

文章编号 1004-924X(2019)03-0726-13

面向高光谱影像分类的多特征流形鉴别嵌入

黄 鸿*, 李政英, 石光耀, 潘银松

(重庆大学 光电技术与系统教育部重点实验室, 重庆 400044)

摘要: 鉴于传统维数约减方法对高光谱遥感影像进行降维时, 往往只利用了单一的光谱特征, 限制了分类性能的提升。提出一种基于多特征流形鉴别嵌入的维数约减方法, 该方法首先提取高光谱数据的 LBP(Local Binary Patterns) 纹理特征, 然后利用样本点的光谱-LBP 特征联合距离及类别信息构建类内图和类间图以发现高光谱影像中的鉴别流形结构, 在低维嵌入空间中不仅保持来自同一像素的光谱和纹理特征的相似性, 而且使同类点尽可能紧致、不同类点远离, 实现空-谱联合低维鉴别特征提取, 以有效提高地物分类性能。在 Indian Pines 和黑河高光谱遥感数据集上的实验表明, 本文算法的分类精度在不同实验条件下均优于传统的维数约减方法, 其分类精度可达 95.05% 和 96.20%, 在较少训练样本条件下优势更为明显, 有利于实际应用。

关键词: 高光谱遥感; 维数约减; 纹理特征; 多特征学习; 流形学习

中图分类号: TP394.1; TH691.9 **文献标识码:** A **doi:** 10.3788/OPE.20192703.0726

Multi-features manifold discriminant embedding for hyperspectral image classification

HUANG Hong*, LI Zheng-ying, SHI Guang-yao, PAN Yin-song

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

* Corresponding author, E-mail: hhuang@cqu.edu.cn

Abstract: The traditional Dimensionality Reduction (DR) methods consider the spectral features but ignores useful spatial information in HSI. To overcome this problem, this paper proposed a new dimensionality reduction method called Multi-Feature Manifold Discriminant Embedding (MFDE). First, the MFDE method extracted the features of the local binary pattern from HSI data. Next, the within-class and between-class graphs were constructed using sample labels to exploit the local manifold structure. Then, an optimal object function was designed to learn the combined spatial-spectral features by compacting the intra-class samples and simultaneously separating the inter-class samples. Thus, the discriminative ability of embedding features was improved. Experimental results in the Indian Pines and Heihe hyperspectral data sets show that the proposed MFDE method performs better than some state-of-the-art DR methods in most cases and achieves an overall classification accuracy of 95.05% and 96.20%, respectively. Its advantage is more significant for less training samples, making

收稿日期: 2018-09-14; 修订日期: 2018-11-16.

基金项目: 国家自然科学基金资助项目 (No. 41371338); 重庆市基础研究与前沿探索项目资助 (No. cstc2018jcyjAX0093); 重庆市研究生科研创新项目资助 (No. CYS18035)

it more conducive to practical applications.

Key words: hyperspectral remote sensing; dimensionality reduction; texture feature; multiple features learning; manifold learning

1 引 言

为发展对地观测技术,我国开展了高分辨率对地观测项目以实现陆地、海洋、大气等各类对地观测信息的获取,掌握高分对地观测信息自主权。2018年发射的高分五号卫星是世界首颗实现对大气和陆地综合观测的全谱段高光谱卫星,可为环境监测、资源勘查、防灾减灾等行业提供数据支持^[1-3]。高光谱影像(Hyperspectral Image, HSI)具有光谱分辨率高、图谱合一的特点,在地物精细分类中具有独到的优势,但其几十甚至数百个光谱波段数易导致“维数灾难”问题^[4-6]。因此,如何有效去除数据中的冗余信息,挖掘隐含于众多维数中的关键鉴别特征,是实现高光谱遥感影像地物分类的关键^[7-9]。

为克服“维数灾难”带来的影响,学者们提出了一系列维数约减(Dimensionality Reduction)方法,将观测数据从高维空间映射到嵌入空间得到低维特征^[10]。其中,主成分分析(Principal Component Analysis, PCA)^[11]和线性鉴别分析(Linear Discriminant Analysis, LDA)^[12]等子空间方法均假设高维数据具有线性结构,但是不能发现HSI数据中的低维流形结构^[13]。等距离映射(Isometric Feature Mapping, ISOMAP)^[14]、局部线性嵌入(Local Linear Embedding, LLE)^[15]等非线性流形学习方法可有效表征HSI中的本征结构,但不能得到直接的投影矩阵,存在样本外学习(out-of-sample)问题。为此,He等提出了邻域保持嵌入(Neighborhood Preserving Embedding, NPE)^[16]、局部保持投影(Locality Preserving Projection, LPP)^[17]等方法,但均为非监督方法,地物分类性能受限。而后,学者们在图嵌入框架下提出了如边界Fisher分析(Marginal Fisher Analysis, MFA)^[18]、局部Fisher判别分析(Local Fisher Discriminant Analysis, LFDA)^[19]和局部几何结构Fisher分析(Local Geometric Structure Feature Analysis, LGSFA)^[20]等监督学习方法,取得了较好的分类效果,但只利用了HSI数据中

的光谱特征,忽略了其空间信息,而研究证明融合空间信息可有效提高地物分类性能。

近年来,学者们通过利用高光谱遥感影像中空间一致性特点,提出利用纹理、形态学等空间特征对高光谱数据集进行分类。李伟等利用局部二值模式(Local Binary Patterns, LBP)算子提取HSI数据的纹理特征,并结合极限学习机(ELM)进行分类^[21]。Mauro等提出了扩展形态学多属性剖面(Extended Multiattribute Profiles, EMAPs)算法^[22],以提取HSI数据中的形态学特征。李军等融合光谱及EMAPs特征进行分类,有效提升了分类性能^[23]。Song等提出了采用LBP算子提取纹理特征,然后将光谱和纹理特征进行堆叠,以改善分类性能^[24]。虽然上述方法对HSI数据空-谱特征提取进行了积极地探索,但大多是利用单一空间特征,或是将光谱与空间特征进行简单堆叠,不能实现将光谱、空间特征在低维流形空间上的有效融合,提取鉴别特征。

针对上述问题,本文提出一种面向高光谱遥感影像的多特征学习方法——多特征流形鉴别嵌入(Multi-feature manifold discriminant embedding, MFDE)。该方法首先计算高光谱遥感数据的LBP纹理特征,然后利用样本数据的光谱-纹理联合距离与类别信息构建类内图和类间图以发现高光谱影像中的鉴别流形结构,并将其同时投影到同一低维嵌入空间,在嵌入空间中同类样本尽可能聚集、不同类样本远离,实现空-谱鉴别特征提取,有效提升分类性能。在Indian Pines和黑河高光谱数据集上的实验结果表明,本文方法相比其他维数约减方法可明显提升地物分类精度,尤其在训练样本较少时具有更明显的优势。

2 本文算法

假设高光谱数据集为 $\mathbf{X}=[\mathbf{x}_1, \mathbf{x}_2, \mathbf{x}_3, \dots, \mathbf{x}_N] \in \mathbf{R}^{D \times N}$, N 为样本数, D 为高光谱数据集包含的波段个数, \mathbf{x}_i 对应的类别标签集为 $\mathbf{L}(\mathbf{x}_i) = \{1, 2, \dots, c\}$, c 为类别数。低维嵌入特征可表示为

$Y \in \mathbf{R}^{n \times d}, d \ll D$.

