

面向高光谱遥感影像分类的 监督多流形鉴别嵌入方法

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: 流形学习方法可以发现嵌入于高维观测数据中的低维流形结构,但是传统的流形学习算法都是假设所有数据位于单一流形上,忽略了高维数据中不同的子集可能存在不同的流形. 针对上述问题,本文提出一种监督多流形鉴别嵌入的维数约简方法,并应用于高光谱遥感影像分类. 该方法首先利用样本数据的类别标签进行多子流形划分,在此基础上采用图嵌入理论构造流形内图和流形间图,然后通过最小化流形内距离同时最大化流形间距离以增强类内数据聚集性和类间数据分散性,提取低维鉴别特征,改善地物分类性能. 在 University of Pavia (PaviaU) 和 Kennedy Space Center (KSC) 高光谱数据集上的实验表明,相较于其他单流形算法和多流形算法,该方法取得了更高的分类精度,在随机选取 2% 训练样本时,其总体分类精度分别达到 88.04% 和 84.53%,有效提升了地物分类性能.

关键词: 高光谱遥感影像; 分类; 特征提取; 图嵌入; 多流形学习

中图分类号: TP751.1

文献标识码: A

文章编号: 0372-2112 (2020)06-1099-09

电子学报 URL: <http://www.ejournal.org.cn>

DOI: 10.3969/j.issn.0372-2112.2020.06.008

Supervised Multi-manifold Discriminant Embedding Method for Hyperspectral Remote Sensing Image Classification

HUANG Hong, WANG Li-hua, SHI Guang-yao

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

Abstract: Manifold learning method can find the low-dimensional manifold structures embedded in high-dimensional data. However, the traditional manifold learning algorithms assume that all samples lie on a single manifold, while the samples in different subsets may belong to different sub-manifolds. To solve the above problem, a new dimensionality reduction (DR) method termed supervised multi-manifold discriminant embedding (SMMDE) is proposed for classification of hyperspectral remote sensing image. At first, the proposed method explore the labels of HSI data to divide samples into different sub-manifolds. Based on the graph embedding framework, the intra-manifold and inter-manifold graphs are constructed to represent the multi-manifold structure of HSI data, and the intra-class aggregation and inter-class separation are enhanced by minimizing the intra-manifold distance and maximizing the inter-manifold distance simultaneously. Therefore, low-dimensional discriminant features are obtained to improve the performance of HSI classification. Experimental results on the PaviaU and KSC hyperspectral data sets show that the overall classification accuracies respectively reach 88.04% and 84.53% when 2% training samples are randomly selected for training. The proposed SMMDE method can effectively improve classification performance compared with many state-of-art DR algorithms.

Key words: hyperspectral remote sensing image; classification; feature extraction; graph embedding; multi-manifold learning

1 引言

高光谱影像包含丰富的辐射、空间和光谱信息,但

其具有数据量大、波段多、相关性强的特点,给地物分类带来了极大的挑战^[1-4]. 因此,如何在减少数据冗余信息的同时,有效保持其内在本质特性,实现低维嵌入特

收稿日期:2019-01-22;修回日期:2019-05-13;责任编辑:梅志强

基金项目:重庆市基础研究与前沿探索项目(No. cstc2018jcyjAX0093);国家自然科学基金(No. 41371338);重庆市研究生科研创新项目(No. CYB19039)

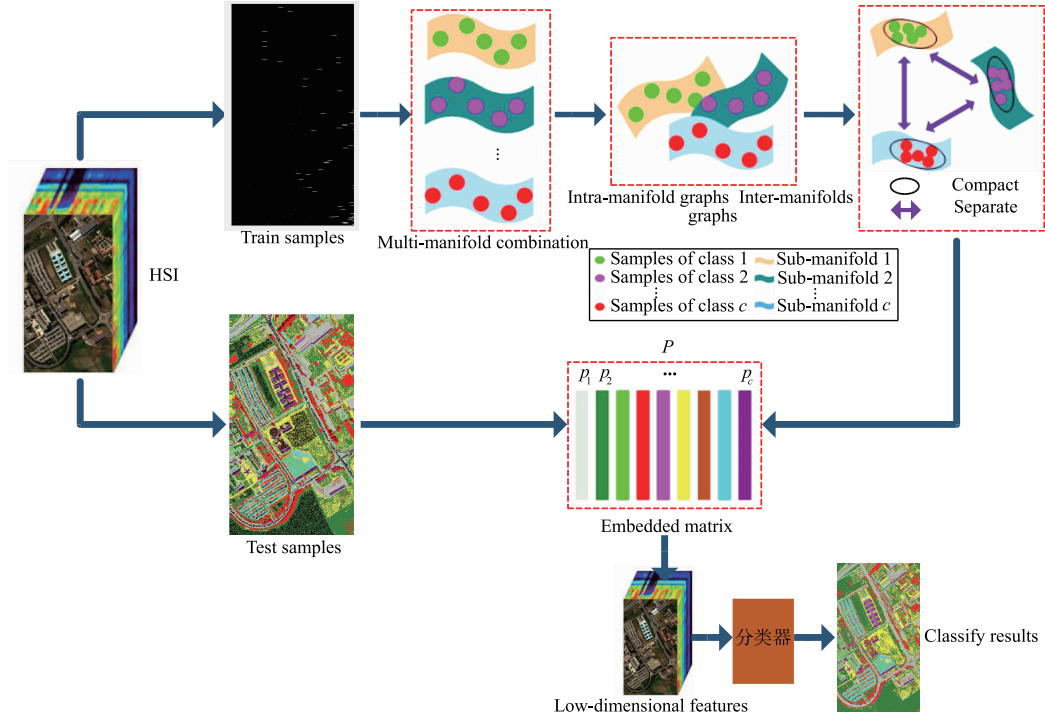


图1 SMMDE算法流程图

在流形内图 $G_r^{\text{intra}}(\mathbf{V}, \mathbf{W}_r^{\text{intra}})$ 中,若两点来自同一流形,则用一条边连接这两点,否则不连接.其相似度可用权值 w_{ij}^{intra} 表示,该子流形内权值定义如下:

$$w_{ij}^{\text{intra}} = \begin{cases} \exp\left(-\frac{\|\mathbf{V}_r(i) - \mathbf{V}_r(j)\|^2}{2t_i^2}\right), & l_i = l_j \\ 0, & \text{其他} \end{cases} \quad (2)$$

