

doi:10.3788/gzxb20154412.1228001

基于监督稀疏流形嵌入的高光谱遥感影像分类

黄鸿, 杨娅琼, 罗甫林, 冯海亮

(重庆大学 光电技术及系统教育部重点实验室, 重庆 400044)

摘 要:稀疏流形聚类 and 嵌入算法通过仿射空间中的稀疏表示获得稀疏系数,并能由稀疏系数自适应地选取来自同一流形的数据点.但稀疏流形聚类和嵌入算法没有直接的投影矩阵,且为非监督学习方法.针对稀疏流形聚类和嵌入算法的不足,提出一种新的监督稀疏流形嵌入算法.该方法首先在仿射空间中采用稀疏优化法得到稀疏系数,然后根据稀疏系数构建相似权值,并在权值中嵌入样本类别信息,增加同类数据间的聚集性,并在低维嵌入空间中保持这种相似性不变,提取鉴别特征来提升分类性能.实验结果表明:该方法不仅能保持数据的稀疏特性,而且通过利用样本数据的类别信息使同类数据在低维空间尽可能聚集,提取鉴别特征,进而改善高光谱影像的地物分类效果.

关键词:高光谱影像;地物分类;维数约简;图嵌入;稀疏流形学习

中图分类号:TP751.2

文献标识码:A

文章编号:1004-4213(2015)12-1228001-9

Classification of Hyperspectral Remote Sensing Images Based on Supervised Sparse Manifold Embedding

HUANG Hong, YANG Ya-qiong, LUO Fu-lin, FENG Hai-liang

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

Abstract: Sparse Manifold Clustering and Embedding (SMCE) can adaptively select nearby points that lie in the same manifold based on sparse representation. However, there is no explicit project matrix in SMCE, and the unsupervised nature restricts its discriminating capability. Supervised Sparse Manifold Embedding (SSME) was proposed for dimensionality reduction of hyperspectral data. At first, the SSME method finds the sparse coefficients in affine subspace by solving a sparse optimization problem. It constructs the similarity weight matrix using the sparse coefficients, and naturally incorporates the label information into the weights. Then, it tries to extract discriminative features by increasing the compactness between homogeneous data in a low-dimensional embedding space. The experiments show that the SSME method not only inherits the merits of the sparsity property but also improves the severability of data points from different classes.

Key words: Hyperspectral image; Land cover classification; Dimensionality reduction; Graph embedding; Sparse manifold learning

OCIS Codes: 280.0280 ; 110.4234; 100.4145; 100.5010

0 引言

高光谱遥感影像中含有丰富的地物光谱信息,在描述地表特征以及地物分类等方面具有独特的优势^[1-2].但由于其波段多,传统分类方法易导致“维数灾难”^[3],因此,如何在保持有效信息的同时尽可能地减

少其波段数,已成为高光谱遥感影像分类中的研究热点.

维数约简方法可从高光谱数据中提取出有效的特征信息,消除数据间的冗余信息,是解决高光谱遥感影像分类中“维数灾难”问题的有效手段.流形学习能够很好地揭示高光谱遥感数据的内在非线性结构^[4],其代

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,博士,副教授,博导,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:2015-05-26; **录用日期:**2015-08-17

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

表性方法有局部线性嵌入(Local Linear Embedding, LLE)^[5]、等距映射(Isometric Feature Mapping, ISOMAP)^[6]和拉普拉斯特征映射(Laplacian Eigenmap, LE)^[7]等.但这些方法只在训练样本集上有定义,不能直接处理新样本,导致了“样本外学习”问题.针对此问题,学者们提出了局部保持投影(Locality Preserving Projection, LPP)^[8]和邻域保持嵌入(Neighborhood Preserving Embedding, NPE)^[9]算法,分别是LLE和LE的线性化近似,但都属于无监督方法,限制了鉴别特征提取.为充分利用样本类别信息,学者们提出了边界Fisher分析(Marginal Fisher Analysis, MFA)^[10]和局部Fisher鉴别分析(Local Fisher Discriminant Analysis, LFDA)^[11].上述维数约简方法都能被统一在图嵌入框架下,共同之处在于都需构建相似图来表征数据间的相似关系.该图的构建首先需要选取近邻,常用的方法有 k 近邻法或 ϵ 半径法,但 k 和 ϵ 值的设置对算法的性能影响较大,选取较为困难.

稀疏表示是近年来的研究热点,其代表性方法稀疏保持投影(Sparsity Preserving Projections, SPP)^[12]和稀疏鉴别分析(Sparse Discriminant Analysis, SDA)^[13]等.这些方法具有一定的自然鉴别能力,能够在全局数据结构中自动度量数据间的相似性,由此构建的相似图不受近邻参量选取的影响.Elhamifar^[14]等提出了一种稀疏流形聚类 and 嵌入方法(Sparse Manifold Clustering and Embedding, SMCE),该方法能够自适应地选取来自同一流形的数据,在此基础上构建的相似图能更好地揭示出数据中不同流形的内在特性.SMCE首先对数据进行聚类,然后再采用现有维数约简方法对每个聚类数据进行降维,但其没有直接的投影矩阵,所以不能解决“样本外学习”问题.

