

面向高光谱分类的局部几何稀疏保持嵌入

黄 鸿¹ 唐玉枭¹ 段宇乐¹

摘要 大量维数约简 (Dimensionality reduction, DR) 方法表明保持数据间稀疏特性的同时, 确保几何结构的保持能更有效提取出具有鉴别的特征, 为此本文提出一种联合局部几何近邻结构和局部稀疏流形的维数约简方法. 该方法首先通过局部线性嵌入方法重构每个样本以保持数据的局部线性关系, 同时计算样本邻域内的局部稀疏流形结构, 在此基础上通过图嵌入框架保持数据的局部几何近邻结构和稀疏结构, 最后在低维嵌入空间中使类内数据尽可能聚集, 提取低维鉴别特征, 从而提升地物分类性能. 在 Indian Pines 和 PaviaU 高光谱数据集上的实验结果表明, 本文方法相较于传统维数约简方法能明显提高地物的分类性能, 总体分类可达到 83.02% 和 91.20%, 有利于实际应用.

关键词 高光谱图像, 维数约简, 稀疏表示, 流形学习, 协同嵌入

引用格式 黄鸿, 唐玉枭, 段宇乐. 面向高光谱分类的局部几何稀疏保持嵌入. 自动化学报, 2022, 48(10): 2496–2507

DOI 10.16383/j.aas.c190594

Local Geometry and Sparsity Preserving Embedding for Hyperspectral Image Classification

HUANG Hong¹ TANG Yu-Xiao¹ DUAN Yu-Le¹

Abstract A large number of dimensionality reduction methods show that while maintaining the sparse characteristics between data, ensuring that the geometry is maintained can more effectively extract discriminative features. To address this issue, a dimensionality reduction (DR) method combining joint local geometry neighbor structure and local sparse manifold is proposed. The method first reconstructs each sample by local linear embedding to maintain the local linear relationship, and calculates the local sparse manifold structure in the neighbors. Then the local geometry neighbor structure and sparse manifold structure are maintained by the graph embedding frame. Finally, in the low-dimensional embedded space, the intra-class data is compacted as much as possible, so that the low-dimensional discriminative features are extracted to improve the classification performance. The experimental results on the Indian Pines and PaviaU hyperspectral datasets show that the proposed method can significantly improve the classification precision compared with the traditional DR methods. The overall classification can reach 83.02% and 91.20%, respectively, which is beneficial to practical applications.

Key words Hyperspectral image, dimensionality reduction (DR), sparse representation, manifold learning, collaborative embedding

Citation Huang Hong, Tang Yu-Xiao, Duan Yu-Le. Local geometry and sparsity preserving embedding for hyperspectral image classification. *Acta Automatica Sinica*, 2022, 48(10): 2496–2507

2018 年我国发射的高分五号和“珠海一号”高光谱卫星推动着高光谱遥感行业发展, 为农业监测、资源勘查、环境管理和国防建设等领域提供数据支持^[1–2]. 高光谱遥感图像的光谱分辨率高, 包含几十乃至几百个光谱波段, 具有“图谱合一”特征, 这种

独特的优势为地物精细分类提供应用基础^[3–4]. 但同时高光谱图像也存在光谱数据量大、波段数多、相关性强等特点^[5], 传统地物分类方法易导致“维数灾难”问题^[6–7]. 因此, 如何去除冗余、减少光谱波段数、降低计算复杂度, 提取出高光谱图像中更有鉴别力的特征是实现地物精细分类的关键^[8–9].

目前, 学者们提出了一系列维数约简 (Dimensionality reduction, DR) 方法, 以实现将高维数据投影到低维嵌入空间中, 提取出低维鉴别特征, 改善地物分类性能. 主成分分析 (Principal component analysis, PCA)^[10] 和线性鉴别分析 (Linear discriminant analysis, LDA)^[11] 等经典维数约简方法的目的在于将数据投影到线性子空间中, 但忽略了高维数据中可能存在的低维流形结构. 学者们提出 LE (Laplacian eigenmaps)^[12]、LLE (Locally linear

收稿日期 2019-08-18 录用日期 2020-04-06

Manuscript received August 18, 2019; accepted April 6, 2020
国家自然科学基金 (42071302), 重庆市基础研究与前沿探索项目 (cstc2018jcyjAX0093) 资助

Supported by National Natural Science Foundation of China (42071302) and Chongqing Basic Research and Frontier Exploration Project (cstc2018jcyjAX0093)

本文责任编辑 张军平

Recommended by Associate Editor ZHANG Jun-Ping

1. 重庆大学光电工程学院光电技术与系统教育部重点实验室 重庆 400044

1. Key Laboratory of Optoelectronic Technique System of the Ministry of Education, College of Optoelectronic Engineering, Chongqing University, Chongqing 400044

embedding)^[13] 和 ISOMAP (Isometric feature mapping)^[14] 等流形学习方法, 以揭示高维观测数据中的流形结构。但上述流形学习方法为非线性方法, 没有直接的投影矩阵, 存在样本外学习问题。为此, 学者提出了邻域保持嵌入 (Neighborhood preserving embedding, NPE)^[15] 和局部保持投影 (Locality preserving projection, LPP)^[16] 等线性方法, 但由于其无监督学习特性, 限制了所提取低维特征的鉴别力。而后, Yan 等^[17] 提出了一种图嵌入 (Graph embedding, GE) 框架, 将上述 PCA、LDA、LE、LLE 和 ISOMAP 等方法统一到该框架下。在此框架下, 学者通过引入训练样本的先验知识提出 Supervised NPE (SNPE)^[18]、Supervised LPP^[19]、局部 Fisher 判别分析 (Local Fisher discriminant analysis, LFDA)^[20] 和局部几何结构 Fisher 分析 (Local geometric structure feature analysis, LGSFA)^[21] 等方法, 来挖掘高维数据中的鉴别特征, 以提高分类性能。

上述图嵌入方法均通过 k 近邻法或 ε 半径球法选择近邻样本来构建图, 通过近邻点进行构图存在参数选择困难问题, 且提取性能易受到高光谱数据中“同物异谱”或“异物同谱”现象影响。为此, 学者结合稀疏表示 (Sparsity representation, SR) 方法提出稀疏保持投影 (Sparsity preserving projection, SPP)^[22] 和基于稀疏表示投影的鉴别学习 (Discriminative learning by SR projections, DLSP)^[23] 以自适应地保持数据间的稀疏特性, 解决构图过程中参数选择等问题。而后, 学者为增强稀疏表示的鉴别性, 将样本的标记信息同稀疏表示和流形散度矩阵结合提出稀疏鉴别学习 (Sparse discriminant learning, SDL)^[24], 虽然流形结构也是几何结构的一种, 但直接计算流形散度矩阵对数据的结构描述不够细致, 忽略了数据间更多的相似特性, 有学者提出的鉴别稀疏保持嵌入 (Discriminant sparse preserving embedding, DSPE)^[25], 直接将流形中的稀疏点用于构图也存在相似问题。学者提出多结构流形嵌入 (Multi-structure manifold embedding, MSME)^[26] 方法, 在保持稀疏图与稀疏超图结构的同时, 保持数据间的局部线性结构, 说明局部空间内的数据能更好地表征数据的本质结构。Huang 等基于稀疏流形编码 (Sparse manifold coding, SMC)^[27] 模型对数据进行稀疏表征, 提出一种稀疏鉴别流形嵌入 (Sparse discriminant manifold embedding, SDME)^[28] 方法, 该方法通过稀疏系数获得同类数据间的相似性, 增强了同类数据在局部流形空间的表达性能。

针对上述问题, 为进一步加强同类数据在局部

空间的相似关系, 本文提出一种面向高光谱图像特征提取的局部几何稀疏保持嵌入 (Local geometry and sparsity preserving embedding, LGSPE) 方法。该方法通过各同类样本的邻域点线性重构每个样本, 保持数据邻域内的几何近邻结构, 并通过 SMC 模型计算各样本的局部稀疏流形结构, 并获得局部稀疏系数, 通过图嵌入框架保持数据的稀疏关系的同时保持局部几何近邻结构, 在嵌入空间使同类样本尽可能聚集, 提取出具有鉴别力的低维特征, 从而提升分类精度。本文在 Indian Pines 和 PaviaU 高光谱数据集上进行实验以验证提出 LGSPE 方法的有效性。

1 本文算法

本文假设高光谱图像数据集表示为 $X = [\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_n] \in \mathbf{R}^{D \times n}$, 其中 D 为样本波段数, n 为样本个数, 其中 \mathbf{x}_i 对应的标签为 $L = [l_1, l_2, \dots, l_c]$, $l_i \in \{1, 2, \dots, c\}$, c 为类别数。 X 的低维嵌入特征可表示为 $Y = P^T X \in \mathbf{R}^{d \times n}$, d ($d \ll D$) 为嵌入维数, $P \in \mathbf{R}^{D \times d}$ 为投影矩阵。

1.1 图嵌入学习

为更好地解释维数约简算法在特征提取过程中的含义, 学者们提出图嵌入学习以描述数据间的结构关系, 目前图嵌入学习已广泛应用于高维数据的维数约简过程。图嵌入的主要思想是, 通过构建本征图 $G = \{X, W\}$ 来表示同类数据间的几何或统计特性或惩罚图 $G^P = \{X, W^P\}$ 来描述非同类数据间的几何或统计特性, 其中 X 为图中的顶点, W 和 W^P 为权值矩阵, 通过权值可表征数据在低维嵌入空间中的相似关系。

图嵌入的主要目的在于, 在低维投影空间中保持顶点间的相似性或抑制点间关系。根据图嵌入原理, 其优化目标函数可定义为

$$\min_{\mathbf{y}^T H \mathbf{y} = c} \frac{1}{2} \sum_{i \neq j} \|\mathbf{y}_i - \mathbf{y}_j\|^2 w_{ij} = \min_{\mathbf{y}^T H \mathbf{y} = c} Y^T LY \quad (1)$$

