

文章编号 1004-924X(2018)02-0450-11

面向高光谱图像分类的空谱判别分析

侯榜焕, 姚敏立*, 贾维敏, 张峰干, 王道平

(火箭军工程大学, 陕西 西安 710025)

摘要:针对传统的基于特征提取的高光谱图像地物分类算法大多只考虑光谱信息而忽略空间信息的问题,提出了一种面向高光谱分类的半监督空谱全局与局部判别分析(S^3GLDA)算法。该算法首先利用少量标记样本保存数据集的线性可分性和全局判别信息,再依靠较多的无标记的空间局部近邻像元来揭示局部判别信息和非线性局部流形,使高光谱遥感图像的光谱域全局判别结构和空间域局部判别结构在低维特征空间同时得以保留,并在输出特征中自动融入了空间信息,构成了半监督的空谱判别分析。在 Indian Pines 和 PaviaU 数据集的实验表明,总体分类精度分别达到 76.24% 和 82.96%。与现有几种算法比较,该算法有效提高了输出特征在低维空间的判别能力,更好地揭示了数据集的内在非线性多模本质,有效提升了高光谱图像数据集的地物分类精度。

关键词:高光谱图像分类;特征提取;判别分析;空谱联合;半监督学习;空间近邻

中图分类号:TP751.1 **文献标识码:**A **doi:**10.3788/OPE.20182602.0450

Spatial-spectral discriminant analysis for hyperspectral image classification

HOU Bang-huan, YAO Min-li*, JIA Wei-min, ZHANG Feng-gan, WANG Dao-ping

(Rocket Force Engineering University, Xi'an 710025, China)

* Corresponding author, E-mail: yaominli@sohu.com

Abstract: The traditional hyperspectral image classification methods consider only spectral information while spatial information is ignored. To address this problem, a semi-supervised spatial-spectral global and local discriminant analysis (S^3GLDA) algorithm for hyperspectral image classification was proposed. The method firstly made use of a few labeled samples to preserve the linear separability and global discriminant information of the data set, then the local discriminant information and nonlinear manifold was uncovered by the unlabeled spatial neighbors. The spectral-domain global discriminant structure and spatial-domain local discriminant structure were exploited simultaneously and the spatial information was incorporated into the output low-dimension features automatically, which constitute the semi-supervised spatial-spectral discriminant analysis. The overall classification accuracies reached 76.24% and 82.96% on the Indian Pines and PaviaU data sets, respectively. Compared with several existing methods, the proposed algorithm can effectively improve the discriminant ability of the output features in the low-dimension subspace, which can uncover the intrinsic nonlinear multi-modal struc-

收稿日期:2017-06-06;修订日期:2017-08-15.

基金项目:国家自然科学基金资助项目(No. 61401471);中国博士后基金资助项目(No. 2014M562636)

ture of the data set and obtain higher ground objects classification accuracy.

Key words: hyperspectral image classification; feature extraction; discriminant analysis; spatial-spectral; semi-supervised learning; spatial neighbors

1 引言

高光谱遥感图像数据集能在广阔的波长范围内对地物进行分类识别,目前已广泛应用于农业监测、城市规划和国防建设等领域^[1-6]。直接进行地物分类时,易出现“维数灾难”^[4-5]。特征提取是解决这个难题的途径之一。通过特征提取,减少无效冗余、发现内在结构、提取判别信息,是提升高光谱图像分类性能的关键。

以主成分分析(Principal Component Analysis, PCA)^[7]和线性判别分析(Linear Discriminant Analysis, LDA)^[8]为代表的经典特征提取算法,均为全局线性方法。PCA以方差最大化准则寻求达到全局最佳逼近的投影方向;LDA能保持数据集的全局判别能力,在线性二分类问题上有较好的效果。高光谱图像数据集本质上是非线性多模的。为此,研究者们将监督的全局线性判别分析(LDA)和无监督的局部流形学习或全局方差信息相结合,产生了半监督判别分析(Semi-supervised Discriminant Analysis, SDA)^[9]、半监督局部费舍尔判别分析(Semi-supervised Local Fisher Discriminant Analysis, SELF)^[10]、半监督局部判别分析(Semi-supervised Local Discriminant Analysis, SELD)^[11]等算法,改善了特征提取效果^[9-12]。但是,这些算法都没有利用数据集的局部判别信息。局部判别信息比全局判别信息更重要^[13-17]。流形学习能发现蕴藏在高维空间的非线性低维嵌入^[13],文献[14]对局部流形邻域应用Fisher判别准则后,得到无监督的局部判别全局集成(Local Discriminant Models and Global Integration, LDMGI)^[14]算法,该算法利用了数据集的局部判别信息,在聚类 and 特征选择中效果较好^[14-17]。

以上算法应用于高光谱特征提取时,均未考虑高光谱图像特有的空间信息在提取低维判别特征中的作用。联合使用空间信息和光谱信息(简

称空谱)能有效提升地物分类精度^[1,18-21]。空谱特征提取算法主要包括在光谱、纹理、数学形态学等多模特征空间进行特征变换^[18],或者利用空间域平滑滤波处理从光谱信息提取的低维特征^[19],但这些方法都没有在特征提取算法的目标函数中考虑高光谱图像的空间信息。文献[20-21]在流形学习目标函数中,考虑了像元之间空间位置距离,或以空间近邻像元块改进相似性度量,改善了特征提取效果;但受限于无监督的本质,无法进一步提升地物分类精度。

针对以上问题,本文提出面向高光谱分类的半监督空谱全局与局部判别分析(Semi-supervised Spatial-Spectral Global and Local Discriminant Analysis, S³GLDA)。S³GLDA首先利用少量样本的标记信息保存高光谱图像数据集的全局判别信息和线性可分性,再依靠较多的无标记的空间近邻像元发现数据集的局部判别信息和非线性流形,并将高光谱图像特有的空间信息融入特征提取目标函数中,使光谱近邻像元和空间近邻像元的判别结构在低维空间保持不变,提取判别特征。在Indian Pines和PaviaU数据集上验证了本文算法的有效性。

2 本文算法

先简单介绍线性判别分析(LDA)和局部判别全局集成(LDMGI)。在此基础上,本文提出无监督的局部像元判别分析(Local Pixel Discriminant Analysis, LPDA)和半监督空谱全局与局部判别分析(S³GLDA)。