2.1 高光谱数据光谱及纹理特征

高光谱遥感影像具有图谱合一特性,提供了丰富的光谱及空间特征信息。其中,光谱特征提供了地物近乎连续的光谱信息,而空间特征是指由像素及其邻域内像素通过数学运算获取的反映影像局部空间特性的数值。纹理特征是一种典型的空问特征,可用来描述图像局部纹理特征,可通过基于统计特征、模型、空间频率等进行提取。

LBP 是一种计算局部窗口内像素的局部结构与灰度反差并采用统计的方法来描述纹理的算子。该算子计算简单、纹理描述能力强,且具有旋转不变性和灰度不变性等优点,在图像纹理分析中应用广泛。原始 LBP 算子以 3×3 窗口中心像素为阈值,将相邻 8 pixel 的灰度值与其进行比较,若邻域像素值大于中心像素值,则该像素点的位置被标记为 1,否则为 0。得到的 8 位二进制数即为中心像素点的 LBP 值,可有效反映该区域的纹理信息。高光谱数据的纹理特征提取如图 1 所示。




图 1 高光谱数据 LBP 纹理特征计算示意图

Fig. 1 Computation of LBP textural features in hyperspectral data

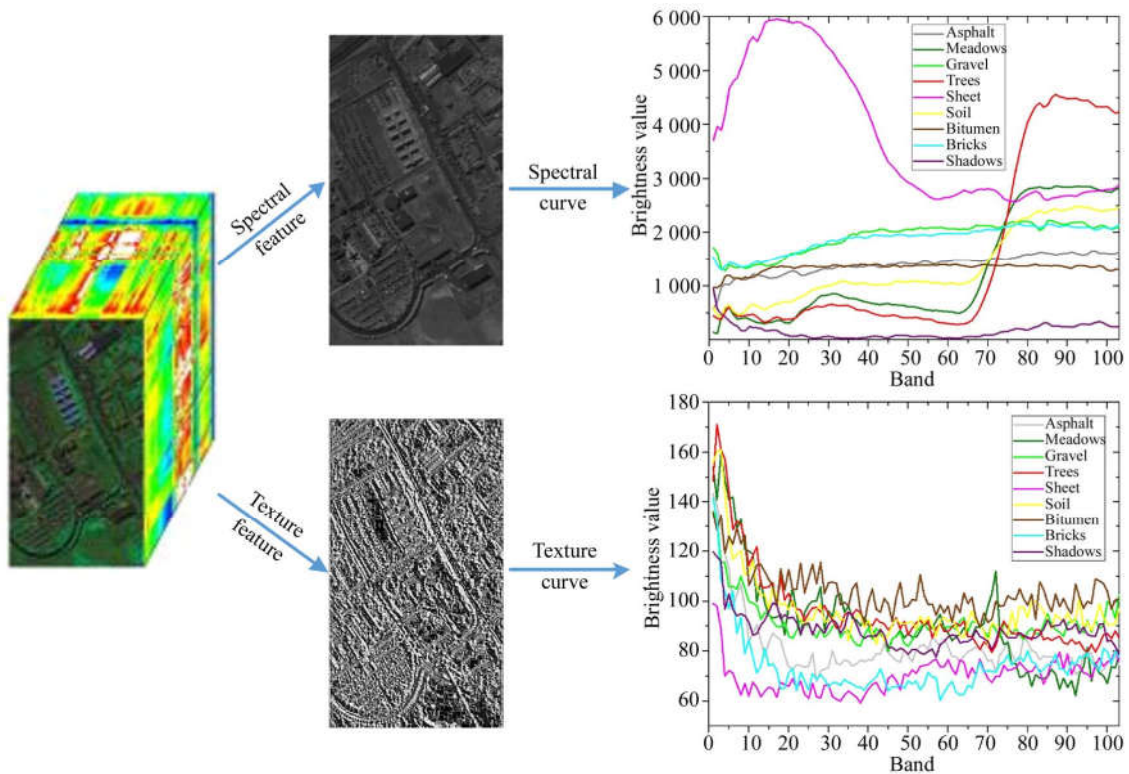


图 2 高光谱遥感影像的光谱和纹理特征

Fig. 2 Spectral and textural features of hyperspectral remote sensing images

图 2 为 PaviaU 高光谱数据集中光谱和 LBP 纹理特征示意图。由图 2 可得知,高光谱数据集中无论是光谱还是纹理等单一特征并不能有效区分不同地物,且维数较高,给分类带来困难。鉴于此,本文通过对高光谱遥感影像的光谱和 LBP 特征进行学习,提取低维空-谱联合鉴别特征,进而提高后续分类性能。

2.2 多特征流形鉴别嵌入

针对上述高光谱数据单一特征分类中存在

的问题,本文提出了一种多特征流形鉴别嵌入方法(MFDE),该方法首先提取高光谱数据的光谱-LBP 纹理特征,并利用样本数据的光谱-LBP 特征联合距离及类别标签信息构建类内和类间图以表征其鉴别流形结构,然后将两种特征同时投影到同一低维嵌入空间,提取低维空-谱联合鉴别特征,实现类内点尽可能聚集、类间点远离,有效提高地物分类性能。图 3 为 MFDE 方法的示意图。




图 3 多特征流形鉴别嵌入(MFDE)算法示意图

Fig. 3 Diagram of multi-feature manifold discriminant embedding

在提取高光谱数据的空-谱联合特征时,需将光谱与 LBP 纹理特征投影到同一低维嵌入空间。但是,来自高光谱影像中同一像元点的光谱和纹理数据的嵌入特征需在低维空间中应尽可能紧致,以保持其相似性关系。因此,其目标函数可构建为:

$$\min \sum_{i=1}^N \| \mathbf{A}_s^T \mathbf{x}_i^s - \mathbf{A}_l^T \mathbf{x}_i^l \|^2, \quad (1)$$

其中: $\mathbf{A}_s \in \mathbf{R}^{D \times d}$ 为面向光谱数据的投影矩阵, $\mathbf{A}_l \in \mathbf{R}^{D \times d}$ 为纹理数据投影矩阵, $\mathbf{x}_i^s \in \mathbf{R}^{D \times N}$ 为光谱特征向量, $\mathbf{x}_i^l \in \mathbf{R}^{D \times N}$ 为纹理特征向量。

与此同时,为提升光谱和纹理数据的低维嵌入特征的鉴别能力,以改善地物分类性能,本文通过利用样本数据的光谱、纹理特征及其类别信息构建空-谱类内图 $\mathbf{G}_w(\mathbf{X}, \mathbf{W}^w)$ 和类间图 $\mathbf{G}_p(\mathbf{X}, \mathbf{W}^p)$, 以表征其鉴别流形结构。其中, \mathbf{X} 表示图的顶点集, $\mathbf{W}^w \in \mathbf{R}^{n \times n}$ 和 $\mathbf{W}^p \in \mathbf{R}^{n \times n}$ 分别为图 \mathbf{G}_w 和 \mathbf{G}_p 对应的权重矩阵。在图 \mathbf{G}_w 中,若两顶点 \mathbf{x}_i 和 \mathbf{x}_j 属于来自同类数据的 n_w 近邻,则用一条边连接,否则不连接。顶点之间的近邻关系通过采用光谱和 LBP 特征的联合距离 $\mathbf{D}_{c,ij}$ 来进行度量,具体为:

$$\mathbf{D}_{c,ij} = \mathbf{D}_{s,ij} + \mathbf{D}_{l,ij}, \quad (2)$$

其中 $\mathbf{D}_{s,ij}$, $\mathbf{D}_{l,ij}$ 分别为顶点 \mathbf{x}_i 和 \mathbf{x}_j 之间的光谱特征和 LBP 特征的欧式距离。图 \mathbf{G}_w 中边的权值为 w_{ij}^w 反应了同类特征 w_{ij}^s 和 \mathbf{x}_j 间的相似关系, 定义为:

$$w_{ij}^w = \begin{cases} \frac{1}{n_w}, & \mathbf{x}_i \in \mathbf{N}_1(\mathbf{x}_j) \text{ or } \mathbf{x}_j \in \mathbf{N}_1(\mathbf{x}_i), \\ 0, & \text{otherwise} \end{cases}, \quad (3)$$

