(x_i)$  和  $N_{K_w}(x_j)$  分别为属于  $x_i, x_j$  的类内  $K_w$  近邻;  $l_j$  为第  $j$  个样本的类别标签。

构造类间图  $\mathbf{G}^b(\mathbf{X}, \mathbf{W}^b)$ ,  $\mathbf{W}^b$  为类间图  $\mathbf{G}^b$  中各顶点之间的连接权重,若  $x_i$  与  $x_j$  为来自非同类数

据的  $K_b$  近邻( $K_b$  近邻表示  $x_i$  与其他所有样本之间的距离,按从小到大的方式排列,取前  $K_b$  个值,则前  $K_b$  个值所对应的样本就是  $x_i$  的  $K_b$  近邻),则可用一条边连接两点,否则无连接。揭示两点相似性的边权值  $\tau_{ij}^b$  定义为

$$\tau_{ij}^b = \begin{cases} \exp\left(-\frac{\|x_i - x_j\|^2}{2\sigma_{i,b}^2}\right), & x_i \in N_{K_b}(x_j) \text{ or } x_j \in N_{K_b}(x_i) \ \& \ l_i \neq l_j, \\ 0, & \text{otherwise} \end{cases}, \quad (4)$$

式中: $\sigma_{i,b}$  具有与  $\sigma_{i,w}$  相同的表示形式;  $N_{K_b}(x_i)$  与  $N_{K_b}(x_j)$  分别为  $x_i, x_j$  的类间  $K_b$  近邻。

#### 2) 空间正则化

对于给定的高光谱数据  $\mathbf{X} \in \mathbf{R}^{D \times M}$ , 利用 ERS 对其进行分割处理,可以得到超像素集  $S = \{s_1,$

$s_2, \dots, s_N\}$ ,  $N$  为超像素个数,如图 2 所示。对比超像素分割图与真实地物图可看出,同一个超像素内的像素通常来自于同一地物类别。因此,本文利用 ERS 处理后的空间信息构造空域类内图,并将其作为正则项,以强化类内数据的聚集性。




图 2 ERS 分割图与真实地物图。(a) ERS 分割图;(b)真实地物图

Fig. 2 ERS segmentation and ground-truth images. (a) ERS segmentation image; (b) ground-truth image

构造空间正则化类内图  $\mathbf{G}^{sw}(\mathbf{X}, \mathbf{W}^{sw})$ ,  $\mathbf{W}^{sw}$  为类内图  $\mathbf{G}^{sw}$  中各顶点之间的连接权重,  $s_t$  为超像素, 若两点  $x_i, x_j \in s_t$ , 且  $x_j$  为  $x_i$  的  $K_{sw}$  近邻(前  $K_{sw}$  个

值所对应的样本), 则可在两点之间连一条边, 否则, 两点间无连接边。反映该两点近似程度的边权值  $\tau_{ij}^{sw}$  定义为

$$\tau_{ij}^{sw} = \begin{cases} \exp\left(-\frac{\|x_i - x_j\|^2}{2\sigma_{i,sw}^2}\right), & x_i \in N_{K_{sw}}(x_j) \text{ or } x_j \in N_{K_{sw}}(x_i) \ \& \ l_i = l_j, \\ 0, & \text{otherwise} \end{cases}, \quad (5)$$

式中:  $\sigma_{i,sw} = \frac{1}{n} \sum_{x_j \in s_t} \|x_i - x_j\|$ ;  $n$  为  $s_t$  内的像素总数;  $N_{K_{sw}}(x_i)$  与  $N_{K_{sw}}(x_j)$  分别为  $x_i, x_j$  的空间正则化类内  $K_{sw}$  近邻。

3) 嵌入矩阵

在低维空间中, 要使类内数据尽可能地聚集, 类间数据尽可能地远离, 以增加数据的可分性, 则算法的目标函数可表达为

$$\begin{aligned} F_1 &= \min \left\{ (1-\alpha) \sum_{i,j=1}^M \|Z^T x_i - Z^T x_j\|^2 \tau_{ij}^w + \alpha \frac{1}{N} \sum_{t=1}^N \sum_{x_i, x_j \in s_t} \|Z^T x_i - Z^T x_j\|^2 \tau_{ij}^{sw} \right\} = \\ &= \min \operatorname{tr} \left\{ (1-\alpha) Z^T \mathbf{X} (\mathbf{D}^w - \mathbf{W}^w) \mathbf{X}^T \mathbf{Z} + \alpha \frac{1}{N} \sum_{t=1}^N Z^T \mathbf{X}_t (\mathbf{D}^{sw} - \mathbf{W}^{sw}) \mathbf{X}_t^T \mathbf{Z} \right\} = \\ &= \min \operatorname{tr} \left\{ (1-\alpha) Z^T \mathbf{X} \mathbf{L}^w \mathbf{X}^T \mathbf{Z} + \alpha \frac{1}{N} \sum_{t=1}^N Z^T \mathbf{X}_t \mathbf{L}^{sw} \mathbf{X}_t^T \mathbf{Z} \right\}, \end{aligned} \quad (6)$$

$$F_2 = \max \sum_{i,j=1}^M \|Z^T x_i - Z^T x_j\|^2 \tau_{ij}^b = \max \operatorname{tr} Z^T \mathbf{X} \mathbf{L}^b \mathbf{X}^T \mathbf{Z}, \quad (7)$$