式中, $t_i = \frac{1}{n_r} \sum_{j=1}^{n_r} \|\mathbf{V}_r(i) - \mathbf{V}_r(j)\|$, $\mathbf{V}_r \in \mathbf{V}$, \mathbf{V}_r 是 \mathbf{V} 的第 r 部分顶点数据.

在流形间图 $G_{q,r}^{\text{inter}}(\mathbf{V}, \mathbf{W}_{q,r}^{\text{inter}})$ 中,若两点来自于不同的子流形,则用一条边连接这两点,否则不连接.其相似度用权值 w_{ij}^{inter} 表示,该流形间权值定义如下:

$$w_{ij}^{\text{inter}} = \begin{cases} \exp\left(-\frac{\|\mathbf{V}_r(i) - \mathbf{V}_q(j)\|^2}{2t_i^2}\right), & l_i \neq l_j \\ 0, & \text{其他} \end{cases} \quad (3)$$

式中, $t_i = \frac{1}{n_r} \sum_{j=1}^{n_r} \|\mathbf{V}_r(i) - \mathbf{V}_q(j)\|$, $\mathbf{V}_q \in \mathbf{V}$, \mathbf{V}_q 是 \mathbf{V} 的第 q 部分顶点数据.

在低维空间中,为更有利于高光谱地物分类,则需尽可能保持流形内图的本质特性.来自同一流形的数据在低维嵌入空间应尽可能相近,其目标函数可表示为:

$$J^{\text{intra}}(\mathbf{P}_r) = \min \sum_{i,j=1}^{n_r} \|\mathbf{z}_i - \mathbf{z}_j\|^2 w_{ij}^{\text{intra}}$$

$$\begin{aligned} &= \sum_{i,j=1}^{n_r} \|\mathbf{P}_r^T \mathbf{V}_r(i) - \mathbf{P}_r^T \mathbf{V}_r(j)\|^2 w_{ij}^{\text{intra}} \\ &= \text{tr}(\mathbf{P}_r^T [\sum_{i,j=1}^{n_r} (\mathbf{V}_r(i) - \mathbf{V}_r(j)) (\mathbf{V}_r(i) \\ &\quad - \mathbf{V}_r(j))^T w_{ij}^{\text{intra}}] \mathbf{P}_r) \\ &= \text{tr}(\mathbf{P}_r^T \mathbf{D}_r^{\text{intra}} \mathbf{P}_r) \end{aligned} \quad (4)$$

式中, $\mathbf{D}_r^{\text{intra}}$ 表示图 $G_r^{\text{intra}}(\mathbf{V}, \mathbf{W}_r^{\text{intra}})$ 内数据点间的距离,表达如下:

$$\mathbf{D}_r^{\text{intra}}(\mathbf{V}_r) = d_r^{\text{intra}}(\mathbf{V}_r(i,j)) + d_r^{\text{intra}}(\mathbf{V}_r(j,i)) \quad (5)$$

其中:

$$d_r^{\text{intra}}(\mathbf{V}_r(i,j)) = \sum_{i,j=1}^{n_r} (\mathbf{V}_r(i) - \mathbf{V}_r(j)) (\mathbf{V}_r(i) - \mathbf{V}_r(j))^T w_{ij}^{\text{intra}} \quad (6)$$

由权值式(2)可得知,来自于同一流形上两点的权值不为零,且在高维空间中距离越近其权值越大.因此,若在低维嵌入空间中相距较远,与权值相乘将产生一个较大的惩罚项.因此最小化目标函数式(6)可以使来自同一个流形的数据点更加聚集.

与此同时,为使来自不同流形的数据点在低维嵌入空间中具有更好的可分性,其目标函数表示为:

$$\begin{aligned} J^{\text{inter}}(\mathbf{P}_r) &= \max \sum_{i=1}^{n_r} \sum_{j=1}^{n_r} \|\mathbf{z}_i - \mathbf{z}_j\|^2 w_{ij}^{\text{inter}} \\ &= \sum_{i=1}^{n_r} \sum_{j=1}^{n_r} \|\mathbf{P}_r^T \mathbf{V}_r(i) - \mathbf{P}_r^T \mathbf{V}_q(j)\|^2 w_{ij}^{\text{inter}} \end{aligned}$$

$$\begin{aligned}
&= \text{tr}(\mathbf{P}_r^T [\sum_{i=1}^{n_r} \sum_{j=1}^{n_s} (\mathbf{V}_r(i) - \mathbf{V}_q(j)) (\mathbf{V}_r(i) \\
&\quad - \mathbf{V}_q(j))^T \mathbf{w}_{ij}^{\text{inter}}] \mathbf{P}_r) \\
&= \text{tr}(\mathbf{P}_r^T \mathbf{D}_{q,r}^{\text{inter}} \mathbf{P}_r) \quad (7)
\end{aligned}$$