针对SMCE算法的不足,并结合图嵌入框架,本文提出了一种监督稀疏流形嵌入算法(Supervised Sparse Manifold Embedding, SSME),该算法首先通过在仿射空间中得到稀疏系数,构建稀疏图,然后根据稀疏系数计算相似权值,在权值中融入样本类别信息来增加同类数据间的聚集性,提取鉴别特征,实现维数约简.用PaviaU和Urban高光光谱遥感数据集验证了本文方法的有效性.

1 相关方法

假设高维空间数据集 \mathbf{X} 为 $\{x_1, x_2, \dots, x_N\}$,其中 $x_i (i=1, 2, \dots, N) \in \mathbf{R}^D$, N 为数据点的个数,低维嵌入特征 \mathbf{Y} 表示为 $\{y_1, y_2, \dots, y_N\}$,其中 $y_i \in \mathbf{R}^d$,且 $d \ll D$.

1.1 图嵌入理论

图嵌入(GE)理论^[15]的主要思想是构建一个相似

图 $G = \{\mathbf{X}, \mathbf{W}\}$,其中 \mathbf{X} 为图中的顶点,若 x_i 和 x_j 是近邻点,则在两顶点间构建一连线边. \mathbf{W} 表示各点间连线边的权值矩阵, w_{ij} 表示图中顶点 x_i 和 x_j 间连线边的权值,其大小反映了数据点之间的相似程度.

图嵌入理论通过构建原图的一个相似图 G ,并在低维嵌入空间中保持近邻点之间的相似关系不变,得到低维嵌入特征,实现维数约简.其目标函数可表示为

$$\min \frac{1}{2} \sum_{ij=1}^N (y_i - y_j)^2 w_{ij} = \min \text{tr}(\mathbf{Y}(\mathbf{D} - \mathbf{W})\mathbf{Y}^T) = \min \text{tr}(\mathbf{Y}\mathbf{L}\mathbf{Y}^T) \quad \text{s. t.} \quad \mathbf{Y}\mathbf{D}\mathbf{Y}^T = \mathbf{I} \quad (1)$$

式中 \mathbf{D} 为对角矩阵,且 $D_{ii} = \sum_{j=1}^N w_{ij}$; $\mathbf{L} = \mathbf{D} - \mathbf{W}$ 为拉普拉斯矩阵.

1.2 SMCE 算法

SMCE的主要思想是假设每个数据点的近邻都是来自同一流形,由与 x_i 同一切空间的数据点构成了仿射空间,然后在所构成的仿射空间中建立一个目标函数选取近邻,使选取的近邻数最小,通过稀疏优化方法,求解稀疏系数,进而可以自适应地选取来自同一流形的最优近邻点,其目标函数表示为

$$\min \lambda \|\mathbf{Q}\mathbf{c}_i\|_1 + \frac{1}{2} \|\mathbf{X}_i\mathbf{c}_i\|_2^2 \quad \text{s. t.} \quad \mathbf{1}^T \mathbf{c}_i = 1 \quad (2)$$

式中: λ 是平衡参量, $\mathbf{c}_i = [c_{i1}, c_{i2}, \dots, c_{iN}]$, c_{ij} 为 x_i 和 x_j 之间的稀疏系数, $\mathbf{X}_i = \left[\frac{x_1 - x_i}{\|x_1 - x_i\|_2} \dots \frac{x_N - x_i}{\|x_N - x_i\|_2} \right] \in \mathbf{R}^{D \times N-1}$,其中 $i \neq j$, \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地为零,且 $\mathbf{Q}_i = \text{diag} \left(\frac{\|x_j - x_i\|_2}{\sum_{t \neq i} \|x_t - x_i\|_2} \right)$ 为一个正定对角矩阵.

根据稀疏系数, x_i 与 x_j 间的相似权值设置为

$$w_{ii} = 0, w_{ij} = \frac{c_{ij} / \|x_j - x_i\|_2}{\sum_{t \neq i} c_{it} / \|x_t - x_i\|_2}, j \neq i \quad (3)$$

SMCE能够揭示出数据点间的流形结构,自适应地选取来自同一流形的近邻,能较好地实现数据聚类.但是,该方法只在训练样本集上有定义,不能直接得到新样本的低维嵌入特征,不能直接应用于分类问题.

2 监督稀疏流形嵌入算法

监督稀疏流形嵌入算法(SSME).通过在仿射空间求解稀疏系数,然后由稀疏系数构建相似图,并结合样本类别信息来增加同类数据间的聚集性,提取低维鉴别特征,实现维数约简.