其中 $\mathbf{N}_1(\mathbf{x}_i)$ 定义了样本点 \mathbf{x}_i 的 n_w 个类内近邻点集, 在低维嵌入空间需保留图 \mathbf{G}_w 中同类点之间的相似关系。

在类间图 \mathbf{G}_p 中, 若两顶点 \mathbf{x}_i 和 \mathbf{x}_j 属于来自不同类数据的 n_b 近邻, 则用一条边连接, 否则不连接。边的权值为 w_{ij}^b 设置为:

$$w_{ij}^b = \begin{cases} \frac{1}{n_b}, & \mathbf{x}_i \in \mathbf{N}_2(\mathbf{x}_j) \text{ or } \mathbf{x}_j \in \mathbf{N}_2(\mathbf{x}_i), \\ 0, & \text{otherwise} \end{cases}, \quad (4)$$

其中 $\mathbf{N}_2(\mathbf{x}_i)$ 定义了 \mathbf{x}_i 的 n_b 个类间近邻点集, 类间近邻点仍用联合距离来选取。在低维嵌入空间中需抑制图 \mathbf{G}_p 中来自不同类点之间的近邻相似关系。

在低维嵌入空间中, 不仅需保持类内图 \mathbf{G}_w 中的相似关系, 而且需要使属于同一类的光谱和 LBP 特征数据的嵌入特征尽可能聚集, 以减小同类数据间的差异。其目标函数可表示为:

$$\min \sum_{i=1}^N \sum_{j=1}^N \| \mathbf{A}_S^T \mathbf{x}_i^s - \mathbf{A}_L^T \mathbf{x}_j^l \|^2 w_{ij}^w. \quad (5)$$

$$\begin{aligned} \min \{ & \sum_{i=1}^N \| \mathbf{A}_S^T \mathbf{x}_i^s - \mathbf{A}_L^T \mathbf{x}_i^l \|^2 + \alpha \sum_{i,j=1}^N \sum_{i,j=1}^N \| \mathbf{A}_S^T \mathbf{x}_i^s - \mathbf{A}_L^T \mathbf{x}_j^l \|^2 w_{ij}^w - (1-\alpha) \sum_{i=1}^N \sum_{j=1}^N \| \mathbf{A}_S^T \mathbf{x}_i^s - \mathbf{A}_L^T \mathbf{x}_j^l \|^2 w_{ij}^b \} = \\ & \sum_{i=1}^N (\mathbf{A}_S^T \mathbf{x}_i^s - \mathbf{A}_L^T \mathbf{x}_i^l) (\mathbf{A}_S^T \mathbf{x}_i^s - \mathbf{A}_L^T \mathbf{x}_i^l)^T + \alpha \sum_{i=1}^N \sum_{j=1}^N (\mathbf{A}_S^T \mathbf{x}_i^s - \mathbf{A}_L^T \mathbf{x}_i^l) (\mathbf{A}_S^T \mathbf{x}_i^s - \mathbf{A}_L^T \mathbf{x}_i^l)^T w_{ij}^w - \\ & (1-\alpha) \sum_{i=1}^N \sum_{j=1}^N (\mathbf{A}_S^T \mathbf{x}_i^s - \mathbf{A}_L^T \mathbf{x}_i^l) (\mathbf{A}_S^T \mathbf{x}_i^s - \mathbf{A}_L^T \mathbf{x}_i^l)^T w_{ij}^b = \sum_{i=1}^N (\mathbf{A}_S^T \mathbf{x}_i^s (\mathbf{x}_i^s)^T \mathbf{A}_S - \mathbf{A}_L^T \mathbf{x}_i^l (\mathbf{x}_i^l)^T \mathbf{A}_S - \\ & \mathbf{A}_S^T \mathbf{x}_i^s (\mathbf{x}_i^l)^T \mathbf{A}_L + \mathbf{A}_L^T \mathbf{x}_i^l (\mathbf{x}_i^s)^T \mathbf{A}_L) + \alpha \sum_{i=1}^N \sum_{j=1}^N (\mathbf{A}_S^T \mathbf{x}_i^s w_{ij}^w (\mathbf{x}_i^s)^T \mathbf{A}_S - \mathbf{A}_L^T \mathbf{x}_i^l w_{ij}^w (\mathbf{x}_i^s)^T \mathbf{A}_S - \mathbf{A}_S^T \mathbf{x}_i^s w_{ij}^w (\mathbf{x}_i^l)^T \mathbf{A}_L + \\ & \mathbf{A}_L^T \mathbf{x}_i^l w_{ij}^w (\mathbf{x}_i^l)^T \mathbf{A}_L) - (1-\alpha) \sum_{i=1}^N \sum_{j=1}^N (\mathbf{A}_S^T \mathbf{x}_i^s w_{ij}^b (\mathbf{x}_i^s)^T \mathbf{A}_S - \mathbf{A}_L^T \mathbf{x}_i^l w_{ij}^b (\mathbf{x}_i^s)^T \mathbf{A}_S - \\ & \mathbf{A}_S^T \mathbf{x}_i^s w_{ij}^b (\mathbf{x}_i^l)^T \mathbf{A}_L + \mathbf{A}_L^T \mathbf{x}_i^l w_{ij}^b (\mathbf{x}_i^l)^T \mathbf{A}_L) = \\ & \text{tr} \begin{bmatrix} \mathbf{B} \\ \mathbf{C} \end{bmatrix}^T \begin{bmatrix} (\mathbf{X}^S)^T & 0 \\ 0 & (\mathbf{X}^L)^T \end{bmatrix} \begin{bmatrix} \mathbf{X}^S & 0 \\ 0 & \mathbf{X}^L \end{bmatrix} \begin{bmatrix} \mathbf{I} + \alpha \mathbf{D}_S^w - (1-\alpha) \mathbf{D}_L^b & -\mathbf{I} - \alpha \mathbf{W}^w + (1-\alpha) \mathbf{W}^b \\ -\mathbf{I} - \alpha \mathbf{W}^w + (1-\alpha) \mathbf{W}^b & \mathbf{I} + \alpha \mathbf{D}_L^w - (1-\alpha) \mathbf{D}_L^b \end{bmatrix} \\ & \begin{bmatrix} (\mathbf{X}^S)^T & 0 \\ 0 & (\mathbf{X}^L)^T \end{bmatrix} \begin{bmatrix} \mathbf{X}^S & 0 \\ 0 & \mathbf{X}^L \end{bmatrix} \begin{bmatrix} \mathbf{B} \\ \mathbf{C} \end{bmatrix} = \text{tr}(\mathbf{A}^T \mathbf{E} \mathbf{L} \mathbf{E}^T \mathbf{A}), \quad (9) \end{aligned}$$

与此同时, 为在嵌入空间中分离非同类数据, 提高低维特征的鉴别能力, 需在低维空间中抑制类间图 \mathbf{G}_p 中光谱和纹理数据的嵌入特征之间相似性, 并尽可能增大非同类数据间的差异。其目标函数定义如下:

$$\max \sum_{i=1}^N \sum_{j=1}^N \| \mathbf{A}_S^T \mathbf{x}_i^s - \mathbf{A}_L^T \mathbf{x}_j^l \|^2 w_{ij}^b. \quad (6)$$