式中, $\mathbf{D}^{\text{inter}} = \sum_{q=1, q \neq r}^c \mathbf{D}_{q,r}^{\text{inter}}$, $\mathbf{D}_{q,r}^{\text{inter}}$ 表示图 $\mathbf{G}_r^{\text{intra}}(\mathbf{V}_r, \mathbf{W}_r^{\text{intra}})$ 与图 $\mathbf{G}_q^{\text{intra}}(\mathbf{V}_q, \mathbf{W}_q^{\text{intra}})$ 间的距离, 具体表达如下:

$$\mathbf{D}_{q,r}^{\text{inter}}(\mathbf{V}_q, \mathbf{V}_r) = d_{q,r}^{\text{inter}}(\mathbf{V}_q, \mathbf{V}_r) + d_{r,q}^{\text{inter}}(\mathbf{V}_r, \mathbf{V}_q) \quad (8)$$

其中:

$$d_{q,r}^{\text{inter}}(\mathbf{V}_q, \mathbf{V}_r) = \sum_{i=1}^{n_r} \sum_{j=1}^{n_s} (\mathbf{V}_r(i) - \mathbf{V}_q(j)) (\mathbf{V}_r(i) - \mathbf{V}_q(j))^T \mathbf{w}_{ij}^{\text{inter}} \quad (9)$$

根据权值式(3)可知, 来自不同流形间的两点的权值较小, 且距离越远其权值越小. 若在低维嵌入空间中相距较近, 与其相应的权值相乘将产生一个较大的惩罚项. 因此最小化目标函数式(9)可以使来自不同流形的数据点更加远离, 使嵌入特征在低维空间中具有更好的可分性, 有利于提升分类性能.

联合式(4)和式(7), SMMDE 算法的目标函数可进一步优化如下:

$$\begin{cases} \max \mathbf{P}_r^T \mathbf{D}^{\text{inter}} \mathbf{P}_r \\ \min \mathbf{P}_r^T \mathbf{D}_r^{\text{intra}} \mathbf{P}_r \end{cases} \quad (10)$$

由拉格朗日乘子法, 式(10)的最优解可表示为:

$$\mathbf{D}^{\text{inter}} \mathbf{P}_r = \lambda_r \mathbf{D}_r^{\text{intra}} \mathbf{P}_r \quad (11)$$

根据广义特征值问题, 求取式(11)的特征值, 并且按照从大到小的顺序, 取前 d 个最大的特征值对应的特征向量为投影向量 $\mathbf{P}_r = [\mathbf{p}_1, \mathbf{p}_2, \dots, \mathbf{p}_d]$, 同理, 按照类别信息求取每个子流形的投影向量, 组成一组最佳嵌入矩阵 $\mathbf{P} = [\mathbf{P}_1, \mathbf{P}_2, \dots, \mathbf{P}_c]$. SMMDE 具体算法步骤如算法 1 所示.

算法 1 SMMDE 算法步骤

Input: 高光谱遥感数据 $\mathbf{X} = [\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_N] \in \mathbb{R}^{D \times N}$, \mathbf{x}_i 的类别标签 $l_i \in \{1, 2, \dots, c\}$, 嵌入维度 $d (d \ll D)$.

Output: 投影矩阵 $\mathbf{P} = [\mathbf{P}_1, \mathbf{P}_2, \dots, \mathbf{P}_c] \in \mathbb{R}^{D \times d}$.

Step1: 根据标签信息将训练样本数据划分为不同的流形, $\mathbf{M} = [\mathbf{M}_1, \mathbf{M}_2, \dots, \mathbf{M}_c]$;

Step2: 构造流形内图 $\mathbf{G}_r^{\text{intra}}(\mathbf{V}, \mathbf{W}_r^{\text{intra}})$, 根据式(2)求取权值 $\mathbf{w}_{ij}^{\text{intra}}$;

Step3: 构造流形间图 $\mathbf{G}_{q,r}^{\text{inter}}(\mathbf{V}, \mathbf{W}_{q,r}^{\text{inter}})$, 根据式(3)求取权值 $\mathbf{w}_{ij}^{\text{inter}}$;

Step4: 由 $\mathbf{D}_r^{\text{intra}}(\mathbf{V}_r(i, j)) = d_{r,r}^{\text{intra}}(\mathbf{V}_r(i, j)) + d_{r,r}^{\text{intra}}(\mathbf{V}_r(j, i))$ 计算流形内距离;

Step5: 由 $\mathbf{D}_{q,r}^{\text{inter}}(\mathbf{V}_q, \mathbf{V}_r) = d_{q,r}^{\text{inter}}(\mathbf{V}_q, \mathbf{V}_r) + d_{r,q}^{\text{inter}}(\mathbf{V}_r, \mathbf{V}_q)$ 计算流形间距离;

Step6: 计算 $\mathbf{D}^{\text{inter}} \mathbf{P}_r = \lambda_r \mathbf{D}_r^{\text{intra}} \mathbf{P}_r$ 的特征值, 每个流形选取前 d 个最大的特征值对应的特征向量组成投影向量 $\mathbf{P}_r = [\mathbf{p}_1, \mathbf{p}_2, \dots, \mathbf{p}_d]$, 最佳嵌入矩阵 $\mathbf{P} = [\mathbf{P}_1, \mathbf{P}_2, \dots, \mathbf{P}_c]$, $\mathbf{P}_i \in \mathbb{R}^{D \times d}$.

4 实验与分析

4.1 实验数据集

(1) PaviaU 数据集是在 2001 年由 ROSIS 传感器采集的 PaviaU 大学区域的遥感影像. 其大小为 610×340 , 包含从 $0.43 \mu\text{m}$ 至 $0.86 \mu\text{m}$ 的 115 个波段, 剔除因噪声影响的 12 个波段, 选取剩余的 103 个波段进行实验. 该数据集包括草地、树木等 9 种地物, 其假彩色图和真实地物分布如图 2 所示, 括号内为相应类别样本数量.