式中:  $\alpha (0 < \alpha < 1)$  为正则化参数;  $\mathbf{X}_t$  为第  $t$  个超像素块内的样本数据;  $\mathbf{L}^w = \mathbf{D}^w - \mathbf{W}^w$ ;  $\mathbf{L}^{sw} = \mathbf{D}^{sw} - \mathbf{W}^{sw}$ ;  $\mathbf{L}^b = \mathbf{D}^b - \mathbf{W}^b$ ;  $\mathbf{D}^w = \operatorname{diag}\left(\sum_{i,j=1}^M \tau_{ij}^w\right)$ ;  $\mathbf{D}^{sw} = \operatorname{diag}\left(\sum_{i,j=1}^M \tau_{ij}^{sw}\right)$ ;  $\mathbf{D}^b = \operatorname{diag}\left(\sum_{i,j=1}^M c\right)$ ;  $\mathbf{W}^{sw} = \sum \tau_{ij}^{sw}$ ;  $\mathbf{W}^b = \sum \tau_{ij}^b$ ;  $\mathbf{W}^w = \sum \tau_{ij}^w$ 。

通过优化目标函数, 将(6)~(7)式转换为以下优化问题:

$$\min \frac{(1-\alpha) Z^T \mathbf{X} \mathbf{L}^w \mathbf{X}^T \mathbf{Z} + \alpha \frac{1}{N} \sum_{t=1}^N Z^T \mathbf{X}_t \mathbf{L}^{sw} \mathbf{X}_t^T \mathbf{Z}}{Z^T \mathbf{X} \mathbf{L}^b \mathbf{X}^T \mathbf{Z}}. \quad (8)$$

由拉格朗日乘子法可得

$$(1-\alpha) Z^T \mathbf{X} \mathbf{L}^w \mathbf{X}^T \mathbf{Z} + \alpha \frac{1}{N} \sum_{t=1}^N Z^T \mathbf{X}_t \mathbf{L}^{sw} \mathbf{X}_t^T \mathbf{Z} = \lambda Z^T \mathbf{X} \mathbf{L}^b \mathbf{X}^T \mathbf{Z}. \quad (9)$$

求解(9)式的特征值, 然后按照降序排列, 选取前  $d$  个最大的特征值对应的特征向量组成投影矩阵  $\mathbf{Z} = [\mathbf{z}_1, \mathbf{z}_2, \dots, \mathbf{z}_d]$ 。

为进一步分析 SSRMDA 算法的运行效率, 用符号  $O$  表征计算的复杂度。假设高光谱数据集的光谱波段数和样本总数分别为  $D$  和  $M$ , 那么  $(\mathbf{X} \mathbf{L} \mathbf{X}^T)^{-1}$  的计算复杂度为  $O(DM^2 + D^3)$ ,  $\mathbf{L}$  为拉普拉斯矩阵。由于超像素内部的像素个数一般小于训练样本的个数, 所以  $\mathbf{X} \mathbf{L} \mathbf{X}^T + \frac{1}{N} \sum_{t=1}^N \mathbf{X}_t \mathbf{L}^{sw} \mathbf{X}_t^T$  的



计算复杂度为  $O(DM^2)$ , 而特征值分解问题的计算复杂度为  $O(D^3)$ , 因此 SSRMDA 算法总的计算复杂度为  $O(DM^2 + D^3)$ 。本文算法的运行效率主要取决于遥感影像的光谱波段数以及训练样本的个数, 本文算法也可应用于波段数少于高光谱影像的航空/卫星遥感图像。

### 3 实验分析

#### 3.1 实验数据

为验证本文算法的有效性, 采用公开的 Indian Pines 和 Washington DC Mall 高光谱数据集进行测试。

Indian Pines 数据集是 1992 年由美国国家航空航天局的 AVIRIS 光谱仪获取的美国印第安纳州西

北部某区域的图像, 该图像大小为  $145 \text{ pixel} \times 145 \text{ pixel}$ , 包含光谱范围为  $0.4 \sim 2.45 \mu\text{m}$  的 220 个波段, 去除受水汽、噪声影响的 20 个波段, 实验选取剩余的 200 个波段作为研究对象。该数据集中包括玉米、燕麦等 16 种地物, 其假彩色图和地面调查样地分布图如图 3 所示。

Washington DC Mall 数据集是由 HYDICE 传感器获取的华盛顿购物中心的图像, 图像大小为  $1208 \text{ pixel} \times 307 \text{ pixel}$ , 包含光谱范围为  $0.4 \sim 2.5 \mu\text{m}$  的 210 个波段, 剔除受水汽影响的部分, 实验选取余下的 191 个波段作为实验对象, 大小为  $250 \text{ pixel} \times 307 \text{ pixel}$ 。该数据集包含水、建筑、道路等 6 类地物, 其假彩色图和地面调查样地分布图如图 4 所示。




图 3 Indian Pines 高光谱图像。(a)假彩色图;(b)真实地物图

Fig. 3 Hyperspectral images in Indian Pines dataset. (a) False-color image; (b) ground-truth image




图 4 Washington DC Mall 高光谱图像。(a)假彩色图;(b)真实地物图

Fig. 4 Hyperspectral images in Washington DC Mall dataset. (a) False-color image; (b) ground-truth image

#### 3.2 实验设置

实验时, 每次从数据集中随机选取一定量的样本用于训练, 其余样本用于测试。采用不同的特征提取算法得到低维嵌入特征, 然后采用最近邻分类器(1-NN)对地物进行分类, 并以总体分类精度(OA)、平均分类精度(AA)及 Kappa 系数为分类结果的评价指标。

