

面向高光谱图像分类的空谱半监督局部判别分析

侯榜焕, 姚敏立, 王 榕*, 张峰干, 戴定成

火箭军工程大学信息工程系, 陕西 西安 710025

摘要 针对传统的基于特征提取的高光谱图像分类算法大多只考虑光谱信息而忽略空间信息的问题, 提出了一种基于空谱半监督局部判别分析(S^3 ELD)和空谱最近邻(SSNN)分类器的高光谱图像分类算法。该算法结合高光谱图像的空间一致性, 在利用标记样本的判别信息保持数据集可分性的基础上, 定义空间近邻像元散度矩阵来保存像元的空间近邻结构, 提出基于空谱距离的相似性度量并将其应用于局部流形结构的发现和 SSNN 的构建。 S^3 ELD 算法不仅能揭示数据集的局部几何关系, 而且增强了光谱域同类像元和空间域近邻像元在低维嵌入空间的聚集性。结合 SSNN 进行分类, 进一步提升了分类精度。利用 PaviaU 和 Salinas 数据集进行的实验结果表明, S^3 ELD 算法的总体分类精度分别达到了 92.51% 和 96.29%; 与现有几种算法相比, 该算法能更有效地提取出判别特征信息, 并达到更高的分类精度。

关键词 遥感; 高光谱图像分类; 半监督局部判别分析; 空谱距离; 空间近邻

中图分类号 TP751.1 文献标识码 A

doi: 10.3788/AOS201737.0728002

Spatial-Spectral Semi-Supervised Local Discriminant Analysis for Hyperspectral Image Classification

Hou Banghuan, Yao Minli, Wang Rong, Zhang Fenggan, Dai Dingcheng

Department of Information Engineering, Rocket Force Engineering University, Xi'an, Shaanxi 710025, China

Abstract In traditional hyperspectral image classification algorithm based on feature extraction, spectral information is usually considered while spatial information is ignored. To address this problem, a hyperspectral image classification algorithm based on semi-supervised spatial-spectral local discriminant analysis (S^3 ELD) and spatial-spectral nearest neighbor (SSNN) classifier is proposed in this paper. Combining the spatial consistency of hyperspectral images and on the basis that the discriminant information of the labeled samples is used to maintain the separability of the data set, we define the spatial local pixel scatter matrix to preserve the spatial-domain neighborhood structures of pixel. A similarity measure method based on the spatial-spectral distance is then proposed to discover the local manifold structure and to construct SSNN. S^3 ELD algorithm not only reveals the local geometric relations of the data set but also enforces the compactness of the spectral-domain same class pixels and the spatial-domain local neighbor pixels in the low-dimension embedding space. Combining SSNN to classify, the classification accuracy is further enhanced. The experiments on the PaviaU and Salinas data sets show that the overall classification accuracy of S^3 ELD algorithm reaches 92.51% and 96.29%, respectively. Compared with several existing algorithms, the proposed algorithm can efficiently extract the information of discriminant characteristics and obtain higher classification accuracy.

Key words remote sensing; hyperspectral image classification; semi-supervised local discriminant analysis; spatial-spectral distance; spatial neighbor

OCIS codes 280.4750; 100.3008; 110.2960

收稿日期: 2017-03-09; 收到修改稿日期: 2017-03-21

基金项目: 国家自然科学基金青年科学基金(61401471)、中国博士后科学基金(2014M562636)

作者简介: 侯榜焕(1985—), 男, 博士研究生, 主要从事高光谱图像处理方面的研究。E-mail: chinayouth001@aliyun.com

导师简介: 姚敏立(1966—), 男, 博士, 教授, 主要从事卫星通信和信号处理方面的研究。E-mail: yaominli@sohu.com

* 通信联系人。E-mail: wangrong07@tsinghua.org.cn

1 引 言

高光谱遥感图像能在紫外到红外波长范围内提供更精细的光谱波段和更丰富的地物信息,因而有利于对遥感地物进行更细致的分类识别^[1-2]。但是,高光谱数据具有波段数多、信息冗余多和波段间相关性强等特点,且易受 Hughes 现象影响^[3-4]。因此,必须对高光谱图像数据集进行特征提取,并设计合适的分类器,以提高地物分类的准确度。

特征提取的目的是找到一种特征变换将高维数的特征空间变换到低维数的特征空间,同时保持数据集的某些特性。经典的线性方法包括主成分分析(PCA)和线性判别分析(LDA)^[5],这两种方法都假定数据集存在于全局线性结构中,而高光谱遥感图像本质上是非线性的。以局部线性嵌入(LLE)^[6]、拉普拉斯特征映射(LE)^[7]、局部保持投影(LPP)^[8]和邻域保持嵌入(NPE)^[9]等为代表的流形学习算法,能处理非线性的高光谱遥感数据集,但忽视了标记样本的判别信息,无法增强同类像元在低维空间的聚集性。为了同时利用少量宝贵的标记样本和大量廉价的无标记样本,学者们相继提出了半监督判别分析(SDA)^[10]、半监督局部费舍尔判别分析(SELF)^[11]和半监督局部判别分析(SELD)^[12]等算法,这些算法提取的低维特征既包含了判别信息,又充分挖掘了数据集的局部几何特性或方差信息,在一定程度上提升了分类性能。

