

doi: 10.3788/gzxb20164503.0330001

基于半监督稀疏多流形嵌入的高光谱影像分类

黄鸿, 杨娅琼, 罗甫林

(重庆大学 光电技术及系统教育部重点实验室, 重庆 400044)

摘 要:提出了一种半监督稀疏多流形嵌入方法,并应用于高光谱影像分类.该方法充分利用少量标记和大量无标记样本,采用稀疏表示方法得到样本的稀疏系数,并选取来自同一流形的点作为近邻点,然后构建相似图来表征多流形结构,得到样本在每个流形上低维鉴别特征,增加来自同一流形的数据点聚集性,进而提升分类性能.本文方法在 PaviaU 和 Salinas 两个高光谱数据集上的总体分类准确度分别达到 84.91% 和 89.74%,相较于其他方法明显提高了地物分类性能.

关键词:高光谱影像分类;维数约简;多流形;稀疏表示;半监督学习

中图分类号:TP751.2

文献标识码:A

文章编号:1004-4213(2016)03-0330001-7

Classification of Hyperspectral Images Based on Semi-supervised Sparse Multi-manifold Embedding

HONG Hong, YANG Ya-qiong, LUO Fu-lin

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

Abstract: In this paper, a semi-supervised learning method called semi-supervised sparse multi-manifold embedding (S^3 MME) was proposed for the classification of hyperspectral image. S^3 MME exploits both labeled and unlabeled samples to adaptively find neighbors of each sample from the same manifold by using an optimization program based on sparse representation, which constructs an appropriate graph to characterize the manifold structure. Then it tries to extract discriminative features on each manifold in low dimensional space such that the data points in the same manifold become closer. The overall classification accuracies of the proposed method can reach 84.91% and 89.74% on PaviaU and Salinas hyperspectral data sets respectively, which significantly improves the classification of land cover compared with the conventional methods.

Key words: Hyperspectral image classification; Dimensionality reduction; Multiple manifolds; Sparse representation; Semi-supervised learning

OCIS Codes: 300.6170; 280.0280; 110.4234; 100.4145; 100.5010

0 引言

高光谱影像包含了丰富的地物光谱信息,已广泛应用于环境监测、精细农业和目标探测等领域^[1-2].但是,由于其具有数据量大、波段数多、信息冗余多等特点,直接进行地物分类时易致使“维数灾难”问题^[3].维数约简方法不仅能保持高维数据的内在特征,而且能降低数据复杂性,因而成为高光谱影像处理中的研究

热点.

在维数约简方法中,流形学习能有效发现隐藏在高维数据中的低维流形结构,可应用于高光谱影像处理中,其代表性的方法有:等距映射(Isometric Feature Mapping, Isomap)^[4]、局部线性嵌入(Local Linear Embedding, LLE)^[5]和拉普拉斯特征映射(Laplacian Eigenmaps, LE)^[6]等.近年来,Yan等提出了一种图嵌入框架理论^[7],将目前大部分的维数约简方法都统一

基金项目:国家自然科学基金(Nos. 41371338, 61101168)、重庆市基础与前沿研究计划(No. cstc2013jcyjA40005)、中央高校基本科研业务费项目(Nos. 106112013CDJZR125501, 1061120131204)和重庆市研究生科研创新项目(No. CYB15052)资助

第一作者:黄鸿(1980—),男,副教授,博士,主要研究方向为高光谱遥感图像处理. Email: hhuang@cqu.edu.cn

收稿日期:2015-09-25; **录用日期:**2015-12-07

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

到该框架下. 在此基础上, 研究者通过融入样本的标记信息, 提出监督流形学习方法用于分类, 包括边界 Fisher 分析 (Marginal Fisher Analysis, MFA)^[8] 和局部 Fisher 判别分析 (Local Fisher Discriminant Analysis, LFDA)^[9] 等. 在图嵌入框架中, 其关键在于相似图的构建, 常用方法有 k 近邻法和 ϵ 半径法, 但 k 和 ϵ 值的设置对算法的性能影响较大, 且选取较为困难.