SSME算法的主要步骤为:

1) 计算数据集 \mathbf{X} 的稀疏系数

将向量 $\{x_j - x_i\}_{j \neq i}$ 标准化,在仿射空间构建优化目标函数,根据式(2)求解,得到稀疏系数.

2) 构建无向权重图 G

根据稀疏系数构建无向图 G :在图 G 中,若 x_i 和 x_j 之间的稀疏系数不为零,则在两点之间设置一条边,并设置一边权值;若 x_i 和 x_j 之间的稀疏系数为零,则在两点之间则不设置边,边权值设为零. x_i 和 x_j 之间的权值 s_{ij} 设置为

$$s_{ij} = \begin{cases} \beta \frac{c_{ij} / \|x_j - x_i\|_2}{\sum_{t \neq i} c_{it} / \|x_t - x_i\|_2}, & c_{ij} \neq 0, x_i \text{ and } x_j \text{ same kind} \\ \frac{c_{ij} / \|x_j - x_i\|_2}{\sum_{t \neq i} c_{it} / \|x_t - x_i\|_2} & c_{ij} \neq 0, x_i \text{ and } x_j \text{ different kind} \\ 0, & \text{other} \end{cases} \quad (4)$$

式中:参量 $\beta > 1$ 为增加同类数据的聚集性; c_{ij} 为稀疏系数.

3) 计算投影矩阵 A

在低维嵌入空间中,保持数据在仿射空间的稀疏特性不变,其目标函数可构建为

$$\min \frac{1}{2} \sum_{i,j=1}^N s_{ij} (y_i - y_j)^2 = \min \text{tr}(\mathbf{Y}(\mathbf{D}_s - \mathbf{S})\mathbf{Y}^T) = \min \text{tr}(\mathbf{Y}\mathbf{L}_s\mathbf{Y}^T) = \min \text{tr}(\mathbf{A}^T\mathbf{X}\mathbf{L}_s\mathbf{X}^T\mathbf{A}) \quad (5)$$

式中 \mathbf{D}_s 为对角矩阵,并且 $D_{s,ii} = \sum_{j=1}^N s_{ij}$, $\mathbf{L}_s = \mathbf{D}_s - \mathbf{S}$ 为拉普拉斯矩阵, \mathbf{S} 为权值矩阵, \mathbf{A} 为投影矩阵.

为了得到唯一解,消除尺度因子的影响,增加约束项 $\mathbf{A}^T\mathbf{X}\mathbf{D}_s\mathbf{X}^T\mathbf{A} = \mathbf{I}$,其目标函数可进一步表示为

$$\min \mathbf{A}^T\mathbf{X}\mathbf{L}_s\mathbf{X}^T\mathbf{A} \quad \text{s. t. } \mathbf{A}^T\mathbf{X}\mathbf{D}_s\mathbf{X}^T\mathbf{A} = \mathbf{I} \quad (6)$$

对式(6)运用拉格朗日乘数法求解,得

$$\frac{\partial}{\partial \mathbf{A}} (\mathbf{A}^T\mathbf{X}\mathbf{L}_s\mathbf{X}^T\mathbf{A} - \lambda (\mathbf{A}^T\mathbf{X}\mathbf{D}_s\mathbf{X}^T\mathbf{A} - \mathbf{I})) = 0 \quad (7)$$

可将其表示为广义特征值求解问题,即

$$\mathbf{X}\mathbf{L}_s\mathbf{X}^T\mathbf{A} = \lambda \mathbf{X}\mathbf{D}_s\mathbf{X}^T\mathbf{A} \quad (8)$$

求取式(7)的广义特征值特征向量,选取最小的 d 个特征值及其对应的特征向量 $\mathbf{a}_1, \mathbf{a}_2, \dots, \mathbf{a}_d$. 令投影矩阵 $\mathbf{A} = [\mathbf{a}_1, \mathbf{a}_2, \dots, \mathbf{a}_d]$,可得到低维嵌入特征 $\mathbf{Y} = \mathbf{A}^T\mathbf{X}$.

SSME 算法能自适应地选取来自同一流形的近邻,并在低维空间中保持数据点在高维空间中的相似性关系,提取鉴别特征,提升分类性能.

3 实验结果及分析

为了验证本文算法的有效性,取 PaviaU 和 Urban 两个高光谱遥感数据集进行实验,并将 SSME 算法与 LPP、NPE、SPP、LDA、MFA、监督 LPP (Supervised LPP, SLPP)^[8] 和 监督 NPE (Supervised NPE, SNPE)^[9] 等维数约简算法进行对比. 在实验中,LPP、NPE、MFA 等流形学习算法的近邻参量 k 设置为 5, LDA 算法的嵌入维数设置为 $c-1$, c 为类别数. 在使用各种 DR 算法得到低维嵌入特征后,用最近邻分类器 (1-NN) 进行分类. 在实验中,采用土地利用/土地覆盖分类体系.