图2 PaviaU高光谱遥感影像

(2) KSC 数据集是在 1996 年由 AVIRIS 成像光谱仪获取的肯尼迪空间中心 (Kennedy Space Center, KSC) 影像. 其大小为 614×512 , 光谱范围 $0.4 \sim 2.45 \mu\text{m}$, 共 224 个波段. 采用剔除受大气影响及信噪比低的波段后的 176 个波段进行实验. 该数据集包含水、泥滩等 13 类地物, 其假彩色图和地面真实图如图 3 所示, 括号内为相应类别样本数量.

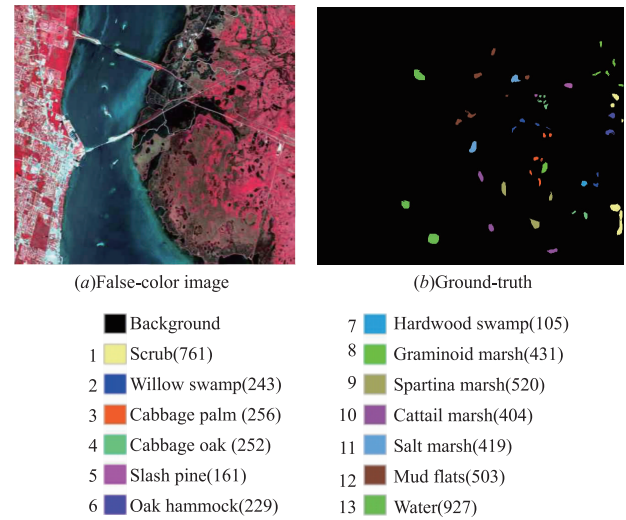


图3 KSC高光谱遥感影像

4.2 实验设置

在实验中, 将高光谱数据集随机划分为训练集和

测试集,并采用总体分类精度(Overall Accuracy, OA)、平均分类精度(Average Accuracy, AA)和 Kappa 系数三个指标来评价不同维数约简算法的性能。

为验证本文提出的 SMMDE 算法的分类性能,选取 RAW、PCA(Principal Component Analysis, PCA)^[17]、NPE(Neighborhood Preserving Embedding, NPE)^[18]、LPP(Locality Preserving Projection, LPP)^[19]、LDA(Linear Discriminant Analysis, LDA)^[20]、MFA(Marginal Fisher Analysis, MFA)^[16]、LGSFA、SMML、M-LPP、M-LLGPE 进行实验对比,其中 RAW 表示直接用分类器对样本进行分类,最后三种为多流形学习方法。在每种实验条件下,为使各种算法达到较优的分类结果,采用交叉验证反复对各算法参数进行调试。实验中, NPE、LPP、MFA、MLPP、M-LLGPE 的近邻数 k 设置为 5, LGSFA 的近邻数设置为 9, LDA 的嵌入维数设置为 $c-1$, c 为类别数。利用各算法进行学习得到低维嵌入特征后,采用分类器进行分类。M-LPP、M-LLGPE 方法采用重构误差分类器(Reconstruction Error-based Classifier, REC)进行分类,其他算法则采用最近邻分类器(1-Nearest Neighbor, 1-NN)进行分类。

4.3 PaviaU 数据集实验

在实验中,为研究不同嵌入维数对各维数约简算法的影响,从该数据集每类地物中随机选取 30 个数据进行训练,其余样本进行测试。图 4 为各算法进行 10 次实验后不同嵌入维数下平均分类精度。




图4 PaviaU数据集上各算法在各维度下的总体分类精度

从图 4 中可得知,随着嵌入维数的增加,各算法的分类精度逐渐提高,这是因为维数越高包含的信息越丰富,越有利于分类。但是嵌入维数增加到一定程度后,大部分算法分类精度趋于稳定,其原因是嵌入特征中蕴含的信息趋于饱和。相比于其他算法,本文 SMMDE 算法的分类精度在各维数下都优于其他算法,且能快速达到最佳分类性能,这是因为该算法可以更好地表征数据内在多流形结构,获取低维鉴别特征。为使各算法都能达到较好的分类性能,实验中除 LDA 外,其余

算法的嵌入维度均设置为 20。

实验中,为验证各类算法针对不同训练样本条件的分类性能,从 PaviaU 数据集每类地物中随机选取 10、20、30、40 和 50 个数据点作为训练样本,其余作为测试样本。表 1 为各算法在不同训练样本下 10 次实验的平均总体分类精度及其标准差、Kappa 系数。

由表 1 可知,随着训练样本数增加,各算法的分类精度和 Kappa 系数都有明显提升,这是因为样本数越多,蕴含信息就越丰富,越有利于进行特征提取。在相同实验条件下,本文提出的 SMMDE 算法比其他算法分类精度都高,具体分析如下:PCA、NPE、LPP 等非监督学习方法未能充分利用样本数据的类别信息,其分类性能受限;MFA 和 LGSFA 等监督学习方法,其分类性能虽有不同程度的提升,但其没有充分表征数据的潜在多流形结构,不能充分提取鉴别特征;M-LLGPE 等多流形算法分类结果相对其他方法分类精度均有明显的提升,但是对小样本的鉴别能力不足,实际应用受限;本文 SMMDE 方法充分利用数据的多流形结构构造流形内图和流形间图,有效增强了流形内数据聚集性和流形间数据分离性,提取低维鉴别特征,在不同的训练条件下均取得了最佳的分类性能,特别是小样本下效果更明显。

为对比各算法对每类地物的分类效果,从 PaviaU 数据集中随机选取 2% 作为训练样本,其余为测试样本进行研究。表 2 每类地物的分类精度、总体分类精度和 Kappa 系数,图 5 为不同算法相应的分类结果图。

