

文章编号 1004-924X(2015)05-1434-09

## 面向高光谱图像分类的半监督丛流形学习

李志敏<sup>1</sup>, 张杰<sup>1\*</sup>, 黄鸿<sup>1</sup>, 江涛<sup>2</sup>

- (1. 重庆大学 光电技术与系统教育部重点实验室, 重庆 400044;
2. 酒泉卫星发射中心, 甘肃 酒泉 735300)

**摘要:** 考虑高光谱遥感数据集多类别非线性的特点, 本文假设高光谱遥感数据集具有丛流形结构属性, 提出了一种半监督丛流形学习(SSBML)算法来有效提取高光谱遥感图像的鉴别特征。该算法利用标记样本和无标记样本构建两个邻域关系图来保持数据集中丛流形的“整体”结构(各个子流形之间的相互关系)和每个子流形的内蕴结构特征, 实现半监督的丛流形学习。在肯尼迪航天中心(KSC)和帕维亚大学(PaviaU)高光谱数据集上的实验结果表明: 该算法可以发现高光谱遥感数据集中丛流形结构的精细特征, 有效提升高光谱遥感图像的分类精度。实验显示: 该算法的总体分类精度比单一流形假设的局部保形投影(LPP)和邻域保持嵌入(NPE)算法提升了约2.9%~15.7%, 比半监督最大边界准则(SSMMC)和半监督流形保持嵌入(SSSMPE)等半监督算法提升了约2.6%~12.4%。

**关键词:** 高光谱遥感图像; 鉴别特征; 丛流形结构; 半监督丛流形学习

**中图分类号:** TP751.1    **文献标识码:** A    **doi:** 10.3788/OPE.20152305.1434

## Semi-supervised bundle manifold learning for hyperspectral image classification

LI Zhi-min<sup>1</sup>, ZHANG Jie<sup>1\*</sup>, HUANG Hong<sup>1</sup>, JIANG Tao<sup>2</sup>

- (1. Key Laboratory of Optoelectronic Technique and Systems of the Ministry of Education, Chongqing University, Chongqing 400044, China;
  2. Jiuquan Satellite Launch Center, Jiuquan 735300, China)
- \* Corresponding author, E-mail: zhangjie\_fly@126.com

**Abstract:** On the basis of multi-class and nonlinear characteristics of hyperspectral remote sensing image database, this paper assumes that hyperspectral remote sensing database have a bundle manifold structure property and proposes a Semi-supervised Bundle Manifold Learning (SSBML) algorithm to effectively extract the discriminant characteristics of hyperspectral remote sensing image. The algorithm uses labeled samples and unlabeled samples to construct two neighborhood graphs to maintain a “whole” structure (the relationship between the various sub-manifolds) of bundle manifold in the data set and the intrinsic structure characteristics in each sub-manifold. By which, it achieves

**收稿日期:** 2014-12-04; **修订日期:** 2015-02-02.

**基金项目:** 国家自然科学基金资助项目(No. 61101168, No. 41371338); 中国博士后科学基金资助项目(No. 2012M511906, No. 2013T60837); 重庆市基础与前沿研究计划资助项目(No. cstc2013jcyjA40005); 重庆市博士后科研资金特别资助项目(No. XM2012001); 中央高校基本科研业务费专项资金资助项目(No. 1061120131204, No. 106112013CDJZR125501)

semi-supervised bundle manifold learning. The experimental results on Kennedy Space Center(KSC) and PaviaU hyperspectral database show that the algorithm efficiently discovers the subtle characteristics of the bundle manifold structure in hyperspectral remote sensing database, and enhances the classification accuracy of hyperspectral remote sensing images. For the overall classification accuracy, this algorithm is improved by 2.9%—15.7% as compared with those of Locality Preserving Projection(LPP) and Neighborhood Preserving Embedding(NPE) algorithm based on single-manifold assumptions, and increased by 2.6%—12.4% as compared with those of the Semi-Supervised Maximum Margin Criterion (SSMMC) and the Semi-Supervised Sub-Manifold Preserving Embedding(SSMPE) based on semi-supervised algorithms.

**Key words:** hyperspectral remote sensing image; discriminant characteristics; bundle manifold structure; Semi-supervised Bundle Manifold Learning(SSBML)

## 1 引言

由于高光谱遥感图像具有详细的地物几何空间及丰富的光谱特征信息,故其数据量大、维数高、冗余性强,如果直接对其进行分类,容易产生“维数灾难”问题<sup>[1-2]</sup>。因此,如何提取出有用的鉴别特征信息以提升高光谱图像的分类性能已成为一个亟待深入探究的问题<sup>[3-4]</sup>。