稀疏表示理论能够揭示样本间的稀疏重构关系, 可解决上述问题, 其代表性方法包括: 稀疏 PCA (Sparse Principal Component Analysis, SPCA)^[10]、稀疏保持投影 (Sparsity Preserving Projections, SPP)^[11]. 但上述稀疏表示方法都是无监督学习方法, 为改善鉴别性能, 研究人员提出了监督稀疏表示方法, 如基于稀疏表示的鉴别学习方法 (Discriminative Learning by Sparse Representation, DLSP)^[12] 和鉴别稀疏邻域保持嵌入 (Discriminant Sparse Neighborhood Preserving Embedding, DSNPE)^[13] 等. 然而, 这些方法都是基于数据点均匀分布于单一流形的假设, 在实际应用中数据可能位于多个不同的流形上. Elhamifar^[14] 等提出的稀疏流形聚类 and 嵌入 (Sparse Manifold Clustering and Embedding, SMCE) 方法用于具有多流形结构的高维数据的维数约简和聚类, 但 SMCE 存在“样本外学习”问题, 且无监督特性限制了其鉴别能力.

另外, 高光谱影像标记信息在实际应用中获取困难, 但无标记样本很容易得到^[15]. 因此, 本文提出了一种半监督稀疏多流形嵌入算法 (Semi-supervised Sparse Multi-manifold Embedding, S³MME), 该方法有效融合稀疏表示和多流形学习方法, 通过稀疏优化方法利用有标记和无标记的数据点选取来自同一流形的近邻点, 并能自发地获得与所选近邻点对应的权值, 提取出每个流形上数据的鉴别特征, 进而有效提升分类性能.

1 相关方法

假设来自不同流形 $\{M_i\}_{i=1}^{N_c}$ 的数据集 $\mathbf{X} = [\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_N]$, $\mathbf{x}_i \in \mathbf{R}^m$, 前 n 个点为有标记的, 其余 $N - n$ 个点为无标记的. $l_i \in \{1, \dots, N_c\}$ 表示 \mathbf{x}_i 的类别标签, $d_i \in \{d_1, \dots, d_{N_c}\}$ 表示第 i 个流形的内在维数. 在基于单一流形假设的维数约简中, 所有嵌入特征的维数一致, 其映射关系为 $(\mathbf{X} \in \mathbf{R}^m) \mapsto (\mathbf{Y} \in \mathbf{R}^d)$, 即

$$\mathbf{Y} = \mathbf{V}^T \mathbf{X}, \mathbf{V} \in \mathbf{R}^{m \times d} \quad (1)$$

式中, $d \ll m$ 而在多流形维数约简中, 不同流形上的投影矩阵不同, 嵌入特征也不一定相同, 表示为

$$\mathbf{y}_i = \mathbf{V}_i^T \mathbf{x}_i, \mathbf{V}_i \in \mathbf{R}^{m \times d_i} \quad (2)$$

式中, \mathbf{V}_i 是第 M_i 个流形上的投影矩阵, $d_i \ll m$. 在维数约简中, 监督学习方法仅用了标记样本点, 而半监督学

习方法可同时利用标记和无标记的样本.

1.1 图嵌入框架

图嵌入 (Graph Embedding, GE) 框架需构建相似图 \mathbf{G} 和惩罚图 \mathbf{G}_p , 其中 $\mathbf{G} = \{\mathbf{X}, \mathbf{W}\}$ 和 $\mathbf{G}_p = \{\mathbf{X}, \mathbf{W}_p\}$ 是无向权值图, \mathbf{W} 和 \mathbf{W}_p 为边权值矩阵. 其目标函数为

$$\min_{\mathbf{y}} \sum_{i \neq j} \|\mathbf{y}_i - \mathbf{y}_j\|^2 \mathbf{W}_{ij} = \min_{\mathbf{y}} \mathbf{y}^T \mathbf{L} \mathbf{y} \quad (3)$$

式中, Δ 是一个常量, \mathbf{C} 是约束矩阵, 可设置为单位矩阵 \mathbf{I} 或是惩罚图 \mathbf{G}_p 的拉普拉斯矩阵 \mathbf{L}_p , \mathbf{L} 是图 \mathbf{G} 的拉普拉斯矩阵. \mathbf{L} 和 \mathbf{L}_p 分别表示为

$$\begin{cases} \mathbf{L} = \mathbf{D} - \mathbf{W}, \mathbf{D}_{ii} = \sum_{i \neq j} \mathbf{W}_{ij} \\ \mathbf{L}_p = \mathbf{D}_p - \mathbf{W}_p, \mathbf{D}_{p,ii} = \sum_{i \neq j} \mathbf{W}_{p,ij} \end{cases} \quad (4)$$

1.2 SMCE 算法

SMCE 的主要思想是找到每个数据点的最小邻域, 在邻域范围内, 数据点来自相同的流形, 且其所在的低维切空间被称作仿射空间. 通过稀疏表示能获得每个数据点的近邻点, 稀疏解中的非零元素表示来自相同流形的数据点, 揭示了数据的多流形结构.