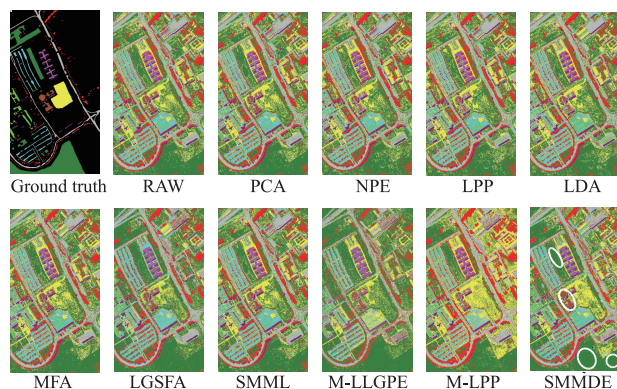


图5 各算法在PaviaU数据集上的分类图

由表 2 知,与其他算法相比, SMMDE 算法在大部分地物中都能达到较好的分类效果,且其总体分类精度、平均分类精度和 Kappa 系数均为最高,说明 SMMDE 算法能有效地揭示高光谱图像的内在多流形结构,更好地提取鉴别特征,进而有效提高分类性能。在图 5 中, SMMDE 算法得到的分类图更为光滑,特别是白色圆圈标记的“Gravel”、“Bitumen”等地物类别上效果尤为明显。

表 1 不同算法在 PaviaU 数据集上的分类精度 (OA \pm std(%)) (Kappa)

| algorithms | 10 | 20 | 30 | 40 | 50 |
|------------|--------------------------------|--------------------------------|--------------------------------|--------------------------------|--------------------------------|
| RAW | 61.79 \pm 3.29(0.531) | 67.37 \pm 1.55(0.592) | 70.47 \pm 1.67(0.628) | 71.40 \pm 1.74(0.638) | 72.93 \pm 2.03(0.657) |
| PCA | 61.78 \pm 3.29(0.531) | 67.31 \pm 1.55(0.591) | 70.37 \pm 1.68(0.627) | 71.31 \pm 1.78(0.637) | 72.85 \pm 2.03(0.656) |
| NPE | 60.10 \pm 3.27(0.511) | 63.26 \pm 1.91(0.545) | 67.76 \pm 2.20(0.596) | 69.46 \pm 1.32(0.615) | 70.72 \pm 1.79(0.631) |
| LPP | 60.63 \pm 3.09(0.517) | 63.97 \pm 2.24(0.554) | 66.11 \pm 2.52(0.577) | 70.40 \pm 1.41(0.627) | 72.50 \pm 1.53(0.653) |
| LDA | 61.05 \pm 2.79(0.523) | 64.32 \pm 2.33(0.557) | 67.48 \pm 1.84(0.588) | 70.10 \pm 1.67(0.621) | 73.24 \pm 1.59(0.659) |
| MFA | 64.15 \pm 2.92(0.558) | 69.45 \pm 1.76(0.617) | 72.51 \pm 1.34(0.652) | 73.73 \pm 1.54(0.666) | 75.03 \pm 2.30(0.683) |
| LGSFA | 56.13 \pm 5.22(0.461) | 67.50 \pm 1.50(0.590) | 72.95 \pm 2.34(0.657) | 74.14 \pm 2.49(0.671) | 76.65 \pm 2.08(0.701) |
| SMML | 61.63 \pm 3.32(0.529) | 68.72 \pm 1.57(0.606) | 70.02 \pm 1.73(0.623) | 71.05 \pm 1.71(0.634) | 72.54 \pm 1.86(0.652) |
| M-LLGPE | 64.14 \pm 7.07(0.556) | 67.32 \pm 7.61(0.591) | 68.04 \pm 4.27(0.599) | 72.76 \pm 2.62(0.656) | 73.10 \pm 2.59(0.661) |
| M-LPP | 68.73 \pm 3.66(0.609) | 73.91 \pm 2.85(0.673) | 75.67 \pm 1.71(0.694) | 78.23 \pm 2.22(0.722) | 79.67 \pm 1.14(0.738) |
| SMMDE | 70.69 \pm 1.75(0.632) | 76.25 \pm 1.72(0.698) | 79.69 \pm 1.07(0.740) | 81.47 \pm 1.45(0.752) | 83.25 \pm 1.26(0.772) |

表 2 各算法对 PaviaU 数据集上每类地物的分类精度 (%) 和分类结果

| Classes | RAW | PCA | NPE | LPP | LDA | MFA | LGSFA | SMML | MLLGPPE | MLPP | SMMDE |
|---------|-------|-------|-------|-------|-------|------------|--------------|-------|--------------|--------------|--------------|
| 1 | 80.42 | 80.34 | 78.82 | 79.50 | 79.11 | 81.76 | 82.18 | 81.33 | 75.11 | 87.76 | 83.96 |
| 2 | 90.50 | 90.26 | 82.99 | 83.21 | 83.88 | 91.31 | 96.76 | 89.55 | 96.45 | 90.86 | 96.21 |
| 3 | 52.94 | 53.18 | 45.89 | 47.10 | 48.51 | 61.83 | 59.01 | 52.79 | 49.78 | 69.08 | 75.79 |
| 4 | 74.92 | 74.89 | 73.59 | 73.52 | 73.86 | 72.79 | 87.94 | 75.29 | 54.11 | 94.73 | 79.39 |
| 5 | 98.78 | 98.78 | 98.63 | 98.86 | 98.33 | 98.93 | 99.62 | 98.71 | 99.84 | 99.77 | 99.54 |
| 6 | 58.42 | 58.42 | 48.23 | 48.39 | 47.66 | 61.85 | 50.67 | 56.71 | 46.51 | 82.30 | 74.94 |
| 7 | 83.80 | 84.03 | 60.86 | 61.70 | 65.61 | 87.10 | 80.81 | 83.42 | 76.13 | 66.38 | 92.40 |
| 8 | 75.61 | 75.49 | 71.92 | 72.42 | 72.09 | 76.74 | 69.15 | 75.91 | 58.06 | 55.26 | 77.25 |
| 9 | 99.89 | 99.89 | 99.89 | 99.89 | 99.89 | 100 | 99.24 | 99.89 | 25.32 | 99.35 | 99.89 |
| AA | 79.48 | 79.48 | 73.43 | 73.85 | 74.33 | 81.37 | 80.60 | 79.29 | 64.59 | 82.84 | 86.60 |
| OA | 81.19 | 81.08 | 74.99 | 75.34 | 75.66 | 82.64 | 83.87 | 80.74 | 76.55 | 85.23 | 88.04 |
| Kappa | 0.749 | 0.747 | 0.668 | 0.673 | 0.677 | 0.768 | 0.782 | 0.743 | 0.677 | 0.806 | 0.840 |