目前,研究者已提出了一系列的有关高维数据降维及特征提取的理论和算法。如传统的主成分分析(Principal Component Analysis, PCA)<sup>[5]</sup>、线性判别分析(Linear Discriminant Analysis, LDA)<sup>[6]</sup>、极大边界准则(Maximum Margin Criterion, MMC)<sup>[7]</sup>等,这些算法均为全局假设的线性算法,不适用于非线性属性的数据集降维。近年来,学者们还提出各种基于局部邻域关系的流形学习方法,如等距映射(Isometric Feature Mapping, ISOMAP)<sup>[8]</sup>、局部线性嵌入(Locally Linear Embedding, LLE)<sup>[9]</sup>、拉普拉斯特征映射(Laplacian Eigenmap, LE)<sup>[10]</sup>等,这些方法虽然具有较好的非线性流形学习能力,但不能学习处理新样本。文献[11]和文献[12]分别提出邻域保持嵌入(Neighborhood Preserving Embedding, NPE)算法和局部保持投影(Locality Preserving Projection, LPP)算法,有效地解决了新样本的学习问题,但这些算法都是基于数据集中只存在单一流形结构的假设下提出来的,难以发现多流形或者丛流形结构的精细特征。

此外,在高光谱遥感图像分类的实际应用中,为降低人工标记样本所需的高额成本,需要同时

利用标记样本和大量未标记样本的鉴别特征信息,来提升分类精度。因此,研究者提出了半监督的学习方法。例如,文献[13]和文献[14]分别提出半监督最大边界准则(Semi-supervised Maximum Margin Criterion, SSMMC)算法和半监督流形保持嵌入(Semi-supervised Sub-Manifold Preserving Embedding, SSSMPE)算法,将它们用于图像识别时具有较好的识别效果。

本文假设高光谱遥感数据集具有丛流形的结构属性,并提出一种半监督丛流形学习(Semi-supervised Bundle Manifold Learning, SSBML)算法。该算法利用标记样本和无标记样本构建两个不同的近邻关系图来保持数据集中丛流形结构的“整体”联系(各个子流形之间的相互关系)和每个子流形的内蕴结构特征,实现半监督的丛流形学习。另外,该算法得到了一个明晰的目标投影矩阵,对训练样本集外的新样本点具有学习能力,从而解决了高光谱遥感数据中新样本的分类问题。

## 2 半监督的丛流形学习

### 2.1 丛流形学习

假设在拥有多种类别数据的数据集中,相同类别的数据点因具有某种潜在的相同因子而构成一个数据子集,且它们分布在同一个子流形上,而不同类别的数据点构成的数据子集对应不同的子流形结构,同时各个不同的子流形结构之间又具有某种相互联系,那么数据集在特征空间中形成了一种丛流形的结构特征。传统的流形学习算法几乎都是假设数据集分布于单一流形结构,而数据集中具有多流形或丛流形结构的情况,则难以

获得各个子流形结构的精细结构。文献[15]中提出一种非局部流形学习 (non-local manifold learning) 算法。它是以监督的方式处理多个流形的数据集, 即该算法要求数据点的近邻点必须位于同一流形上。另外, Li Chun-Guang 等提出无监督的丛流形学习 (Bundle Manifold Learning)<sup>[16]</sup> 算法, 其主要思想是通过构建两重邻域关系图, 使它们分别对应丛流形结构中各个子流形之间的外在关系和每个子流形结构的内蕴结构, 进而利用特征图方法来保持丛流形的精细特征。该算法能够较好地从高维空间中获丛流形结构的低维嵌入表示, 但它是一种无监督的流形学习算法, 没有利用标记数据点的标记信息, 且没有具体、明晰的投影矩阵, 不能处理训练样本集外的新样本点, 从而不能直接应用于高光谱遥感图像的分类处理问题中。

### 2.2 半监督的丛流形学习

基于丛流形学习的思想, 以及高光谱遥感数据的多类别特点, 假设高光谱遥感数据集中具有类似丛流形结构的属性特征, 为保持这种丛流形结构关系, 需要同时保持数据集中各个子流形之间的相互关系和每个子流形的内蕴结构。基于 Li Chun-Guang 等提出的两重邻域关系图思想, 本文提出一种半监督丛流形学习 (SSBML) 方法。该算法充分利用标记数据点和大量无标记数据点, 构建各个子流形之间的外近邻关系图  $G_b$  和每个子流形的内近邻关系图  $G_w$  来保持数据集中丛流形结构的精细特征, 实现半监督的丛流形学习。另外该算法会得到一个具体的目标投影矩阵, 能够将新样本点直接从高维特征空间映射到低维特征空间, 从而解决高光谱遥感数据中新样本的分类处理问题。

实现半监督的丛流形学习算法的步骤如下:

(1) 构建外近邻关系图  $G_b$ , 保持丛流形结构中各个子流形之间的相互关系。

据分析, 维护各个子流形之间的相互关系可以通过保持数据集中丛流形结构的“整体”关系来实现, 这种“整体”是相对于子流形而言的。在此, 将数据集形式化为一个近邻加权图  $G_b = (V, E)$ , 图  $G_b$  中顶点  $V$  对应数据集中的各数据点, 边  $E$  表示数据点之间的邻域关系或者相似度, 其权重值  $W$  的关系表达式如下:

$$W_{ij} = \begin{cases} e^{-\frac{\|x_i - x_j\|}{\sigma_i \sigma_j}}, & x_i \in k(x_j) \text{ or } x_j \in k(x_i) \\ 0, & \text{otherwise} \end{cases}, \quad (1)$$