实验中, 将本文提出的 SSRMDA 算法的结果与 RAW(表示未进行特征提取直接采用分类器进行

分类的结果)、PCA、NPE、LPP、LDA、MFA、LGSFA (Local Geometric Structure Fisher Analysis)<sup>[20]</sup>、DSSM、LPNPE、SSRLDE (Spatial and Spectral Regularized Local Discriminant Embedding)<sup>[17]</sup> 进行对比。为使各算法的分类效果最优, 采用交叉验证法获得最佳参数。NPE、LPP 的近邻设置为 5; 对于类内和类间近邻的设置, MFA 分别设置为 5、100, DSSM 分别设置为 3、5, SSRLDE 分别设置为 5、5。在 Indian Pines 和 Washington DC Mall 数据

集上,对于空间窗口的设置,DSSM 分别设置为 11、11,LPNPE 分别设置为 15、5,SSRLDE 分别设置为 15、5。LDA 的嵌入维数为  $c-1$ , $c$  为类别数,其余算法的嵌入维数均设置为 30。

为验证 SSRMDA 算法中不同光谱类内近邻、类间近邻、空间类内近邻以及空间正则化参数对分类性能的影响,从每类数据集中随机选取 10 个样本进行训练,其余样本用来测试。令超像素个数  $N=100$ ,光谱类内近邻  $K_w$ 、空间类内近邻  $K_{sw}$  均用  $K$  表示, $K$  和  $K_b$  的取值分别设置为  $\{3,5,7,\dots,25\}$  和  $\{5,10,15,\dots,50\}$ , $\alpha$  的取值设置为  $\{0,0.1,0.2,\dots,$

1)。图 5 为不同数据集下 SSRMDA 算法在不同  $K, K_b$  下的平均总体分类精度,图 6 为不同数据集下 SSRMDA 算法在不同  $\alpha$  值下的平均总体分类精度。

分析图 5 可得知:随着  $\alpha$  增大,总体分类精度先增加后减小。造成此现象的原因如下:当  $\alpha$  值较小时,不能提取足够有效的信息来表征高光谱图像的内在结构;而当  $\alpha$  值较大时,边界学习会出现过拟合现象。在实验中,为使算法表现最佳的分类性能,在 Indian Pines 数据集上,令  $K=11, K_b=20$ ;在 Washington DC Mall 数据集上,令  $K=9, K_b=10$ 。

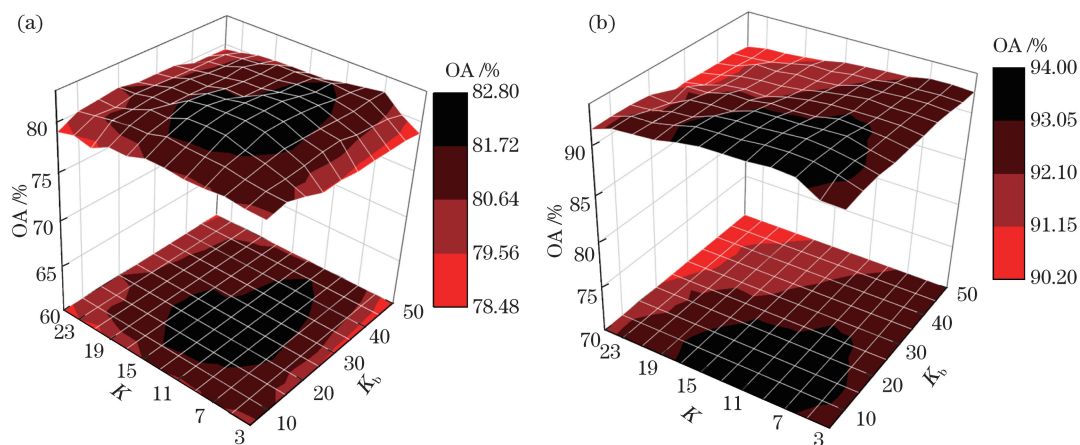


图 5 不同数据集下 SSRMDA 算法在不同  $K, K_b$  值下的总体分类精度。(a) Indian Pines 数据集;  
(b) Washington DC Mall 数据集

Fig. 5 Overall classification accuracy of SSRMDA algorithm with different values of  $K$  and  $K_b$  on different datasets.  
(a) Indian Pines dataset; (b) Washington DC Mall dataset

由图 6 可以看出,随着  $\alpha$  增大,分类精度先提高后降低。这是因为 SSRMDA 算法要平衡光谱信息和空间信息在特征提取中的作用,当  $\alpha$  较小时,容易忽略空间特征结构,而当  $\alpha$  较大时,不能充分利用光谱特征。在实验中,为使光谱信息和空间信息都得到有效利用,对于 Indian Pines 数据集,令  $\alpha=0.8$ ;对于 Washington DC Mall 数据集,令  $\alpha=0.3$ 。

### 3.3 Indian Pines 数据集上的实验

实验中,为分析各算法在不同训练样本下的分类性能,从每类地物中随机选取  $n_i$  个数据作为训练样本,其余为测试样本。表 1 为各算法在不同条件下进行 10 次随机实验的平均总体分类精度(OA)及其标准差(std)以及 Kappa 系数。表中  $n_i$  为每类训练样本数目。

由表 1 可知,随样本数增加,各算法的总体分类精度和 Kappa 系数都明显增大,因为训练样本越多,包含的类别信息越丰富,越有利于特征提取。与仅利用光谱信息的算法如 RAW、PCA、NPE 等相