4.4 KSC 数据集实验

在实验中,为研究不同算法在不同嵌入维度下的分类性能,从 KSC 数据集每类地物中随机选取 30 个数据进行实验,图 6 给出了各算法在不同嵌入维度下重复 10 次实验的分类结果。

由图 6 可得,各算法 OA 值随着嵌入维度的增加而不断提高,而后趋于稳定.与此同时,SMMDE 算法在大多数嵌入维数中其分类精度优于其他算法,这是表明本文提出的 SMMDE 算法能更有效发现高光谱数据中的多流形结构,提取低维鉴别特征.在后续实验中,LDA 算法的嵌入维数为 $c-1$,其他算法的嵌入维数均设置为 20,以保证各算法获得较好的分类效果。

为验证各类算法在不同训练样本情况下的分类性能,实验中从 KSC 数据集每类地物中随机选取 10、20、30、40 和 50 个数据点作为训练样本,其余作为测试样




图 6 KSC 数据集上各算法在各嵌入维度下的总体分类精度

本进行实验.表 3 为各类算法在不同训练样本下进行 10 次重复实验的平均总体分类精度及其标准差、Kappa 系数。

表 3 不同算法在 KSC 数据集上的分类精度(OA \pm std(%))(Kappa)

| algorithms | 10 | 20 | 30 | 40 | 50 |
|------------|---|---|---|---|---|
| RAW | 72.96 \pm 1.33(0.699) | 78.30 \pm 1.04(0.758) | 80.68 \pm 0.98(0.784) | 82.14 \pm 0.72(0.800) | 83.61 \pm 0.64(0.816) |
| PCA | 72.92 \pm 1.34(0.699) | 78.21 \pm 1.04(0.757) | 80.59 \pm 1.02(0.783) | 82.00 \pm 0.67(0.799) | 83.44 \pm 0.67(0.815) |
| NPE | 53.36 \pm 5.07(0.485) | 70.56 \pm 2.05(0.673) | 78.09 \pm 1.21(0.756) | 81.65 \pm 1.15(0.795) | 83.33 \pm 1.83(0.813) |
| LPP | 52.76 \pm 3.84(0.479) | 65.00 \pm 1.81(0.612) | 76.65 \pm 1.41(0.740) | 81.44 \pm 1.57(0.793) | 84.01 \pm 1.22(0.821) |
| LDA | 61.87 \pm 3.30(0.580) | 79.42 \pm 1.17(0.771) | 86.37 \pm 0.69(0.848) | 88.78 \pm 0.60(0.874) | 90.18 \pm 0.55(0.890) |
| MFA | 72.98 \pm 1.41(0.700) | 78.23 \pm 1.04(0.758) | 80.59 \pm 1.02(0.783) | 82.07 \pm 0.63(0.780) | 83.57 \pm 0.61(0.816) |
| LGSFA | 77.44 \pm 1.29(0.749) | 84.27 \pm 0.82(0.825) | 86.97 \pm 0.76(0.854) | 87.65 \pm 0.59(0.862) | 88.44 \pm 0.70(0.870) |
| SMML | 72.64 \pm 1.33(0.696) | 77.90 \pm 1.21(0.754) | 80.28 \pm 1.02(0.780) | 81.78 \pm 0.76(0.796) | 83.06 \pm 0.67(0.810) |
| M-LLGPE | 76.98 \pm 2.81(0.744) | 83.62 \pm 1.78(0.817) | 83.87 \pm 1.54(0.820) | 86.29 \pm 0.73(0.847) | 86.94 \pm 0.67(0.854) |
| M-LPP | 73.73 \pm 2.29(0.709) | 77.38 \pm 2.27(0.748) | 79.58 \pm 3.58(0.772) | 89.12 \pm 0.86(0.878) | 90.18 \pm 0.78(0.890) |
| SMMDE | 82.50 \pm 1.34(0.806) | 87.42 \pm 0.86(0.861) | 89.98 \pm 0.90(0.887) | 90.75 \pm 0.61(0.896) | 91.45 \pm 0.80(0.905) |