为了选择来自同一流形的点, 将点 \mathbf{x}_i 与在仿射子空间中来自同一流形的点相连. 在邻域 N_i 范围内, 包含了来自与 \mathbf{x}_i 相同流形和不同流形的点. 为了排除其它流形的点, 对所有的点 i , 存在 $\epsilon \geq 0$ 使得式 (5) 的稀疏解的非零元素与来自同一流形的 \mathbf{x}_i 的近邻点相对应.

$$\left\| \sum_{j \in N_i} c_{ij} (\mathbf{x}_i - \mathbf{x}_j) \right\|_2 \leq \epsilon, \sum_{j \in N_i} c_{ij} = 1 \quad (5)$$

式 (5) 可以进一步转化为式 (6) 所示的加权稀疏优化问题, 利用数据点可获得稀疏系数 $\{c_i\}_{i=1}^N$.

$$\min \lambda \|\mathbf{Q}_i \mathbf{c}_i\|_1 + \frac{1}{2} \|\mathbf{X}_i \mathbf{c}_i\|_2^2 \quad (6)$$

式中, λ 是平衡参量, $\mathbf{c}_i = [c_{i1}, c_{i2}, \dots, c_{iN}]$, c_{ij} 为 \mathbf{x}_i 和 \mathbf{x}_j 之间的稀疏系数, \mathbf{X}_i 为

$$\mathbf{X}_i = \begin{bmatrix} \frac{\mathbf{x}_1 - \mathbf{x}_i}{\|\mathbf{x}_1 - \mathbf{x}_i\|_2} & \dots & \frac{\mathbf{x}_n - \mathbf{x}_i}{\|\mathbf{x}_n - \mathbf{x}_i\|_2} \end{bmatrix} \in \mathbf{R}^{m \times (N-1)}, i \neq j$$

\mathbf{Q}_i 为距离惩罚矩阵, 使距离远的数据点对应的稀疏系数尽可能为零, 且

$$\mathbf{Q}_i = \text{diag} \left(\left[\frac{\|\mathbf{x}_j - \mathbf{x}_i\|_2}{\sum_{t \neq i} \|\mathbf{x}_t - \mathbf{x}_i\|_2} \right]_{j \neq i} \right) \in \mathbf{R}^{(N-1) \times (N-1)}$$

为一个正定对角矩阵.

2 半监督稀疏多流形嵌入

针对 SMCE 不能直接处理新样本以及标记样本获取困难问题, 本文提出了一种半监督学习方法—半监督稀疏多流形嵌入算法 (S³MME). 该方法利用了来自标记和无标记样本的有用信息, 在保持数据集稀疏结构的同时增加了不同流形上数据的可分性, 提取各流形上的鉴别特征, 提高分类性能.

为了获得最佳的鉴别特征,在构建相似图时,需要将来自同一流形的点两两相连,并赋予能反映其相似信息的权值,来自同一流形的样本点可通过式(6)来确定;若数据点来自不同的流形则不相连。

根据每个数据点对应的稀疏系数可构建一个稀疏图 $G_s(\mathbf{V}, \mathbf{E}, \mathbf{W}_s)$, $\mathbf{V} = \{x_1, x_2, \dots, x_N\}$ 为顶点集, \mathbf{E} 为边缘集, \mathbf{W}_s 为对称权值矩阵,其中 $\{c_i\}$ 中的非零元素与 x_i 位于相同的流形.若 x_i 和 x_j 有相同的类别标签,或者 x_i 和 x_j 为无标记的但 c_{ij} 为非零元素,则将节点 i 和 j 连接.图 G_s 中,与 x_i 相关的权向量 $\mathbf{W}_{s,i} = [w_{s,i1}, \dots, w_{s,iN}] \in \mathbf{R}^N$ 表示为

$$w_{s,ij} = \begin{cases} \beta \exp\left(-\frac{c_{ij}^2}{2t_c^2}\right) \exp\left(-\frac{d_{ij}^2}{2t_d^2}\right) & \text{若 } c_{ij} \neq 0, x_i \text{ 与 } x_j \text{ 有} \\ & \text{标记且 } l(x_i) = l(x_j) \\ \exp\left(-\frac{c_{ij}^2}{2t_c^2}\right) \exp\left(-\frac{d_{ij}^2}{2t_d^2}\right) & \text{若 } c_{ij} \neq 0, x_i \text{ 或} \\ & x_j \text{ 无标记} \\ 0 & \text{其他} \end{cases} \quad (7)$$