式中, L 为图 G 的拉普拉斯矩阵, $L = D - W$, 对角矩阵 $D_{ii} = \sum_{j \neq i} w_{ij}$, c 为常量。约束矩阵 H 的目的在于消除退化解, 通常设置为单位矩阵, 也可以设置为惩罚图 G^P 的拉普拉斯矩阵即 $H = L^P = D^P - W^P$, $D_{ii}^P = \sum_{j \neq i} w_{ij}^P$ 。

1.2 稀疏流形编码

在图嵌入框架下, 构建图时首先要选择与目标点相关的数据连接成边, k -近邻和 ε -近邻是目前

最常用的边连接方法,但参数近邻数 k 和球半径 ε 易受噪声的影响难以确定最佳值。为此,采用 SMC 优化模型来选择具有相似结构的点,该方法假设每个点 x_i 的邻域内存在一个流形结构,通过构建一个稀疏优化问题来自适应选取同一流形上的稀疏点,从而揭示高维数据的流形结构。其优化目标函数为

$$\min \|Q_i s_i\|_1 \text{ s.t. } \|Z s_i\| \leq \varepsilon, \quad \mathbf{1}^T s_i = 1 \quad (2)$$

式中, $\|\cdot\|_1$ 为 1 范数, ε 为稀疏误差阈值, 稀疏系数 $s_i = [s_{i1}, s_{i2}, \dots, s_{ij}, \dots, s_{in}]^T_{j \neq i}$, $\mathbf{1}^T$ 为全 1 向量, Q 为正定对角矩阵, 表示邻域内与目标点间的惩罚权值, 权值越小表示与目标点越接近, Z 为样本 X 的归一化后的数据, Q 和 Z 可定义为

$$Q_i = \text{diag} \left\{ \left[\frac{d_{ij}}{\sum d_{ij}} \right]_{j \neq i} \right\} \in \mathbb{R}^{(n-1) \times (n-1)} \quad (3)$$

$$Z_i = \begin{bmatrix} \frac{\mathbf{x}_1 - \mathbf{x}_i}{\|\mathbf{x}_1 - \mathbf{x}_i\|}, \dots, \frac{\mathbf{x}_j - \mathbf{x}_i}{\|\mathbf{x}_j - \mathbf{x}_i\|}, \dots \\ \frac{\mathbf{x}_n - \mathbf{x}_i}{\|\mathbf{x}_n - \mathbf{x}_i\|} \end{bmatrix}_{j \neq i} \in \mathbb{R}^{D \times (n-1)} \quad (4)$$

式 (3) 中, $d_{ij} = \|\mathbf{x}_i - \mathbf{x}_j\|_{j \neq i}$, 表示 \mathbf{x}_i 和 \mathbf{x}_j 两点的欧氏距离。

综上,相比于采用传统的近邻选择 k -近邻法和 ε -近邻法,SMC 通过稀疏表示探索数据间的稀疏特性揭示数据邻域内的流形结构。

1.3 局部几何稀疏保持嵌入

为充分利用样本的局部几何近邻结构和稀疏特性,本文提出一种局部几何稀疏保持嵌入 (LGSPE) 方法,以提取高维数据的低维鉴别特征。该方法利用邻域样本进行局部线性重构,保持同类数据间的局部几何结构并削减噪声所带来的影响,通过稀疏流形编码模型求出稀疏系数,以保持样本邻域内存在于同一流形上的稀疏关系,在图嵌入过程中保持几何近邻结构和稀疏关系,实现在低维嵌入空间中类内样本尽可能聚集,有效提升地物的分类性能。LGSPE 方法的流程图如图 1 所示。

由于高光谱图像光谱分辨率较高,一些波段易受噪声影响,并且距离相近的样本一般保持相似的结构关系。通过对各样本点周围的同类近邻样本进行线性重构可减少噪声所带来的影响,同时能保持同类数据间的局部线性结构,每个点 \mathbf{x}_i 可由其周围的 k 近邻同类邻域 $\Omega(\mathbf{x}_i)$ 点重构表示,可以通过计算最小化重构误差得到局部重构权重

$$\min \sum_{i=1}^n \left\| \mathbf{x}_i - \sum_{j=1}^n c_{ij} \mathbf{x}_j \right\|^2 \text{ s.t. } \sum_{j=1}^n c_{ij} = 1 \quad (5)$$

其中, c_{ij} 为样本 \mathbf{x}_i 和 \mathbf{x}_j 之间的权重,如果 \mathbf{x}_i 和 \mathbf{x}_j 为同类样本则 $c_{ij} \neq 0$;否则 $c_{ij} = 0$ 。进一步简化式 (5),有

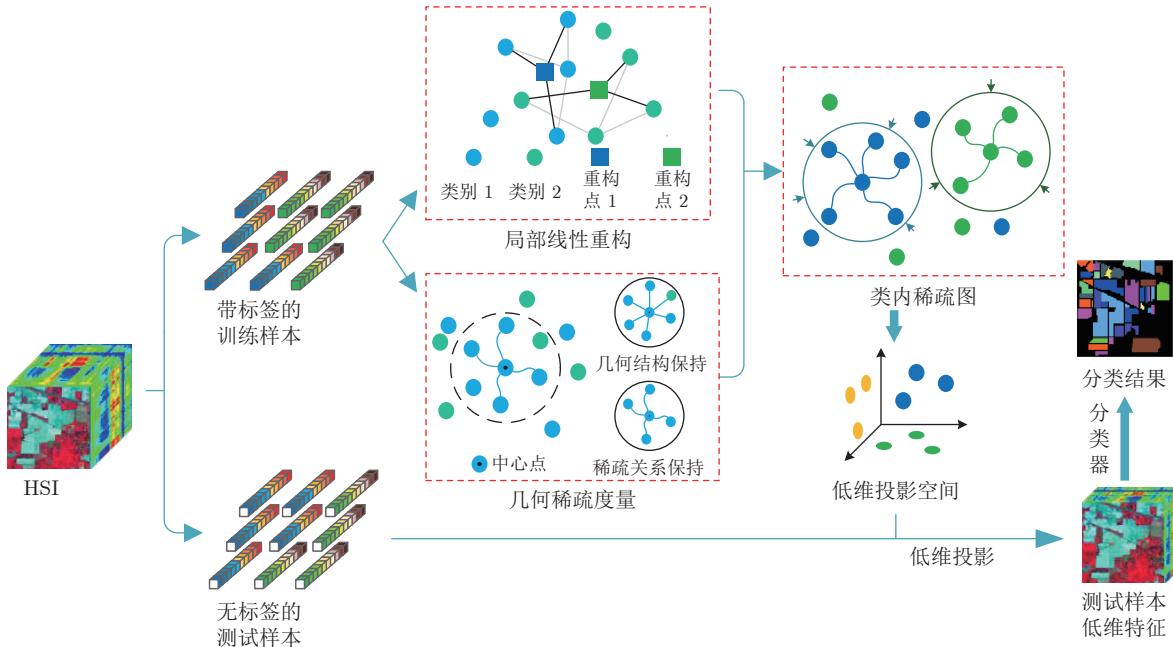


图 1 局部几何稀疏保持嵌入 (LGSPE) 方法流程图

Fig.1 Flowchart of the LGSPE method

$$\begin{aligned} \sum_{i=1}^n \left\| \mathbf{x}_i - \sum_{j=1}^n c_{ij} \mathbf{x}_j \right\|^2 &= \sum_{i=1}^n \left\| \mathbf{x}_i \sum_{j=1}^n c_{ij} - \sum_{j=1}^n c_{ij} \mathbf{x}_j \right\|^2 = \\ \sum_{i=1}^n \left\| \sum_{j=1}^n c_{ij} (\mathbf{x}_i - \mathbf{x}_j) \right\|^2 &= \\ \sum_{i=1}^n \left\| [\mathbf{x}_i - \mathbf{x}_1, \dots, \mathbf{x}_i - \mathbf{x}_k] [c_{i1}, \dots, c_{ik}]^\top \right\|^2 &= \\ \sum_{i=1}^n c_i^\top z_i c_i & \end{aligned} \quad (6)$$

式中, $\mathbf{c}_i = [c_{i1}, \dots, c_{ik}]^\top$, $z_i = [z_{mn}]_{k \times k} = [\mathbf{x}_i - \mathbf{x}_{i1}, \dots, \mathbf{x}_i - \mathbf{x}_{ik}]^\top [\mathbf{x}_i - \mathbf{x}_{i1}, \dots, \mathbf{x}_i - \mathbf{x}_{ik}]$, \mathbf{x}_{ik} 为 \mathbf{x}_i 的类内 k 近邻点, 因此式(5)可简化为

$$\min \sum_{i=1}^n \mathbf{c}_i^\top z_i \mathbf{c}_i \quad \text{s.t.} \quad \sum_{j=1}^k c_{ij} = 1 \quad (7)$$

根据拉格朗日乘子法, 式(7)求解的最优值为

$$c_{ij} = \begin{cases} \frac{\sum_{m=1}^k (z_{jm}^i)^{-1}}{\sum_{p=1}^k \sum_{q=1}^k (z_{pq}^i)^{-1}}, & \mathbf{x}_j \in \Omega(\mathbf{x}_i) \\ 0, & \text{否则} \end{cases} \quad (8)$$

通过式(8)得出的局部重构权重 $\mathbf{c}_i = [c_{i1}, c_{i2}, \dots, c_{ik}]^\top$, 重构后的点可线性表示为 $\mathbf{x}_i \approx X \mathbf{c}_i$.