其中:  $\sigma_i = \|x_i - x_i^k\|_2, \sigma_j = \|x_j - x_j^k\|_2, x_i^k, x_j^k$  分别表示  $x_i, x_j$  的第  $k$  个近邻点,  $k(x_i), k(x_j)$  分别表示  $x_i, x_j$  的  $k$  近邻点集合。由此可得到一个包含有丛流形“整体”结构关系的权重矩阵  $W = [w_{ij}]_{N \times N}$ 。利用该权重矩阵可以保持数据集中丛流形结构的“整体”结构关系, 从而保持各个子流形之间的相互关系。但外近邻关系图  $G_b$  不包含标记类别信息, 因此该权重矩阵不能很好地突出分类识别能力。

(2) 构建内近邻关系图  $G_w$ , 保持丛流形结构中每个子流形的内蕴结构。

假设相同类别的数据子集内的每个数据点均与其近邻的数据点分布于同一光滑的子流形结构上, 且具有局部线性特性, 即可由其最近邻数据点重构出来。首先利用数据点之间的欧式距离  $d(x_i, x_j) = \sqrt{\|x_i - x_j\|^2}$  计算每个数据点  $x_i$  的  $k$  个最近邻点, 即  $k(x_i)$ ; 再通过数据点的标记信息和是否为近邻关系将欧式距离调整为如下距离关系:

$$D^2(x_i, x_j) = \begin{cases} -e^{-\frac{d^2(x_i, x_j)}{\sigma_i \sigma_j}}, & \text{if } c_i = c_j \\ 1 - e^{-\frac{d^2(x_i, x_j)}{\sigma_i \sigma_j}}, & \text{if } x_i \text{ or } x_j \text{ is unlabeled,} \\ & x_i \in k(x_j) \text{ or } x_j \in k(x_i) \\ e^{-\frac{d^2(x_i, x_j)}{\sigma_i \sigma_j}}, & \text{otherwise} \end{cases} \quad (2)$$

其中:  $c_i, c_j$  分别表示  $x_i, x_j$  的标记信息,  $D^2(x_i, x_j)$  的函数曲线如图 1 所示。

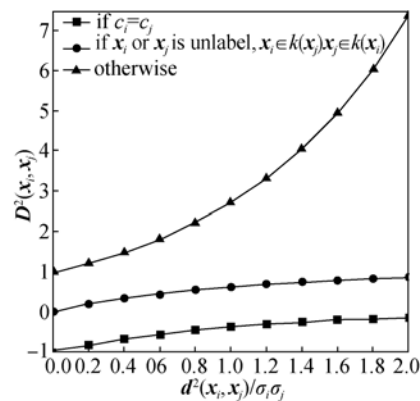


图 1  $D^2(x_i, x_j)$  的函数曲线

Fig. 1 Function curves of  $D^2(x_i, x_j)$

由图1可知,若  $x_i$  与  $x_j$  同类时,  $-1 < \mathbf{D}^2(x_i, x_j) < 0$ ; 若  $x_i$  或  $x_j$  无标记, 但为近邻关系时,  $0 < \mathbf{D}^2(x_i, x_j) < 1$ ; 若  $x_i$  与  $x_j$  有标记且不同类、无标记且非近邻关系时,  $1 < \mathbf{D}^2(x_i, x_j) < \infty$ 。通过调整  $\mathbf{D}^2(x_i, x_j)$  使相同类别的标记数据点和互为近邻关系的无标记数据点始终保持距离较近, 不同类别的标记数据点之间和非近邻关系的无标记数据点之间始终保持距离较远, 然后利用该  $\mathbf{D}^2(x_i, x_j)$  距离关系构建内近邻关系图  $\mathbf{G}_w$ , 并通过  $\mathbf{D}^2(x_i, x_j)$  重新计算每个数据点的最近邻点  $x_i^j, j \in N(x_i)$ , 其中  $N(x_i)$  表示距离调整后  $x_i$  的最近邻点的标号集合, 再由  $x_i$  的最近邻点集合重构  $x_i$ , 其表达式如下:

$$\begin{aligned} \min \epsilon(\omega_{ij}) &= \left\| x_i - \sum_{j \in N(x_i)} q_{ij} x_i^j \right\|^2 \\ \text{s. t.} \quad &\sum_{j \in N(x_i)} q_{ij} = 1 \\ &q_{ij} > 0, \end{aligned} \quad (3)$$