以上算法在特征提取时只利用了光谱信息,忽略了高光谱图像特有的空间信息。由于高光谱图像具有空间一致性,即空间近邻像元在很大概率上属于同类地物,故仅使用光谱信息不能全面有效地表征高光谱图像的本质,在相似性度量和特征提取时应该考虑像元的空间相关性^[13-19]。为此,研究人员开始将高光谱图像的空间信息融入到特征提取和分类过程中。现有算法大部分是在分类过程中加入空间信息,文献[14]将空间邻域均值等作为空间特征与光谱特征一起融入核函数,文献[15]使用空间滤波对分类识别图进行平滑,其本质是利用空间信息对分类结果进行纠错。特征提取过程中融入空间信息的算法相对较少,文献[16-17]以像元的空间近邻区域替代单一像元进行相似性度量,再选取近邻点构建相似图;文献[18-20]在计算近邻图的相似权重时,同时考虑了光谱距离和空间距离的影响,这几种算法虽然在一定程度上改善了分类效果,但都是无监督的,没有利用标记样本的判别信息,不能从本质上提高后续的地物分类效果^[4]。

针对以上问题,本文提出了一种基于空谱半监督局部判别分析(S^3 ELD)和空谱最近邻(SSNN)分类器的高光谱分类算法(S^3 ELD-SSNN)。该算法结合高光谱图像的空间一致性,既利用少量珍贵的标记信息保持数据集的可分性,又保存了像元的空间近邻结构,还以空谱距离相似性度量更好地表征了图像的局部流形结构,使光谱相似像元和空间近邻像元的聚集关系在低维嵌入空间保持不变,得到了更有效的判别特征。结合 SSNN 进一步提升了分类精度。最后,利用 PaviaU 和 Salinas 高光谱数据集验证了本算法的有效性。

2 空谱半监督判别分析和 SSNN

2.1 SELD

记 n_1 个标记样本构成的样本集为 $\mathbf{X}_1 \in \mathbb{R}^{d \times n_1}$,其中 $\mathbf{x}_i \in \mathbb{R}^d$, d 是数据维数(即高光谱数据的波段数);无标记样本集 $\mathbf{X}_u \in \mathbb{R}^{d \times n_u}$, n_u 是无标记样本数量。记低维嵌入数据 $\mathbf{y}_i \in \mathbb{R}^r$, r 是嵌入维数。半监督算法 SELD 包括基于 LDA 与 NPE 的 SELD_{npe}^[12]和基于 LDA 与 LPP 的 SELD_{lpp}^[12]。其中,SELD_{npe} 的目标函数^[12]为

$$\mathbf{a}_{\text{opt}} = \underset{\mathbf{a}}{\operatorname{argmax}} \frac{\mathbf{a}^T (\mathbf{S}_b + \mathbf{X}_u \mathbf{X}_u^T) \mathbf{a}}{\mathbf{a}^T (\mathbf{S}_w + \mathbf{X}_u \mathbf{M} \mathbf{X}_u^T) \mathbf{a}}, \quad (1)$$

式中 \mathbf{a} 是投影向量; $\mathbf{M} = (\mathbf{I} - \mathbf{S})^T (\mathbf{I} - \mathbf{S})$, \mathbf{I} 是单位矩阵, \mathbf{S} 是 NPE^[9]算法的重构系数矩阵,具体求解方法参见文献[9]。同类数据的类内散度矩阵 \mathbf{S}_w 和异类数据的类间散度矩阵 \mathbf{S}_b 只定义在标记样本集 \mathbf{X}_1 上。分别为

$$\mathbf{S}_w = \sum_{i=1}^c \sum_{j=1}^{n_i} (\mathbf{x}_j^i - \boldsymbol{\mu}^i) (\mathbf{x}_j^i - \boldsymbol{\mu}^i)^T, \quad (2)$$

$$\mathbf{S}_b = \sum_{i=1}^c n_i (\boldsymbol{\mu}^i - \boldsymbol{\mu}) (\boldsymbol{\mu}^i - \boldsymbol{\mu})^T, \quad (3)$$

式中 c 是类别数, n_i 是第 i 类的样本数, \mathbf{x}_j^i 表示第 i 类的第 j 个样本, $\boldsymbol{\mu}^i$ 是第 i 类样本的均值向量, $\boldsymbol{\mu}$ 是标记