根据式(1)、式(5)、式(6), MFDE 方法的多特征联合低维嵌入目标函数可表示为:

$$\begin{cases} \min \sum_{i=1}^N \| \mathbf{A}_S^T \mathbf{x}_i^s - \mathbf{A}_L^T \mathbf{x}_i^l \|^2 \\ \min \sum_{i=1}^N \sum_{j=1}^N \| \mathbf{A}_S^T \mathbf{x}_i^s - \mathbf{A}_L^T \mathbf{x}_j^l \|^2 w_{ij}^w \\ \max \sum_{i=1}^N \sum_{j=1}^N \| \mathbf{A}_S^T \mathbf{x}_i^s - \mathbf{A}_L^T \mathbf{x}_j^l \|^2 w_{ij}^b \end{cases}. \quad (7)$$

式(7)中的多目标优化问题, 可等价于以下的优化问题:

$$\min \{ \sum_{i=1}^N \| \mathbf{A}_S^T \mathbf{x}_i^s - \mathbf{A}_L^T \mathbf{x}_i^l \|^2 + \alpha \sum_{i=1}^N \sum_{j=1}^N \| \mathbf{A}_S^T \mathbf{x}_i^s - \mathbf{A}_L^T \mathbf{x}_j^l \|^2 w_{ij}^w - (1-\alpha) \sum_{i=1}^N \sum_{j=1}^N \| \mathbf{A}_S^T \mathbf{x}_i^s - \mathbf{A}_L^T \mathbf{x}_j^l \|^2 w_{ij}^b \}, \quad (8)$$

其中 α 为平衡参数, 用于调节类内紧致性和类间分离性。

令 $\mathbf{X}^S = [\mathbf{x}_1^s, \dots, \mathbf{x}_N^s]$, $\mathbf{X}^L = [\mathbf{x}_1^l, \dots, \mathbf{x}_N^l]$, 将 \mathbf{A}_S 和 \mathbf{A}_L 分别参数化为: $\mathbf{A}_S = \mathbf{X}^S \mathbf{B}$, $\mathbf{A}_L = \mathbf{X}^L \mathbf{C}$, 经数学推导后, 目标函数可进一步化简为:

其中: $\mathbf{A} = \begin{bmatrix} \mathbf{B} \\ \mathbf{C} \end{bmatrix}$, $\mathbf{E} = \begin{bmatrix} (\mathbf{X}^s)^T \mathbf{X}^s & 0 \\ 0 & (\mathbf{X}^l)^T \mathbf{X}^l \end{bmatrix}$, $\mathbf{L} = \begin{bmatrix} \mathbf{I} + \alpha \mathbf{D}_s^w - (1 - \alpha) \mathbf{D}_s^b & -\mathbf{I} - \alpha \mathbf{W}^w + (1 - \alpha) \mathbf{W}^b \\ -\mathbf{I} - \alpha \mathbf{W}^w + (1 - \alpha) \mathbf{W}^b & \mathbf{I} + \alpha \mathbf{D}_L^w - (1 - \alpha) \mathbf{D}_L^b \end{bmatrix}$, \mathbf{L} 中 \mathbf{I} 为单位阵, $\mathbf{W} = [\mathbf{w}_{ij}]_{N \times N}$ 为权值矩阵, \mathbf{D} 为对角矩阵, 且 $[\mathbf{D}_s]_{ii} = \sum_{j=1}^N \mathbf{w}_{ij}$, $[\mathbf{D}_L]_{jj} = \sum_{i=1}^N \mathbf{w}_{ij}$ 。

为消除尺度因子的影响, 增加约束条件后目标函数可进一步表示为:

$$\begin{cases} \min \{ \text{tr}(\mathbf{A}^T \mathbf{E} \mathbf{L} \mathbf{E}^T \mathbf{A}) \} \\ \text{s. t. } \mathbf{A}^T \mathbf{E} \mathbf{E}^T \mathbf{A} = \mathbf{I} \end{cases} \quad (10)$$

根据约束条件, 对式(10)采用拉格朗日乘子法求解可得:

$$\mathbf{E} \mathbf{L} \mathbf{E}^T \mathbf{A} = \lambda \mathbf{E} \mathbf{E}^T \mathbf{A} \quad (11)$$

求解式(11)的广义特征值和与其对应的特征向量, 即可得到投影矩阵 $\mathbf{A} = [\mathbf{a}_1, \mathbf{a}_2, \dots, \mathbf{a}_d]$, 其中 \mathbf{a}_1 到 \mathbf{a}_d 为前 d 个特征值按升序排序后对应的特征向量。

2.3 算法步骤

本文提出的 MFDE 算法的实现步骤如表 1 所示。

表 1 MFDE 算法步骤

Tab.1 Steps of MFDE algorithm

输入: 高光谱数据集 \mathbf{X} , 类别标签 \mathbf{L} , 参数 n_w, n_b, α
输出: 映射向量 $[\mathbf{A}_s, \mathbf{A}_L]$, 高光谱数据的低维嵌入特征 $\mathbf{Y} = [\mathbf{Y}_s, \mathbf{Y}_L]$
1. 计算高光谱数据的 LBP 特征, 然后将光谱和 LBP 特征进行归一化预处理;
2. 随机选取训练样本 $\mathbf{X}^s, \mathbf{X}^l$, 测试样本 $\mathbf{X}_t^s, \mathbf{X}_t^l$;
3. 由训练样本构建类内图 \mathbf{G}_w 和类间图 \mathbf{G}_p , 并由式(3)、式(4)计算边权值;
4. 根据公式(10)求得矩阵 \mathbf{A} , 由 $\mathbf{A}_s = \mathbf{X}^s \mathbf{B}$ 与 $\mathbf{A}_L = \mathbf{X}^l \mathbf{C}$ 得到光谱特征和纹理特征各自的投影矩阵 $\mathbf{A}_s, \mathbf{A}_L$;
5. 得到测试样本集的低维嵌入 $\mathbf{Y}_s = \mathbf{A}_s^T \mathbf{X}_t^s, \mathbf{Y}_L = \mathbf{A}_L^T \mathbf{X}_t^l$ 。

3 实验结果及分析

3.1 实验数据集

(1) Indian Pines 数据集: 该数据集由美国国家宇航局用 AVIRIS 传感器在美国印第安纳州采集得到, 剔除受水气或其他干扰因素影响的 20 个

波段被后, 共有 200 个波段可供实验。该数据集大小为 145×145 pixel, 空间分辨率为 20 m, 主要包括房屋、植被、森林等 16 类地物。图 4 为 Indian Pines 数据集的假彩色图和实际地物分布图, 括号中的数值表示每类地物的样本数量。

(2) 黑河数据集^[25]: 该数据集由中国国家自然科学基金委员会黑河计划科学数据中心用 CASI/ SASI 传感器在甘肃省黑河流域中游的张掖盆地区域采集得到, 其大小为 684×453 pixel, 空间分辨率为 2.4 m, 去除受水气影响严重的 14 个波段后, 剩余的 135 个波段可以用于实验。黑河数据集中含有玉米、土豆、西瓜等 9 类不同的作物, 其中共 104 917 pixel 已标注了类别信息, 其假彩色图和真实地物分布如图 5 所示。