为探索数据的局部子流形结构, 采用 SMC 模型自适应选择来自同一切空间的近邻点. 首先通过 l_1 范数寻找目标点 x_i 的欧氏近邻点来探索基本的几何关系, 同时通过求解稀疏优化问题以寻找 x_i 邻域内来自同一流形的像元. 求解目标问题可表示为

$$\begin{cases} \min \alpha \|Q_i \mathbf{s}_i\|_1 + \frac{1}{2} \|Z_i \mathbf{s}_i\|^2 \\ \text{s.t. } \mathbf{1}^\top \mathbf{s}_i = 1 \end{cases} \quad (9)$$

式中, α ($\alpha > 0$) 为稀疏解与表示误差间的权值. 式(9)通过交叉乘子法 (Alternating direction method of multipliers, ADMM) 计算局部稀疏优化问题, 可求出每个样本的稀疏近邻关系.

通过计算每个样本的局部稀疏系数和几何距离, 并构建一个稀疏类内相似图 $G^w = \{X, W^w\}$ 来表征数据的判别嵌入结构. 为减少邻域范围内来自同一流形点间的差异性, 并保持相似图的局部几何信息和稀疏关系, 设计一个相似权值系数

$$w_{ij}^w = \begin{cases} \exp\left(-\frac{d_{ij}^2 + s_{ij}^2}{\bar{d}_i^2 + \bar{s}_i^2}\right), & \text{若 } s_{ij} \neq 0 \text{ 且 } l(\mathbf{x}_i) = l(\mathbf{x}_j) \\ 0, & \text{否则} \end{cases} \quad (10)$$

式中, \bar{d}_i 和 \bar{s}_i 分别为欧氏距离 d_i 和稀疏系数 s_i 的均值, 为增加相似图的判别性, 只连接具有相同类别标签的点, 以构建一个类内相似图.

由式(7)计算得到的局部重构权重 \mathbf{c}_i , 式(9)得到的稀疏系数 \mathbf{s}_i , 式(10)的相似权值系数 W^w , 可通过一个维数约简算法来学习最优投影矩阵 P , 将测试样本投影到低维空间, 提取出更有鉴别力的特征. 在此低维嵌入空间中, 同类数据可保持其原有的几何近邻结构和稀疏关系, 同时再通过局部线性重构和类内稀疏图嵌入使类内样本更加靠近, 其构建目标函数可表示为

$$\min_P \sum_{i, j=1}^n \left(\beta \|P^\top \mathbf{x}_i - P^\top X \mathbf{c}_j\| + (1 - \beta) \|P^\top \mathbf{x}_i - P^\top X \mathbf{s}_j\|^2 \right) w_{ij}^w \quad (11)$$

式中, β 为平衡参数, 用于调节局部线性重构和稀疏重构的重要性. 经数学推导后, 式(11)可进一步简化为

$$\begin{aligned} \min \sum_{i, j=1}^n & \left(\beta \|P^\top \mathbf{x}_i - P^\top X \mathbf{c}_j\| + (1 - \beta) \|P^\top \mathbf{x}_i - P^\top X \mathbf{s}_j\|^2 \right) w_{ij}^w = \\ & \beta \text{tr} \left\{ P^\top \left[\sum_{i, j=1}^n (\mathbf{x}_i w_{ij}^w \mathbf{x}_i^\top + X \mathbf{c}_j w_{ij}^w \mathbf{c}_j^\top X^\top - \mathbf{x}_i w_{ij}^w \mathbf{c}_j^\top X^\top - X \mathbf{c}_j w_{ij}^w \mathbf{x}_i^\top) \right] P \right\} + \\ & (1 - \beta) \text{tr} \left\{ P^\top \left[\sum_{i, j=1}^n (\mathbf{x}_i w_{ij}^w \mathbf{x}_i^\top + X \mathbf{s}_j w_{ij}^w \mathbf{s}_j^\top X^\top - \mathbf{x}_i w_{ij}^w \mathbf{s}_j^\top X^\top - X \mathbf{s}_j w_{ij}^w \mathbf{x}_i^\top) \right] P \right\} = \\ & \beta \text{tr} [P^\top X (D^w + C W^w C^\top - W^w C^\top - C W^w) X^\top P] + \\ & (1 - \beta) \text{tr} [P^\top X (D^w + S W^w S^\top - W^w S^\top - S W^w)^\top X^\top P] = \\ & \text{tr} (P^\top X L_c X^\top P) + (1 - \beta) \text{tr} (P^\top X L_s X^\top P) = \text{tr} [\beta P^\top X L_c X^\top P + (1 - \beta) P^\top X L_s X^\top P] = \\ & \text{tr} \{P^\top X [\beta L_c + (1 - \beta) L_s] X^\top P\} \end{aligned} \quad (12)$$

式中, $L_c = D^w + CW^wC^T - W^wC^T - CW^w$ 和 $L_s = D^w + SW^wS^T - W^wS^T - SW^w$ 分别为局部线性重构和类内稀疏重构的拉普拉斯矩阵, 对角矩阵 $D^w = \text{diag}\{\sum_{j=1}^n w_{1j}^w, \sum_{j=1}^n w_{2j}^w, \dots, \sum_{j=1}^n w_{nj}^w\}$, W^w 为相似权值 w_{ij}^w 的矩阵, $S = [s_1, s_2, \dots, s_n]$ 和 $C = [c_1, c_2, \dots, c_n]$ 分别为稀疏系数和线性重构系数矩阵。

为消除尺度效应的影响, 进一步添加约束项 $P^T X X^T P = I$ 后目标函数可表示为

$$\begin{cases} \min_P P^T X [\beta L_c + (1 - \beta) L_s] X^T P \\ \text{s.t. } P^T X X^T P = I \end{cases} \quad (13)$$

通过拉格朗日乘子法, 式(13)的优化解可表示为

$$X [\beta L_c + (1 - \beta) L_s] X^T P = \lambda X X^T P \quad (14)$$

求解式(14)的广义特征值和其对应的特征向量, 并将特征值按升序排序, 取前 d 个特征值对应的特征向量可得到投影矩阵 $P = [p_1, p_2, \dots, p_d]$, 投影后的数据可表示为 $Y = P^T X \in \mathbf{R}^{d \times n}$.

LGSPE 算法的主要步骤如下.

算法 1. LGSPE 算法

输入. 高光谱数据集 $X \in \mathbf{R}^{D \times n}$, 类别标签集 L , 嵌入维度 d ($d \ll D$), 平衡参数 β , 局部线性嵌入近邻数 C_n , 局部稀疏近邻数 S_n , 稀疏度 λ .

输出. 低维投影矩阵 P , 嵌入特征 $Y = P^T X$.

1) 将高光谱数据 X 进行归一化预处理, 根据标签信息, 在每类中按比例随机选取一定数量的样本进行训练, 其余用于测试;

2) 选取训练样本的同类 C_n 近邻, 根据式(7)计算各个训练样本的局部重构权重 c_i ;

3) 根据式(10)计算局部稀疏系数 s_i 和局部几何关系 d_i ;

4) 计算各边的权值 $W^w = [w_{ij}^w]_{n \times n}$, 并构建类内相似图 $G^w = \{X, W^w\}$;

5) 计算局部线性重构和稀疏重构的拉普拉斯矩阵 L_c, L_s ;

6) 求解式(14)中的广义特征值问题, 选取前 d

个特征值对应的特征向量构成低维投影矩阵 $P = [p_1, p_2, \dots, p_d]$;

7) 将测试样本嵌入低维投影空间, 得到低维鉴别特征 $Y = P^T X$.

2 实验结果与分析

2.1 实验数据集

1) Indian Pines 数据集由美国宇航局采用 AVIRIS (Airborne visible infrared imaging spectrometer) 传感器获取位于美国印第安纳州西北部的高光谱图像, 该数据集大小为 145×145 像素, 包含 220 个光谱波段, 空间分辨率为 20 m, 去除受噪声影响的 20 个波段后, 剩余 200 个波段用于实验, 地物主要包含农作物、草地、房屋等 16 类. 图 2 为该数据集的假彩色图、地物分布图和每类地物对应的样本数量.

2) PaviaU 数据集由 ROSIS (Reflective optics system imaging spectrometer) 传感器获取位于意大利北部帕维亚大学北部的高光谱图像, 该数据集大小为 610×340 像素, 共 115 个光谱波段, 空间分辨率为 1.3 m, 剔除易受水气影响的 12 个波段后, 余下 103 个波段用于实验研究, 主要包括裸土、草地、砖块等 9 类地物. 图 3 为该数据集的假彩色图、地物分布图和每类地物对应的样本数量.

2.2 实验设置

在实验中, 每次选取一定数量的标记样本用于训练, 其余用于测试, 通过各维数约简算法对训练样本进行学习, 得到低维投影矩阵, 进而将测试样本嵌入到低维投影空间, 最后采用最近邻分类器 (1-NN) 对嵌入的低维样本进行分类. 实验结果使用总分类精度 (Overall accuracy, OA)、平均分类精度 (Average accuracy, AA) 和 Kappa 系数作为评价指标, 并进行显著性差异分析.