2.1 线性判别分析(LDA)

以 $\mathbf{X}_i \in \mathbf{R}^{d \times n_i}$ 表示 n_i 个有标记样本构成的样本集。样本点为 $\mathbf{x}_i \in \mathbf{R}^d$,投影后的数据为 $\mathbf{z}_i \in \mathbf{R}^r$ 。LDA通过构建类内散度矩阵 \mathbf{S}_w 和类间散度矩阵 \mathbf{S}_b ,建立样本集的全局线性判别结构,得到的投影方向能使异类数据距离更远、同类数据距离更近,保存了数据集在低维嵌入空间的线性可

分性^[8]。定义：

$$S_b = \sum_{i=1}^c n_i (\mathbf{u}^i - \boldsymbol{\mu})(\boldsymbol{\mu}^i - \boldsymbol{\mu})^T, \quad (1)$$

$$S_w = \sum_{i=1}^c \sum_{j=1}^{n_i} (\mathbf{x}_j^i - \boldsymbol{\mu}^i)(\mathbf{x}_j^i - \boldsymbol{\mu}^i)^T, \quad (2)$$

其中： n_i 是第 i 类样本个数， \mathbf{x}_j^i 表示第 i 类的第 j 个样本， $\boldsymbol{\mu}^i$ 是第 i 类样本的均值， $\boldsymbol{\mu}$ 是样本集 \mathbf{X}_i 的均值， c 代表类别个数。以 $\mathbf{W} \in \mathbf{R}^{d \times r}$ 代表投影矩阵，则 LDA 的目标函数可表示为^[8]：

$$\mathbf{W}_{opt} = \arg \max_{\mathbf{W}} \frac{\text{Tr}(\mathbf{W}^T \mathbf{S}_b \mathbf{W})}{\text{Tr}(\mathbf{W}^T \mathbf{S}_w \mathbf{W})}. \quad (3)$$

2.2 局部判别全局集成 (LDMGI)

记 n 个无标记样本组成的样本集为 $\mathbf{X} \in \mathbf{R}^{d \times n}$ ，簇标记矩阵为 $\mathbf{Y} \in \mathbf{R}^{n \times r}$ ，归一化簇标记矩阵为 $\mathbf{G} = [\mathbf{g}_1, \dots, \mathbf{g}_n]^T = \mathbf{Y}(\mathbf{Y}^T \mathbf{Y})^{-1/2}$ 且。中心化矩阵是 $\mathbf{H}_n = \mathbf{I}_n - \frac{1}{n} \mathbf{I}_n \mathbf{I}_n^T$ ， \mathbf{I}_n 表示元素全为 1 的列向量， $\tilde{\mathbf{X}} = \mathbf{X} \mathbf{H}_n$ 是 \mathbf{X} 减去均值的结果。最优的归一化簇标记矩阵 \mathbf{G} 的目标函数为^[14]：

$$\arg \min_{\mathbf{G}} \text{Tr}[\mathbf{G}^T \mathbf{G} - \mathbf{G}^T \tilde{\mathbf{X}}^T (\tilde{\mathbf{X}} \tilde{\mathbf{X}}^T + \lambda \mathbf{I})^{-1} \tilde{\mathbf{X}} \mathbf{G}]. \quad (4)$$

局部信息比全局判别信息更重要^[13-17]。记 $\mathbf{X}_i = [\mathbf{x}_i, \mathbf{x}_{i1}, \dots, \mathbf{x}_{ik}]$ ，易知 $\tilde{\mathbf{X}}_i = \mathbf{X}_i \mathbf{H}_{k+1}$ 。样本 \mathbf{x}_i 与 k 个近邻点 $\mathbf{x}_{i1}, \dots, \mathbf{x}_{ik}$ 构成局部流形邻域，其局部判别模型可表示为^[14]：

$$\arg \min_{\mathbf{G}_{(i)}} \text{Tr}[\mathbf{G}_{(i)}^T \mathbf{H}_{k+1} \mathbf{G}_{(i)} - \mathbf{G}_{(i)}^T \tilde{\mathbf{X}}_i^T (\tilde{\mathbf{X}}_i \tilde{\mathbf{X}}_i^T + \lambda \mathbf{I})^{-1} \tilde{\mathbf{X}}_i \mathbf{G}_{(i)}]. \quad (5)$$

定义 $\mathbf{S}_i \in \mathbf{R}^{n \times (k+1)}$ ，当 $p = F_i\{q\}$ 时， $\{\mathbf{S}_i\}_{pq} = 1$ ，否则 $\{\mathbf{S}_i\}_{pq} = 0$ ； $F_i = \{i, i_1, \dots, i_k\}$ 是近邻点的索引的集合。易知 $\mathbf{G}_{(i)} = [\mathbf{g}_i, \mathbf{g}_{i1}, \dots, \mathbf{g}_{ik}]^T$ 且 $\mathbf{G}_{(i)} = \mathbf{S}_i^T \mathbf{G}$ 。对所有样本点处的局部判别模型求和，得 LDMGI 的目标函数^[14]：

$$\arg \min_{\mathbf{G}} \text{Tr}(\mathbf{G}^T \mathbf{L} \mathbf{G}), \quad (6)$$

其中 $\mathbf{L} = \sum_{i=1}^n (\mathbf{S}_i \mathbf{L}_i \mathbf{S}_i^T)$ ，易验证 \mathbf{L} 是拉普拉斯矩阵，且 $\mathbf{L}_i = \mathbf{H}_{k+1} (\tilde{\mathbf{X}}_i^T \tilde{\mathbf{X}}_i + \lambda \mathbf{I})^{-1} \mathbf{H}_{k+1}$ ^[14]。LDMGI 算法的详细推导和求解过程参见文献^[14]。

2.3 局部像元判别分析 (LPDA)

当 LDMGI 应用于高光谱数据集时，无法利用数据集的空间信息。考虑高光谱图像数据集的图谱合一的特性，受 LDMGI 算法启发，下面提出无监督的局部像元判别分析 (LPDA)。