3.1 PaviaU 数据集

PaviaU 是由西班牙巴斯克大学提供的已标注地物样本类别的数据集^[16],覆盖了 Pavia 大学区域,该数据集共有 103 个波段,像素为 610×340 ,空间分辨率为 1.3 m,包含了土地利用/土地覆盖分类体系中 9 类主要的地物,并赋予不同的颜色表示,具体如图 1.




图 1 PaviaU 高光谱遥感影像(括号中为样本数)

Fig. 1 The hyperspectral remote sensing image of PaviaU (the number of samples in the brackets)

为了验证本文提出方法的有效性,从该数据集中选取了“Gravel”、“Trees”、“Metal Sheets”和“Soil”这 4

类地物,然后从每类中随机选取 50 个样本将其投影到 2 维空间进行可视化实验,并采用 Fisher 判别率^[17]

$J_{B/W}$ 对其结果进行评价, $J_{B/W} = \text{tr}(S_W^{-1}S_B)$, 其中 S_W 为类内散度矩阵, S_B 为类间散度矩阵. 由 $J_{B/W}$ 表达式可知, 其值越大则同类数据更加聚集, 不同类数据更加分离. 图 2 为不同的方法进行维数约简后的 2 维分布图. 从图中可得知, 其他算法中不同类数据之间存在不同

程度的混叠现象, 可分性较差, 而 SSME 算法中不同类数据具有较好的可分性. 同时, SSME 算法的 $J_{B/W}$ 值最大, 说明该方法通过在稀疏系数中嵌入样本类别信息, 能更好地表征数据的内在本质特性, 对不同地物具有更好的鉴别性, 可有效改善地物分类效果.

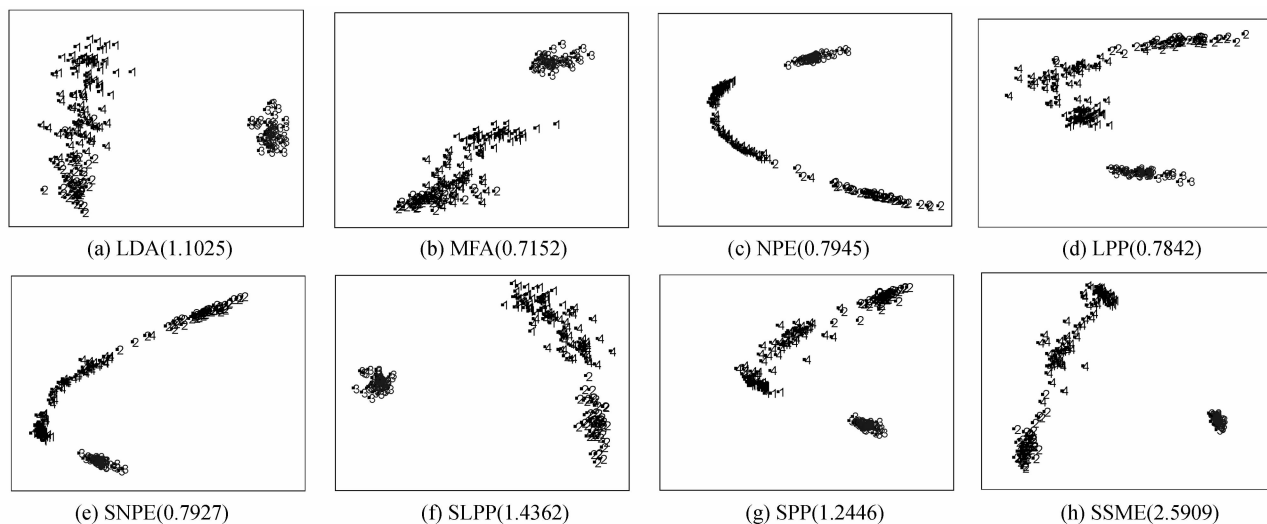


图 2 选取 4 类的二维嵌入结果(括号中为 Fisher 判别率)

Fig. 2 Embedding results of two dimensions of four chosen classes (the Fisher discriminating ratio in the brackets)

在实验中, 分别从每类中随机选取 30、40、50 和 60 个点作为训练样本, 200 个数据点作为测试样本, 表示为 30-train、40-train、50-train 和 60-train, 重复 10 次实

验, 取其均值作为最终分类准确度, 最优结果采用粗体显示. 不同维数约简方法的平均分类准确度如图 2, 对应的最高分类准确度如表 1.