为验证本文算法的有效性, 选取 RAW、PCA^[10]、

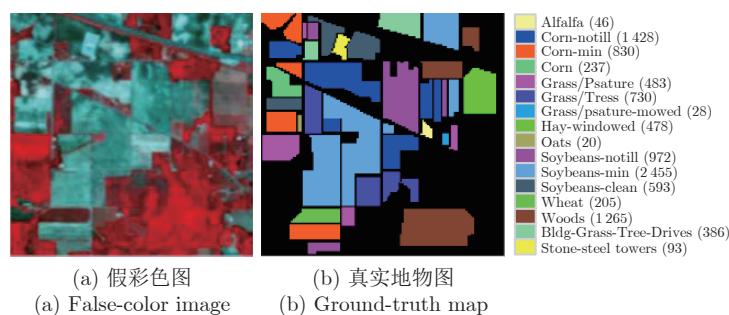


图 2 Indian Pines 高光谱图像

Fig. 2 Indian Pines hyperspectral image

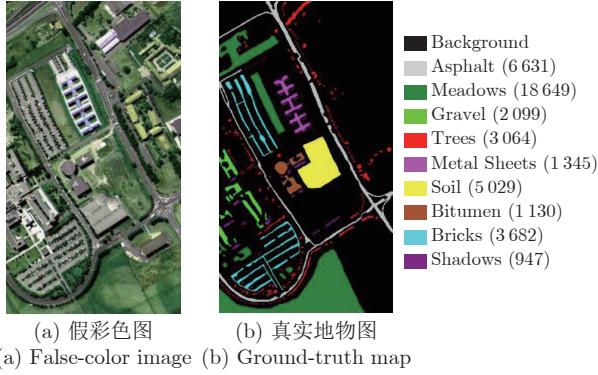
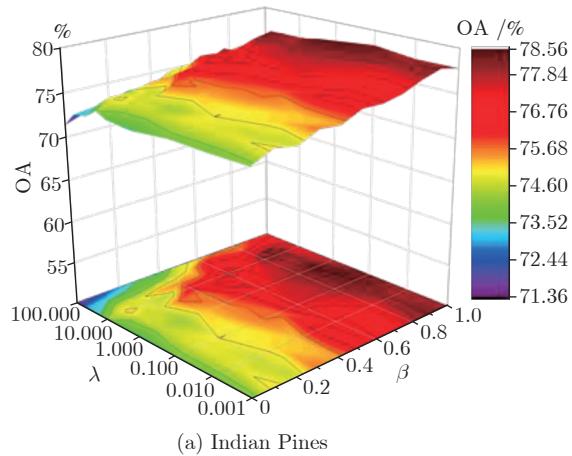


图 3 PaviaU 高光谱图像

Fig.3 PaviaU hyperspectral image

LDA^[11]、LFDA^[20]、SNPE^[18]、SPP^[22]、DLSP^[23]、SDL^[24]、DSPE^[25]、MSME^[26]、LGSFA^[21] 和 SDME^[28] 与本文维数约简算法进行对比, RAW 为不降维直接进行分类的结果。实验中采用交叉验证方法获取各个算法的最优参数, 对于近邻数, LFDA、SNPE 分别设为 9 和 5, LGSFA 类内为 9, 类间为 20; 对于稀疏误差阈值, SDL、DSPE、SDME 设置为 0.1, DLSP 设置为 0.9, SPP 设置为 5, MSME 设置为 100; SDME 的加权参数设为 50, MSME 的权衡系数 α 和 β 分别设置为 0.8 和 0.5。LDA 算法的嵌入维数设置为 $c - 1$, c 为类别数, 其余算法嵌入维数设置为 30。每种算法的实验均重复 10 次, 取均值及方差作为实验结果。

为分析本文方法中稀疏误差阈值 λ 和平衡参数 β 对分类精度的影响, 从 Indian Pines 数据集中每类随机选取 10% 的样本、从 PaviaU 数据集中选取 1% 的样本进行训练, 其余用于分类测试。实验中, λ 和 β 的调试范围分别为 $[0.001, 0.01, 0.1, 1, 5, 10, 20, 50, 100]$ 和 $[0, 0.1, 0.2, \dots, 0.9, 1]$, 参数 C_n 、 S_n

图 4 不同参数 λ 和 β 在两个数据集上的总体分类精度Fig.4 OAs with different parameters λ and β on two datasets

设置为 $C_n = S_n = 30$ 。图 4 为 LGSPE 在两个数据集上测试 λ 、 β 两个参数的总体分类精度。

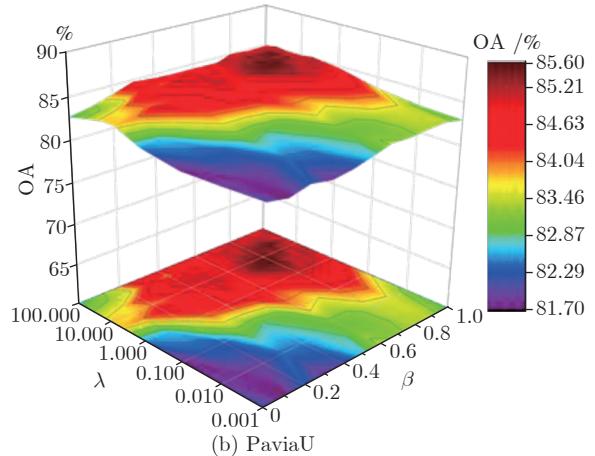
由图 4 可知, 分类精度随稀疏误差阈值 λ 的增加先增大后减小, 这是由于 λ 设置越小, 得到的点越稀疏, 不足以表征数据结构, 而当 λ 太大时, 又得到太多的冗余点, 导致分类精度降低, 因此 λ 在某一合适区域内, 能够得到较好的分类效果。分类精度随权值系数 β 的增大先增大后趋于平滑, 可知局部线性重构在整个特征提取过程中有较大的比重, 能够较好地保持数据的本质属性。基于上述结果, 在 Indian Pines 数据集上取 $\lambda = 1$, $\beta = 0.9$, 在 PaviaU 数据集上取 $\lambda = 5$, $\beta = 0.8$ 。

同时, 为探索局部线性嵌入近邻数 C_n 和局部稀疏近邻数 S_n 对分类精度的影响, 两参数范围均设置为 $[20, 40, \dots, 200]$, 在 Indian Pines 上固定 $\lambda = 1$, $\beta = 0.9$, 在 PaviaU 上固定 $\lambda = 5$, $\beta = 0.8$ 。图 5 为 LGSPE 在两个数据集上测试 C_n 和 S_n 两个参数的总体分类精度。

由图 5 可知, 分类精度在 S_n 较小时获得较高精度, 随着 S_n 的增加出现下降趋势, 这说明流形结构存在于样本点周围较小的空间上, 在此邻域内以获得数据间具有较好鉴别的稀疏流形结构; 分类精度在 Indian Pines 数据集上随 C_n 先增大后减小, 在 PaviaU 数据集上随 C_n 的增大呈较小趋势。这是由于两个数据集在数据分布上不同需要的局部重构点数也会有较大差异, 根据上述分析, 在 Indian Pines 数据集上取 $S_n = 40$, $C_n = 120$, 在 PaviaU 数据集上取 $S_n = 40$, $C_n = 50$ 。

2.3 Indian Pines 数据集实验

为分析训练样本数对各算法特征提取效果的影



响, 从 Indian Pines 数据集每类地物中随机选取 2%, 4%, 6%, 8%, 10% 的样本进行训练, 由于该数据集每类地物的数量差距较大, 每类包含 20 到 2 455 不等样本, 当某类训练样本数量小于 10 时, 固定该类训练样本为 10, 剩余样本用于测试。实验采用各特征提取算法训练得到低维特征后, 用 1-NN 分类器进行分类, 每次实验重复 10 次, 实验结果采用双侧 T 检验计算对比各个算法与本文算法 LGSPE 的显著性差异, T 检验的显著性水准取 0.05, 若 p 值小于 0.05 则假设检验结果 $h = 1$, 表示该对比算法与 LGSPE 的实验结果显著性差异性较大。**表 1** 为不同训练样本数量下各算法的总体分类精度、标准差和 p, h 值。

由**表 1** 的实验结果可知, 随训练样本数量的增加, 各特征提取算法的分类精度都不断提高, 因为

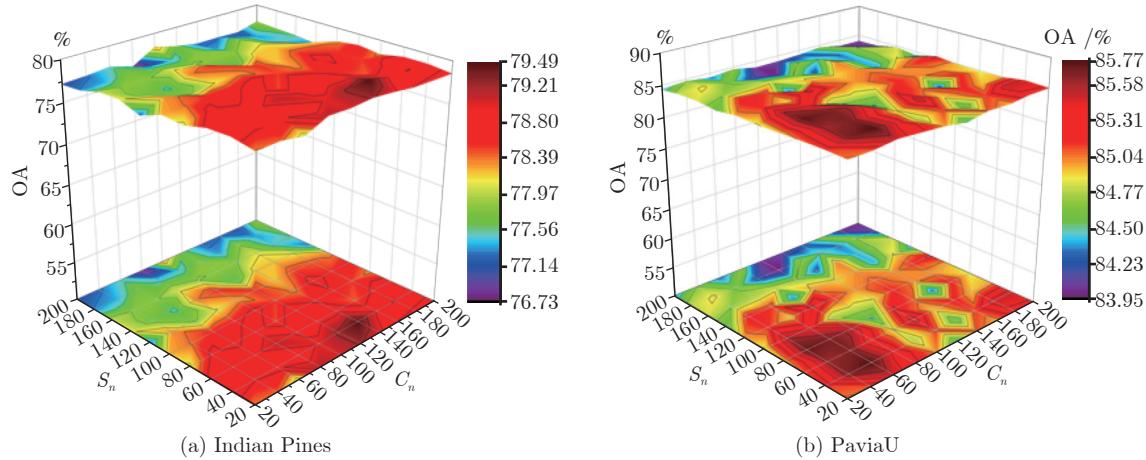


图 5 不同参数 S_n 和 C_n 在两个数据集上的总体分类精度

Fig.5 OAs with different parameters S_n and C_n on two datasets

表 1 不同算法在 Indian Pines 数据集上的分类结果 (总体分类精度±标准差 (%)) (p, h)
Table 1 Classification results with different methods on Indian Pines dataset (OA ± Std (%)) (p, h)