式中, β 是加权参量, $t_d = \frac{1}{t} \sum_{c_{ij} \neq 0, j} d_{ij}$, $t_c = \frac{1}{t} \sum_{c_{ij} \neq 0, j} c_{ij}$, t 是 c_i 中非零元素的数量, d_{ij} 是点 x_i 和 x_j 之间的欧氏距离. $\mathbf{W}_{s,i}$ 中的非零元素与 x_i 在相同流形中的近邻点相对应,且其大小反映了到点 x_i 的距离.若两个数据点具有相同的类别标签,那么它们极有可能在相同的流形,因而它们之间的权值应该相对较大,通过 β 可增强同类标记样本的权重。

通过将来自相同流形的数据点连接,来自不同流形的数据点则不连接,即可构建稀疏图,其权值矩阵表示形式为

$$\mathbf{W}_s = [w_{s,1} \dots w_{s,N}] = \begin{bmatrix} \mathbf{W}_s[1] & 0 & \dots & 0 \\ 0 & \mathbf{W}_s[2] & \dots & 0 \\ \dots & \dots & \ddots & \dots \\ 0 & 0 & 0 & \mathbf{W}_s[N_c] \end{bmatrix} \quad (8)$$

式中, $\mathbf{W}_s[l]$ 是流形 M_l 上的数据点的权值矩阵,包括了有标记和无标记数据的权值。

为使来自相同流形的数据点之间的距离之和最小,在 M_l 流形上最佳目标函数为

$$\arg \min_{\mathbf{V}_l} \sum_{ij} \| \mathbf{V}_l^T x_{l,i} - \mathbf{V}_l^T x_{l,j} \|^2 w_s[l, ij] \quad (9)$$

式中, x_i 和 x_j 是在来自于同一流形 M_l 上的点, \mathbf{V}_l 是在流形 M_l 上得到的投影矩阵。

目标函数式(9)的目的是找到一个最优投影矩阵以增强数据点在流形 M_l 上低维嵌入特征的聚集性.经过化简,可得

$$\begin{aligned} J_s(\mathbf{V}_l) &= \sum_{ij} \| \mathbf{V}_l^T x_i - \mathbf{V}_l^T x_j \|^2 w_s[l, ij] = \\ & 2\text{tr}(\mathbf{V}_l^T \mathbf{X}_l (\mathbf{D}_s[l] - \mathbf{W}_s[l]) \mathbf{X}_l^T \mathbf{V}_l) = \\ & 2\text{tr}(\mathbf{V}_l^T \mathbf{X}_l \mathbf{L}_s[l] \mathbf{X}_l^T \mathbf{V}_l) \end{aligned} \quad (10)$$

式中, $\mathbf{D}_s[l]$ 是一个对角矩阵,且 $\mathbf{D}_s[l, ii] =$

$\sum_j w_s[l, ij]$; $\mathbf{L}_s[l] = \mathbf{D}_s[l] - \mathbf{W}_s[l]$ 是拉普拉斯矩阵。

为了消除尺度因子的影响,增加了对流形 M_l 上嵌入向量的约束,该目标函数可转化为

$$\begin{aligned} \min \text{tr}(\mathbf{V}_l^T \mathbf{X}_l \mathbf{L}_s[l] \mathbf{X}_l^T \mathbf{V}_l) \\ \text{subject to } \mathbf{V}_l^T \mathbf{X}_l \mathbf{D}_s[l] \mathbf{X}_l^T \mathbf{V}_l = \mathbf{I} \end{aligned} \quad (11)$$

为得到式(11)的最优解,根据拉格朗日数乘法对 \mathbf{V}_l 求导等于零为

$$\begin{aligned} \frac{\partial}{\partial \mathbf{V}_l} \text{tr}(\mathbf{V}_l^T \mathbf{X}_l \mathbf{L}_s[l] \mathbf{X}_l^T \mathbf{V}_l - \lambda_i (\mathbf{V}_l^T \mathbf{X}_l \mathbf{D}_s[l] \\ \mathbf{X}_l^T \mathbf{V}_l - \mathbf{I})) = 0 \end{aligned} \quad (12)$$