其中:  $q_{ij}$  是重构系数, 若  $j \notin N(x_i)$ , 则  $q_{ij} = 0$ 。于是, 可以得到基于内近邻关系图  $\mathbf{G}_w$  的重构系数矩阵  $\mathbf{Q}$ 。可知, 内近邻关系图  $\mathbf{G}_w$  利用数据点的标记类别信息, 重构系数矩阵  $\mathbf{Q}$  携带各个子流形的内蕴结构关系, 从而保持了各个子流形结构之间的精细差异, 具有分类识别能力。

(3) 组合关系矩阵, 将高维数据集映射到低维嵌入空间。

基于外近邻关系图  $\mathbf{G}_b$  和内近邻关系图  $\mathbf{G}_w$ , 采用线性方法来组合近邻关系矩阵  $\mathbf{W}$  和重构系数矩阵  $\mathbf{Q}$ ,  $\mathbf{U} = (1 - \alpha)\mathbf{W} + \alpha\mathbf{Q}$ 。取  $0 < \alpha < 1$ , 当  $\alpha$  越大时, 丛流形结构中子流形的内蕴结构越突出。利用组合关系矩阵  $\mathbf{U}$ , 采用类似 Laplacian Eigenmap 方式来构造如下目标函数:

$$\begin{aligned} \min \quad &\frac{1}{2} \sum_{i,j=1}^N (y_i - y_j)^2 u_{ij} = \\ &\frac{1}{2} \sum_{i,j=1}^N (y_i u_{ij} y_i^T + y_j u_{ij} y_j^T - y_i u_{ij} y_j^T - y_j u_{ij} y_i^T) = \\ &\mathbf{YDY}^T - \mathbf{YWY}^T \\ &= \text{tr}(\mathbf{YL}_u \mathbf{Y}^T) = \\ &\text{tr}(\mathbf{A}^T \mathbf{X} \mathbf{L}_u \mathbf{X}^T \mathbf{A}), \end{aligned} \quad (4)$$

其中:  $\mathbf{L}_u = \mathbf{D} - \mathbf{U}$ ,  $\mathbf{D}$  为对角矩阵,  $\mathbf{D}_{ii} = \sum_{j=1}^N \mathbf{U}_{ij}$ ,  $\mathbf{A}$  为投影矩阵,  $\mathbf{A}^T \mathbf{X} = \mathbf{Y}$ 。为去除因尺度不同带来的影响, 增加约束条件  $\mathbf{YDY}^T = \mathbf{I}$ , 根据 Lagrange 乘

子法可得:

$$\mathbf{X} \mathbf{L}_u \mathbf{X}^T \mathbf{A} = \lambda \mathbf{X} \mathbf{D} \mathbf{X}^T \mathbf{A}. \quad (5)$$

通过对式(5)求取广义特征值和特征向量, 取出  $d$  个最小的特征值及其对应的特征向量  $a_1, a_2, \dots, a_d$ , 构成投影矩阵  $\mathbf{A} = [a_1, a_2, \dots, a_d]$ , 计算低维嵌入空间  $\mathbf{Y} = \mathbf{A}^T \mathbf{X}$ 。

本文 SSBML 算法的详细步骤, 如表1所示。

表1 SSBML 算法步骤

Tab. 1 Process of SSBML algorithm

输入:  $N$  个训练样本点的数据  $\mathbf{X} = \{(x_1, l_1), (x_2, l_2), \dots, (x_i, l_i), x_{i+1}, \dots, x_N\}$ ,  $x_i \in \mathbb{R}$  和低维嵌入空间维数  $d$ , 其中  $l_i$  表示标记信息。

输出: 最佳投影矩阵  $\mathbf{A}$ , 低维嵌入空间  $\mathbf{Y}$

Step1: 构建外近邻关系图  $\mathbf{G}_b$ , 利用式(1)得到权重矩阵  $\mathbf{W}$ ;

Step2: 构建内近邻关系图  $\mathbf{G}_w$ , 利用式(3)得到重构系数矩阵  $\mathbf{Q}$ ;

Step3: 采用线性方法来组合近邻关系矩阵  $\mathbf{W}$  和重构系数矩阵  $\mathbf{Q}$ , 得到组合矩阵  $\mathbf{U} = (1 - \alpha)\mathbf{W} + \alpha\mathbf{Q}$ ;

Step4: 利用式(5)计算投影矩阵  $\mathbf{A}$  和低维嵌入空间  $\mathbf{Y}$ 。

### 3 实验与分析

在 Intel (R) Core (TM) 2 T6570 2.10Hz CPU 和 2.00GB RAM 硬件平台上进行实验, 利用 matlab 软件对 KSC (Kennedy Space Center, KSC) 和 PaviaU (Pavia University) 高光谱遥感数据集中不同地物数据进行分类识别。首先通过各种特征提取算法提取出 KSC 和 PaviaU 高维数据集中不同的鉴别特征, 然后在低维嵌入空间中采用 K-近邻 (K-NN) 分类器进行分类处理。为验证 SSBML 算法的有效性, 在各算法参数选取最优的条件下将 PCA、LDA、LPP、NPE、MMC、SSMMC 及 SSMPE 算法与 SSBML 算法的实验结果进行比较分析。