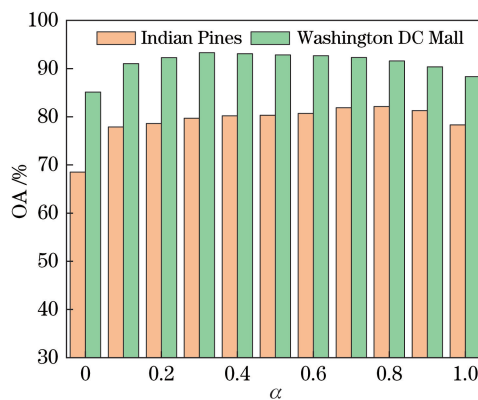


图 6 SSRMDA 算法在不同  $\alpha$  值下的总体分类精度  
Fig. 6 Overall classification accuracy of SSRMDA algorithm with different  $\alpha$  values

比,DSSM、LPNPE 等算法较好地融合了空间信息的算法分类性能,这是因为高光谱图像存在同物异谱和同谱异物现象(如 Corn-Notill 类别中一些样本的光谱曲线自身差异较大,为同物异谱现象,但 Corn-Notill 类别与 Corn 类别中某些样本的光谱曲

线更为接近,为同谱异物现象),单纯的光谱分类未能很好地对地物类别进行区分,而空间信息的融入则克服了这一缺点,增强了地物分类的准确度。在不同的训练样本下,本文提出的 SSRMDA 算法的分类性能均表现最优,尤其是在样本较少的情况下与其他对比算法的分类效果差异明显,在训练样本为 5 时,其分类精度比 MFA 高 8.7 个百分点,这是由于 SSRMDA 不仅利用光谱信息构造类内图和类间图,以充分揭示高光谱图像潜在的低维流形结构,

而且采用超像素方法提取了更为细致的空间信息,并将其作为正则项,有效平衡了光谱信息与空间信息在提取低维鉴别特征过程中的作用,进而提高了分类精度。

为分析各算法对图像中每类地物的分类效果,从 Indian Pines 数据集中随机选取 2% 的数据进行训练,其余用来测试。表 2 为各算法对每类地物的分类精度、总体分类精度 OA、平均分类精度 AA 及 Kappa 系数,图 7 为对应的分类结果图。

表 1 不同算法在 Indian Pines 数据集上的分类精度(±前的数字表示总体分类精度,%; ±后的数字表示总体分类精度的标准差,%;括号内的数字表示 Kappa 系数)

Table 1 Classification accuracy of different algorithms on Indian Pines dataset (number before ± indicates overall classification accuracy, and the unit is %; number after ± indicates standard deviation of overall classification accuracy, and the unit is %; number in bracket indicates Kappa coefficient)

Algorithm	$n_i=5$	$n_i=10$	$n_i=15$	$n_i=20$	$n_i=30$
RAW	51.81±2.37(0.463)	59.48±1.72(0.547)	65.43±1.39(0.613)	68.45±1.03(0.645)	71.72±1.04(0.681)
PCA	51.73±2.39(0.462)	59.30±1.71(0.545)	65.17±1.36(0.610)	68.22±0.98(0.643)	71.42±1.05(0.678)
NPE	50.17±2.32(0.445)	56.65±1.81(0.516)	61.86±1.67(0.574)	64.78±1.35(0.605)	67.02±1.24(0.629)
LPP	52.08±2.09(0.467)	59.47±1.80(0.547)	64.87±1.68(0.607)	67.13±1.35(0.631)	70.10±1.08(0.663)
LDA	54.82±2.38(0.498)	63.71±1.70(0.595)	69.87±1.55(0.662)	72.26±1.06(0.688)	75.12±1.10(0.719)
MFA	62.10±3.79(0.577)	74.82±2.03(0.716)	80.05±1.35(0.775)	82.99±1.20(0.807)	86.51±1.09(0.846)
LGSFA	60.80±4.10(0.563)	72.56±1.94(0.691)	80.38±1.62(0.778)	83.71±0.99(0.815)	88.05±1.20(0.864)
DSSM	54.15±3.30(0.490)	62.63±2.95(0.582)	72.08±1.51(0.686)	74.44±1.23(0.712)	76.91±1.17(0.739)
LPNPE	56.81±3.37(0.522)	70.14±2.27(0.666)	76.89±1.60(0.740)	81.97±1.55(0.796)	88.26±0.94(0.866)
SSRLDE	56.85±3.19(0.523)	71.38±2.80(0.680)	78.97±2.64(0.763)	83.34±1.97(0.812)	89.46±0.99(0.880)
SSRMDA	<b>70.80±2.87(0.672)</b>	<b>82.14±2.65(0.798)</b>	<b>86.22±1.82(0.844)</b>	<b>89.21±1.51(0.876)</b>	<b>91.58±1.34(0.904)</b>

表 2 各算法对 Indian Pines 数据集上每类地物的分类精度

Table 2 Classification accuracy of each-class grand object on Indian Pines dataset obtained by different algorithms %