算法	2%	4%	6%	8%	10%
RAW	$58.08 \pm 1.01 (1.5 \times 10^{-08}, 1)$	$63.17 \pm 0.95 (5.8 \times 10^{-12}, 1)$	$64.97 \pm 0.65 (1.2 \times 10^{-14}, 1)$	$66.11 \pm 0.57 (2.2 \times 10^{-17}, 1)$	$67.88 \pm 0.55 (3.9 \times 10^{-20}, 1)$
PCA	$58.02 \pm 1.03 (1.1 \times 10^{-08}, 1)$	$62.99 \pm 1.04 (8.7 \times 10^{-12}, 1)$	$64.83 \pm 0.53 (4.6 \times 10^{-15}, 1)$	$66.09 \pm 0.70 (7.2 \times 10^{-17}, 1)$	$67.80 \pm 0.53 (2.3 \times 10^{-20}, 1)$
LDA	$47.39 \pm 1.49 (5.9 \times 10^{-16}, 1)$	$63.15 \pm 1.47 (1.5 \times 10^{-09}, 1)$	$68.52 \pm 1.19 (1.3 \times 10^{-09}, 1)$	$71.05 \pm 1.03 (7.5 \times 10^{-11}, 1)$	$73.53 \pm 0.63 (2.2 \times 10^{-14}, 1)$
LFDA	$57.68 \pm 0.80 (2.3 \times 10^{-10}, 1)$	$63.00 \pm 1.26 (2.1 \times 10^{-11}, 1)$	$65.17 \pm 0.84 (9.3 \times 10^{-14}, 1)$	$67.25 \pm 0.63 (3.5 \times 10^{-16}, 1)$	$68.78 \pm 0.79 (1.5 \times 10^{-17}, 1)$
SNPE	$47.29 \pm 1.82 (1.5 \times 10^{-14}, 1)$	$65.04 \pm 1.29 (2.1 \times 10^{-08}, 1)$	$68.72 \pm 1.28 (2.3 \times 10^{-09}, 1)$	$70.19 \pm 0.73 (6.2 \times 10^{-13}, 1)$	$71.67 \pm 0.44 (1.7 \times 10^{-17}, 1)$
SPP	$51.95 \pm 1.04 (8.0 \times 10^{-14}, 1)$	$60.00 \pm 0.80 (1.6 \times 10^{-15}, 1)$	$64.29 \pm 0.96 (6.2 \times 10^{-15}, 1)$	$65.98 \pm 0.59 (2.8 \times 10^{-17}, 1)$	$67.97 \pm 0.55 (5.2 \times 10^{-20}, 1)$
DLSP	$57.47 \pm 1.36 (2.1 \times 10^{-06}, 1)$	$63.63 \pm 1.18 (1.5 \times 10^{-10}, 1)$	$66.05 \pm 0.58 (7.6 \times 10^{-14}, 1)$	$67.65 \pm 0.74 (1.4 \times 10^{-15}, 1)$	$69.35 \pm 0.94 (1.6 \times 10^{-16}, 1)$
SDL	$57.56 \pm 1.08 (8.8 \times 10^{-09}, 1)$	$64.04 \pm 0.52 (2.3 \times 10^{-13}, 1)$	$69.05 \pm 0.97 (2.4 \times 10^{-11}, 1)$	$71.27 \pm 0.88 (9.0 \times 10^{-11}, 1)$	$74.03 \pm 0.72 (3.3 \times 10^{-13}, 1)$
DSPE	$61.66 \pm 1.80 (2.5 \times 10^{-01}, 0)$	$65.63 \pm 1.89 (5.5 \times 10^{-06}, 1)$	$69.00 \pm 1.37 (3.8 \times 10^{-09}, 1)$	$69.25 \pm 1.28 (1.7 \times 10^{-11}, 1)$	$70.84 \pm 1.15 (3.9 \times 10^{-13}, 1)$
MSME	$51.66 \pm 1.34 (2.4 \times 10^{-13}, 1)$	$57.76 \pm 1.38 (1.3 \times 10^{-14}, 1)$	$61.65 \pm 0.84 (1.7 \times 10^{-16}, 1)$	$64.36 \pm 0.57 (8.0 \times 10^{-19}, 1)$	$66.57 \pm 0.99 (4.5 \times 10^{-18}, 1)$
LGSFA	$58.44 \pm 1.64 (3.7 \times 10^{-06}, 1)$	$68.17 \pm 1.69 (6.0 \times 10^{-03}, 1)$	$72.77 \pm 1.13 (3.4 \times 10^{-03}, 1)$	$75.45 \pm 0.90 (4.6 \times 10^{-03}, 1)$	$77.24 \pm 0.59 (2.4 \times 10^{-05}, 1)$
SDME	$58.99 \pm 1.41 (3.8 \times 10^{-06}, 1)$	$66.84 \pm 1.34 (4.0 \times 10^{-06}, 1)$	$72.71 \pm 1.09 (1.5 \times 10^{-03}, 1)$	$76.05 \pm 0.55 (7.2 \times 10^{-03}, 1)$	$78.30 \pm 0.30 (2.0 \times 10^{-03}, 1)$
LGSPE	62.79 ± 1.25	70.34 ± 1.05	74.64 ± 1.25	77.04 ± 0.86	79.13 ± 0.53

训练样本越多, 所得到的有用信息也越丰富, 有利于发现数据的本征结构, 进而改善分类精度。LDA、SNPE、SDL 等监督方法总体要优于 PCA、SPP、DLSP 等非监督方法, 这是由于监督方法利用了数据的类别信息, 增强低维特征的鉴别力, 但在训练样本较少时分类精度受限, LDA、SNPE、SPP、MSME 等方法存在过拟合现象。但同样在样本量较少时 DSPE、LGSFA、SDME、LGSPE 的分类精度要明显优于其他对比方法, 这是由于它们通过监督训练局部子空间内的数据能发现更具有鉴别的结构, 且随着样本量的增加 LGSPE 的精度一直优于其他算法, 说明 LGSPE 能更好地保持数据在局部空间的本质结构, 进而改善分类精度。

其中 LFDA、SNPE 仅通过 k 近邻法表征高维数据的局部结构, 提取出的鉴别特征受到限制, 无

监督 SPP 和监督 DLSP 利用稀疏表示直接对数据结构进行表征同样不能揭示数据的内部结构, 然而基于局部几何结构进行构图的 LGSFA 能较好地揭示数据的局部几何特性, 同样以稀疏表示自适应选择存在于同一流形上的点进行图嵌入的方法 SDL、SDME、LGSPE 能很好地发现数据内具有鉴别力的流形结构。且在大部分条件下, 本文方法 LGSPE 能获得最佳分类精度, 这是由于 LGSPE 能同时保持数据的局部几何近邻结构和稀疏特性, 增强了数据的表达能力, 更利于提升分类精度。

将各个算法的实验结果与本文方法 LGSPE 的结果计算出双侧 T 检验的 p 值和 h 值可知, 除了极少数情况下, 各个对比算法与本文算法的显著性差异较大, 且随着训练样本量的增加, 显著性差异基本呈增长趋势。本文方法 LGSPE 在大多数训练条件下分类精度均高于其他算法, 这是由于 LGSPE 构建的图能在低维嵌入时保持高维空间中的局部几何线性结构与稀疏流形结构, 增强了不同类别数据间的可分性, 提取出有利于分类的特征。

为分析各算法对各类地物的特征提取效果, 在每类地物中随机选取 15% 的样本作为训练样本, 其余作为测试样本。表 2 通过每类分类精度、总体分类精度、平均分类精度、Kappa 系数及维数简约 (DR)

所用的时间来对比各算法的优劣, 图 6 为各算法在 Indian Pines 数据集上对应表 2 的分类结果图。

由表 2 可看到, LGSPE 的大多数类别分类精度要优于其他方法, 且根据图 6 中可观察到对应的 2, 5, 6, 11 类具有较好的分类效果, 错分点相对较少, 并在图 6 中做出标记, 以便对应观察, 对应的地物为 “Notill”、“Grass/Psature”、“Grass/Tress”、“Soybeans-min”。同时, 大多数稀疏表示方法的降维时间明显要高于 k 近邻法, 因为稀疏表示的实质是一个优化问题通常采用迭代求解, 稀疏阈值设置的越小, 迭代次数越多, 计算出的相关点越少, 所花费的时间越长。通过表 2 可观察到本文方法 LGSPE 相较于 SDME 分类精度更高的同时训练时间也要少许多, 这是由于本文的稀疏点是从一个邻域内寻找的, 因此计算量相对较低, 获得了不错的训练速度。

2.4 PaviaU 数据集实验

进一步采用 PaviaU 数据集验证算法的有效性和泛化性, 从每类地物中随机选取 0.4%, 0.8%, 1.2%, 1.6%, 2% 的训练样本作为训练集, 其余作为测试集, 由于该数据集的总样本量较大且类别数少, 为保证在两数据集上每类的训练数量差别不大, 因

表 2 不同算法在 Indian Pine 数据集上各类地物的分类结果
Table 2 Classification results of each class samples via different methods on Indian Pines dataset