#### 3.1 KSC 数据集

KSC 数据集是位于美国 Florida 的肯尼迪航天中心的高光谱遥感图像, 如图2所示。已知该遥感图像大小为  $614 \text{ pixel} \times 512 \text{ pixel}$ , 光谱为  $400 \sim 2500 \text{ nm}$ , 波段数为 224, 经过预处理后将剩余的 176 个波段进行分类实验研究。该数据集中含有 13 类已知地物, 共有 5211 个样本点, 本

实验选取其中含地物数据样本点最多的 12 个类别数据进行分类实验,其类别信息如表 2 所示。

本实验从表 2 中的每类已知地物中分别随机选取 10,20,30 个标记样本和 30 个无标记样本作为训练样本,100 个样本点作为测试样本。每种算法重复进行 10 次分类实验,然后对 10 次实验的分类精度求平均值得到最终的总体分类精度;并且在不同的低维嵌入空间维数下进行了分类实验。为对比分析不同算法在不同训练样本数目情况下的分类效果,图 3 给出了不同算法在不同训练样本数、不同维数下分类实验的总体分类精度;同时,表 3 给出了不同算法在不同训练样本数情况下的最高总体分类精度值及其标准偏差和所在低维嵌入空间的维数。



图 2 KSC 高光谱遥感图像

Fig. 2 Hyperspectral remote sensing image of KSC

此外,为进一步验证 SSBML 算法的丛流形学习能力,对表 2 中每种地物类别数据分别进行识别实验。从具体地物中随机选取 30 个标记样本和 30 个无标记样本作为训练样本,100 个样本点作为测试样本。在低维嵌入空间维数  $d=30$  ( $d_{LDA}=11$ )下重复进行 10 次实验,统计得出 10 次识别实验的平均识别率作为最终结果,由表 4 给出不同类别数据在不同算法下的识别率。

表 2 KSC 数据集的类别信息

Tab. 2 Label information of KSC data set

Category	Class name	Sample number
C1	Water	927
C2	Scrub	761
C3	Spartina marsh	520
C4	Mud flats	503
C5	Graminoid marsh	431
C6	Salt marsh	419
C7	Cattail marsh	404
C8	Cabbage Palm hammock	256
C9	Cabbage Palm/oak	252
C10	Oak/broadleaf hammock	229
C11	Willow swamp	243
C12	Slash pine	161




图 3 不同算法在不同训练样本数、不同维数下的总体分类精度

Fig. 3 Overall classification accuracy of different algorithms with different trains in different dimensions

由图 3 可知,SSBML 算法在分类性能上明显优于其它几种算法。这是因为 SSBML 算法是在高光谱遥感数据集的多类别特点、丛流形假设前提下提出的,通过标记样本和无标记样本构建两

个近邻关系图来分别保持丛流形结构中各个子流形之间的相互关系和每个子流形的内蕴结构,有效提取出高光谱遥感数据集中丛流形结构的精细特征,故具有更高的分类精度。

表 3 不同算法在 KSC 数据集中的最高总体分类精度 (平均值±标准偏差(%)(维数))

Tab. 3 The highest overall classification accuracy of different algorithms in KSC data set (mean ± std(%)(dimensions))

Algorithm	10labels	20 labels	30 labels
	30unlabels	30unlabels	30unlabels
PCA	66.78±2.30(33)	74.08±1.34(49)	75.91±0.88(43)
LDA	60.10±2.85(11)	72.14±2.27(11)	82.18±1.00(11)
LPP	75.06±0.79(36)	78.68±1.28(37)	81.40±1.39(36)
NPE	71.45±1.69(43)	74.02±1.24(50)	73.88±1.40(44)
MMC	65.80±2.27(46)	71.75±1.62(22)	73.54±0.73(15)
SSMMC	74.78±0.97(11)	76.93±0.95(37)	77.17±0.76(46)
SSSMPE	79.87±1.97(18)	83.27±1.78(39)	84.22±2.84(27)
SSBML	83.78±1.09(28)	87.66±0.82(29)	89.59±1.23(19)

PCA 算法是通过最小化均方误差来寻求全局线性最佳逼近,目的是消除高维数据中的冗余性,但高光谱遥感数据是非线性属性的,故 PCA

算法的总体分类精度并不理想;LDA 和 MMC 算法为监督的全局线性算法,在二分类问题中应用较好,但高光谱遥感数据中存在多类数据,且为非线性属性,因而这 2 种方法分类效果不佳;LPP 和 NPE 算法是基于单一流形结构假设提出的特征提取算法,将它们应用于存在多个类别数据,兼丛流形属性的高光谱遥感数据时,难以发现数据集中精细的丛流形特征,从而分类性能不突出。