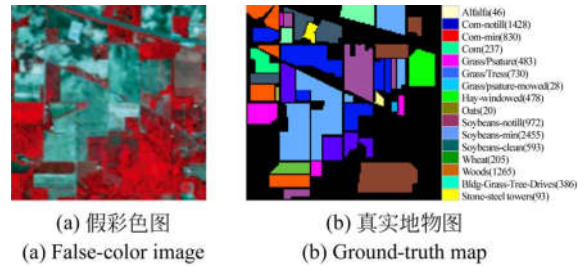


图 4 Indian Pines 高光谱影像

Fig.4 Indian Pines hyperspectral image

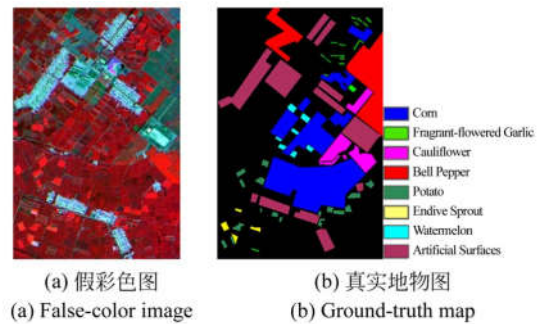


图 5 黑河高光谱影像

Fig.5 Heihe hyperspectral image

3.2 实验设置

在实验中, 将 HSI 数据集随机分为训练样本和测试样本, 通过各算法对训练样本进行学习, 求得特征映射矩阵, 进而提取测试样本的低维嵌入特征, 然后采用支持向量机(Support Vector Machine, SVM)进行分类。实验使用总体分类精度 (Overall Accuracy, OA)、平均分类精度 (Aver-

age Accuracy, AA) 和 Kappa 系数来评价各种算法的分类性能。

为分析 MFDE 方法中参数 n_w 、 n_b 对于分类精度的影响, 从 Indian Pines 每类地物中随机选取 40 个样本进行训练, 其余样本作为测试样本进行分类。实验中, 令参数 $\alpha = 0.8$, n_w 、 n_b 调试范围分别设置为 $[1, 2, 3, \dots, 9]$ 和 $[0, 40, 80, \dots, 520]$ 。图 6 为 MFDE 算法对参数 n_w 和 n_b 的总体分类精度。




图 6 Indian Pines 数据集中 MFDE 在不同参数下的分类结果

Fig. 6 Classification result of MFDE with different parameters on Indian Pines dataset

由图 6 可得知, 随着 n_w 和 n_b 的增加, 分类精度随之增加, 而后趋于平缓, 这是因为随着类内近邻点和类间近邻点的增加, 可更充分利用训练样本中先验信息来提升分类精度。但是, 当 n_w 和 n_b 增加到一定程度后, 已经有足够样本的类别信息可以利用, 近邻数增加对分类性能提升相对有限。根据实验结果, 本文选取 $n_w = 33$, $n_b = 320$ 。

为了验证本文算法的有效性, 将本文 MFDE 方法与 Baseline、PCA、LDA、LPP、NPE、MFA 和 LGSFA 算法进行对比, 其中 Baseline 表示直接利用分类器对特征进行分类, 不进行降维处理。为使各算法得到最优分类结果, 利用交叉验证法来得到其参数, LDA 降维到 $c-1$ 维 (c 为类别数), 其他算法的嵌入维数均为 40 维。每种算法均重复实验 10 次, 取 10 次实验的平均值及其方差作为最终实验结果。

3.3 特征可分性实验

采用黑河数据集来可视化对比各算法的特征提取性能, 实验中, 从每类地物随机选取 30 个样本的光谱和 LBP 融合特征进行训练, 随机选取 90 个样本并将其融合特征投影到二维空间, 进行可视化。其中, Baseline 为从融合特征中随机选择二维进行可视化。图 7 展示了应用不同的维数约减方法将每类 90 个测试样本嵌入于二维空间后的分布情况。

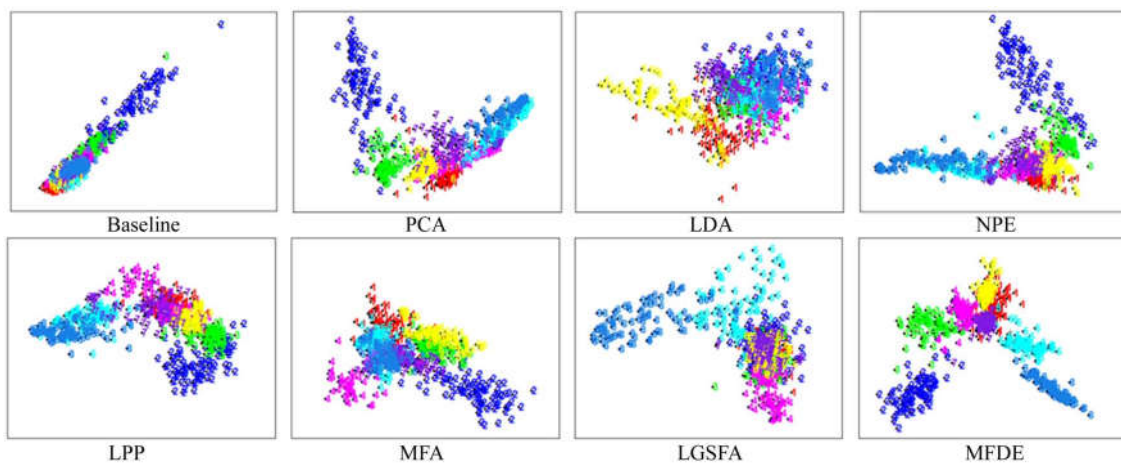


图 7 不同算法在黑河数据集上嵌入数据的二维分布图

Fig. 7 Two-dimensional distribution of embedding features by different methods on Heihe dataset

图7表明,原始光谱数据重叠现象较为严重。由于PCA、NPE、LPP为非监督方法,其嵌入特征可分性不理想。LDA尽管为监督方法,但不能发现HSI数据中鉴别流形结构导致不同类别数据存在明显的重叠现象。MFA与LGSFA等尽管是监督流形学习方法,由于是直接对简单堆叠后特征进行学习,导致不能发现位于不同特征上的子流形,依然产生了较多的重叠点。本文提出的MFDE方法不仅可在低维空间保持同一像元点不同特征的相似性,且通过为不同特征构建类内和类间图以发现其子流形,提取空-谱融合鉴别特征,其可视化效果最好,在二维嵌入空间中不同类

别特征重叠较少,具有更好的可分性,有利于后续分类。

3.4 Indian Pines 数据集实验

为分析各算法在不同数量的训练样本下的分类性能,从每类地物中随机选取 n_i ($n_i=5, 10, 20, 30, 40$) 个样本进行训练,剩余数据作为测试样本。实验中采用SVM进行分类。表2为不同数目训练样本条件下各种算法分别在光谱、纹理和融合特征下进行特征提取后的总体分类精度,其中融合特征是指将光谱与LBP特征分别归一化处理,然后进行堆叠形成的特征向量。

表2 Indian Pines数据集上不同算法的分类结果(总体分类精度±标准差)

Tab. 2 Classification results with different methods in Indian Pines data set (Overall Accuracy ± Std) (%)