式中, λ_i 为拉格朗日乘数,于是可得

$$\mathbf{X}_l \mathbf{L}_s[l] \mathbf{X}_l^T \mathbf{v}_{l,i} = \lambda_i \mathbf{X}_l \mathbf{D}_s[l] \mathbf{X}_l^T \mathbf{v}_{l,i} \quad (13)$$

式中, $\mathbf{v}_{l,i}$ 为 $\mathbf{X}_l \mathbf{L}_s[l] \mathbf{X}_l^T$ 和 $\mathbf{X}_l \mathbf{D}_s[l] \mathbf{X}_l^T$ 的广义特征向量。

根据式(13)的特征值 $\lambda_0 \leq \lambda_1 \leq \dots \leq \lambda_{l,d-1}$ 得到投影向量 $\mathbf{v}_{l,0}, \mathbf{v}_{l,1}, \dots, \mathbf{v}_{l,d-1}$. 那么在 M_l 流形上的低维嵌入特征为 $\mathbf{y}_{l,i} = \mathbf{V}_l^T \mathbf{x}_{l,i}$.

3 实验结果及分析

3.1 高光谱影像数据集

1) PaviaU 数据集^[16]是由 Reflective Optics System Imaging Spectrometer(ROSIS)成像光谱仪获得的,覆盖了 Pavia 大学区域.该数据集包含了 103 个波段,大小为 610×340 ,空间分辨率为 1.3 m.该影像包含了小建筑物、材料和树等。

2) Salinas 数据集^[16]是 1998 年由 Airborne Visible-Infrared Imaging Spectrometer (AVIRIS) 在 Salinas Valley 上空获得的.该数据集的空间分辨率为 3.7m,大小为 512×217 ,包含了 162 个通道.该区域覆盖了包括蔬菜、裸土以及葡萄园等 16 类真实地物。

3.2 实验设置

在每个实验中,将高光谱数据集随机划分为训练集和测试集,然后随机将训练集分为标记集和无标记集.本文通过总体分类准确度(Overall Accuracy, OA)和 Kappa 系数来评价不同维数约简方法的有效性。

为了研究加权参量 β 对 S^3 MME 算法性能的影响,在 PaviaU 数据集中每类随机选取 80 个有标记样本和 3000 个无标记样本作为训练样本,其余数据点作为测试样本进行实验.图 1 为 S^3 MME 在 PaviaU 数据集上 10 次实验的平均总体分类准确度(OA)与参量 β 之间的关系图。

由图 1 可知,当参量 β 的值大于 1 且不是特别大时 S^3 MME 算法能取得较好的效果.这是因为一个较大的 β 值对有标记样本有相当重要的影响,即能提高来自相同流形数据之间的聚集性.然而,若 β 值过大,稀疏系数 $\{c_i\}_{i=1}^N$ 的作用将会减弱,导致 S^3 MME 算法就不能充分利用包含大量无标记样本稀疏表示的鉴别能

力. 为了获得较好的实验结果, 本文将 β 的值设置为 40.




图1 分类准确度与参量 β 之间的关系

Fig.1 Classification accuracy with respect to parameter β

实验中将 S^3 MME 算法与主成分分析 (Principal Component Analysis, PCA)、线性判别分析 (Linear Discriminant Analysis, LDA)、邻域保持嵌入 (Locality Preserving Projection, LPP)、LFDA、SPP、DLSP、DSNPE、半监督子流形保持嵌入 (Semi-Supervised Sub-Manifold Preserving Embedding, S^3 MPE) 以及半监督鉴别分析 (Semi-supervised Discriminant Analysis, SDA) 进行对比. 由于高光谱遥感影像数据集存在多流形结构, 且每个流形的固有维数不同, 因而本文提出的 S^3 MME 采用重构误差分类器 (Reconstruction Error-based Classifier, REC)^[17] 进行分类, 其余维数约简方法使用最近邻分类器 (1-Nearest Neighborhood, 1-NN)

进行分类. 将 SPP、DLSP 和 DSNPE 中的 ϵ 值设置为 0.1, 近邻数 k 设置为 7. 嵌入特征维数除 LDA 设置为类别数减 1 外, 其余维数约简方法都设置为 30.