高光谱图像不仅具有非线性多模的特点，各类地物还具有明显的空间聚集分布^[1,18-21]；即空间近邻的像元在很大概率上属于同类地物，且具有较强的光谱相关性、近似性和一致性。为此，若以 $\mathbf{N}(\mathbf{x}_i)$ 代表以像元 \mathbf{x}_i 为中心的大小为 $\omega \times \omega$ 的正方形空间邻域内所有像元，则此集合内的像元的光谱具有较强的相似性，故相互之间也可视为局部近邻流形邻域 $\mathbf{N}(\mathbf{x}_i)$ 。 $\mathbf{N}(\mathbf{x}_i)$ ($1 \leq i \leq n_i$) 内的所有像元构成样本集 \mathbf{X} ，样本数 $n = \omega^2 n_i$ ；记 $\mathbf{N}(\mathbf{x}_i)$ 内的像元为 \mathbf{X}_i 。

与 LDMGI 类似，对空间近邻局部流形邻域组成的样本集 \mathbf{X} 使用公式 (5) 和 (6) 进行无监督判别分析。

假设 $\mathbf{g}_i = \mathbf{W}^T \mathbf{x}_i$ ， $\mathbf{W} \in \mathbf{R}^{d \times r}$ 。 $\mathbf{G}_{(i)} = [\mathbf{g}_i, \mathbf{g}_{i1}, \dots, \mathbf{g}_{ik}]^T$ 即 $\mathbf{G}_{(i)} = \mathbf{S}_i^T \mathbf{G} = \mathbf{S}_i^T \mathbf{X}^T \mathbf{W}$ ^[14-17]。故 LPDA 目标函数为：

$$\arg \min_{\mathbf{W}^T \mathbf{X} \mathbf{X}^T \mathbf{W} = \mathbf{I}} \text{Tr}(\mathbf{W}^T \mathbf{X} \mathbf{L} \mathbf{X}^T \mathbf{W}). \quad (7)$$

记 $\mathbf{S}_r = \mathbf{X} \mathbf{X}^T$ ， $\mathbf{S}_L = \mathbf{X} \mathbf{L} \mathbf{X}^T$ ，则 LPDA 的投影矩阵 \mathbf{W} 由 $\mathbf{S}_L \mathbf{w} = \lambda \mathbf{S}_r \mathbf{w}$ 的前 r 个最小的广义特征值 $\lambda_1 > \lambda_2 > \dots > \lambda_r$ 对应的特征向量 $\mathbf{w}_1, \mathbf{w}_2, \dots, \mathbf{w}_r$ 构成。

LPDA 的样本集 \mathbf{X} ，包括样本集 \mathbf{X}_i 及其空间近邻的无标记像元，故 LPDA 同时利用了光谱信息和空间信息，实质是对空间近邻的局部像元进行判别分析，同时保存了局部判别信息和图像的空间结构信息。由于 LPDA 没有使用 \mathbf{X}_i 的标记信息，故属于无监督算法。

2.4 半监督空谱全局与局部判别分析 (S³GLDA)

LDA 是监督算法，能维持数据集在低维嵌入空间的全局判别能力和线性可分性。但 LDA 无法利用局部判别信息，也破坏了高光谱图像像元间的空间近邻结构。如果能保存更多的非线性流形的局部判别信息和像元间的空间结构信息，就能提取更有判别能力的低维特征，也更符合高光谱图像的地物分布特点。

反之，LPDA 是无监督算法，能保存数据集局部空间近邻像元构成的流形邻域内的局部判别信息和图像的空间信息。但 LPDA 无法保存光谱域全局判别结构和同类像元的全局相似性结构（即全局性的光谱近邻关系）。假如融入全局判别信息，就能更好地增强同类数据的聚集性，保存较

多的判别信息,改善分类精度。

为此,本文综合了 LDA 和 LPDA 的优势,提出面向高光谱分类的半监督空谱全局与局部判别分析(S^3GLDA)。其目标函数为:

$$\mathbf{W}_{opt} = \arg \max_{\mathbf{W}} \frac{\text{Tr}(\mathbf{W}^T(\mathbf{S}_b + \alpha\mathbf{S}_T)\mathbf{W})}{\text{Tr}(\mathbf{W}^T(\mathbf{S}_w + \alpha\mathbf{S}_L)\mathbf{W})}. \quad (8)$$

S^3GLDA 能充分利用少数标记样本和较多的未标记样本,将高光谱图像的光谱信息和空间信息自动融合,使光谱域全局判别信息、空间域局部判别信息和数据集的非线性局部几何结构在输出的低维嵌入特征中得以保存;其选取的未标记样本是标记样本的空间近邻,有明确的物理解释,更符合高光谱图像数据集的本质属性。总之, S^3GLDA 能更有效地提取判别信息,更好地表达数据集的本质特征,从而有利于提升分类精度。

求解 $(\mathbf{S}_b + \alpha\mathbf{S}_T)\mathbf{w} = \lambda(\mathbf{S}_w + \alpha\mathbf{S}_L)\mathbf{w}$ 的前 r 个最大的广义特征值 $\lambda_1 > \lambda_2 > \dots > \lambda_r$ 对应的特征向量 $\mathbf{w}_1, \mathbf{w}_2, \dots, \mathbf{w}_r$, 得到 S^3GLDA 的投影矩阵 \mathbf{W} 。

2.5 S^3GLDA 求解步骤

S^3GLDA 算法求解的具体步骤为:

输入:用于训练投影矩阵的标记样本集 \mathbf{X}_l , \mathbf{X}_l 和它的无标记的空间近邻像元构成的样本集 \mathbf{X} , 类别数 c , 嵌入维数 r , 空间邻域大小 ω , 正则参数 α 。

步骤 1: 利用公式(1)和(2)求散度矩阵 \mathbf{S}_w 和 \mathbf{S}_b ;

步骤 2: 求散度矩阵 \mathbf{S}_T 和 \mathbf{S}_L ;

步骤 3: 求解 $(\mathbf{S}_b + \alpha\mathbf{S}_T)\mathbf{w} = \lambda(\mathbf{S}_w + \alpha\mathbf{S}_L)\mathbf{w}$, 得到该广义特征值问题对应的前 r 个最大的特征值对应的特征向量 $\mathbf{w}_1, \mathbf{w}_2, \dots, \mathbf{w}_r$, 得到最优投影矩阵 \mathbf{W} 。