	Algorithm	5	10	20	30	40
Spectral Feature	Baseline	42.21±4.63	53.72±3.97	64.05±2.03	69.72±1.25	69.78±1.58
	PCA	42.00±5.56	53.35±4.70	64.04±1.73	68.07±1.05	68.72±1.59
	LDA	40.27±4.46	40.29±1.76	52.93±1.44	61.00±0.84	63.51±1.23
	NPE	34.25±6.33	48.49±3.36	60.61±1.45	65.82±1.76	67.22±1.63
	LPP	35.40±5.40	47.41±2.77	60.14±2.37	66.64±1.82	69.10±1.51
	MFA	42.98±4.78	49.66±1.71	60.38±2.59	64.09±1.87	66.16±0.89
	LGSFA	41.26±5.35	49.57±3.00	60.95±1.91	66.40±0.65	68.81±1.36
Texture Feature	Baseline	68.12±5.00	79.07±2.97	87.58±1.66	90.36±2.82	93.54±1.53
	PCA	65.72±6.98	75.50±4.09	83.89±2.15	86.37±3.40	89.80±1.35
	LDA	71.30±3.75	79.69±3.24	87.62±1.78	91.02±2.04	93.63±1.25
	NPE	66.71±4.61	75.06±4.32	84.60±1.95	86.55±1.89	89.87±1.24
	LPP	65.88±2.80	75.73±4.51	85.17±1.97	87.71±1.55	89.77±0.85
	MFA	65.60±7.20	75.69±4.70	84.68±1.63	85.73±2.55	90.34±1.24
	LGSFA	65.59±2.11	74.90±5.18	84.92±1.70	87.86±1.67	91.34±1.34
Spectral & Textural Feature	Baseline	56.36±5.70	73.25±2.15	82.74±2.33	89.46±1.49	90.83±1.62
	PCA	54.22±5.04	68.83±2.83	76.39±1.66	81.34±1.30	83.71±1.25
	LDA	70.06±4.65	84.37±2.34	89.58±2.52	92.93±0.59	94.24±1.26
	NPE	56.02±6.91	66.73±3.68	74.37±2.51	76.28±1.71	78.62±0.91
	LPP	58.08±4.73	70.81±2.49	74.43±2.54	78.59±1.36	79.30±0.73
	MFA	53.94±2.49	69.44±2.47	77.15±2.12	80.57±2.70	82.94±1.83
	LGSFA	63.83±5.17	73.35±1.03	79.10±0.37	83.15±1.77	84.57±0.57
MFDE		73.44±3.77	84.78±3.02	91.19±1.30	93.76±1.17	95.05±0.88

由表 2 可知,随着训练样本数目的增加,各算法在不同特征上的分类精度都随之不断增加,这是因为有更丰富的样本信息可以利用,且各算法在纹理特征上的分类结果皆优于光谱特征,说明 LBP 特征有利于高光谱数据地物分类。与此同时,各算法在 LBP 特征上分类结果要明显优于对光谱和纹理的直接融合特征,主要由于简单的特征堆叠未能有效融合不同类型的特征,导致低维嵌入特征分类性能受限。本文 MFDE 算法在不同训练条件下分类性能都比其他算法要好,这是因为该方法不仅保证同一像素的光谱和纹理特征在低维嵌入空间的相似性,且通过利用样本数据的

类别标签构建类内和类间图来发现高光谱数据中流形结构,进而提取空-谱联合低维鉴别特征,实现类内紧致、类间远离,有效提升了地物分类性能。

为分析算法在各类地物上的分类精度,在每类地物中随机选取 3% 的数据作为训练样本,剩余数据作为测试样本。在表 2 中,各种维数约减方法在 LBP 特征上分类性能要优于其他特征,因此选用 LBP 特征与本文 MFDE 方法进行对比。表 3 列出了 Indian Pines 数据集中不同地物的分类精度、总体分类精度、平均分类精度、Kappa 系数以及各算法的运行时间,图 8 为各种算法相应的分类结果图。

表 3 Indian pines 数据集中各类地物在不同算法下的分类结果

Tab. 3 Classification results of each class samples via different methods in Indian Pines data set (%)

Class	Train	Test	Baseline	PCA	LDA	NPE	LPP	MFA	LGSFA	MFDE
1	10	36	99.72	99.17	98.89	99.44	99.72	99.44	99.44	98.89
2	43	1385	93.91	92.94	93.86	92.25	93.23	94.09	93.10	92.65
3	25	805	94.31	92.42	93.74	92.01	91.69	91.66	92.46	94.63
4	10	227	95.37	94.85	94.98	92.73	93.66	94.98	94.23	92.95
5	14	469	84.54	82.41	83.22	83.71	84.86	82.90	84.61	85.61
6	22	708	93.29	92.97	92.19	92.13	91.44	92.20	91.91	98.79
7	10	18	100	100	100	100	100	100	100	99.44
8	14	464	98.53	98.38	98.41	97.91	98.38	97.80	97.95	100
9	10	10	100	100	100	100	100	100	99.00	98.00
10	29	943	89.72	88.23	90.38	88.29	87.41	89.00	88.09	88.65
11	74	2381	95.46	94.93	95.72	94.51	94.49	95.08	95.09	96.35
12	18	575	87.84	83.34	88.52	85.63	85.76	86.73	87.06	91.11
13	10	195	96.36	95.74	95.85	94.67	95.49	94.72	95.85	98.41
14	38	1227	96.85	96.27	97.42	95.98	96.09	96.10	95.75	99.74
15	12	374	87.86	89.12	84.47	87.54	88.34	86.47	87.99	91.20
16	10	83	95.78	96.27	92.89	96.39	96.39	96.27	95.42	98.80
	OA		93.57	92.57	93.43	92.29	92.43	92.78	92.72	94.72
	AA		94.35	93.56	93.78	93.33	93.56	93.59	93.62	95.33
	Kappa		0.93	0.92	0.92	0.91	0.91	0.92	0.92	0.94
	Running time of DR/s		—	0.13	0.03	0.09	0.08	0.60	0.21	12.24
	Running time of Classification/s		189.58	5.4	1.05	3.22	3.08	3.03	2.98	6.33

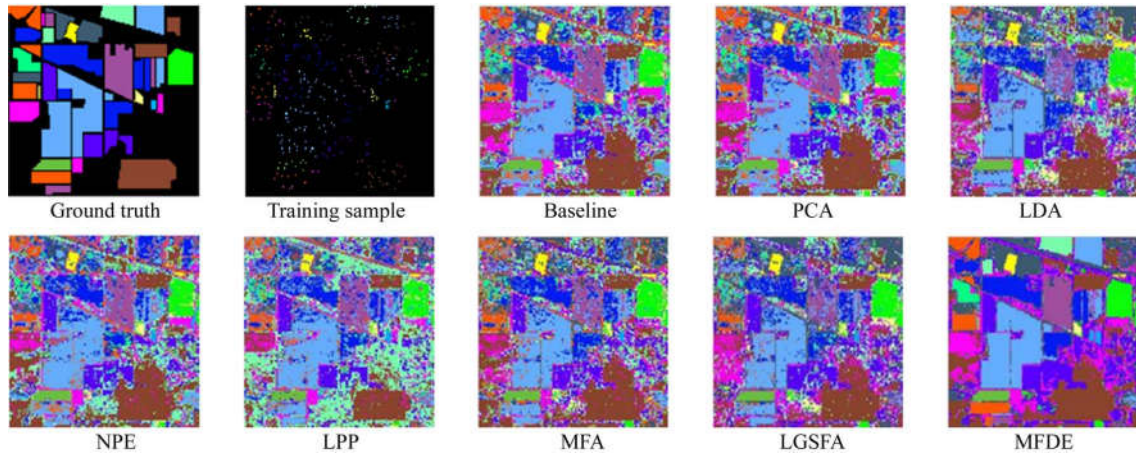


图 8 Indian pines 数据集上各算法的分类结果图

Fig. 8 Classification results of different algorithms on Indian pines dataset

由表 3 可知, MFDE 算法在大多数地物类别上都取得了较好的分类结果, 尤其是在“Wheat”, “Grass/Trees”, “Hay-windowed”, “Woods”等类别中更为明显。上述实验结果表明, MFDE 方法通过在低维嵌入空间使来自同一像素点以及来自同一类别的光谱特征和 LBP 纹理特征聚集, 来自不同类的两种特征尽可能远离, 有效保证了嵌入特征的可分性, 提升了分类性能。由于高光谱数据中波段多, 导致未进行降维的 Baseline 方法分类耗时远高于其他维数约简方法。MFDE 方法需要针对不同的特征构建图模型, 因此其耗时比其他维数约简方法要长, 但是相对分类性能的明

显提升是可以接受的。在图 8 的分类结果图中, 其他方法均出现比较严重“椒盐”现象, 而 MFDE 算法相比其他维数约减方法, 分类结果图更为平滑, 错分点较少, 分类优势明显。