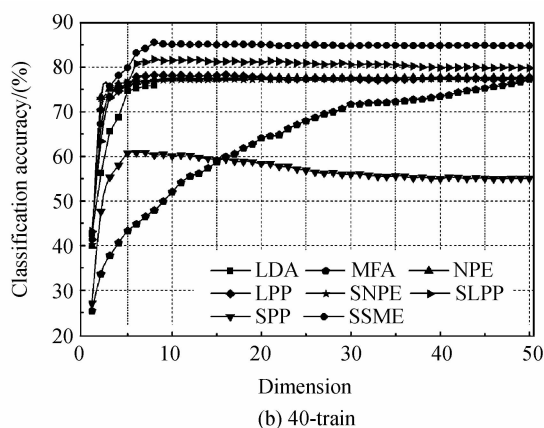

表 1 各种算法在 PaviaU 数据集上的最高分类准确度

Table 1 The highest overall classification accuracy of different algorithms in PaviaU

Algorithms	30-train	40-train	50-train	60-train
LDA	71.21±1.37(6)	75.84±0.97(8)	77.38±1.21(6)	78.77±1.93(6)
MFA	76.64±2.68(50)	77.28±1.86(50)	77.55±2.81(50)	77.97±2.59(50)
NPE	76.92±1.64(17)	77.68±1.49(40)	79.07±1.17(38)	80.21±0.74(35)
LPP	75.14±1.52(24)	78.28±1.24(16)	79.81±1.61(13)	81.99±1.11(34)
SNPE	76.33±1.44(50)	77.47±1.35(44)	78.64±1.54(19)	79.32±0.84(49)
SLPP	78.85±1.50(8)	81.73±1.02(8)	83.72±0.89(10)	85.78±1.02(8)
SPP	58.68±2.20(5)	60.87±2.12(7)	63.47±1.74(8)	65.39±1.60(17)
SSME	84.06±1.28(21)	85.49±0.88(8)	86.55±0.63(10)	87.10±0.93(10)

由图 3 和表 1 可得知, 随着训练样本数的增加, 所含的已知信息越丰富, 在特征提取时, 可利用的信息就

越充足, 因而能更好地表征高光谱数据的本征结构, 使各算法的总体分类准确度不断地提高. SSME 和 SLPP



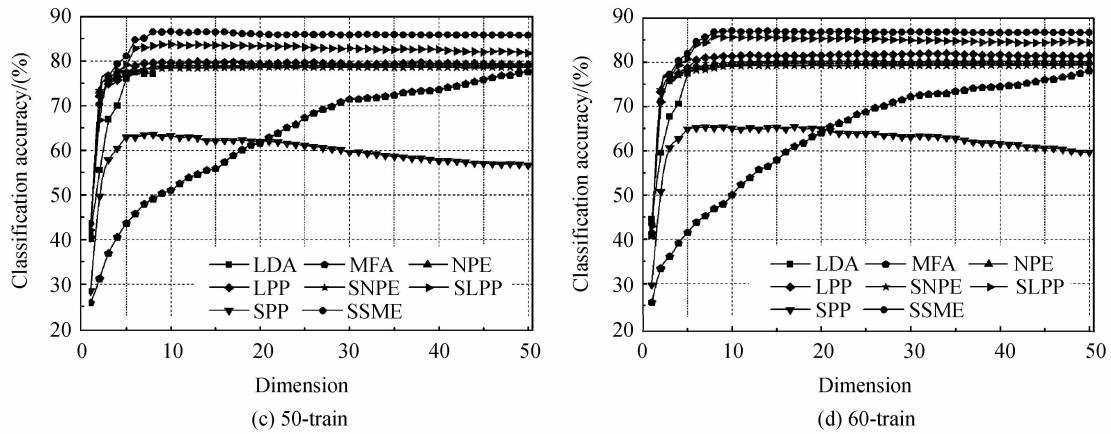


图3 不同算法在 PaviaU 数据集上的平均分类准确度

Fig. 3 The average classification accuracy of different algorithms in PaviaU

算法分别比非监督的 SPP 和 LPP 算法分类效果更好, 主要是由于监督算法能够充分利用样本类别信息, 能够提取更有效地鉴别特征.


为了进一步说明 SSME 算法的有效性, 对数据集中每一类地物进行分类实验. 实验中, 每类随机选取

60 个训练样本. 从图 3 可知, 大部分算法在特征维数为 40 时其分类准确度趋于稳定, 因此实验中嵌入特征维数设定为 40. 表 2 给出了每一类地物的分类准确度, 图 4 为各种算法的地物分类结果图.

表 2 不同方法对每种地物的分类准确度 (%) 及分类结果

Table 2 The classification accuracy and result of every ground object with different methods (%)

Classes	LDA	MFA	NPE	LPP	SNPE	SLPP	SPP	SSME
Asphalt	67.15	58.35	75.00	70.10	72.61	75.61	30.40	71.59
Meadow	82.89	76.47	73.56	77.41	72.08	80.17	52.20	84.56
Gravel	71.08	68.41	65.51	68.46	62.65	76.85	44.97	74.85
Trees	92.82	90.67	89.92	89.43	88.94	92.36	81.43	93.99
Metal Sheets	100.00	99.70	98.96	99.63	98.74	99.78	56.51	99.93
Soil	72.60	62.68	65.14	72.70	65.86	74.59	39.53	77.89
Bitumen	70.53	84.89	85.64	89.92	83.53	86.24	51.20	89.17
Bricks	58.61	60.13	70.15	69.23	66.11	69.20	33.08	64.23
Shadows	99.79	100.00	100.00	100.00	100.00	99.89	88.60	99.79
Average accuracy	79.50	77.92	80.43	81.88	78.95	83.85	53.10	84.00
Overall accuracy	77.81	72.77	75.04	77.03	73.47	79.81	48.34	81.18
Kappacoefficient	0.7128	0.6518	0.6803	0.7051	0.6614	0.7397	0.3714	0.7563