Class	RAW	PCA	NPE	LPP	LDA	MFA	LGSFA	DSSM	LPNPE	SSRLDE	SSRMDA
Alfalfa	97.22	97.22	97.22	97.22	<b>100</b>	<b>100</b>	<b>100</b>	97.22	<b>100</b>	<b>100</b>	<b>100</b>
Corn-Notill	61.33	61.11	55.82	60.25	69.26	83.56	82.63	59.11	76.55	79.63	<b>86.92</b>
Corn-mintill	58.55	58.55	52.89	54.73	67.52	75.89	76.99	56.58	76.26	77.61	<b>89.54</b>
Corn	53.30	53.74	43.61	48.01	67.84	92.07	<b>93.83</b>	44.05	85.90	90.31	88.99
Grass-pasture	71.46	71.24	63.63	67.44	83.51	89.21	89.43	73.57	89.21	89.85	<b>91.12</b>
Grass-trees	90.49	90.35	85.17	82.51	97.90	99.44	<b>99.58</b>	93.98	82.93	79.86	<b>99.58</b>
Grassp-asture-mowed	<b>100</b>	<b>100</b>	<b>100</b>	<b>100</b>	<b>100</b>	<b>100</b>	<b>100</b>	<b>100</b>	<b>100</b>	<b>100</b>	<b>100</b>
Hay-windrowed	87.82	87.82	77.35	81.19	71.58	97.43	97.65	88.03	92.52	<b>98.50</b>	97.43
Oats	<b>100</b>	<b>100</b>	<b>100</b>	<b>100</b>	<b>100</b>	<b>100</b>	<b>100</b>	<b>100</b>	<b>100</b>	<b>100</b>	<b>100</b>
Soybean-nottill	77.54	76.81	69.04	70.62	75.34	<b>89.08</b>	85.41	80.06	84.89	86.46	86.25
Soybean-mintill	74.93	74.73	68.70	70.15	73.73	83.41	85.82	72.19	81.21	83.41	<b>92.02</b>
Soybean-clean	47.33	46.64	43.71	46.12	46.47	86.23	78.31	43.37	71.77	83.821	<b>90.88</b>
Wheat	96.92	96.92	96.92	97.94	97.94	<b>98.97</b>	<b>98.97</b>	96.92	98.46	<b>98.97</b>	<b>98.97</b>
Woods	76.53	76.21	73.95	75.56	78.30	82.90	84.27	76.53	84.19	<b>85.80</b>	85.08
Buildings-Grass-Trees-Drives	71.01	71.27	68.88	69.15	76.59	85.63	84.84	72.87	<b>91.49</b>	88.03	86.97
Stone-Steel-Towers	<b>100</b>	<b>100</b>	97.59	<b>100</b>	<b>100</b>	<b>100</b>	<b>100</b>	98.79	<b>100</b>	<b>100</b>	<b>100</b>
OA	72.24	72.01	66.61	68.54	74.66	86.37	86.31	71.33	82.46	84.66	<b>90.37</b>
AA	79.03	78.91	74.65	76.31	81.62	91.49	91.11	78.33	88.46	90.14	<b>93.36</b>
Kappa	0.684	0.682	0.620	0.642	0.712	0.845	0.844	0.674	0.800	0.826	<b>0.890</b>



从表 2 可以看出, SSRMDA 算法对大多数地物都取得了较好的分类精度, 且拥有较高的总体分类精度、平均分类精度及 Kappa 系数, 这是因为 SSRMDA 算法能更好地挖掘高光谱图像中的鉴别信息。在基于光谱特征的维数约减方法中, 监督算法(LDA、MFA、LGSFA)取得了比非监督算法(RAW、PCA、NPE、LPP)更好的分类结果, 这是由于 LDA、MFA、LGSFA 利用了样本的先验标签信息, 能够获得更为有效的鉴别特征, 进而提升了分类性能。同时, 空谱算法(LPNPE、SSRLDE、SSRMDA)在大多数类别分类中取得了比光谱算法更好的分类结果, 这是因为高光谱影像具有空

间一致性, 图像的块状效应比较明显, 相邻像素点具有较为明显的区域一致性, 这一特性可以用来帮助构建更为有效的维度约减模型。空谱算法同时考虑了高光谱影像的空间结构信息和光谱信息, 因此能够取得更高的分类精度。然而, 在一定大小的空间窗口(例如  $5 \times 5$ )内, 往往会掺杂其他类别的样本点, 这些样本点会影响所构建的空谱降维模型的准确性, 从而使得极个别类别的分类精度出现降低的情况。如图 7 所示, 本文算法与其他算法相比, 产生的分类图更光滑, 噪点更少, 各类边界更明显, 相对完好的块区域更多, 与真实图更接近。