由表 3 可得,在 10,20,30 个标记训练样本和 30 个无标记训练样本的情况下,SSBML 算法作为一种半监督丛流形学习算法,能有效提取出高光谱数据集中丛流形结构的精细特征。在总体分类精度上,相对于单一流形假设的算法而言,比 LPP 算法分别提升了 8.72%,8.98%,8.19%;比 NPE 算法分别提升了 12.33%,13.64%,15.71%;同时,SSBML 算法作为一种半监督的特征提取算法,总体分类精度相比于 SSMMC 算法提升了 9.00%,10.73%,12.42%;相对于 SSSMPE 算法分别提升了 3.91%,4.39%,5.37%。

表 4 KSC 数据集中不同类别数据在不同算法下的识别率

Tab. 4 Recognition rates of different class data with different algorithms in KSC data set (%)

Class name	PCA	LDA	LPP	NPE	MMC	SSMMC	SSSMPE	SSBML
Water	76.00	82.40	79.70	75.40	74.30	76.80	84.80	88.50
Scrub	90.80	98.80	94.50	87.30	90.50	92.60	98.60	98.80
Spartina marsh	77.70	70.20	72.60	74.60	74.60	80.90	86.10	86.60
Mud flats	47.40	50.40	50.90	44.20	46.00	47.00	58.70	66.00
Graminoid marsh	58.40	66.20	66.40	54.70	55.00	57.70	70.20	77.10
Salt marsh	48.30	75.40	64.60	50.20	47.00	50.90	62.60	79.90
Cattail marsh	68.60	80.30	74.50	66.90	59.80	68.60	87.90	88.80
Cabbaage Palm hammock	89.00	86.60	90.30	85.40	85.00	86.60	95.00	95.60
Cabbaage Palm/oak hammock	85.90	97.60	93.60	82.70	86.30	89.20	94.40	95.90
Oak/broadleaf hammock	94.40	96.10	95.90	95.40	94.60	96.10	97.60	97.70
Willow swamp	76.30	85.60	81.40	73.90	72.90	75.10	86.90	91.50
Slash pine	98.20	99.50	98.40	98.50	98.40	98.50	98.50	98.30

由表 4 可得,在相同实验条件下,由 SSBML 算法处理后,各类地物数据的识别率都有明显提升,可见针对高光谱遥感数据多类别特点提出丛流形学习的 SSBML 算法具有可行性。

### 3.2 PaviaU 数据集

PaviaU 数据集是由 ROSIS 传感器获取的,位于帕维亚大学区域的高光谱遥感图像,图 4 给出了其伪彩色图像。已知该遥感图像大小为 350

pixel×340 pixel,波段数为 103,包含 9 类地物(包括阴影)信息,其类别信息如表 5 所示。

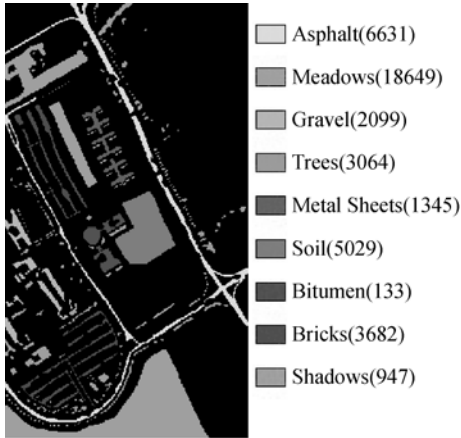


图 4 PaviaU 伪彩色图  
Fig. 4 False-color image of PaviaU

该实验从表 5 的每类已知地物中分别随机选取 10,20,30 个标记样本和 30 个无标记样本作为训练样本,100 个样本点作为测试样本。每种算法重复进行 10 次分类实验,然后对 10 次实验的分类精度求平均值得到最终的总体分类精度;并且在不同的低维嵌入空间维数下进行分类实验。图 5 给出不同算法在不同训练样本数、不同维数下分类实验的总体分类精度;表 6 给出不同算法在不同训练样本数情况下的最高总体分类精度值及其标准偏


差和所在低维嵌入空间的维数。

表 5 PaviaU 数据集的类别信息表

Tab. 5 Label information of PaviaU data set

Category	Class name	Sample number
C1	Meadows	18 649
C2	Bitumen	1 330
C3	Bare Soil	5 029
C4	Self-Blocking ricks	3 682
C5	Trees	3 064
C6	Gravel	2 099
C7	Painted metal sheets	1 345
C8	Asphalt	6 631
C9	Shadows	947

利用 PaviaU 数据集进一步验证 SSBML 算法的从流形学习性能,对表 5 中每种地物类别数据分别进行识别实验。从具体地物中随机选取 30 个标记样本和 30 个无标记样本作为训练样本,100 个样本点作为测试样本。在低维嵌入空间维数  $d=30(d_{LDA}=8)$  下重复进行 10 次实验,统计得出 10 次识别实验的平均识别率作为最终结果。表 7 给出了不同类别数据在不同算法下的识别率。