3.3 PaviaU 数据集

在 PaviaU 数据集上为了验证 S^3 MME 的有效性, 每类选取 10、20、40 和 80 个有标记的样本及 3 000 个无标记的样本进行实验, 表 1 为不同维数约简方法的总体分类准确度和 Kappa 系数 (κ). 图 2 为 $l=40$ 和 $u=3 000$ 时不同方法的分类结果图.


由表 1 可知, 所有的方法随着训练样本数的增加, 总体分类准确度不断提高. 对于监督学习方法 LDA, 当标记样本较少时, 由于存在过拟合问题, 致使其分类准确度较低. S^3 MME 方法在各种情况下分类效果都优于其他方法, 并且其在标记样本数较少时仍能得到较好的分类效果. 这是由于 S^3 MME 能够充分利用标记和无标记样本信息, 选取来自相同流形的近邻点, 发现高光谱数据的多流形结构, 能更好地获得数据的鉴别特征.

图 2 为各方法的分类结果图, 由图可知, S^3 MME 方法的分类结果图优于其他算法, 每类地物的错分点相较其他方法较少, 尤其是在“Meadows”、“Trees”和“Bare Soil”这三类中效果最好, 错分点最少. 本文提出的 S^3 MME 方法的总体分类准确度比 Original、PCA、LDA、LPP、SPP、DLSP、DSNPE、 S^3 MPE、SDA 都高, 分别比它们提高了 10.8%、10.84%、9.64%、7.27%、

表 1 在 PaviaU 数据集不同方法的总体分类准确度 (%) 和 Kappa 系数

Table 1 Overall classification accuracies (%) and Kappa coefficient obtained for different methods in PaviaU

	$l=10$	$l=20$	$l=40$	$l=80$
Original	63.64±4.35(0.5496)	67.32±3.04(0.5924)	71.81±1.34(0.6439)	74.75±0.96(0.6780)
PCA	62.79±3.98(0.5428)	67.06±2.25(0.5907)	71.42±1.11(0.6395)	74.74±0.99(0.6780)
LDA	30.18±4.39(0.1737)	58.85±1.72(0.4885)	70.67±2.04(0.6284)	77.51±1.46(0.7101)
LPP	63.95±3.97(0.5569)	69.04±2.62(0.6129)	74.03±2.43(0.6429)	77.49±1.71(0.7121)
SPP	64.45±2.66(0.5607)	68.16±2.51(0.6018)	71.89±2.23(0.6443)	75.01±1.50(0.6802)
DLSP	60.08±4.71(0.5433)	66.59±3.01(0.5840)	69.58±2.66(0.6177)	72.35±2.02(0.6496)
DSNPE	63.62±4.36(0.5494)	67.31±3.05(0.5923)	71.73±1.37(0.6428)	75.40±1.12(0.6861)
S^3 MPE	63.68±4.45(0.5502)	67.08±3.21(0.5897)	71.73±1.33(0.6434)	75.40±1.12(0.6861)
SDA	65.69±4.07(0.5748)	70.18±2.62(0.6269)	75.94±1.07(0.6942)	80.54±1.77(0.7491)
S^3 MME	72.24±3.78(0.6523)	81.60±1.91(0.7619)	84.39±1.98(0.7968)	86.73±1.21(0.8267)



(a) False-color composition (b) Ground truth (c) Original(OA=74.11%) (d) PCA(OA=74.07%) (e) LDA(OA=75.27%) (f) LPP(OA=77.64%)




图2 不同方法在 PaviaU 数据集上的分类结果图($l=40, u=3000$)

Fig. 2 The classification results with different methods in PaviaU ($l=40, u=3000$)

9.02%、12.47%、10.81%、10.38%以及 6.29%。

为了研究无标记样本数对 S^3 MME 分类的影响,实验中每类随机选取 10 个标记训练样本与不同数量的无标记样本进行实验.图 3 为各种算法进行 10 次实验后的平均分类准确度。