输出: 低维数据 $\mathbf{z}_i = \mathbf{W}^T \mathbf{x}_i$ 。


3 实验结果与分析

3.1 实验数据集

为评估本文 S^3GLDA 对高光谱图像的分类性能,使用具有代表性的 Indian Pines 和 PaviaU 高光谱遥感数据集进行分类实验。

(1) Indian Pines 数据集: 该数据集图像是由 AVIRIS 传感器拍摄的美国西部的农业植被区

域。图像空间分辨率为 20 m, 大小为 145 pixel \times 145 pixel; 去除噪声影响严重的波段后, 在 400 nm 到 2 500 nm 光谱范围内剩余 200 个波段。参考数据样本共 10 249 个, 含 16 类地物。其假彩色图像和真实地物见图 1;




(a) 假彩色图 (b) 真实地物图

(a) False-color image (b) Ground-truth map

图 1 Indian Pines 高光谱图像

Fig. 1 Indian Pines hyperspectral image

(2) PaviaU 数据集: 该数据集图像是由 RO-SIS 传感器在意大利北部 Pavia 大学区域获取的航空遥感图像。图像大小为 610 pixel \times 340 pixel, 空间分辨率为 1.3 m; 去除噪声影响严重的波段后, 在 430 nm 到 860 nm 光谱范围内剩余 103 个波段。该图像参考数据样本共计 42 776 个, 含有 9 类地物信息。其假彩色图像和真实地物信息如图 2 所示。



(a) 假彩色图 (b) 真实地物图

(a) False-color image (b) Ground-truth map

图 2 PaviaU 高光谱图像

Fig. 2 PaviaU hyperspectral image

3.2 实验设置

实验中, 与 Baseline、LDA、SDA、SELF、SELDlpp 和 SELDnpe^[11] 等进行对比。其中 Baseline 是对未降维数据直接分类的结果, SDA、SELF、SELDlpp 和 SELDnpe 均是半监督算法。

在学习投影矩阵时, 训练集包括标记样本集 $\mathbf{X}_l \in \mathbf{R}^{d \times n_l}$ 和无标记样本集 $\mathbf{X}_u \in \mathbf{R}^{d \times n_u}$; 从每类地物随机选取的 300 个样本点构成 \mathbf{X}_u (对不足 300

个样本的类别,选取除 \mathbf{X}_i 之外的全部样本),样本总数为 n_0 。LDA 只使用 \mathbf{X}_i 进行学习;SDA、SELF、SELDlpp 与 SELDnpe 使用整个训练集;S³GLDA 显式利用 \mathbf{X}_i ,且隐式使用 \mathbf{X}_i 中每个样本的无标记的空间近邻像元。

实验中,SDA、SELDlpp 和 SELDnpe 的近邻数 k 设置为 5,SDA 的参数 α 和 SELF 的参数 β 分别在 $\{0.1, 0.5, 2.5, 12.5, 62.5\}$ 和 $\{0, 0.1, 0.2, \dots, 0.9, 1.0\}$ 中选取,使分类精度最优。S³GLDA 的空间邻域设置为 3,参数 α 在 $\{10^{-6}, 10^{-5}, \dots, 10^{-1}, 10^0, 10^1\}$ 内选择。LDA、SDA 嵌入维数上界为 $c-1$,其余均为 30。

在分类阶段,所有算法以 \mathbf{X}_i 作为训练样本,对剩余全部样本进行测试分类。应用最近邻分类器(Nearest Neighbor, NN),并以总体精度(Overall Accuracy, OA)、平均精度(Average Accuracy, AA)和 Kappa 系数为评价指标。实验重复进行 10 次,每次随机选取训练样本,将 10 次实验结果求均值。

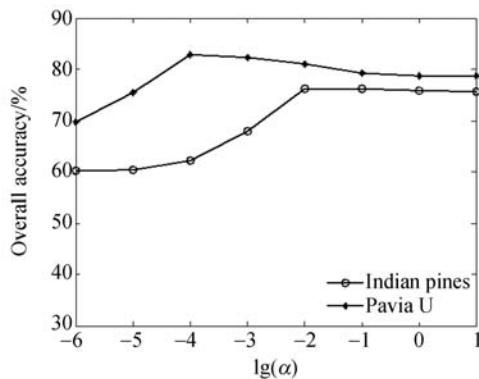


图 3 不同 α 值下的分类精度

Fig. 3 Overall accuracies with different α

3.3 参数影响和各步骤的贡献

为探索参数 α 对 S³GLDA 的影响,分别从 Indian Pines 和 PaviaU 数据集中每类地物选取 30 个标记样本(但不超过该类别样本数的一半)进行实验。参数取值范围为 $\{10^{-6}, 10^{-5}, \dots,$

$10^{-1}, 10^0, 10^1\}$,空间邻域 ω 设置为 3。图 3 为不同 α 值下的分类精度。由图 3 可知,随着 α 值增加,分类精度先增加,然后稍有减小。在 Indian Pines 和 PaviaU 上,当分别取 10^{-2} 和 10^{-4} 时,具有较优的分类精度,此时能更好地表征数据集的内在特性。

以每类地物选取 30 个标记样本为例进行实验。表 1 给出了算法各步骤对最终分类精度的贡献。为方便对比,表中也给出了未考虑高光谱数据集空间信息的 SGLDA 和 LDMGI 的分类结果。SGLDA 是 LDA 与 LDMGI 构成的半监督全局与局部判别分析算法,其目标函数与 S³GLDA 在形式上是相同的。实验中,S³GLDA 和 LPDA 的空间邻域设置为 3,即空间局部近邻点数为 8;SGLDA 和 LDMGI 选取 8 个光谱近邻点。

表中比较了特征提取(Baseline 与 LDA)、半监督算法(S³GLDA 与 LDA、LPDA)和空间信息(S³GLDA 与 SGLDA、LPDA 与 LDMGI)等步骤对分类精度的贡献。以 Indian Pines 的结果为例,与 LDA、LPDA 相比,S³GLDA 的分类精度分别提升了约 15.97%、6.94%,说明半监督算法相比监督和无监督算法的优势,体现了同时保留全局判别结构和局部判别结构的作用;考虑高光谱图像数据集的空间域地物分布信息后,无监督的 LPDA 的分类精度比 LDMGI 提高了约 13.19%,半监督的 S³GLDA 比 SGLDA 提高了约 10.92%,说明了空间信息在高光谱地物分类中的有效性;虽然 S³GLDA 与 SGLDA 的目标函数相同,但 S³GLDA 考虑了高光谱数据集图谱合一的数据结构,选取的近邻点均位于样本的空间局部邻域,保留了地物分布的空间信息,故得到了较高的分类精度。总之,S³GLDA 提取的低维特征,从光谱域全局线性可分性、空间域局部像元判别结构和局部邻域非线性流形等方面,改善了特征提取效果,提升了分类精度。在 PaviaU 数据集上也有类似结果,不再赘述。