(a) 10 标记样本及 30 无标记样本 (a) 10 labels and 30 unlabels  
(b) 20 标记样本及 30 无标记样本 (b) 20 labels and 30 unlabels  
(c) 30 标记样本及 30 无标记样本 (c) 30 labels and 30 unlabels

图 5 不同算法在不同训练样本数、不同维数下的总体分类精度

Fig. 5 Overall classification accuracy of different algorithms with different trains in different dimensions

由图 5 可知,SSBML 算法的分类精度明显高于其它几种特征提取算法。随着训练样本数的增加,所获得的样本集的先验信息越多,越能更精确

地发现高维数据中的鉴别特征,故各种算法的总体分类精度也大致呈上升趋势。其中,PCA 算法为全局线性算法,而高光谱遥感数据是存在非线性

性属性的,因而 PCA 算法的总体分类精度并不理想;LDA 和 MMC 算法在线性二分类问题中应用效果较好,但高光谱遥感数据属于多类非线性问题;LPP 和 NPE 算法是基于单一流形结构假设的流形学习算法,而高光谱遥感数据存在多类别数据,且具有丛流形属性,单一流形假设的算法难以发现高光谱遥感数据集中丛流形结构的精细特征,导致分类性能不佳。

由表 6 可知,在 10,20,30 个标记训练样本和 30 个无标记训练样本的情况下,SSBML 算法作为一种丛流形学习算法,相对于单一流形假设的算法而言,总体分类精度比 LPP 算法分别提升了 2.93%,3.60%,3.46%;比 NPE 算法分别提升了 3.93%,5.36%,6.94%;同时,SSBML 算法作为一种半监督的特征提取算法,总体分类精度比 SSMMC 算法提升了 2.63%,4.57%,5.86%;比 SSSMPE 算法分别提升了 3.73%,4.16%,4.51%。

表 6 不同算法在 PaviaU 数据集中的最高总体分类精度(平均值±标准偏差(%)(维数))

Tab. 6 The highest overall classification accuracy of different algorithms in PaviaU data set(mean ± std(%)(dimensions))

Algorithm	10labels	20 labels	30 labels
	30unlabels	30unlabels	30unlabels
PCA	73.44±2.14(17)	77.11±2.08(12)	78.06±2.21(2)
LDA	29.80±4.27(8)	63.03±2.48(6)	72.32±2.49(6)
LPP	77.71±1.89(41)	79.86±1.80(37)	80.98±2.00(17)
NPE	76.71±1.10(41)	78.10±2.13(38)	77.50±1.95(12)
MMC	72.44±3.04(46)	75.72±2.03(46)	76.96±2.24 (36)
SSMMC	78.01±1.39(48)	78.89±1.90(48)	78.58±1.92(50)
SSSMPE	76.91±2.34(50)	79.30±1.71(49)	79.93±1.32(50)
SSBML	80.64±2.15(22)	83.46±2.02(15)	84.44±2.13(19)

表 7 PaviaU 数据集中不同类别数据在不同算法下的识别率

Tab. 7 Recognition rate of different class data with different algorithms in PaviaU data set (%)

Class name	PCA	LDA	LPP	NPE	MMC	SSMMC	SSSMPE	SSBML
Meadows	68.30	53.80	69.80	70.70	68.20	70.20	64.80	72.70
Bitumen	65.10	75.20	68.00	61.30	61.20	61.60	65.30	77.30
Bare soil	65.20	60.60	66.20	62.60	61.60	63.10	64.40	71.30
Self-Blocking ricks	88.80	90.40	90.30	90.30	87.70	91.50	92.20	92.70
Trees	99.10	99.70	99.50	98.80	99.10	99.20	98.80	99.70
Gravel	67.20	60.70	76.20	69.50	65.50	67.20	74.20	81.90
Painted metal sheets	88.30	60.30	86.80	86.30	85.80	86.20	85.20	88.90
Asphalt	66.70	51.70	67.90	65.80	66.10	69.50	62.40	71.90
Shadows	99.70	90.90	99.80	99.80	99.70	99.80	99.20	99.70

由表 7 可知,在相同实验条件下,由 SSBML 算法处理后的各类地物数据的识别率比其它算法性能更优,可见针对高光谱遥感数据多类别特点提出的丛流形学习 SSBML 算法具有一定的实用性。

### 4 结 论

针对高光谱遥感数据集的多类别非线性特点,假设其数据集中具有丛流形结构属性,而非单一的流形结构,本文提出一种半监督丛流形学习(SSBML)算法。该算法通过构建两个近邻关系图来分别保持高光谱遥感数据集的丛流形结构中“整体”联系(各个子流形之间的相互关系)和每个子流形的内蕴结构特征,从而发现数据集中丛流