3.5 黑河数据集实验

在此采用黑河数据集进一步验证本文算法的有效性。由于篇幅原因, 仅使用各算法在光谱与纹理融合特征上的分类结果进行对比。实验中, 各算法的参数设置与 Indian Pines 数据集中一致, 每次从黑河数据集中 8 类地物中随机选取 5, 10, 20, 30, 40 个样本进行训练, 剩余的用作测试。表 4 为各种算法在不同数目训练样本下的分类结果。

表 4 不同分类算法在黑河数据集上的分类效果(总体分类精确度±标准差)

Tab. 4 Classification results with different methods in Heihe data set (Overall Accuracy ± Std) (%)

Algorithm		5	10	20	30	40
Spectral & Texture Feature	Baseline	80.46±4.50	85.36±2.14	89.71±2.13	90.61±1.21	91.58±1.16
	PCA	80.45±4.50	85.36±2.14	89.56±2.23	90.67±1.26	91.62±1.20
	LDA	80.94±4.48	89.31±2.70	93.63±0.97	94.89±0.80	95.17±0.69
	NPE	79.17±7.45	87.88±1.99	91.45±1.36	92.25±1.93	91.22±1.03
	LPP	80.08±3.85	83.90±3.78	91.71±1.18	93.09±1.30	93.71±0.86
	MFA	82.69±4.13	88.04±2.73	92.24±1.02	92.74±1.02	93.82±1.04
	LGSFA	84.11±4.40	90.21±1.61	93.46±0.74	94.72±0.97	95.29±0.60
MFDE	86.51±5.56	91.65±1.28	94.54±0.91	95.93±0.79	96.20±0.88	

从表 4 可看出, 监督学习方法的分类效果整体要优于非监督方法, 这是因为利用了训练样本的类别信息来提升嵌入特征鉴别能力。本文方法在各种实验条件下分类性能均优于其他方法, 尤其在训练样本较少时更为明显, 这说明 MFDE 算

法在低维空间中实现了光谱和纹理特征的有效融合, 相比直接堆叠特征可更好地表示高光谱数据的本征属性, 使得到空-谱联合特征能更有效地反映出不同地物类别间的本质差异, 进而提升分类效果。

为进一步对比不同方法在各个地物类别上的分类精度,每类随机选取 0.1% 的样本进行训练,其余为测试样本。表 5 给出了各种算法在黑河数据集上的分类精度,图 9 为其对应的分类结果图。可得知,在选取 0.1% 的标记样本为训练样本的情况下,本文算法运行时间相对较长,但在“Fragrant-flowered Garlic”,“Bell Pepper”等地物上

具有明显的分类优势。LDA 作为一种监督学习方法,尽管在测试数据集上取得了较好的分类性能,但是在整个数据集上的分类结果图上显示其将许多其他类别的样本数据误分为“Artificial Surface”,出现了明显的“过拟合现象”。本文算法不仅在测试集上分类效果好,而且分类结果也更为平滑,更有利于实际应用场景。

表 5 黑河数据集中各类地物在不同算法下的分类结果

Tab. 5 Classification results of each class samples via different methods in Heihe data set (%)										
Class	Train	Test	Baseline	PCA	LDA	NPE	LPP	MFA	LGSFA	MFDE
1	42	41029	96.23	95.87	98.49	97.33	98.07	97.64	98.56	95.76
2	29	28557	97.86	97.53	98.74	96.77	96.89	98.06	97.93	99.51
3	21	20334	95.46	95.26	97.24	95.27	95.77	96.54	95.45	94.71
4	10	7598	81.20	80.72	59.71	63.93	67.57	71.42	59.28	87.10
5	10	3752	84.81	84.21	72.62	84.03	73.25	78.11	72.79	84.21
6	10	1665	84.25	87.98	61.65	61.77	68.06	74.43	61.37	84.22
7	10	975	88.76	88.18	73.56	81.12	69.66	76.39	72.91	87.36
8	10	865	90.97	90.98	92.91	88.31	89.99	89.49	93.57	93.54
	OA		94.72	94.45	93.71	93.10	93.40	94.31	93.14	95.26
	AA		89.94	90.10	81.87	83.57	82.41	85.26	81.48	90.80
	Kappa		0.93	0.92	0.91	0.90	0.91	0.92	0.90	0.93
Running time of DR/s			—	0.71	0.09	0.17	0.95	0.09	0.13	39.08
Running time of Classification/s			76.48	2.02	0.39	1.28	1.20	1.14	1.29	2.22

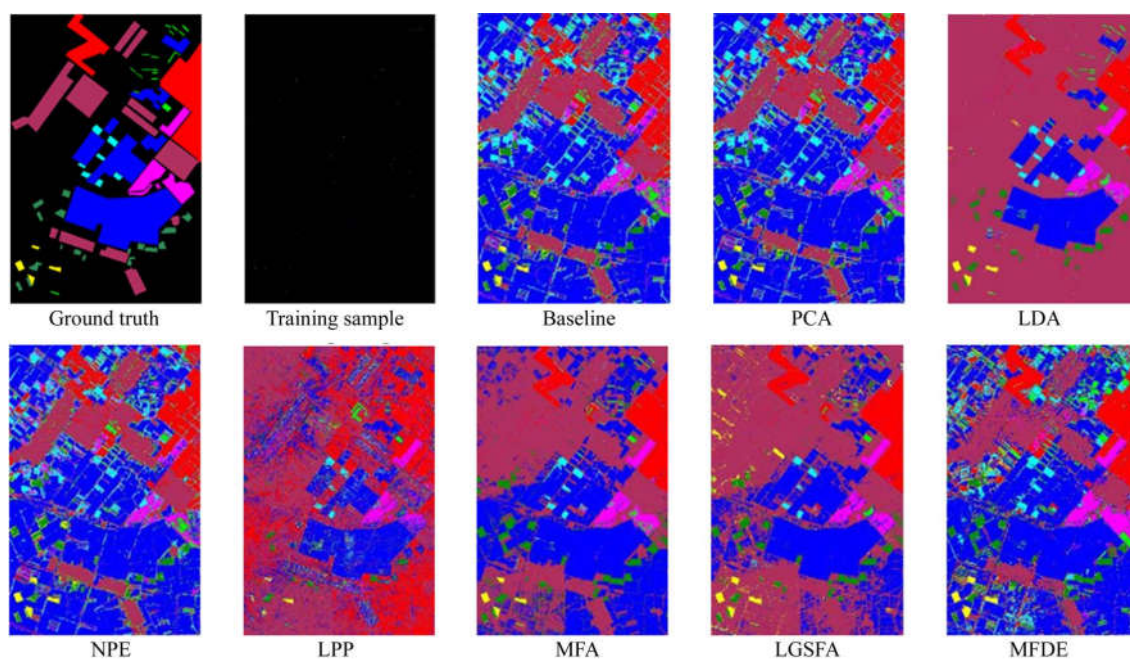


图 9 黑河数据集上各算法的分类结果图

Fig. 9 Classification results of different algorithms on Heihe dataset

4 结 论

传统高光谱数据维数约减方法要么只利用了单一特征,要么将不同类型的特征进行直接堆叠后实现降维。针对此问题,本文提出了一种多特征流形鉴别嵌入(MFDE)方法,该方法通过样本数据的光谱-LBP特征的联合距离与类别信息构建类内和类间图来发现高光谱数据中鉴别流形结构,在低维嵌入空间中不仅保证同一像素的光谱和纹理特征在低维嵌入空间的相似性,并且使同类点紧致、异类点远离,实现空-谱联合低维鉴别特征提取,有效提升地物分类性能。在 Indian Pines 和黑河高光谱数据集上的分类结果表明,本文算法可有效提取高光谱遥感影像的空-谱联