表 1 算法各步骤对最终分类精度的影响

Tab. 1 Classification accuracies to show different contributions of each processing step to final results (%)

Data sets	Baseline	LDA	LDMGI	LPDA	SGLDA	S ³ GLDA
Indian Pines	57.15	60.27	56.11	69.30	65.32	76.24
PaviaU	69.45	69.61	70.62	78.79	79.66	82.96

表 2 不同标记样本下的最大总体分类精度(平均精度±标准差)

Tab. 2 Classification accuracies varies with different number of labeled samples(mean±std) (%)

Labeled	Baseline	LDA	SDA	SELF	SELDlpp	SELDnpe	S ³ GLDA
5	42.95±3.03	43.42±3.09	44.64±3.25	43.77±2.94	42.33±2.93	42.78±2.64	57.88±2.22
10	49.41±2.22	48.20±2.56	51.95±2.32	51.40±2.02	49.27±2.42	50.20±2.26	66.01±2.83
15	51.45±2.16	51.14±2.02	56.20±1.73	55.22±2.44	52.15±1.46	54.09±1.64	70.75±1.59
20	54.77±1.89	54.95±2.86	60.24±1.53	58.35±1.73	55.58±1.40	57.65±1.53	73.19±1.20
25	56.46±1.24	58.76±1.61	62.19±1.95	59.29±0.59	57.20±0.89	59.92±0.88	74.36±1.20
30	57.15±1.60	60.27±1.44	63.96±1.59	60.89±1.48	58.30±0.96	61.08±1.28	76.24±0.86




图 4 不同算法在不同标记样本、不同维数下的分类精度

Fig. 4 Overall accuracies of different algorithms with different labeled samples in different dimensions

3.4 Indian Pines 实验结果及分析

根据实验设置,图 4 为各算法在 Indian Pines 数据集上不同维数下的分类精度曲线,表 2 为不同标记样本数下的最大总体分类精度。

由图 4 可知,各算法的分类精度随着嵌入维数的增加而不断提高,达到最大值之后保持稳定或者逐步降低。这是因为低维特征包含的判别信息随着维数增加而增多,促使分类精度提高;当达到本征维数时,分类精度取得最优值;此时,更多的维数意味着冗余信息或噪声,不利于提升分类精度。由于嵌入在高维数据中的本征维数是未知的、不可确定的,故各个算法的取得最优分类精度的维数不同。由图可知,保留 30 个低维嵌入特征时,各算法均取得了最大分类精度,满足了分类任务的要求。

在表 2 中,当每类地物分别取 5、10、15、20、25、30 个标记训练样本(但不超过该类别样本数的一半)时,各算法的最大总体分类精度随着标记样本数的增加而增加。这是因为标记样本越多,包含的标记信息越丰富,提取的低维特征的判别能力越强,其分类精度越好。在不同的标记样本

数下,相比其它算法,S³GLDA 的分类精度始终是最高的,比其余算法提高约 12~18%。

这是因为 LDA 在线性二分类问题中应用效果较好,而高光谱数据集本质是非线性多模的;SDA、SELF、SELDlpp 和 SELDnpe 等半监督算法,充分利用了标记样本的全局判别信息,且通过较多的未标记样本来保存数据集的非线性属性,但它们使用的未标记样本均是随机选取的,其潜在分布是未知的,无法利用高光谱图像中不同地物的空间分布规律。反之,S³GLDA 使用的未标记样本是标记样本的空间近邻像元,有明确的空间分布和物理意义,更符合高光谱图像数据集的本质属性,使光谱域全局判别结构、空间域局部判别结构和数据集非线性几何特性在低维空间得以保留,因此能更有效地提取判别特征,得到更高的分类精度。

在不同标记样本下,由于 S³GLDA 的空间邻域设置为 3,故该算法使用的未标记样本是标记样本数的 8 倍,分别为 40、80、120、160、200、240 个;与其它半监督算法相比,S³GLDA 使用的未标记样本数量较少,但达到了更高的分类精度,这说明了 S³GLDA 选取的未标记样本的有效性。

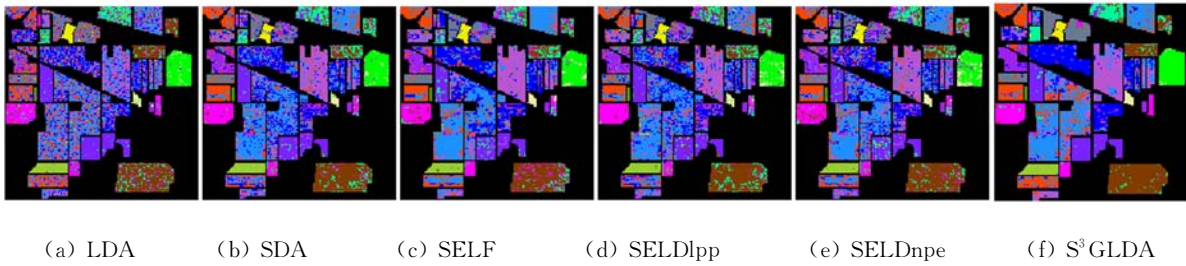


图 5 在 Indian Pines 上各算法的分类识别图

Fig. 5 Classification maps of different algorithms on Indian Pines data set

表 3 Indian Pines 数据集各类地物在不同算法下的分类精度

Tab. 3 Class-specific accuracies in Indian Pines data set by different algorithms (%)