图 4 各种算法在 PaviaU 数据集上分类结果图

Fig. 4 The classification result with different methods in PaviaU

从图 4 中可知,SSME 算法的分类结果较其他算法错分点更少,分类效果更理想.表中 2 进一步证实,SSME 算法在“Meadow”、“Trees”和“Soil”这几类中分类效果最好,在部分类别分类性能要略低于其他算法.由于“Asphalt”和“Bitumen”同为沥青材料,“Gravel”和“Bricks”同为砖石材料,在光谱曲线上相似度较高,因此 SSME 方法通过随机选择训练样本进行稀疏表征时,在这些类别上的得到稀疏系数具有相似性,进而使分类性能受到影响.但是,就数据集整体而言,稀疏表

示方法可以更好地表征高光谱数据,因此 SSME 方法的平均分类准确度、总体准确度和 Kappa 系数都优于其他方法.

3.2 Urban 数据集

Urban 是由美国陆军工程研发中心提供的已标注地物样本类别的高光谱影像数据集^[18],该数据集通过 HYDICE 传感器获取的,其位于美国德克萨斯州,该影像的像素大小为 307×307 ,空间分辨率为 2 m,取出受大气吸收以及噪声影响较大的 48(1-4,76,87,101-

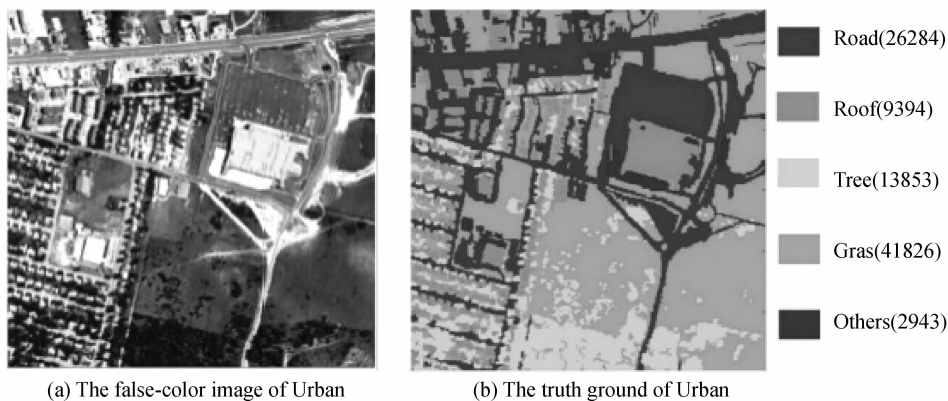


图 5 Urban 高光谱遥感影像(括号中为样本数)

Fig. 5 The hyperspectral remote sensing image of Urban (the number of samples in the brackets)

表 3 各种算法在 Urban 数据集上的最高分类准确度

Table 3 The highest overall classification accuracy of different algorithms in Urban

Algorithms	40-train	60-train	80-train	100-train
LDA	45.11±4.71(4)	58.61±2.03(4)	63.68±2.33(4)	63.98±1.95(4)
MFA	66.08±2.21(50)	67.04±1.76(50)	67.52±1.29(50)	65.36±2.03(49)
NPE	57.26±3.00(49)	61.03±2.08(50)	62.80±1.68(48)	61.39±1.21(48)
LPP	51.65±1.97(50)	61.75±1.62(49)	64.38±1.59(50)	65.13±2.18(48)
SNPE	56.62±2.06(42)	63.21±1.85(45)	64.16±0.98(50)	60.66±1.68(49)
SLPP	51.22±4.32(16)	66.08±1.63(43)	68.32±2.08(47)	69.29±2.00(38)
SPP	58.84±1.57(49)	62.93±1.56(47)	64.01±1.29(42)	65.92±1.33(43)
SSME	68.54±1.73(50)	70.63±1.42(46)	70.73±1.62(41)	71.71±1.96(50)

111,136-153,198-210)个波段,将剩下的162个波段用于实验研究,其中包含了土地利用/土地覆盖分类体系中5类主要的地物,并赋予不同的颜色表示,如图5.实验分别从每类地物随机选取40、60、80和100个训练样本,并随机选取200个样本作为测试样本,表示为40-train、60-train、80-train和100-train,进行10次重复实验取均值作为最终的分类准确度.不同方法在Urban数据集上的平均分类结果如图6,对应的最高分类准确度如表3.