表 4 各算法对 KSC 数据集上每类地物的分类精度(%)和分类结果

| Classes | RAW | PCA | NPE | LPP | LDA | MFA | LGSFA | SMML | MLLGPPE | MLPP | SMMDE |
|---------|-------|-------|-------|-------|-------|-------|-------|-------|--------------|--------------|--------------|
| 1 | 79.08 | 78.95 | 49.33 | 27.34 | 66.08 | 78.95 | 80.69 | 78.82 | 83.38 | 89.54 | 86.86 |
| 2 | 66.52 | 66.52 | 32.62 | 22.31 | 57.08 | 66.52 | 75.96 | 67.81 | 87.55 | 87.12 | 78.11 |
| 3 | 60.57 | 60.16 | 20.32 | 20.32 | 42.68 | 59.75 | 73.17 | 60.57 | 59.75 | 48.78 | 73.17 |
| 4 | 37.19 | 37.19 | 16.12 | 9.09 | 31.82 | 36.77 | 40.49 | 36.36 | 54.96 | 52.48 | 60.33 |
| 5 | 62.91 | 62.91 | 25.83 | 19.86 | 31.79 | 62.91 | 63.57 | 63.57 | 58.94 | 68.87 | 62.91 |
| 6 | 36.07 | 36.98 | 16.89 | 22.37 | 15.52 | 36.53 | 41.55 | 36.53 | 49.77 | 45.66 | 42.92 |
| 7 | 76.84 | 77.89 | 55.79 | 35.78 | 49.47 | 76.84 | 81.05 | 76.84 | 77.89 | 92.63 | 93.68 |
| 8 | 67.69 | 67.69 | 38.95 | 27.55 | 50.59 | 67.69 | 72.21 | 67.69 | 82.42 | 93.58 | 79.57 |
| 9 | 85.88 | 86.27 | 38.23 | 40.00 | 55.09 | 86.08 | 89.60 | 86.08 | 72.55 | 97.84 | 96.86 |
| 10 | 75.38 | 75.12 | 57.61 | 28.93 | 76.14 | 75.13 | 81.72 | 75.89 | 77.15 | 88.32 | 87.06 |
| 11 | 90.46 | 90.71 | 81.42 | 74.32 | 66.01 | 90.71 | 93.64 | 90.46 | 99.75 | 98.53 | 94.62 |
| 12 | 72.82 | 72.82 | 28.80 | 60.04 | 45.23 | 72.82 | 77.28 | 72.62 | 46.04 | 6.69 | 79.31 |
| 13 | 97.79 | 97.79 | 89.32 | 96.81 | 88.76 | 97.79 | 97.90 | 97.79 | 97.79 | 99.01 | 99.01 |
| AA | 69.94 | 70.08 | 42.40 | 37.29 | 52.02 | 69.88 | 74.53 | 70.08 | 72.92 | 74.54 | 79.57 |
| OA | 76.33 | 76.39 | 50.01 | 46.46 | 59.80 | 76.30 | 80.06 | 76.39 | 77.40 | 78.66 | 84.53 |
| Kappa | 0.737 | 0.738 | 0.446 | 0.410 | 0.556 | 0.736 | 0.778 | 0.737 | 0.749 | 0.762 | 0.828 |

通过分析表 3 可知,各算法的分类精度随训练样本数增加而提高,同时监督流形学习方法的分类性能要优于非监督学习方法.在不同实验条件下,SMMDE 的分类效果均优于其他算法,在训练样本较少时尤为明显.这是由于 SMMDE 方法通过对划分后的子流形数据进行学习,引入图嵌入框架,分别构造流形内图和流形间图,根据同一子流形和不同子流形间的数据之间的相似性,在低维嵌入空间使流形内数据尽可能聚集、流形间数据尽可能分散,改善了数据的可分性,使不同地物类别的嵌入特征间距最大化,有效提升分类精度,更有利于实际应用.

为进一步表明 SMMDE 算法对每类地物的分类性能,从 KSC 数据集中随机选取 2% 作为训练样本,其余为测试样本进行研究.表 4 为每类地物的分类精度、总体分类精度和 Kappa 系数.图 7 为不同算法的分类结果图.

由表 4 可知,相比于其他算法,SMMDE 在大多数地物类别中都能获得最佳分类效果,且总体分类精度、平均分类精度及 Kappa 系数最高,这表明 SMMDE 能充分揭示高光谱数据的内蕴特性,有利于高光谱数据地物分类.在图 7 中,SMMDE 算法得到的分类图更平滑,特别是白色圈标记的“Water”、“Hardwood swamp”等地

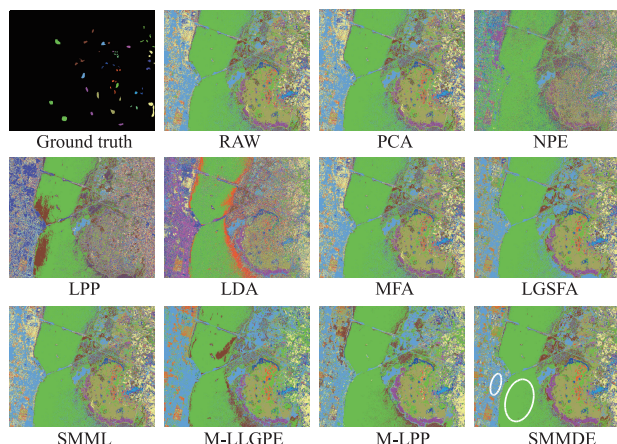


图7 各算法在KSC数据集上的分类图

物类别更为明显。

5 结论

针对目前单流形学习方法不能有效发现高维数据中的多流形结构,本文提出了一种监督多流形鉴别嵌入特征提取算法,并应用于高光谱数据地物分类.该方法将每类地物视为一个子流形,并利用样本数据的类别标签进行子流形划分,在此基础上通过构造类内流形图和类间流形图,并在低维嵌入空间中使流形内距离尽可能最小化、流形间距离尽可能最大化,使类内数据聚集、类间数据分散,增加不同地物间可分性,有效提取鉴别特征,进而改善分类效果.在 PaviaU 和 KSC 高光谱数据集上的实验结果表明,本文提出的 SMMDE 算法与其他单流形、多流形算法相比,分类精度更高,分类效果更明显。

由于高光谱影像具有丰富的光谱及空间信息,本文方法仅考虑了高光谱影像的光谱信息,而忽略了数据的位置空间信息.因此,后续研究将考虑融入空间信息,开展空-谱多流形学习方面的研究工作,进一步提升地物分类性能。

参考文献

- [1] 宋相法,焦李成. 基于稀疏表示及光谱信息的高光谱遥感图像分类[J]. 电子与信息学报, 2012, 34(2): 268-272.
SONG Xiang-fa, JIAO Li-cheng. Classification of hyperspectral remote sensing image based on sparse representation and spectral information[J]. Journal of Electronics & Information Technology, 2012, 34(2): 268-272. (in Chinese)
- [2] 张绍泉,李军,邓承志,汪胜前. 空谱联合的高光谱遥感图像稀疏解混综述与展望[J]. 南昌工程学院学报, 2018, 37(6): 99-105.