No	Classes	Labeled	Test	LDA	SDA	SELF	SELDlpp	SELDnpe	S ³ GLDA
1	Alfalfa	23	23	86.96	87.39	84.78	81.74	78.70	91.74
2	Corn-notill	30	1398	46.89	50.24	52.83	41.56	46.34	70.08
3	Corn-min	30	800	45.31	56.08	60.25	51.11	55.14	69.96
4	Corn	30	207	63.14	72.17	75.31	63.62	72.37	88.07
5	Grass/Pasture	30	453	83.40	83.95	84.64	84.30	84.11	91.77
6	Grass/Trees	30	700	91.73	87.80	88.60	85.74	86.29	96.63
7	Grass/Pasture-mowed	14	14	95.00	88.57	91.43	89.29	92.14	95.00
8	Hay-windrowed	30	448	89.24	90.27	85.76	80.58	79.42	96.52
9	Orats	10	10	93.00	94.00	96.00	79.00	94.00	100.00
10	Soybean-notill	30	942	52.96	70.48	75.56	62.24	65.57	80.11
11	Soybean-min	30	2425	36.62	47.42	51.40	41.62	47.61	58.85
12	Soybean-clean	30	563	60.57	55.47	53.21	45.36	46.91	82.43
13	Wheat	30	175	98.34	97.83	96.23	95.49	96.57	99.43
14	Woods	30	1235	78.73	79.48	76.30	79.71	76.56	85.16
15	Bldg-Grass-Trees-Drives	30	356	62.87	55.48	48.88	44.13	45.84	72.25
16	Stone-steel towers	30	63	91.90	92.22	94.44	89.52	94.44	97.78
	总体精度(OA)			58.76	63.96	65.31	58.30	61.08	76.24
	Kappa 系数			53.80	59.52	61.01	53.28	56.32	73.19
	平均精度(AA)			73.54	75.55	75.98	69.69	72.63	85.99

表 3 是选取 30 个标记样本时各类地物的分类精度。S³GLDA 在所有地物类别上都具有较好的分类效果,尤其是在“Corn-notill”、“Corn-min”、“Bldg-Grass-Trees-Drives”和“Soybean-clean”等类别的分类精度较其它算法明显提高约 5~19%。图 5 为对应的分类图,可以看出 S³GLDA 获得了更多光滑区域。

3.5 PaviaU 实验结果及分析

在 PaviaU 数据集上也进行了实验,图 6 为各

算法在不同标记样本不同维数下的分类精度曲线,表 4 为对应的最高总体分类精度。

从图 6 和表 4 可以看出,在不同标记样本数下,其它算法的分类精度低于 S³GLDA 约 4~14%。除 LDA、SELF 与 Baseline 的结果差别较小外,其余算法都优于 Baseline,这是由于大部分特征提取算法可以消除冗余信息,发现固有内在特性,提取出有效的判别特征,从而改善分类性能。

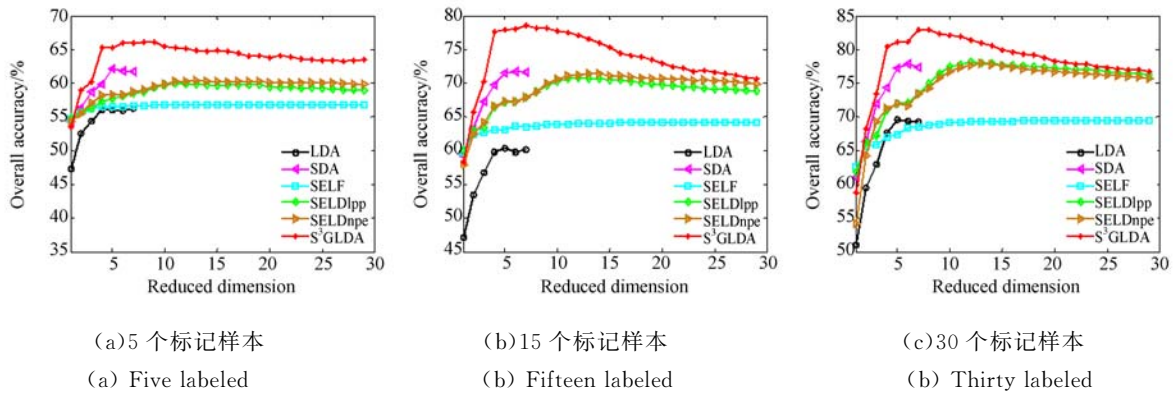



图 6 不同算法在不同标记样本、不同维数下的分类精度

Fig. 6 Overall accuracies of different algorithms with different labeled samples in different dimensions

表 4 不同标记样本下的最大总体分类精度 (平均精度 ± 标准差)

Tab. 4 Classification accuracies varied with different number of labeled samples (mean ± std) (%)

Labeled	Baseline	LDA	SDA	SELF	SELDlpp	SELDnpe	S ³ GLDA
5	56.81 ± 4.52	56.28 ± 4.65	62.35 ± 5.15	57.05 ± 4.50	60.38 ± 4.35	60.20 ± 4.62	66.15 ± 6.83
10	62.07 ± 3.18	52.21 ± 3.32	69.10 ± 3.92	62.41 ± 3.22	67.94 ± 3.02	68.12 ± 2.92	74.49 ± 3.97
15	64.15 ± 3.04	60.28 ± 2.24	72.22 ± 3.60	64.56 ± 3.01	71.04 ± 2.25	71.06 ± 2.57	78.65 ± 1.51
20	66.74 ± 2.58	62.94 ± 2.00	74.88 ± 2.04	67.24 ± 2.51	74.16 ± 1.57	74.30 ± 1.06	80.88 ± 1.32
25	67.20 ± 1.22	68.41 ± 2.01	75.91 ± 1.97	67.78 ± 1.16	75.05 ± 1.40	75.39 ± 1.37	82.30 ± 1.23
30	69.45 ± 1.35	69.61 ± 1.09	77.94 ± 1.85	70.09 ± 1.25	78.48 ± 0.95	78.27 ± 0.77	82.96 ± 1.43



(a) LDA (b) SDA (c) SELF (d) SELDlpp (e) SELDnpe (f) S³GLDA

图 7 在 PaviaU 上各算法的分类识别图

Fig. 7 Classification maps of different algorithms in PaviaU data set

其中, LDA 使数据集的类内散度最小化, 即同类的光谱近邻像素在投影后靠近其均值向量, 保存了高光谱图像的光谱近邻结构和同类地物的光谱相似性关系; SDA、SELF、SELDlpp 和 SELDnpe 等算法, 在 LDA 的基础上还保存了流形结构或方差信息; 但它们都没有考虑高光谱图像的空间聚集属性, 不能较好地表征数据的内在结构, 导致分类精度不能被改善。在不同标记样

本下 S³GLDA 均具有最好的精度, 由于该算法既能利用标记样本增强同类数据的聚集性和异类数据的分离性, 还考虑了高光谱图像的空间邻域的局部判别信息, 并在低维嵌入空间保持这种相似关系和判别关系不变, 提取出更有效的判别特征, 进而改善分类精度。