由图6和表3可知,随着训练样本数的增加,可用的已知信息越丰富,使得大部分算法的总体分类准确度不断地提高. SSME算法的分类准确度要优于其他算法,尤其在训练样本比较少时,这使得SSME算法更具有实用性. SSME算法比SPP算法分类效果有了明显的提升,这说明SSME算法在低维嵌入空间中在保留了稀疏流形特性同时,融入了样本类别信息,能够得到更有效的低维鉴别特征,有效提升分类效果.

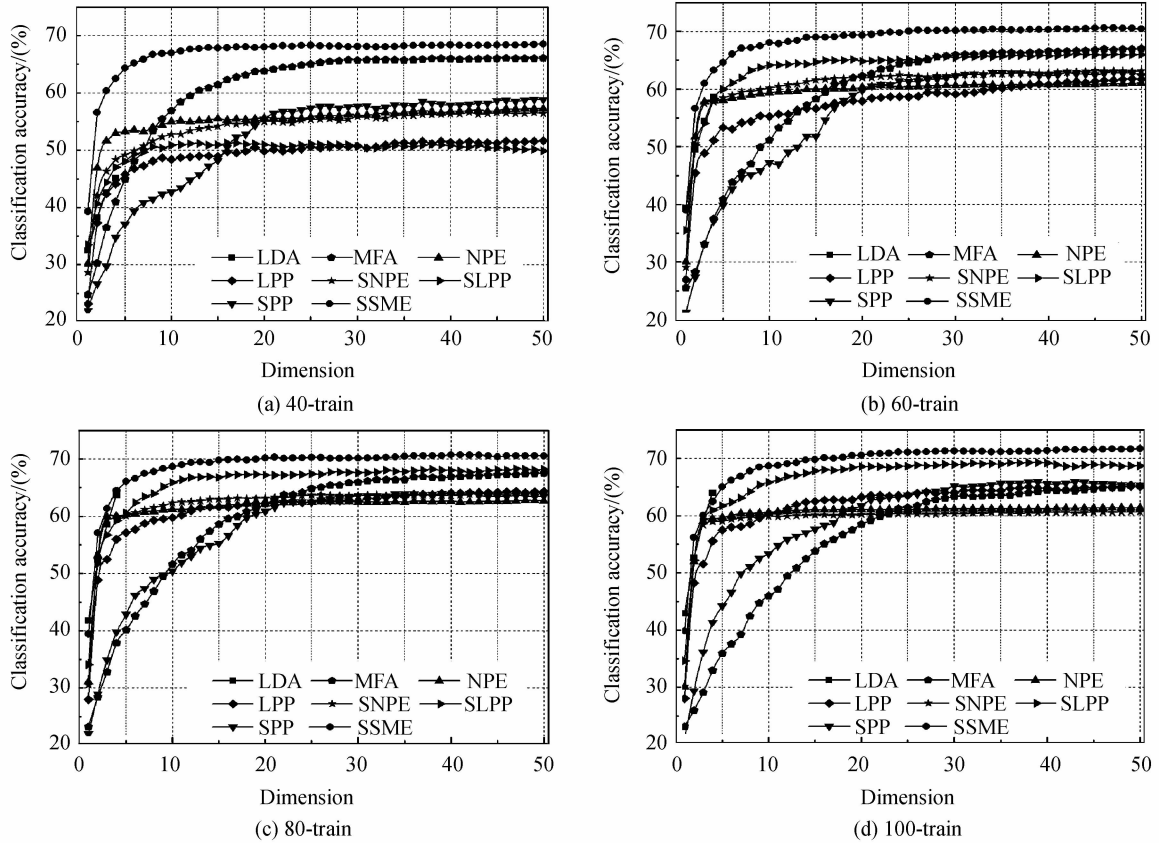



图6 不同算法在Urban数据集上的平均分类准确度
Fig. 6 The average classification accuracy of different algorithms in Urban

为了进一步说明SSME算法的地物分类效果,本文从每类地物中随机选取100个训练样本,所有样本作为测试样本,低维特征维数设定为40,不同算法的分类结果如图7和表4所示.

效果都较好,其平均分类准确度、总分类准确度和Kappa系数相对其他方法有不同程度的提升.同时,由图7可以明显看出,SSME算法相比其他算法,其在“Road”与“Roof”这两类地物上错分的样本点更少.需要指出的是,SLPP在“Tree”和“Grass”上分类性能更

由表4可知,SSME算法对大部分类别的分类






图7 各种算法在 Urban 数据集上的分类结果图

Fig. 7 The classification result with different methods in Urban

表4 不同方法在 Urban 数据集上不同地物的分类准确度(%)

Table 4 The classification accuracy and result of every ground object with different methods (%)