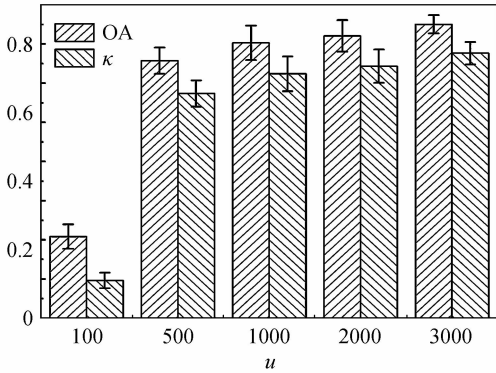


图3 S^3 MME 在 PaviaU 中不同无标记样本下的分类结果
Fig.3 The classification results of S^3 MME with different numbers of unlabeled samples in PaviaU

由图 3 的实验结果可知,随着无标记样本数的增

加, S^3 MME 方法的总体分类准确度和 Kappa 系数随着无标记样本数的增加而增大,说明其通过利用无标记样本中的有用信息可有效提升分类性能。

3.4 Salinas 数据集

在实验中,表 2 为不同方法在 Salinas 数据集上每类选取不同标记样本数的情况下获得的总体分类准确度和 Kappa 系数,图 4 为各种维数约简方法的分类结果图.由图 4 可知,本文提出的 S^3 MME 方法的总体分类准确度比 Original、PCA、LDA、LPP、SPP、DLSP、DSNPE、 S^3 MPE、SDA 提高 5.51%、5.53%、1.73%、4.59%、4.32%、5.53%、6.05%、5.47%以及 3.57%。

此外,每类选取 10 个标记和不同数量的无标记样本作为训练样本,将其余样本作为测试样本进行实验,图 5 为 S^3 MME 进行 10 次随机实验的平均准确度.由图 5 可知, S^3 MME 方法随着无标记样本数的增加,其分类效果得到了提高.这是由于 S^3 MME 能从标记和无标记样本中获得鉴别信息,增加属于同一类样本数据的聚集性,进而提升分类性能。

表 2 在 Salinas 数据集不同方法的总体分类准确度(%)和 Kappa 系数

Table 2 Overall classification accuracies (%) and Kappa coefficient obtained for different methods in Salinas

	$l=10$	$l=20$	$l=40$	$l=80$
Original	80.10±1.04(0.7792)	81.78±1.07(0.7982)	83.77±0.65(0.8199)	84.72±0.49(0.8304)
PCA	80.09±1.04(0.7792)	81.79±1.06(0.7983)	83.32±0.79(0.8149)	84.71±0.50(0.8302)
LDA	64.79±1.92(0.6115)	83.58±1.30(0.8177)	87.67±0.48(0.8629)	88.92±0.71(0.8767)
LPP	81.47±0.86(0.7944)	82.90±1.30(0.8106)	84.50±0.50(0.8279)	85.35±0.49(0.8372)
SPP	82.65±1.27(0.8075)	83.29±1.23(0.8148)	84.41±0.98(0.8273)	85.53±0.53(0.8392)
DLSP	79.10±0.84(0.7682)	81.77±1.06(0.7981)	83.76±0.64(0.7662)	84.72±0.50(0.8303)
DSNPE	79.86±1.06(0.7767)	81.33±1.18(0.7933)	83.34±0.51(0.8152)	84.22±0.50(0.8248)
S^3 MPE	80.16±1.02(0.7800)	81.92±1.03(0.7997)	83.92±0.71(0.8215)	84.87±0.42(0.8320)
SDA	80.97±1.17(0.7889)	83.58±1.10(0.8181)	86.36±0.71(0.8485)	88.13±0.50(0.8680)
S^3 MME	84.45±1.89(0.8272)	86.08±1.60(0.8455)	88.43±1.04(0.8710)	90.49±0.63(0.8940)




图 4 不同的方法在 Salinas 数据集上的分类结果图 ($l=40, u=3000$)

Fig. 4 The classification results with different methods in Salinas ($l=40, u=3000$)




图 5 S^3MME 在 Salinas 中不同无标记样本下的分类结果
Fig. 5 The classification results of S^3MME with different numbers of unlabeled samples in Salinas

4 结论

本文提出的半监督稀疏多流形嵌入学习方法利用标记和无标记样本通过稀疏表示选取来自同一流形的近邻点,并通过一个半监督邻域图增强了标记样本的作用,不仅可揭示高光谱影像中的内在多流形结构,而且实现了每个流形上的鉴别特征提取,使得来自相同

流形的点更聚集.在不同高光谱数据集上的实验表明:本文提出的 S^3MME 方法与其他维数约简方法相比,能提取出更有效的鉴别特征,提高了分类准确度.由于本文方法只考虑了高光谱数据中的光谱信息,忽略了数据之间的空间位置信息,因此在下一步的研究中可将空间信息融入 S^3MME 算法中,进一步提升地物分类性能.