当选取 30 个标记训练样本时, 各类地物的分类精度见表 5。S³GLDA 在“Meadow”等类别的

分类精度较好。同时, S^3GLDA 的分类识别图(图 7)的错分点较少。

3.6 空间邻域大小与无标记样本数的影响

S^3GLDA 的空间邻域 ω 与无标记样本数、局部流形近邻数 k 有直接的对应关系。空间邻域像元集合 $(x_i) (1 \leq i \leq n_i)$ 决定了 S^3GLDA 使用的无标记样本的数量, 邻域 (x_i) 内的样本数也就是空间局部邻域流形的近邻点数 k 。故 S^3GLDA 的无

标记样本有明确物理意义, 其数量受空间邻域大小的限制, 无法任意选取。

以选取 30 个标记训练样本为例进行实验。当 ω 分别选取为 2、3、5、7 时(2 表示选取样本 x_i 和它的上下左右空间近邻共 5 个样本), 算法使用的无标记样本数分别为 120、240、720 和 1 440, 局部流形近邻数 k 分别为 4、8、24、48。

表 5 PaviaU 数据集各类地物在不同算法下的分类精度

Tab. 5 Class-specific accuracies in PaviaU data set by different algorithms (%)

No	Classes	Labeled	Test	LDA	SDA	SELF	SELDlpp	SELDnpe	S^3GLDA
1	Asphalt	30	6601	58.75	72.65	68.24	71.39	67.12	71.54
2	Meadows	30	18 619	72.29	75.31	65.31	77.27	78.85	84.85
3	Gravel	30	2 069	58.84	71.59	62.26	70.79	68.02	73.01
4	Trees	30	3 034	90.66	90.35	88.29	89.31	90.03	90.86
5	Metal Sheets	30	1 315	99.48	99.57	99.14	99.61	99.57	99.65
6	Bare Soil	30	4 099	65.03	78.80	65.26	78.09	80.06	87.94
7	Bitumen	30	1 300	58.53	89.38	87.82	93.42	91.33	88.98
8	Bricks	30	3 652	56.52	75.67	69.45	75.00	71.41	73.79
9	Shadows	30	917	97.80	99.96	99.95	99.97	99.86	99.86
	总体精度(OA)			69.61	77.94	70.09	78.48	78.27	82.96
	Kappa 系数			61.42	71.86	62.30	72.43	72.15	77.97
	平均精度(AA)			73.10	83.70	78.41	83.87	82.91	85.61

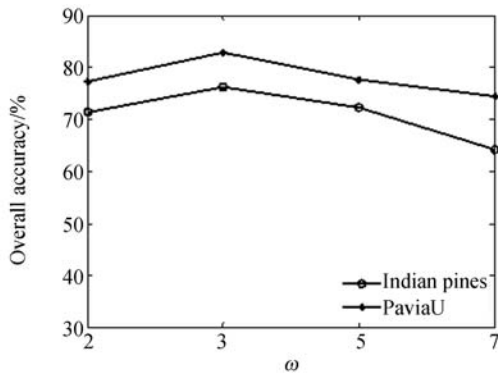


图 8 不同值下的分类精度
Fig. 8 Overall accuracies with different ω

图 8 是不同 ω 时的平均最大分类精度。由图可知, 随着 ω 变大, S^3GLDA 的分类精度先增大再逐步减小; 当 ω 为 3 时, 算法在两个数据集上都达到最大分类精度。这是因为, 此时算法在保存局部判别信息、非线性流形和空间信息等方面均达到较好的效果, 提取的低维特征最能反映数据集的内在本质特征, 故分类精度较高。此时对应

的无标记样本总数为 240, 空间局部流形邻域的近邻数为 8。

3.7 时间复杂度分析

S^3GLDA 算法各步骤的复杂度分别为: (1) 求解矩阵 S_w 和 S_b 的复杂度为 $O(n_i + c) d^2$; (2) 求解拉普拉斯矩阵 L 的复杂度为 $O(n^3 k + n^2 k^2 + n(d^2 k + k^3))$; (3) 求解 S_L 和 S_T 的复杂度分别为 $O(n^2 d + nd^2)$ 和 $O(nd^2)$; (4) 求解广义特征值分解的复杂度为 $O(d^3)$ 。由于 n_i 、 d 、 k 均远小于样本总数 n , 故本文方法的总体时间复杂度可表示为 $O(n^3 + n^2 d + nd^2 + d^3)$, 主要取受样本总数 n 和波段数 d 影响, 且求解拉普拉斯矩阵的复杂度对运行时间的影响较大。

表 6 各算法的运行时间

Tab. 6 Time cost of different algorithms (s)

Data sets	LDA	SDA	SELF	SELDlpp	SELDnpe	S^3GLDA
PaviaU	0.01	0.44	1.94	0.37	0.76	0.46
Indian Pines	0.01	0.77	4.88	0.61	1.21	0.58

为对比各算法的运行时间,选取30个标记样本进行实验。硬件平台为 Intel(R) Core(TM) I7-2600 3.40 GHz CPU 和 16 GB RAM,软件版本为 Matlab8.3。

表6是各算法的运行时间。由于 Indian Pines 数据集的波段数是 PaivaU 的近2倍,且地物类别较多,每次选取的样本总数也较多,故 Indian Pines 数据集上各算法耗时比 PaviaU 数据集多。本文 S³GLDA 的运行时间大于 LDA,小于 SELF 和 SELDnpe,与 SDA 和 SELDlpp 的时间消耗处于同一水平。表中 SELF 的运行时间明显较长,这主要是因为程序设计的原因。由于 S³GLDA 的分类精度明显高于其它算法,体现了本算法的优越性。

4 结 论

在高光谱图像数据集的地物分类研究中,本

文提出一种面向高光谱分类的半监督空谱全局与局部判别分析算法。该算法能充分利用少量的标记样本和较多的无标记的空间近邻样本,不仅保存了数据集的全局线性判别结构,而且发掘了空间域近邻像元的局部判别信息和非线性的低维嵌入流形,将空间信息融入特征提取的目标函数,使全局与局部判别结构和高光谱地物的空间分布细节结构在输出的低维嵌入特征中得以保留,从本质提升了输出特征的判别能力,更好地揭示了数据集的内在的非线性多模本质,达到了较高的地物分类精度。在 Indian Pines 和 PaviaU 数据集的总体分类精度分别达到 76.24% 和 82.96%,相比现有几种算法有了较为明显的提高。下一步,可以根据高光谱图像的物理特性对最近邻分类器进行改进,结合空谱特征提取算法,达到更高的分类精度。