类别	RAW	PCA	LDA	LFDA	SNPE	SPP	DLSP	SDL	DSPE	MSME	LGSFA	SDME	LGSPE
1	58.33	66.67	72.22	61.11	47.22	63.89	58.33	58.33	55.56	52.78	75.00	77.78	77.78
2	55.68	55.93	67.13	60.38	62.36	59.06	58.90	70.76	66.97	58.07	77.35	77.18	79.98
3	58.01	58.16	63.55	59.86	63.26	58.01	58.16	64.40	60.57	59.43	67.52	68.65	70.35
4	38.31	37.31	51.74	36.32	40.80	32.84	43.28	51.74	39.80	32.84	52.24	54.73	61.19
5	83.70	84.18	87.83	84.18	83.94	83.94	86.62	88.56	86.62	82.00	89.29	90.51	91.24
6	93.23	93.71	96.77	94.68	93.71	94.68	94.52	96.94	95.16	92.74	97.58	97.26	97.90
7	77.78	77.78	72.22	55.56	88.89	55.56	83.33	83.33	88.89	66.67	88.89	88.89	88.89
8	94.83	95.57	99.01	93.60	94.83	94.09	96.06	94.83	95.57	92.36	96.06	96.31	96.80
9	50	60.00	90	70	70	40	60	100	90	60	100	80	70
10	66.59	65.38	61.74	68.77	69.61	69.85	65.98	74.21	67.43	67.43	74.33	77.24	77.60
11	70.82	70.96	73.50	72.83	75.13	73.41	72.21	81.74	74.75	74.70	80.88	81.60	82.89
12	43.25	43.85	70.63	46.63	53.77	46.43	49.80	63.10	62.30	43.45	69.64	72.42	75.99
13	89.08	86.78	97.13	86.78	87.93	93.68	85.63	95.98	94.83	82.76	94.83	95.98	95.98
14	88.93	88.56	94.05	90.23	90.88	89.58	90.33	96.65	91.53	90.33	94.60	94.33	95.26
15	35.37	34.76	59.15	39.94	38.11	39.02	35.06	46.04	42.99	33.54	50.91	50.00	56.71
16	92.41	92.41	88.61	91.14	89.87	88.61	92.41	91.14	86.08	86.08	86.08	88.61	89.87
OA (%)	69.65	69.65	76.17	71.62	73.34	71.43	71.28	79.12	74.63	70.65	80.57	81.32	83.02
AA (%)	68.52	69.50	77.83	69.50	71.89	67.67	70.66	78.61	74.94	67.20	80.95	80.72	81.78
Kappa	0.654	0.654	0.728	0.676	0.695	0.674	0.673	0.761	0.710	0.664	0.778	0.787	0.806
DR 时间 (s)	—	0.01	0.01	0.06	0.13	21.94	39.76	3.67	2.07	6.18	5.52	36.64	12.28

此训练样本比例均小于 Indian Pines 数据集. 表 3 为不同训练样本比例下各算法的分类结果.

根据表 3 可知, 随着训练样本数量的增多, 算法的分类精度增长速度减缓, 这是由于训练样本充足时, 特征提取算法训练出较为完备的投影空间, 充分发挥算法的提取性能. 不管是基于局部几何近邻结构的 LFDA、SNPE、LGSFA、LGSPE, 还是基于稀疏流形学习的 SDL、DSPE、MSME、SDME、LGSPE 等方法都旨在探索高维数据的局部结构, 以发掘数据中具有鉴别力的特征. 由 p 和 h 值可知, 各对比算法与本文算法的总体分类精度均具有较大差异, 且相较于 Indian Pines 数据集, 本文方法的分类精度要明显优于其他对比方法, 这是由于 PaviaU 数据集相较于 Indian Pines 类别更少并且样本数量更多, 两数据集的数据结构、复杂度和可分性存在差异. 且可观察出 SDL、MSME 等方法相

比于其他算法在某一个数据集上能获得较佳效果, 而在另一个数据集上效果不明显, 这就体现了算法在不同数据集上的泛化能力. 本文提出的算法 LGSPE 在各种条件下均具有最佳分类效果且具有较好的泛化性, 这是由于通过局部线性重构减弱噪声的影响并减小类内数据的差异性, 通过局部几何稀疏度量的方法保持数据的局部几何近邻结构和稀疏关系, 同时嵌入图框架能较好地保持同类数据的本质结构提高异类数据的可分性, 从而获得最佳分类精度.

为充分探索各算法对各类地物的分类效果, 在每类地物中随机选取 5% 的样本作为训练样本, 其余作为测试样本. 表 4 为分类结果, 图 7 为对应各地物的分类可视化图. 从表 4 可知, LGSPE 在诸多地物类别中均获得较好的分类效果, 且根据图 7 观察可知在第 2, 6, 7, 8 类对应的 “Meadows”、

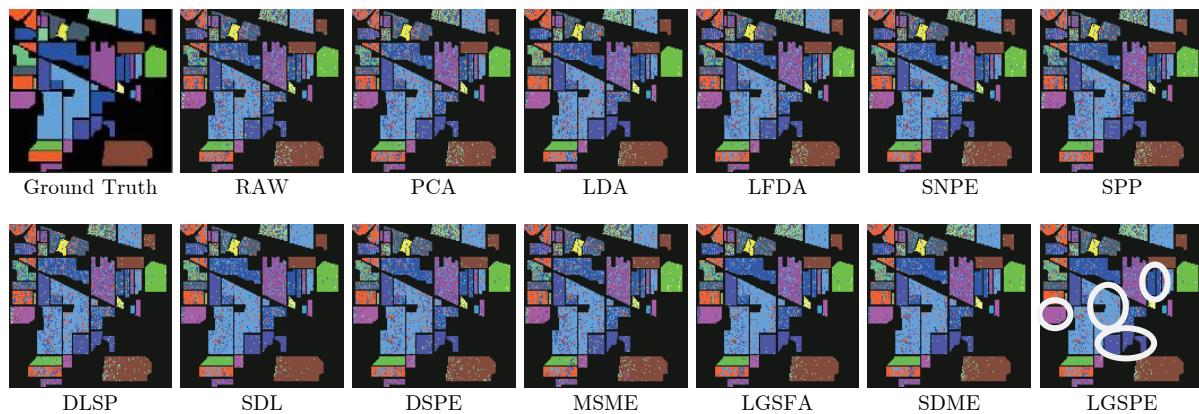


图 6 各算法在 Indian Pines 数据集上的分类结果图

Fig. 6 Classification maps of different method on Indian Pines dataset

表 3 不同算法在 PaviaU 数据集上的分类结果 (总体分类精度±标准差 (%)) (p, h)
Table 3 Classification results with different methods on PaviaU dataset (OA ± Std (%)) (p, h)

算法	0.4%	0.8%	1.2%	1.6%	2%
RAW	$76.16 \pm 1.28 (1.8 \times 10^{-9}, 1)$	$78.13 \pm 0.69 (2.4 \times 10^{-15}, 1)$	$80.50 \pm 0.53 (5.2 \times 10^{-17}, 1)$	$81.11 \pm 0.65 (4.7 \times 10^{-16}, 1)$	$82.20 \pm 0.54 (3.0 \times 10^{-17}, 1)$
PCA	$76.15 \pm 1.27 (1.7 \times 10^{-9}, 1)$	$78.12 \pm 0.69 (2.4 \times 10^{-15}, 1)$	$80.49 \pm 0.54 (6.7 \times 10^{-17}, 1)$	$81.10 \pm 0.64 (4.1 \times 10^{-16}, 1)$	$82.18 \pm 0.54 (2.5 \times 10^{-17}, 1)$
LDA	$68.06 \pm 1.49 (1.2 \times 10^{-14}, 1)$	$76.24 \pm 1.65 (1.1 \times 10^{-12}, 1)$	$78.73 \pm 1.21 (4.2 \times 10^{-14}, 1)$	$80.36 \pm 0.64 (7.0 \times 10^{-17}, 1)$	$81.88 \pm 0.64 (1.1 \times 10^{-16}, 1)$
LFDA	$79.10 \pm 1.16 (3.8 \times 10^{-6}, 1)$	$81.60 \pm 0.57 (1.0 \times 10^{-11}, 1)$	$83.41 \pm 0.26 (6.6 \times 10^{-15}, 1)$	$84.25 \pm 0.68 (1.7 \times 10^{-11}, 1)$	$85.25 \pm 0.48 (3.7 \times 10^{-13}, 1)$
SNPE	$75.17 \pm 1.00 (4.5 \times 10^{-11}, 1)$	$78.32 \pm 1.23 (1.2 \times 10^{-12}, 1)$	$80.48 \pm 0.56 (9.0 \times 10^{-17}, 1)$	$82.15 \pm 1.20 (1.9 \times 10^{-11}, 1)$	$83.09 \pm 0.68 (7.7 \times 10^{-15}, 1)$
SPP	$67.23 \pm 0.44 (1.9 \times 10^{-17}, 1)$	$73.63 \pm 1.27 (6.1 \times 10^{-16}, 1)$	$76.24 \pm 0.96 (1.6 \times 10^{-17}, 1)$	$78.13 \pm 0.48 (5.7 \times 10^{-20}, 1)$	$79.19 \pm 0.92 (5.4 \times 10^{-17}, 1)$
DLSP	$74.32 \pm 1.80 (6.8 \times 10^{-10}, 1)$	$77.73 \pm 1.10 (1.0 \times 10^{-13}, 1)$	$80.47 \pm 0.80 (5.7 \times 10^{-15}, 1)$	$79.69 \pm 1.39 (4.9 \times 10^{-13}, 1)$	$81.52 \pm 1.02 (3.9 \times 10^{-14}, 1)$
SDL	$57.30 \pm 2.31 (9.4 \times 10^{-17}, 1)$	$60.73 \pm 4.15 (2.2 \times 10^{-13}, 1)$	$62.80 \pm 2.30 (1.4 \times 10^{-17}, 1)$	$65.46 \pm 1.89 (2.2 \times 10^{-18}, 1)$	$67.28 \pm 2.63 (1.3 \times 10^{-15}, 1)$
DSPE	$79.50 \pm 1.52 (6.0 \times 10^{-6}, 1)$	$80.50 \pm 2.31 (6.6 \times 10^{-07}, 1)$	$80.75 \pm 1.56 (1.8 \times 10^{-10}, 1)$	$82.09 \pm 1.42 (1.7 \times 10^{-10}, 1)$	$83.62 \pm 1.67 (2.1 \times 10^{-08}, 1)$
MSME	$75.24 \pm 1.76 (3.2 \times 10^{-09}, 1)$	$79.32 \pm 1.90 (3.3 \times 10^{-09}, 1)$	$82.94 \pm 1.01 (2.6 \times 10^{-10}, 1)$	$83.94 \pm 1.12 (1.9 \times 10^{-09}, 1)$	$85.41 \pm 0.64 (2.8 \times 10^{-11}, 1)$
LGSFA	$73.90 \pm 1.05 (4.7 \times 10^{-12}, 1)$	$78.26 \pm 1.80 (1.6 \times 10^{-10}, 1)$	$81.40 \pm 0.93 (5.3 \times 10^{-13}, 1)$	$82.59 \pm 0.65 (2.7 \times 10^{-14}, 1)$	$83.28 \pm 0.78 (9.5 \times 10^{-14}, 1)$
SDME	$79.67 \pm 1.84 (3.2 \times 10^{-04}, 1)$	$82.32 \pm 0.74 (9.0 \times 10^{-10}, 1)$	$83.57 \pm 0.68 (2.2 \times 10^{-11}, 1)$	$84.67 \pm 0.78 (4.6 \times 10^{-10}, 1)$	$85.35 \pm 0.60 (9.7 \times 10^{-12}, 1)$
LGSPE	82.96 ± 1.46	86.24 ± 0.78	87.34 ± 0.47	88.23 ± 0.52	88.74 ± 0.36