参考文献

- [1] CHEN Jia-wei, JIAO Li-cheng. Hyperspectral imagery classification using local collaborative representation[J]. *International Journal of Remote Sensing*, 2015, **36**(3): 734-748.
- [2] DU Bo, ZHANG Le-fei, ZHANG Liang-pei, et al. Discriminant manifold learning approach for hyperspectral image dimension reduction[J]. *Acta Photonica Sinica*, 2013, **42**(3): 320-325.
杜博, 张乐飞, 张良培, 等. 高光谱图像降维的判别流形学习方法[J]. *光子学报*, 2013, **42**(3): 320-325.
- [3] LIU Jia-min, LUO Fu-lin, HUANG Hong, et al. Classification of hyperspectral remote sensing images using correlation neighbor LLE[J]. *Optics and Precision Engineering*, 2014, **22**(6): 1668-1676.
刘嘉敏, 罗甫林, 黄鸿, 等. 应用相关近邻局部线性嵌入算法

- 的高光谱遥感影像分类[J]. 光学精密工程, 2014, **22**(6): 1668-1676.
- [4] TENEBBAUM J, SILVA V, LANGFORD J. A global geometric framework for nonlinear dimensionality reduction [J]. *Science*, 2000, **290**(5500): 2319-2323.
- [5] SOWEIS S, SAUL L. Nonlinear dimensionality reduction by locally linear embedding[J]. *Science*, 2000, **290**(5500): 2323-2326.
- [6] BELKIN M, NIYOGI P. Laplacian eigenmaps for dimensionality reduction and data representation[J]. *Neural Computation*, 2003, **15**(6): 1373-1396.
- [7] GARCÍA-GÓMEZ J, GÓMEZ-SANCHIS J, ESCANDELL-MONTERO P, *et al.* Sparse manifold clustering and embedding to discriminate gene expression profiles of glioblastoma and meningioma tumors[J]. *Computers in Biology and Medicine*, 2013, **43**(11): 1863-1869.
- [8] 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.
- [9] WANG Yong-mao, XU Zheng-guang, ZHAO Shan. Neighborhood graph embedding based local adaptive discriminant projection[J]. *Journal of Electronics & Information Technology*, 2013, **35**(3): 633-638.
王永茂, 徐正光, 赵珊. 基于自适应近邻图嵌入的局部鉴别投影算法[J]. 电子与信息学报, 2013, **35**(3): 633-638.
- [10] D'ASPREMONT A, EL GHAOUI L, JORDAN M I, *et al.* A direct formulation for sparse PCA using semi definite programming[J]. *Siam Review*, 2007, **49**(3): 434-448.
- [11] QIAO Li-shan, CHEN Song-can, TAN Xiao-yan. Sparsity preserving projections with applications to face recognition [J]. *Pattern Recognition*, 2010, **43**(1): 331-341.
- [12] ZANG Fei, ZHANG Jiang-she. Discriminative learning by sparse representation for classification[J]. *Neurocomputing*, 2011, **74**(12): 2176-2183.
- [13] LU Gui-fu, JIN Zhong, ZOU Jian. Face recognition using discriminant sparsity neighborhood preserving embedding[J]. *Knowledge-Based Systems*, 2012, **31**(7): 119-127.
- [14] ELHAMIFAR E, VIDAL R. Sparse manifold clustering and embedding [C]. *Neural Information Processing Systems*, Granada, Spain, 2011: 55-63.
- [15] HUANG Hong, YANG Mei. Dimensionality reduction of ryperspectral images with sparse discriminant embedding[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2015, **53**(9): 5160-5169.
- [16] Online: http://www.ehu.eus/ccwintco/index.php?direction=next&oldid=16520&title=Hyperspectral_Remote_Sensing_Scenes.
- [17] WANG Li-zhi, HUANG Hong, FENG Hai-liang. Multilinear local and global preserving embedding and its application in hyperspectral remote sensing image classification [J]. *Journal of Computer-Aided Design & Computer Graphics*, 2012, **24**(6):780-786.
王立志, 黄鸿, 冯海亮. 多线性局部与全局保持嵌入在高光谱遥感影像分类中的应用[J]. 计算机辅助设计与图形学报, 2012, **24**(6): 780-786.