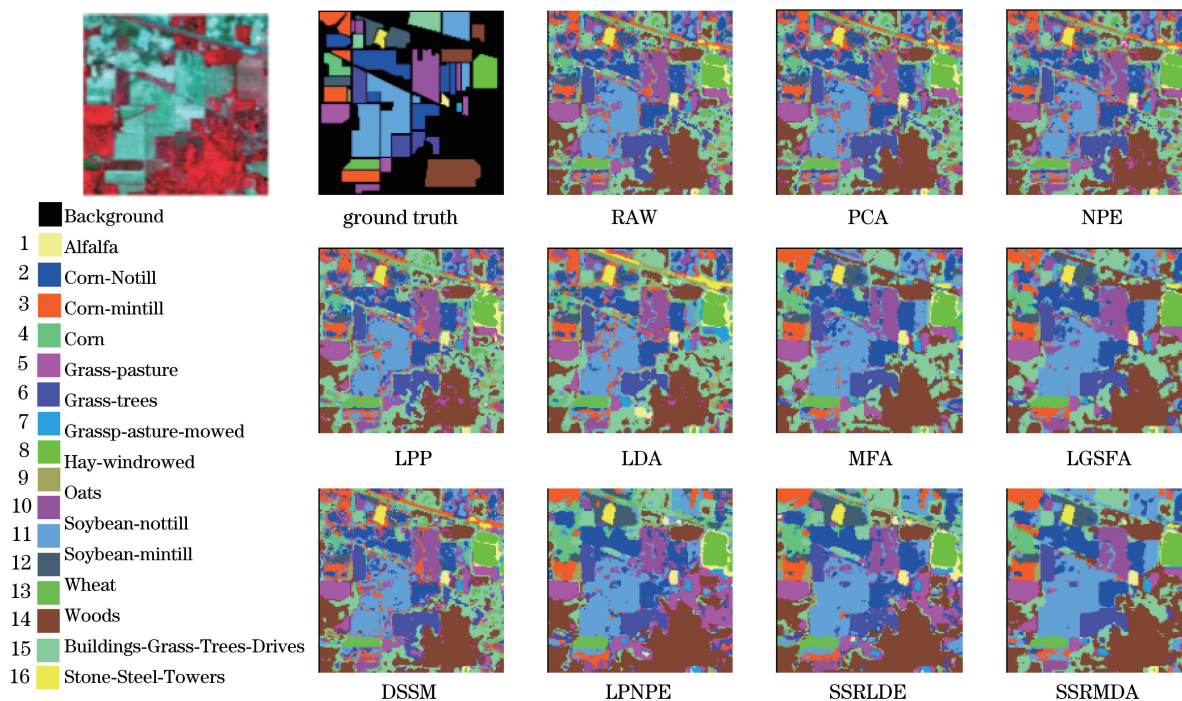


图 7 各算法在 Indian Pines 数据集上的分类图

Fig. 7 Classification diagrams of different algorithms on Indian Pines dataset

### 3.4 Washington DC Mall 数据集上的实验

为验证本文算法的有效性, 实验时从数据集每类地物中随机选取  $n_i$  个数据作为训练集, 剩余的作为测试集。表 3 为在不同情况下各算法进行 10 次随机实验的 Kappa 系数、平均总体分类精度及其标准差。

分析表 3 可知, 各算法的总体分类精度和 Kappa 系数随样本的增多均呈上升的趋势, 这是因为随着样本增多, 高光谱图像中可利用的鉴别信息越充足。DSSM、LPNPE 等加入了空域特征的算法, 在大多数训练条件下都优于 RAW、PCA、NPE 等光谱域算法。相较于 DSSM、LPNPE、SSRLDE 等空-谱算法, SSRMDA 算法在各种训练条件下的分类精度均有明显的提高, 因其通过构造空域类内

图来进行正则化处理, 在充分表达空间特征的同时, 增强了类内聚集性。在不同的实验条件下, SSRMDA 算法较其他算法的分类精度均明显较高, 这是由于 SSRMDA 在充分表达光谱域特征的同时加入了空间信息, 空-谱结合更有利于强化类内信息聚集和类间信息分散, 增加数据的可分性, 从而改善地物分类性能。

为对比不同算法下每类地物的分类效果, 实验时从 Washington DC Mall 数据集中随机选取 1% 的数据作为训练样本, 剩余的用作测试样本。表 4 为各算法得到的每类地物的分类精度、总体分类精度 OA、平均分类精度 AA 及 Kappa 系数, 图 8 为各算法相应的分类图。



表 3 不同算法在 Washington DC Mall 数据集上的分类精度(±前的数字表示总体分类精度,%; ±后的数字表示总体分类精度的标准差,%;括号内的数字表示 Kappa 系数)

Table 3 Classification accuracy of different algorithms on Washington DC Mall dataset (number before ± indicates overall classification accuracy, and the unit is %; number after ± indicates standard deviation of overall classification accuracy, and the unit is %; number in bracket indicates Kappa coefficient)

Algorithm	$n_i = 5$	$n_i = 10$	$n_i = 15$	$n_i = 20$	$n_i = 30$
RAW	80.86±2.96(0.761)	82.80±2.23(0.786)	84.07±2.17(0.802)	85.87±1.86(0.824)	86.60±1.22(0.833)
PCA	80.86±2.96(0.761)	82.79±2.23(0.786)	84.06±2.18(0.802)	85.86±1.86(0.824)	86.58±1.23(0.833)
NPE	79.91±3.33(0.750)	81.20±3.06(0.767)	82.91±2.13(0.788)	84.94±1.74(0.812)	85.28±1.67(0.817)
LPP	80.21±3.35(0.753)	82.24±1.91(0.779)	83.47±1.87(0.795)	85.46±1.81(0.819)	86.39±1.72(0.831)
LDA	81.56±3.33(0.770)	83.08±2.23(0.790)	85.52±1.77(0.820)	86.69±1.48(0.834)	87.84±1.27(0.848)
MFA	84.49±2.51(0.806)	87.92±2.25(0.849)	90.98±2.20(0.887)	91.87±0.89(0.898)	92.70±0.59(0.908)
LGSFA	85.48±2.68(0.818)	88.53±2.20(0.857)	91.28±1.15(0.891)	92.47±1.03(0.906)	93.64±0.98(0.920)
DSSM	80.63±3.31(0.759)	82.80±2.19(0.786)	84.08±2.57(0.802)	85.33±2.11(0.817)	86.61±1.22(0.833)
LPNPE	78.71±5.15(0.736)	86.65±2.63(0.834)	87.75±2.36(0.847)	89.14±1.02(0.864)	90.34±1.06(0.879)
SSRLDE	79.45±5.36(0.744)	86.51±4.22(0.832)	87.34±3.30(0.843)	89.62±1.37(0.870)	90.86±1.19(0.886)
SSRMDA	<b>88.73</b> ±2.15(0.859)	<b>92.78</b> ±1.19(0.910)	<b>94.04</b> ±0.98(0.925)	<b>95.35</b> ±0.73(0.942)	<b>96.67</b> ±0.73(0.958)

表 4 各算法得到的 Washington DC Mall 数据集上每类地物的分类精度  
Table 4 Classification accuracy of each-class ground object on Washington DC Mall dataset obtained by different algorithms