表 4 不同算法在 PaviaU 数据集上各类地物的分类结果
Table 4 Classification results of each class samples via different methods on PaviaU dataset

类别	RAW	PCA	LDA	LFDA	SNPE	SPP	DLSP	SDL	DSPE	MSME	LGSFA	SDME	LGSPE
1	85.76	85.74	87.59	86.28	86.17	83.60	86.25	66.85	76.28	85.33	89.17	85.24	89.08
2	93.48	93.33	93.76	95.49	94.65	93.19	93.28	94.19	93.52	96.14	97.27	93.50	97.92
3	63.09	62.99	62.24	69.26	64.69	57.37	62.69	49.00	58.48	64.54	66.10	63.29	74.12
4	83.10	83.24	84.40	84.40	84.95	80.87	83.37	75.78	79.66	83.72	90.45	87.29	88.94
5	98.75	98.75	99.84	99.30	98.67	99.22	98.75	99.69	99.61	99.77	99.77	99.69	99.61
6	63.02	63.16	68.84	72.35	68.04	67.06	62.89	34.72	73.73	76.81	58.04	72.48	82.52
7	83.93	83.69	74.51	86.22	85.59	76.80	83.45	54.87	71.81	82.34	78.62	84.40	88.28
8	80.70	80.93	76.62	83.16	81.68	76.53	80.85	75.61	70.10	78.90	75.04	74.30	83.59
9	100	100	100	100	100	99.67	99.67	87	97	99.33	99	98.89	100
OA (%)	85.37	85.34	85.90	88.13	86.88	84.38	85.35	76.63	83.40	88.03	87.29	86.20	91.20
AA (%)	83.50	83.50	83.04	86.25	84.90	81.59	83.47	70.91	80.07	85.21	83.79	84.34	89.21
Kappa	0.804	0.804	0.812	0.841	0.824	0.791	0.804	0.682	0.778	0.840	0.828	0.816	0.883
DR 时间 (s)	—	0.009	0.01	0.10	0.28	23.72	71.13	7.30	6.54	8.26	6.31	33.18	12.17

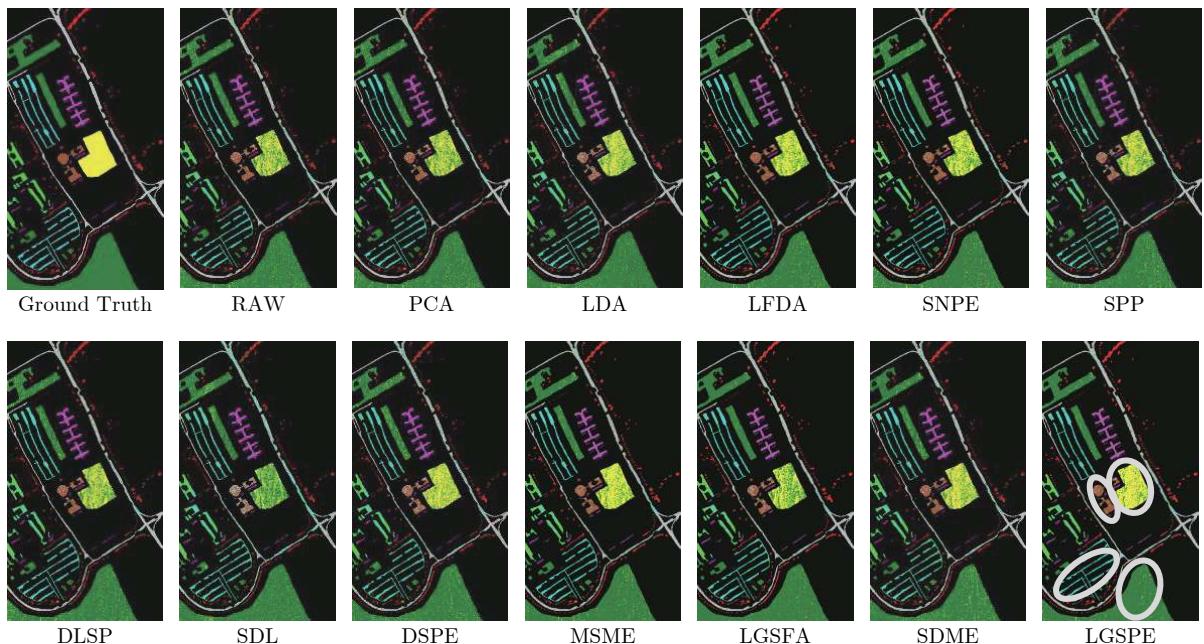


图 7 PaviaU 数据集上各算法的分类结果图
Fig. 7 Classification maps of different method on PaviaU dataset

“Soil”、“Bitumen”、“Bricks”等地物中获得较高分类精度,已在图 7 中相应圈出,以便对比观察。由图 7 可知,相比于其他维数约简算法,本文算法 LGSPE 的分类结果图的错分点较少,更接近真实场景,表明 LGSPE 能较好地保持数据的局部几何近邻结构和稀疏特性,探索高维数据的低维本质结构。

2.5 空间滤波实验

本文方法为基于光谱的特征提取方法,为进一步验证其有效性,在此进行滤波对比实验,并与

RAW、空-谱协同正则化稀疏超图嵌入 (Spatial-spectral regularized sparse hypergraph embedding, SSRSHE)^[20] 算法进行对比。在实验中采用加权中值滤波 (Weighted median filter, WMF) 对高光谱影像进行滤波,分布采用方法对滤波前后数据进行实验。具体参数设置为: WMF 滤波空间窗口设置为 3, SSRSHE 参数与文献 [26]一致, 分别从 Indian Pines 和 PiavaU 数据集中每类随机选取 5, 10, 20, 40, 60 个样本作为训练集, 其余作为测试集, 每次实验重复 10 次, 实验结果如表 5 所示。

表5 不同算法在 Indian Pines 和 PaviaU 数据集上的分类结果(总体分类精度±标准差(%) (Kappa))
Table 5 Classification results with different methods on PaviaU and Indian Pines dataset (OA ± Std (%) (Kappa))

			5	10	20	40	60
Indian	未滤波	RAW	44.02±3.74 (0.376)	48.69±1.92 (0.430)	55.25±2.36 (0.499)	58.78±0.91 (0.538)	61.10±0.33 (0.562)
		SSRSHE	43.65±5.79 (0.375)	49.16±5.34 (0.436)	56.58±4.33 (0.515)	59.91±2.70 (0.550)	66.90±1.69 (0.626)
		LGSPE	45.58±2.97 (0.342)	52.80±2.47 (0.470)	61.82±2.88 (0.572)	70.26±1.42 (0.664)	73.29±1.09 (0.697)
Pines	滤波后	RAW	48.97±2.10 (0.432)	58.53±1.92 (0.535)	65.27±1.66 (0.609)	70.14±1.65 (0.663)	74.30±1.04 (0.709)
		SSRSHE	65.04±4.15 (0.610)	71.50±2.87 (0.680)	79.30±1.63 (0.767)	86.64±2.85 (0.848)	87.75±1.15 (0.860)
		LGSPE	69.17±2.72 (0.657)	78.96±1.82 (0.763)	85.48±1.48 (0.836)	90.68±1.00 (0.894)	93.92±0.50 (0.930)
PaviaU	未滤波	RAW	56.85±7.57 (0.474)	65.12±3.46 (0.564)	68.82±2.72 (0.609)	71.78±0.79 (0.644)	74.58±0.59 (0.676)
		SSRSHE	62.49±3.39 (0.538)	64.29±1.73 (0.559)	67.81±3.25 (0.599)	71.21±1.71 (0.638)	75.36±2.44 (0.685)
		LGSPE	65.58±6.08 (0.567)	69.91±6.06 (0.622)	75.70±1.98 (0.690)	81.76±1.71 (0.765)	81.45±1.30 (0.760)
PaviaU	滤波后	RAW	60.41±2.85 (0.514)	67.39±2.46 (0.590)	71.27±3.06 (0.639)	76.11±1.14 (0.696)	77.86±2.17 (0.718)
		SSRSHE	71.18±4.85 (0.639)	75.17±2.96 (0.686)	82.86±2.07 (0.730)	84.24±0.71 (0.795)	87.02±0.97 (0.803)
		LGSPE	76.10±3.53 (0.697)	80.21±3.05 (0.700)	86.70±2.18 (0.828)	91.02±1.95 (0.883)	93.72±0.93 (0.917)