合鉴别特征,在较少训练样本的情况下其分类精度分别达到了 95.05%和 96.20%,有效提升了地物分类性能。

本文算法通过对光谱、纹理数据分别构建图模型以发现高光谱数据中的低维流形结构,其空-谱联合低维特征具有较好的可分性,但是计算复杂度较高,因此在下一步工作中将对 MFDE 算法进行优化,以提升算法的处理效率。此外,该算法可通过对不同的特征构建图,实现不同种类的特征融合处理,因此可将该算法拓展到其他具有多种特征的自然图像数据集,并根据实际情况通过选取强度、纹理、形状等特征中两种或者多种特征,在低维空间中有效实现多特征融合,以提升后续分类性能。

参考文献:


- [1] 黄鸿,陈美利,段宇乐,等. 空-谱协同流形重构误差的高光谱影像分类[J]. 光学精密工程, 2018,26(7): 1827-1836.
HUANG H, CHENG M L, DUAN Y L, *et al.*. Hyperspectral image classification with combination of spatial-spectral and manifold reconstruction [J]. *Opt. Precision Eng.*, 2018,26(7): 1827-1836. (in Chinese)
- [2] 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 P J, XIA J SH, XUE ZH H, *et al.*. Progress of hyperspectral remote sensing image classification [J]. *Journal of remote sensing*, 2016,20(2): 236-256. (in Chinese)
- [3] LUO F L, DU B, ZHANG L P, *et al.*. Feature learning using spatial-spectral hypergraph discriminant analysis for hyperspectral image [J]. *IEEE Transactions on Cybernetics*, 2018,PP(99): 1-14.
- [4] 何芳,王榕,于强,等. 加权空谱局部保持投影的高光谱图像特征提取[J]. 光学精密工程, 2017,25(1): 263-273.
HE F, WANG R, YU Q, *et al.*. Feature extraction of hyperspectral images of weighted spatial and spectral locality preserving projection [J]. *Opt. Precision Eng.*, 2017,25(1): 263-273. (in Chinese)
- [5] FENG F, LI W, DU Q, *et al.*. Dimensionality reduction of hyperspectral image with graph-based discriminant analysis considering spectral similarity [J]. *Remote Sensing*, 2017,9(4): 323.
- [6] FANG L, WANG C, LI S, *et al.*. Hyperspectral image classification via multiple-feature-based adaptive sparse representation [J]. *IEEE Transactions on Instrumentation & Measurement*, 2017,66(7): 1646-1657.
- [7] XU Y H, ZHANG L P, DU B, *et al.*. Spectral-spatial unified networks for hyperspectral image classification [J]. *IEEE Transactions on Geoscience & Remote Sensing*, 2018,PP(99): 1-17.
- [8] HUANG H, DUAN Y L, SHI G Y, *et al.*. Fusion of weighted mean reconstruction and SVMCK for hyperspectral image classification [J]. *IEEE Access*, 2018,6(99): 15224-15235.
- [9] 王庆超,付光远,汪洪桥,等. 多核融合多尺度特征的高光谱影像地物分类[J]. 光学精密工程, 2018,26(4): 980-988.
WANG Q CH, FU G Y, WANG H Q, *et al.*. Fusion of multi-scale feature using multiple kernel learning for hyperspectral image land cover classification [J]. *Opt. Precision Eng.*, 2018,26(4): 980-988. (in Chinese)
- [10] JIANG J J, HU R M, WANG Z Y, *et al.*. CDM-MA: Coupled discriminant multi-manifold analysis for matching low-resolution face images [J]. *Signal Processing*, 2016,124: 162-172.
- [11] BONIFAZI G, CAPOBIANCO G, SERRANTI S. Asbestos containing materials detection and classification by the use of hyperspectral imaging [J]. *Jour-*

- nal of Hazardous Materials*, 2018,344: 981-993.
- [12] LUO R B, LIAO W Z, PHILIPS W, *et al.*. An improved semi-supervised local discriminant analysis for feature extraction of hyperspectral image [J]. *IEEE Transactions on Geoscience & Remote Sensing*, 2015,51(1): 184-198.
- [13] 李志敏,张杰,黄鸿,等. 面向高光谱图像分类的半监督丛流形学习[J]. *光学精密工程*, 2015,23(5): 1434-1442.
- LI ZH M, ZHANG J, HUANG H, *et al.*. Semi-supervised bundle manifold learning for hyperspectral image classification [J]. *Opt. Precision Eng.*, 2015,23(5): 1434-1442. (in Chinese)
- [14] LI W, ZHANG L P, ZHANG L F, *et al.*. GPU parallel implementation of isometric mapping for hyperspectral classification [J]. *IEEE Geoscience & Remote Sensing Letters*, 2017,14(9): 1532-1539.
- [15] ZHANG L L, ZHAO C H. Sparsity divergence index based on locally linear embedding for hyperspectral anomaly detection [J]. *Journal of Applied Remote Sensing*, 2016,10(2): 25-26.
- [16] LV M, ZHAO X, LIU L, *et al.*. Discriminant collaborative neighborhood preserving embedding for hyperspectral imagery [J]. *Journal of Applied Remote Sensing*, 2017,11(4): 1.
- [17] DENG Y J, LI H C, PAN L, *et al.*. Modified tensor locality preserving projection for dimensionality reduction of hyperspectral images [J]. *IEEE Geoscience & Remote Sensing Letters*, 2018, 15(2): 277-281.
- [18] LU Y, LAI Z, FAN Z, *et al.*. Manifold discriminant regression learning for image classification [J]. *Neurocomputing*, 2015,166(C): 475-486.
- [19] JIA J, RUAN Q, JIN Y. Geometric preserving local fisher discriminant analysis for person re-identification [J]. *Neurocomputing*, 2016,205(C): 92-105.
- [20] 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): 790.
- [21] LI W, CHEN C, SU H, *et al.*. Local binary patterns and extreme learning machine for hyperspectral imagery classification [J]. *IEEE Transactions on Geoscience & Remote Sensing*, 2015, 53(7): 3681-3693.
- [22] MAURO D M, JON A B, BIORN W. Morphological attribute profiles for the analysis of very high resolution images [J]. *IEEE Transactions on Geoscience & Remote Sensing*, 2010,48(10): 3747-3762.
- [23] LI J, HUANG X, GAMBA P, *et al.*. Multiple feature learning for hyperspectral image classification [J]. *IEEE Transactions on Geoscience & Remote Sensing*, 2015,53(3): 1592-1606.
- [24] SONG C Y, YANG F J, LI P J. Rotation invariant texture measured by local binary pattern for remote sensing image classification [C]. 2010 *Second International Workshop on Education Technology and Computer Science*, Wuhan, P. R. China, 2010,3(3): 3-6.
- [25] 肖青,闻建光. 黑河生态水文遥感试验:热红外高光谱航空遥感(2012年7月4日)[Z]. 黑河计划数据管理中心, 2013. doi:10.3972/hiwater.006.2013.db.
- XIAO Q, WEN J G. HiWATER: Thermal-Infrared Hyperspectral Radiometer (4th, July, 2012) [Z]. Heihe Plan Science Data Center, 2013. doi: 10.3972/hiwater.006.2013.db. (in Chinese)

作者简介:



黄 鸿(1980—),男,湖南新宁人,教授,博士生导师,2003,2005,2008年于重庆大学分别获得学士、硕士和博士学位,主要从事流形学习、模式识别、遥感影像智能化处理等方面的研究。E-mail: hhuang@cqu.edu.cn



李政英(1994—),男,山西忻州人,博士研究生,2016年于中北大学获得学士学位,主要从事机器学习、图像处理、模式识别等方面的研究。E-mail: zhengying_li@cqu.edu.cn