Class	RAW	PCA	NPE	LPP	LDA	MFA	LGSFA	DSSM	LPNPE	SSRLDE	SSRMDA
Road	95.04	95.01	94.71	94.38	94.76	97.83	98.71	95.17	93.72	95.06	<b>99.79</b>
Water	94.12	94.12	93.57	94.74	96.33	97.24	98.22	94.13	<b>99.26</b>	96.45	98.39
Building	87.67	87.64	86.56	86.53	88.33	91.40	93.15	87.64	96.93	95.39	<b>98.61</b>
Vegetation	97.34	97.34	97.01	97.27	97.37	97.88	97.88	97.34	97.08	96.40	<b>98.73</b>
Trail	66.83	66.89	64.04	69.39	72.35	89.52	93.20	66.66	91.86	82.38	<b>93.76</b>
Shadow	67.90	67.90	65.03	67.73	68.20	73.78	80.46	67.86	72.85	72.05	<b>82.66</b>
OA	88.09	88.08	87.05	87.91	88.87	92.81	94.64	88.11	92.90	91.64	<b>96.70</b>
AA	84.82	84.82	83.49	85.01	86.22	91.28	93.60	84.80	91.95	89.62	<b>95.49</b>
Kappa	0.850	0.849	0.837	0.848	0.860	0.909	0.933	0.850	0.911	0.895	<b>0.959</b>

由表 4 可知,本文算法对 Washington DC Mall 数据集上所有地物的分类效果皆较好,且各评价指标均最高,说明 SSRMDA 能充分揭示该数据中潜在的低维流形,很好地表达其内在特性。对于只采用光谱信息的降维算法,监督算法利用了样本的先验标签信息,因此在各类别分类中均取得了较高的分类精度;而空谱算法由于融合了高光谱影像的空间结构信息,能够得到更为有效的鉴别特征,因此在大多数类别分类中取得了比光谱算法更好的分类效果。然而,一定大小的空间窗口内往往会包含其他类别的样本点,这些样本点会影响空谱算法维数约减模型的准确性,从而使得极个别类别的分类精度

降低。此外,如图 8 所示,与其他算法相比,SSRMDA 算法得到的分类图更为平滑,地物分类更清晰,更接近实际的地物图。由此可见,本文提出的空间正则化流形鉴别分析算法能更好地提取地物的内在特征,提高分类性能。

#### 4 结 论

鉴于高光谱图像蕴含着丰富的光谱信息和空间信息,而传统特征提取算法大都只研究光谱信息,未能充分获取空间信息的问题,本文提出了一种监督空间正则化流形鉴别分析算法。该算法基于空-谱联合的思想,首先利用光谱信息构造类内图和类间

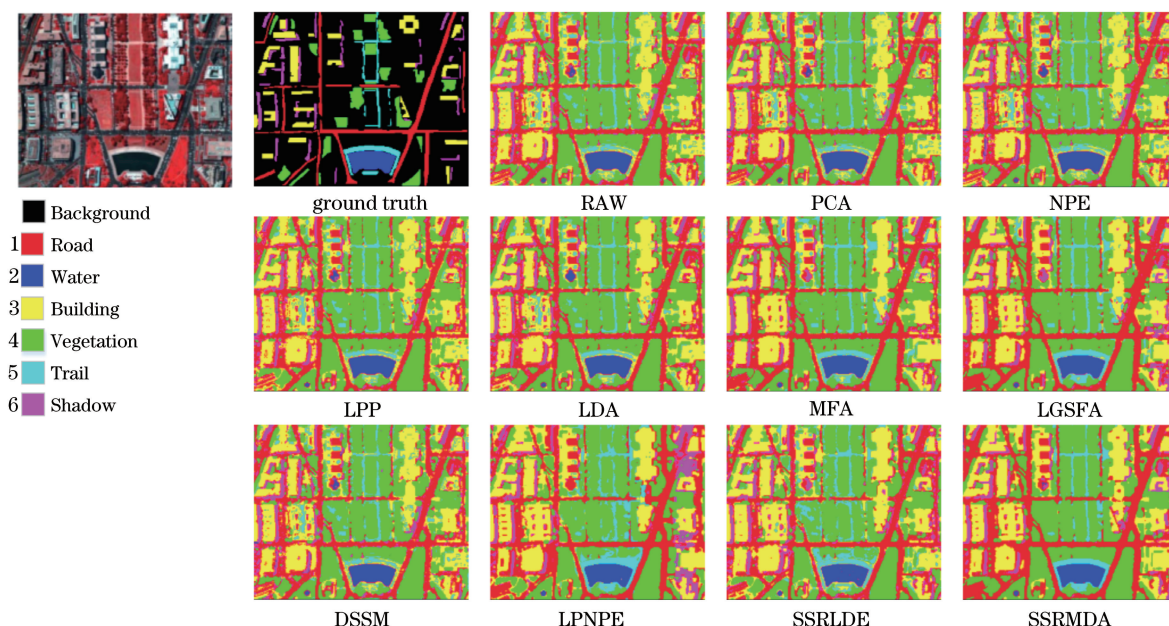


图 8 各算法在 Washington DC Mall 数据集上的分类图

Fig. 8 Classification diagrams of different algorithms on Washington DC Mall dataset

图,以描述复杂的谱域特征,揭示高光谱数据中潜在的低维流形结构;然后利用空间信息构建类内图,并将其以正则化方式融入特征提取目标函数中,以有效解决过拟合学习问题;最后在低维空间中加强了类内数据的聚集度,以有效提高嵌入特征的鉴别能力。在 Indian Pines 和 Washington DC Mall 数据集上的实验结果表明,本文算法的总体分类精度分别可达到 91.58% 和 96.67%,较其他算法都有明显提高,特别是在小样本条件下优势更为明显。因高光谱图像可能存在多流形结构,因此下一步将在空-谱单流形的基础上对空-谱多流形学习算法进行研究,以进一步提高分类精度。