由表5实验结果可知,在各种训练条件,各种算法在进行滤波后分类性能都有明显的提升,这说明滤波后可有效降低噪声的影响。本文提出的LGSPE算法尽管在提取特征时没有利用空间信息,但是其分类结果都要优于空谱方法SSRSHE,主要原因是通过类内重构的方式可有效利用同类样本的信息,使同类样本更具相似性,并且通过保持局部邻域的几何结构和稀疏特性,使嵌入特征更具有鉴别性,提升分类性能。

3 结束语

高光谱图像数据在高维空间中存在复杂的结构关系,针对传统维数约简方法未能充分利用标签信息进行特征学习,以及简单图嵌入方法难以充分利用局部信息发掘数据的内蕴关系等问题,本文提出一种局部几何稀疏保持嵌入算法,以进行特征提取。局部线性重构每个训练样本可增加同类样本的聚集性,通过稀疏流形编码模型能自适应地选取来自同一流形的稀疏数据,以图嵌入方式保持数据在邻域内的几何近邻结构和稀疏关系。在特征投影空间中使同类数据尽可能聚集,提取出更具鉴别的特征。在Indian Pines和PaviaU数据集上验证本文算法的有效性与泛化性,实验结果表明,相较于其他算法,LGSPE在使用较少的训练时间下,能获得最好的地物分类性能。由于本文方法仅利用光谱信息,下一步计划将考虑加入空间信息,进一步提升算法分类性能。

References

- Du Pei-Jun, Xia Jun-Shi, Xue Zhao-Hui, Tan Kun, Su Hong-Jun, Bao Rui. Progress of hyperspectral remote sensing image classification. *Journal of Remote Sensing*, 2016, **20**(2): 236–256
(杜培军, 夏俊士, 薛朝辉, 谭琨, 苏红军, 鲍蕊. 高光谱遥感影像分类研究进展. 遥感学报, 2016, **20**(2): 236–256)
- Huang Hong, Li Zheng-Ying, Shi Guang-Yao, Pan Ying-Song. Multi-features manifold discriminant embedding for hyperspectral image classification. *Optics and Precision Engineering*, 2019, **27**(3): 726–738
(黄鸿, 李政英, 石光耀, 潘银松. 面向高光谱影像分类的多特征流形鉴别嵌入. 光学精密工程, 2019, **27**(3): 726–738)
- Zhang Bing. Advancement of hyperspectral image processing and information extraction. *Journal of Remote Sensing*, 2016, **20**(5): 1062–1090
(张兵. 高光谱图像处理与信息提取前沿. 遥感学报, 2016, **20**(5): 1062–1090)
- Wang Tian-Cheng, Liu Xiang-Zhen, Dong Ze-Zheng, Wang Hai-Bo. A robust minimum volume based algorithm with automatically estimating regularization parameters for hyperspectral unmixing. *Acta Automatica Sinica*, 2017, **43**(12): 2141–2159
(王天成, 刘相振, 董泽政, 王海波. 一种自适应鲁棒最小体积高光谱解混算法. 自动化学报, 2017, **43**(12): 2141–2159)
- Chen M L, Wang Q, Li X L. Discriminant analysis with graph learning for hyperspectral image classification. *Remote Sensing*, 2018, **10**(6): 836
- Zhang Hao-Kui, Li Ying, Jiang Ye-Nan. Deep learning for hyperspectral imagery classification: The state of the art and prospects. *Acta Automatica Sinica*, 2018, **44**(6): 961–977
(张号逵, 李映, 姜晔楠. 深度学习在高光谱图像分类领域的研究现状与展望. 自动化学报, 2018, **44**(6): 961–977)
- Zhang Cheng-Kun, Han Min. Spectral-spatial joint classification of hyperspectral image with edge-preserving filtering. *Acta Automatica Sinica*, 2018, **44**(2): 280–288
(张成坤, 韩敏. 基于边缘保持滤波的高光谱影像光谱-空间联合分类. 自动化学报, 2018, **44**(2): 280–288)
- Gan Y H, Luo F L, Liu J H, Lei B, Zhang T, Liu K. Feature extraction based multi-structure manifold embedding for hyperspectral remote sensing image classification. *IEEE Access*, 2017, **5**: 25069–25080
- Sun W W, Yang G, Du B, Zhang L F, Zhang L P. A sparse and low-rank near-isometric linear embedding method for feature extraction in hyperspectral imagery classification. *IEEE Transactions on Geoscience and Remote Sensing*, 2017, **55**(7): 4032–4046
- Karl P. On lines and planes of closest fit to systems of points in space. *Philosophical Magazine*, 1901, **2**(11): 559–572
- Fisher R A. The use of multiple measurements in taxonomic problems. *Annals of Eugenics*, 1936, **7**: 179–188
- Belkin M, Niyogi P. *Laplacian Eigenmaps for Dimensionality Reduction and data Representation*. MIT Press, 2003.

- 13 Roweis S T, Saul L K. Nonlinear dimensionality reduction by locally linear embedding. *Science*, 2000, **290**(5500): 2323–2326
- 14 Tenenbaum J B, de Silva V, Langford J C. A global geometric framework for nonlinear dimensionality reduction. *Science*, 2000, **290**(5500)
- 15 He X F, Cai D, Yan S C, Zhang H J. Neighborhood preserving embedding. In: Proceedings of the 10th IEEE International Conference on Computer Vision (ICCV), Beijing, China, 2005, 2: 1208–1213.
- 16 He X F, Niyogi P. Locality preserving projections. *Neural Information Processing Systems*, 2004, **16**: 153–160
- 17 Yan S C, Xu D, Zhang B Y, Zhang H J, Yang Q, Lin S. Graph embedding and extensions: A general framework for dimensionality reduction. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2007, **29**(1): 40–51
- 18 Zeng X H, Luo S W. A supervised subspace learning algorithm: Supervised neighborhood preserving embedding. *Advanced Data Mining and Applications, Harbin, China*, 2007, **4632**: 81–85
- 19 Zheng Z L, Yang F, Tan W N, Jia J, Yang J. Gabor feature-based face recognition using supervised locality preserving projection. *Signal Processing*, 2007, **87**(10): 2473–2483
- 20 Sugiyama M. Dimensionality reduction of multimodal labeled data by local Fisher discriminant analysis. *Journal of Machine Learning Research*, 2007, **8**(1): 1027–1061
- 21 Luo F L, Huang H, Duan Y L, Liu J M, Liao Y H. Local geometric structure feature for dimensionality reduction of hyperspectral imagery. *Remote Sensing*, 2017, **9**(8): 790–813
- 22 Qiao L S, Chen S C, Tan X Y. Sparsity preserving projections with applications to face recognition. *Pattern Recognition*, 2010, **43**(1): 331–341
- 23 Zang F, Zhang J S. Discriminative learning by sparse representation for classification. *Neurocomputing*, 2011, **74**: 2176–2183
- 24 Luo Fu-Lin. Sparse manifold learning for hyperspectral imagery. *Acta Geodaetica et Cartographica Sinica*, 2017, **46**(3): 400
(罗甫林. 高光谱图像稀疏流形学习方法研究. 测绘学报, 2017, **46**(3): 400)
- 25 Luo Fu-Lin, Huang Hong, Liu Jia-Min, Ma Ze-Zhong. Hyperspectral image land cover classification based on discriminant sparse preserving embedding. *Chinese Journal of Scientific Instrument*, 2016, **37**(1): 177–183
(罗甫林, 黄鸿, 刘嘉敏, 马泽忠. 基于鉴别稀疏保持嵌入的高光谱影像地物分类. 仪器仪表学报, 2016, **37**(1): 177–183)
- 26 Huang H, Li Z Y, He H B, Duan Y L, Yang S. Self-adaptive manifold discriminant analysis for feature extraction from hyperspectral imagery. *Pattern Recognition*, 2020, **107**(9): 108487
- 27 Elhamifar E, Vidal R. Sparse manifold clustering and embedding. In: Proceedings of the 24th International Conference on Neural Information Processing and Systems. Granada, Spain, 2011. 55–63
- 28 Huang H, Luo F L, Liu J M, Yang Y Q. Dimensionality reduction of hyperspectral images based on sparse discriminant manifold embedding. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2015, **106**: 42–54
- 29 Huang Hong, Chen Mei-Li, Wang Li-Hua, Li Zheng-Yin. Using spatial-spectral regularized hypergraph embedding for hyperspectral image classification. *Acta Geodaetica et Cartographica Sinica*, 2019, **48**(6): 676–687
(黄鸿, 陈美利, 王丽华, 李政英. 空-谱协同正则化稀疏超图嵌入的高光谱图像分类. 测绘学报, 2019, **48**(6): 676–687)



黄 鸿 重庆大学光电工程学院教授. 主要研究方向为流形学习, 模式识别, 遥感影像智能化处理. 本文通信作者. E-mail: hhuang@cqu.edu.cn
(HUANG Hong Professor at the College of Optoelectronic Engineering, Chongqing University. His research interest covers manifold learning, pattern recognition, and intelligent processing of remote sensing images. Corresponding author of this paper.)



唐玉枭 重庆大学光电工程学院硕士研究生. 主要研究方向为模式识别和图像处理.
E-mail: tangyuxiao@cqu.edu.cn
(TANG Yu-Xiao Master student at the College of Optoelectronic Engineering, Chongqing University. His research interest covers pattern recognition and image processing.)



段宇乐 重庆大学光电工程学院博士研究生. 主要研究方向为机器学习, 模式识别和遥感图像处理.
E-mail: duanyule@cqu.edu.cn
(DUAN Yu-Le Ph.D. candidate at the College of Optoelectronic Engineering, Chongqing University. His research interest covers machine learning, pattern recognition, and remote sensing image processing.)