形结构的精细特征,有效提升高光谱遥感图像的分类精度。

在 KSC 和 PaviaU 数据集上的实验结果表明:在总体分类精度上,SSBML 算法相对于单一流形假设的 LLP 和 NPE 算法提升了约 2.9%~15.7%。同时,SSBML 算法作为一种半监督算法,相比于 SSMMC 和 SSSMPE 等算法提升了约 2.6%~12.4%。此外,在对各类地物类别进行具体识别实验时,SSBML 算法的识别率相对较高,从而在一定程度上验证了该算法的可行性。但本文的研究工作还待深入,比如进一步对算法进行优化处理,以提高运算效率,以及更加深入地研究多流形或丛流形数据集的特征提取方法等。

## 参考文献:

- [1] 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.  
DU B, ZHANG L F, ZHANG L P, *et al.*. Discriminant manifold learning approach for hyperspectral image dimension reduction [J]. ACTA PHOTONICA SINICA, 2013, 42(3): 320-325. (in Chinese)
- [2] 陈宏达, 普晗晔, 王斌, 等. 基于图像欧氏距离的高光谱图像流形降维算法[J]. 红外与毫米波学报, 2013, 32(5): 450-455.  
CHEN H D, PU H H, WANG B, *et al.*. Image Euclidean distance-based manifold dimensionality reduction algorithm for hyperspectral imagery [J]. *Journal of Infrared and Millimeter Wave*, 2013, 32(5): 450-455. (in Chinese)
- [3] 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 X F, LI J CH. Classification hyperspectral remote sensing image based on sparse representation and spectral information [J]. *Journal of Electronics & Information Technology*, 2012, 34(2): 268-272. (in Chinese)
- [4] 黄鸿, 曲焕鹏. 基于半监督稀疏鉴别嵌入的高光谱遥感影像分类[J]. 光学精密工程, 2014, 22(2): 434-442.  
HUANG H, QU H P. Hyperspectral remote sensing image classification based on SSDE [J]. *Opt. Precision Eng.*, 2014, 22(2): 434-442. (in Chinese)
- [5] ABDI H, WILLIAMS L J. Principal component analysis [J]. *Wiley Interdisciplinary Reviews: Computational Statistics*, 2010, 2(4): 433-459.
- [6] MOULIN C, LARGERON C, DUCOTTET C, *et al.*. Fisher linear discriminant analysis for text-image combination in multimedia information retrieval [J]. *Pattern Recognition*, 2014, 47(1): 260-269.
- [7] WAN M, LAI Z, JIN Z. Feature extraction using two-dimensional local graph embedding based on maximum margin criterion [J]. *Applied Mathematics and Computation*, 2011, 217(23): 9659-9668.
- [8] ROSMAN G, BRONSTEIN M M, BRONSTEIN A M, *et al.*. Nonlinear dimensionality reduction by topologically constrained isometric embedding [J]. *International Journal of Computer Vision*, 2010, 89(1): 56-68.
- [9] ZHAO X, ZHANG S. Facial expression recognition using local binary patterns and discriminant kernel locally linear embedding [J]. *EURASIP Journal on Advances in Signal Processing*, 2012, 2012(1): 1-9.
- [10] LUO W. Face recognition based on Laplacian Eigenmaps [C]. *Proceedings of the 2011 IEEE International Conference on Computer Science and Service System (CSSS)*, Nanjing, China, 2011: 416-419.
- [11] HE X, CAI D, YAN S, *et al.*. Neighborhood preserving embedding [C]. *Proceedings of the 2005 IEEE International Conference on Computer Vision (ICCV)*, Beijing, china, 2005: 1208-1213.
- [12] HE X, NIYOGI P. Locality preserving projections [C]. *Proceedings of the Advances in Neural Information Processing Systems, Vancouver, BC, Canada*, 2004: 234-241.
- [13] SONG Y Q, NIE F P, ZHANG C S, *et al.*. A unified framework for semi-supervised dimensionality reduction [J]. *Pattern Recognition*, 2008, 41(9): 2789-2799.
- [14] SONG Y Q, NIE F P, ZHANG C S. Semi-supervised sub-manifold discriminant analysis [J]. *Pattern Recognition Letters*, 2008, 29(13): 1806-1813.
- [15] BENGIO Y, MONPERRUS M. Non-local manifold tangent learning [J]. *Advances in Neural Information Processing Systems*, 2005, 17: 129-136.
- [16] LI CH G, GUO J, ZHANG H G. *Learning Bundle Manifold by Double Neighborhood Graphs* [M]. *Computer Vision-ACCV 2009*, Springer Berlin Heidelberg, 2010: 321-330.

## 作者简介:



李志敏(1955—),男,重庆人,副教授,硕士生导师,1978年于浙江大学获得工学学位,主要从事计算机图像处理、机器视觉、光学智能仪器的研究。E-mail: lzm@cquc. du. cn.



张杰(1988—),男,四川泸州人,硕士研究生,2012年于陕西理工学院获得工学学士学位,主要从事图像处理、遥感影像分类、嵌入式系统等方面的研究。E-mail: zhangjie\_fly@126. com

(版权所有 未经许可 不得转载)