## 参 考 文 献

- [1] Zhang Y, Kang X D, Li S T, et al. Feature extraction from hyperspectral images using learned edge structures[J]. Remote Sensing Letters, 2019, 10(3): 244-253.
- [2] Cheng B Z, Zhao C H, Zhang L L, et al. Joint spatial preprocessing and spectral clustering based collaborative sparsity anomaly detection for hyperspectral images[J]. Acta Optica Sinica, 2017, 37(4): 0428001.  
成宝芝, 赵春晖, 张丽丽, 等. 联合空间预处理与谱聚类的协同稀疏高光谱异常检测[J]. 光学学报, 2017, 37(4): 0428001.
- [3] Li F Y, Huo H T, Bai J, et al. Hyperspectral target detection based on sparse representation and adaptive model[J]. Acta Optica Sinica, 2018, 38(12): 1228004.  
李非燕, 霍宏涛, 白杰, 等. 基于稀疏表示和自适应模型的高光谱目标检测[J]. 光学学报, 2018, 38(12): 1228004.
- [4] Zhang C K, Han M. Spectral-spatial joint classification of hyperspectral image with edge-preserving filtering[J]. Acta Automatica Sinica, 2018, 44(2): 280-288.  
张成坤, 韩敏. 基于边缘保持滤波的高光谱影像光谱-空间联合分类[J]. 自动化学报, 2018, 44(2): 280-288.
- [5] Peng J T, Sun W W, Du Q. Self-paced joint sparse representation for the classification of hyperspectral images[J]. IEEE Transactions on Geoscience and Remote Sensing, 2019, 57(2): 1183-1194.
- [6] Cao J Y, Wang B. Embedding learning on spectral-spatial graph for semisupervised hyperspectral image classification[J]. IEEE Geoscience and Remote Sensing Letters, 2017, 14(10): 1805-1809.
- [7] Hou B H, Yao M L, Wang R, et al. Spatial-spectral semi-supervised local discriminant analysis for hyperspectral image classification[J]. Acta Optica Sinica, 2017, 37(7): 0728002.  
侯榜焕, 姚敏立, 王榕, 等. 面向高光谱图像分类的空谱半监督局部判别分析[J]. 光学学报, 2017, 37(7): 0728002.
- [8] Kang X D, Xiang X L, Li S T, et al. PCA-based edge-preserving features for hyperspectral image classification[J]. IEEE Transactions on Geoscience and Remote Sensing, 2017, 55(12): 7140-7151.
- [9] Bandos T V, Bruzzone L, Camps-Valls G. Classification of hyperspectral images with regularized linear

- discriminant analysis[J]. IEEE Transactions on Geoscience and Remote Sensing, 2009, 47(3): 862-873.
- [10] Roweis S T, Saul L K. Nonlinear dimensionality reduction by locally linear embedding [J]. Science, 2000, 290(5500): 2323-2326.
- [11] Samat A, Gamba P, Liu S C, et al. Jointly informative and manifold structure representative sampling based active learning for remote sensing image classification[J]. IEEE Transactions on Geoscience and Remote Sensing, 2016, 54(11): 6803-6817.
- [12] He X F, Niyogi P. Locality preserving projections [C]//Advances in Neural Information Processing System, December 13-18, 2004, Vancouver, British Columbia, Canada. Canada: NIPS, 2004: 153-160.
- [13] Xu D, Yan S C, Tao D C, et al. Marginal fisher analysis and its variants for human gait recognition and content-based image retrieval[J]. IEEE Transactions on Image Processing, 2007, 16(11): 2811-2821.
- [14] Sugiyama M. Dimensionality reduction of multimodal labeled data by local fisher discriminant analysis[J]. Journal of Machine Learning Research, 2007, 8: 1027-1061.
- [15] Fauvel M, Tarabalka Y, Benediktsson J A, et al. Advances in spectral-spatial classification of hyperspectral images[J]. Proceedings of the IEEE, 2013, 101(3): 652-675.
- [16] Feng Z X, Yang S Y, Wang S G, et al. Discriminative spectral-spatial margin-based semisupervised dimensionality reduction of hyperspectral data [J]. IEEE Geoscience and Remote Sensing Letters, 2015, 12(2): 224-228.
- [17] Zhou Y C, Peng J T, Chen C L P. Dimension reduction using spatial and spectral regularized local discriminant embedding for hyperspectral image classification [J]. IEEE Transactions on Geoscience and Remote Sensing, 2015, 53(2): 1082-1095.
- [18] Hou B H, Yao M L, Jia W M, et al. Spatial-spectral discriminant analysis for hyperspectral image classification [J]. Optics and Precision Engineering, 2018, 26(2): 450-460.  
侯榜焕, 姚敏立, 贾维敏, 等. 面向高光谱图像分类的空谱判别分析[J]. 光学精密工程, 2018, 26(2): 450-460.
- [19] Liu M Y, Tuzel O, Ramalingam S, et al. Entropy rate superpixel segmentation[C]//CVPR 2011, June 20-25, 2011, Colorado Springs, CO, USA. New York: IEEE, 2011: 2097-2104.
- [20] Luo F L, Huang H, Duan Y L, et al. Local geometric structure feature for dimensionality reduction of hyperspectral imagery[J]. Remote Sensing, 2017, 9(8): 790.