参考文献:

- [1] FAUVEL M, TARABALKA Y, BENEDIKTSSON A, *et al.*. Advances in spectral-spatial classification of hyperspectral images [J]. *Proceedings of the IEEE*, 2013, 101(3): 652-675.
- [2] 黄鸿, 郑新磊. 加权空-谱与最近邻分类器相结合的高光谱图像分类[J]. *光学精密工程*, 2016, 24(4): 873-880.
HUANG H, ZHENG X L. Hyperspectral image classification with combination of weighted spatial-spectral and KNN[J]. *Opt. Precision Eng.*, 2016, 24(4): 873-880. (in Chinese)
- [3] 唐中奇, 付光远, 陈进, 等. 基于多尺度分割的高光谱图像稀疏表示与分类[J]. *光学精密工程*, 2015, 23(9): 2708-2714.
TANG ZH Q, FU G Y, CHEN J, *et al.*. Multi-scale segmentation-based sparse coding for hyperspectral image classification [J]. *Opt. Precision Eng.*, 2015, 23(9): 2708-2714. (in Chinese)
- [4] 何芳, 王榕, 于强, 等. 加权空谱局部保持投影的高光谱图像特征提取[J]. *光学精密工程*, 2017, 25(1): 263-273.
HE F, WANG R, YU Q, *et al.*. Feature extraction of hyperspectral images of weighted spatial and spectral locality preserving projection (WSSLPP) [J]. *Opt. Precision Eng.*, 2017, 25(1): 263-273. (in Chinese)
- [5] 方敏, 王君, 王红艳, 等. 应用监督近邻重构分析的高光谱遥感数据特征提取[J]. *红外与激光工程*, 2016, 45(10): 1028003.
FANG M, WANG J, WANG H Y, *et al.*. Feature extraction of hyperspectral remote sensing data using supervised neighbor reconstruction analysis[J]. *Infrared and Laser Engineering*, 2016, 45(10): 1028003. (in Chinese)
- [6] 邓承志, 张绍全, 汪胜前, 等. L1 稀疏正则化的高光谱混合像元分解算法比较[J]. *红外与激光工程*, 2015, 44(3): 1092-1097.
DENG CH ZH, ZHANG SH Q, WANG SH Q, *et al.*. Hyperspectral unmixing algorithm based on L1 regularization[J]. *Infrared and Laser Engineering*, 2015, 44(3): 1092-1097. (in Chinese)
- [7] EDWARD J J. *A User's Guide to Principal Components*[M]. New York: A Wiley-Interscience Publication, 1992.
- [8] DUDA R O, HART P E, STOCK D G. *Pattern Classification* [M]. 2nd ed. New York, NY, USA: Wiley, 2000.
- [9] CAI D, HE X F, HAN J. Semi-supervised discriminant analysis[C]. *Proceedings of the 11th IEEE International Conference on Computer Vision*,

- IEEE, 2007: 1-7.
- [10] SUGIYAMA M, IDE T, NAKAJIMA S, *et al.*. Semi-supervised local fisher discriminant analysis for dimensionality reduction [J]. *Machine Learning*, 2010, 78(1-2): 36-61.
- [11] LIAO W, PIZURICA A, SCHEUNDEP P, *et al.*. Semisupervised local discriminant analysis for feature extraction in hyperspectral images [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2013, 51(1): 184-198.
- [12] LUO R B, LIAO W Z, HUANG X, *et al.*. Feature extraction of hyperspectral images with semisupervised graph learning[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2016, 9(9): 4389-4399.
- [13] ROWEIS S, SAUL L. Nonlinear dimensionality reduction by locally linear embedding [J]. *Science*, 2000, 290(5500): 2323-2326.
- [14] YANG Y, XU D, NIE F P, *et al.*. Image clustering using local discriminant models and global integration[J]. *IEEE Transactions on Image Processing*, 2010, 19(10): 2761-2773.
- [15] YANG Y, SHEN H T, MA ZH G, *et al.*. -norm regularized discriminative feature selection for unsupervised learning[C]. *Proceedings of the 22th International Joint Conference on Artificial Intelligence*, AAAI Press, 2011: 1589-1594.
- [16] DU L, SHEN ZH Y, LI X, *et al.*. Local and Global Discriminative Learning for unsupervised feature selection [C]. *Proceedings of the 13th IEEE International Conference on Data Mining*, IEEE, 2013: 131-140.
- [17] DU X ZH, YAN Y, PAN P B, *et al.*. Multiple graph unsupervised feature selection[J]. *Signal Processing*, 2016, 120:754-760.
- [18] ZHANG L F, ZHANG Q, DU B, *et al.*. Simultaneous spectral-spatial feature selection and extraction for hyperspectral images [J]. *IEEE Transactions on Cybernetics*, 2017, 48(1): 16-28.
- [19] XIA J S, BOMBRUN L, ADALI T, *et al.*. Spectral-spatial classification of hyperspectral data using ICA and edge preserving filtering via an ensemble strategy[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2016, 54(8): 4971-4981.
- [20] PU H, CHEN Z, WANG B, *et al.*. A Novel Spatial-spectral similarity measure for dimensionality reduction and classification of hyperspectral imagery[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2014, 52(11): 7008-7022.
- [21] DALTON L, SAURABH P, MELBA M C, *et al.*. Manifold-learning based feature extraction for classification of hyperspectral data: a review of advances in manifold learning [J]. *IEEE Signal Processing Magazine*, 2014, 31(1): 55-66.

作者简介:



侯榜焕(1985—),男,陕西咸阳人,博士研究生,2006年、2009年于西北工业大学分别获得学士、硕士学位,主要从事通信与信号处理、高光谱图像处理、机器学习等方面的研究。E-mail: chinayouth001@aliyun.com

导师简介:



姚敏立(1966—),男,山西运城人,教授,博士生导师,1989年、1992年于原第二炮兵工程学院分别获得学士、硕士学位,1999年于西安交通大学获得博士学位,主要从事卫星通信等方面的研究。E-mail: yaominli@sohu.com