Classes	LDA	MFA	NPE	LPP	SNPE	SLPP	SPP	SSME
Road	60.47	68.38	61.63	60.03	62.15	70.40	62.32	74.12
Roof	70.77	70.62	62.91	70.83	63.67	73.86	69.69	78.26
Tree	76.56	73.90	74.74	76.07	75.50	79.16	75.64	78.55
Grass	69.44	68.35	67.39	71.67	67.83	73.76	67.30	73.43
Others	49.30	56.78	46.65	57.02	48.11	59.63	58.00	63.10
Average accuracy	65.31	67.61	62.67	67.12	63.45	71.36	66.59	73.49
Overall accuracy	67.49	69.04	65.77	68.53	66.34	73.18	67.08	74.53
Kappa coefficient	0.5605	0.5765	0.5368	0.5718	0.5442	0.631	0.5521	0.6494

好,其原因是这两类部分样本在光谱曲线上具有相似性,而SLPP是一种监督的图嵌入方法,直接利用类别标记来定义权重,因此相对SSME利用随机选择的训练本来计算稀疏系数而言,受到的影响较小.但是,就整个数据集的所有类别而言,由稀疏系数能自适应的构建图,可以更好地表征高光谱数据,因此其平均分类准确度、总分类准确度和Kappa系数均优于SLPP方法.

4 总结

SMCE算法能够揭示出数据的内在流形结构,自适应地选取来自同一流形的近邻,较好地实现数据聚类,但是其存在“样本外学习”问题,不能直接得到新样本的嵌入特征.针对SMCE算法的不足,本文提出一种新的监督稀疏流形嵌入算法(SSME).该算法结合了SMCE算法和图嵌入理论的优点,首先在仿射空间中求解稀疏系数,再由稀疏系数构建相似图,并融合样本类别信息来增加同类数据间的聚集性,提取低维鉴别特征,实现维数约简.SSME算法不仅保留了样本数据在仿射空间中的稀疏特性,而且增大了非同类数据间的区分度,更利于高光谱遥感数据的分类.在PaviaU和Urban两个高光谱数据集上的实验结果表明:本文提出的SSME算法能更有效地提取鉴别特征,提升地物分类效果.

参考文献

[1] 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.

[2] SUN W W, HALEVY A, BENEDETTO J, et al. UL-Isomap based nonlinear dimensionality reduction for hyperspectral imagery classification [J]. *Journal of Photogrammetry and Remote Sensing*, 2014, **89**(2): 25-36.

[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] WEI Feng, HE Ming-yi, SHEN Zhi-ming, et al. Manifold based semi-supervised feature selection for hyperspectral data [J]. *Acta Photonica Sinica*, 2014, **43**(6): 630002.

魏峰, 何明一, 申志明, 等. 高光谱数据基于流形的半监督特征选择[J]. *光子学报*, 2014, **43**(6): 630002.

[5] SOWEIS S, SAUL L. Nonlinear dimensionality reduction by locally linear embedding [J]. *Science*, 2000, **290**(5500): 2323-2326.

[6] TENENBAUM J, SILVA V, LANGFORD J. A global geometric framework for nonlinear dimensionality reduction [J]. *Science*, 2000, **290**(5500): 2319-2323.

[7] BELKIN M, NIYOGI P. Laplacian eigenmaps for dimensionality reduction and data representation [J]. *Neural Computation*, 2003, **15**(6): 1373-1396.

[8] HE X F, YAN S C, HU Y, et al. Face recognition using Laplacianfaces [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2005, **27**(3): 328-340.

[9] HE X F, CAI D, YAN S C, et al. Neighborhood preserving

- embedding [C]. Proceedings of the 10th IEEE International Conference on Computer Vision, Beijing, China, 2005: 1208-1213.
- [10] YAN S C, XU D, ZHANG B Y, *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.
- [11] 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.
- [12] QIAO L S, CHEN S C, TAN X Y. Sparsity preserving projections with application to face recognition [J]. *Pattern Recognition*, 2010, **43**(1): 331-341.
- [13] CLEMMENSEN L, HASTIE T, WITTEN D, *et al.* Sparse discriminant analysis [J]. *Technometrics*, 2011, **53**(4): 406-413.
- [14] ELHAMIFAR E, VIDAL R. Sparse manifold clustering and embedding [C]. Neural Information Processing Systems, Granada, Spain, 2011: 55-63.
- [15] 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.
- [16] Online: http://www.ehu.eus/ccwintco/index.php?title=Hyperspectral_Remote_Sensing_Scenes.
- [17] SUGIYAMA M. Dimensionality reduction of multimodal labeled data by local fisher discriminant analysis [J]. *Journal of Machine Learning Research*, 2007, **8**: 1027-1061.
- [18] Online: <http://www.erd.c.usace.army.mil/Media/FactSheets/FactSheetArticleView/tabid/9254/Article/476681/hypercube.aspx>.

Foundation item: The National Natural Science Foundation of China (Nos. 41371338, 61101168), the Basic and Advanced Research Program of Chongqing (No. cstc2013jcyjA40005), the Fundamental Research Funds for the Central Universities (Nos. 106112013CDJZR125501, 1061120131204) and the Postgraduate Research and Innovation Program of Chongqing (No. CYB15052)