ZHANG Shao-quan, LI Jun, DENG Cheng-zhi, WANG Sheng-Qian. Survey and prospect of spatial-spectral sparse regression-based hyperspectral image unmixing[J]. Journal of Nanchang Institute of Technology, 2018, 37(6): 99-105. (in Chinese)

- [3] 杜培军,夏俊士,薛朝辉,等. 高光谱遥感影像分类研究进展[J]. 遥感学报, 2016, 20(2): 236-256.
DU Pei-jun, XIA Jun-shi, XUE Zhao-hui, et al. Review of hyperspectral remote sensing image classification[J]. Journal of Remote Sensing, 2016, 20(2): 236-256. (in Chinese)
- [4] 童庆禧,张兵,张立福. 中国高光谱遥感的前沿进展[J]. 遥感学报, 2016, 20(5): 689-707.
TONG Qing-xi, ZHANG Bing, ZHANG Li-fu. Current progress of hyperspectral remote sensing in China[J]. Journal of Remote Sensing, 2016, 20(5): 689-707. (in Chinese)
- [5] 王雪松,胡汇涓,程玉虎. 遥感影像的半监督判别局部排列降维[J]. 电子学报, 2014, 42(1): 84-88.
WANG Xue-song, HU Hui-juan, CHENG Yu-hu. Dimensionality reduction of remote sensing image using semi-supervised discriminative locality alignment[J]. Acta Electronica Sinica, 2014, 42(1): 84-88. (in Chinese)
- [6] 唐意东,黄树彩,薛爱军. 面向目标检测基于稀疏表示的波段选择方法[J]. 电子学报, 2017, 45(10): 2368-2374.
TANG Yi-dong, HUANG Shu-cai, XUE Ai-jun. Sparse representation based band selection for hyperspectral imagery target detection[J]. Acta Electronica Sinica, 2017, 45(10): 2368-2374. (in Chinese)
- [7] 陈允杰,马辰阳,等. 基于边缘修正的高光谱图像超像素空谱核分类方法[J]. 电子学报, 2019, 47(1): 73-81.
CHEN Yun-jie, MA Chen-yang, et al. Edge-modified superpixel based spectral-spatial kernel method for hyperspectral image classification[J]. Acta Electronica Sinica, 2019, 47(1): 73-81. (in Chinese)
- [8] BACHMANN C M, AINSWORTH T L, FUSINA R A. Exploiting manifold geometry in hyperspectral imagery[J]. IEEE Transactions on Geoscience and Remote Sensing, 2005, 43(3): 441-454.
- [9] 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): 6197-6211.
- [10] HUANG H, LUO F L, LIU J M, et al. Dimensionality reduction of hyperspectral images based on sparse discriminant manifold embedding[J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2015, 106: 42-54.
- [11] LV M, HOU Q L, et al. Collaborative discriminative manifold embedding for hyperspectral imagery[J]. IEEE Geo-

- science and Remote Sensing Letters, 2017, 14 (4) : 569 – 573.
- [12] 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学报, 2012, 24(6) : 780 – 786.
WANG Li-zhi, HUANG Hong, FENG Hai-liang. Multi-linear 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. (in Chinese)
- [13] XIAO R, ZHAO Q J, et al. Facial expression recognition on multiple manifolds [J]. Pattern Recognition, 2011, 44 (1) : 107 – 116.
- [14] HETTIARACHCHI R, PETERS J F. Multi-manifold LLE learning in pattern recognition [J]. Pattern Recognition, 2015, 48(9) : 2947 – 2960.
- [15] SHI L K, HAO J S, ZHANG X. Image recognition method based on supervised multi-manifold learning [J]. Journal of intelligent & fuzzy systems, 2017, 32(3) : 2221 – 2232.
- [16] 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.
- [17] PRASAD S, BRUCE L M. Limitations of principal components analysis for hyperspectral target recognition [J]. IEEE Geoscience and Remote Sensing Letters, 2008, 5 (4) : 625 – 629.
- [18] HE X F, CAI D, YAN S C, et al. Neighborhood preserving embedding [A]. Tenth IEEE International Conference on Computer Vision (ICCV) [C]. Beijing, China: IEEE, 2005. 1208 – 1213.
- [19] HE X F, YAN S, HU Y, et al. Face recognition using Laplacianfaces [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2005, 27(3) : 328 – 340.
- [20] BANDOS T V, et al. Classification of hyperspectral images with regularized linear discriminant analysis [J]. IEEE Transactions on Geoscience and Remote Sensing, 2009, 47 (3) : 862 – 873.

作者简介



黄 鸿 男, 1980 年生于湖南新宁, 2008 年获重庆大学博士学位, 现为重庆大学教授、博士生导师. 主要研究方向为无人机遥感、遥感信息处理、流形学习、稀疏表示等.
E-mail: hhuang@cqu.edu.cn



王丽华 女, 1993 年生于云南宣威, 硕士研究生, 2017 年获郑州大学学士学位, 主要研究方向为图像处理、遥感影像分类等.
E-mail: 20170802019t@cqu.edu.cn



石光耀 男, 1988 年生于河南项城, 博士研究生, 2015、2017 年于重庆大学分别获得学士和硕士学位, 主要从事图像处理、遥感影像分类、机器视觉等方面的研究.
E-mail: shiguangyao@cqu.edu.cn