样本集 \mathbf{X}_1 的均值向量。SELDnpe 算法的最佳投影向量可通过求解下式得到

$$(\mathbf{S}_b + \mathbf{X}_u \mathbf{X}_u^T) \mathbf{a} = \lambda (\mathbf{S}_w + \mathbf{X}_u \mathbf{M} \mathbf{X}_u^T) \mathbf{a}, \quad (4)$$

即广义特征值问题的最大非零特征值对应的特征向量, (4) 式中 λ 是特征值。

2.2 基于空谱距离的相似性度量算法

由于高光谱图像的空间近邻像元在很大程度上属于同类地物, 即对于某一特定像元 \mathbf{x}_i , 它与空间位置近邻的像元不仅具有较强的频谱相关性, 还有明显的空间相关性; 并且空间距离越近, 相关性越强, 属于同类地物的概率就越大, 呈现出明显的空间聚集属性^[16-17]。鉴于此, 本研究提出一种基于空谱距离的相似性度量算法, 并将其应用于流形降维和最近邻(NN)分类器。

本算法利用像元 \mathbf{x}_i 的空间邻域 \mathbb{N}_i 替代单一像元 \mathbf{x}_i 参与相似性度量。像元 \mathbf{x}_i 的空间邻域 \mathbb{N}_i , 即以像元 \mathbf{x}_i 为中心的大小为 $\omega_1 \times \omega_1$ 的正方形空间区域 (ω_1 为奇正整数); 当像元 \mathbf{x}_i 位于图像边缘或角落时, 空间邻域不完整, 其空缺部分以该像元自身填充。

对任意像元 \mathbf{x}_i 和 \mathbf{x}_j , 对应空间邻域为 \mathbb{N}_i 和 \mathbb{N}_j , 定义两者的空谱距离为

$$d(\mathbf{x}_i, \mathbf{x}_j) = \|\hat{\mathbf{x}}_i - \hat{\mathbf{x}}_j\|. \quad (5)$$

$\hat{\mathbf{x}}_i$ 定义为

$$\hat{\mathbf{x}}_i = \frac{\sum_{\mathbf{x}_k \in \mathbb{N}_i} \exp[-(\|i - k\|^2)/\delta_s^2] \exp(-\|\mathbf{x}_i - \mathbf{x}_k\|^2/\delta_r^2) \mathbf{x}_k}{\sum_{\mathbf{x}_k \in \mathbb{N}_i} \exp[-(\|i - k\|^2)/\delta_s^2] \exp(-\|\mathbf{x}_i - \mathbf{x}_k\|^2/\delta_r^2)}, \quad (6)$$

式中 \mathbf{x}_k 是像元 \mathbf{x}_i 的空间邻域 \mathbb{N}_i 内的像元, 即空间近邻像元。参数 $\delta_s = (\omega_1 - 1)/2$, $\delta_r^2 = 1/\text{std}(\mathbf{d})$, $\mathbf{d} = [d_{i,1}, \dots, d_{i,k}, \dots, d_{i,\omega_1^2}]$ 且 $d_{i,k} = \|\mathbf{x}_i - \mathbf{x}_k\|^2$ 。 $\|i - k\|$ 表示像元 \mathbf{x}_i 和 \mathbf{x}_k 之间的空间距离。 $\|\cdot\|$ 表示向量的欧几里德范数。

由(6)式可知, 空谱距离 $d(\mathbf{x}_i, \mathbf{x}_j)$ 利用像元空间邻域内所有像元参与相似性度量, 弥补了单一像元度量的不足。 $\hat{\mathbf{x}}_i$ 不仅考虑了空间近邻像元与中心像元 \mathbf{x}_i 的空间距离, 还计入了光谱差异的影响; 空间距离越近或光谱相似性越强的空间近邻像元, 在计算 $\hat{\mathbf{x}}_i$ 时权重越大、作用越明显; 反之, 空间距离越远或光谱相似性越弱的空间近邻的异类地物像元, 在计算 $\hat{\mathbf{x}}_i$ 时权重越小、作用也越小。 $d(\mathbf{x}_i, \mathbf{x}_j)$ 融合了光谱距离和空间距离, 将高光谱图像的空间信息自动融入相似性度量结果中, 能增大同类地物的相似性和异类地物的差异性, 降低异类地物被选为近邻的可能性, 提高同类地物尤其是空间位置较近的同类像元被选为光谱近邻的概率。

2.3 S³ELD

半监督局部判别分析 SELDnpe 只利用了图像的光谱特征, 得到的低维特征保存了数据集的类别可分性和局部流形结构, 但无法保存图像的空间近邻信息。而高光谱遥感数据集具有独特的空间聚集属性, 即同一空间邻域内的像元在很大概率上具有类别一致性和光谱相似性^[18-20]; 如果在特征提取时融入空间信息, 就能够保存更多的地物分布细节, 降低同一空间邻域像元在低维特征空间的波动起伏, 有利于改善分类结果^[13]。

对某个较小的空间邻域内的像元, 其均值向量往往代表此处像元的典型光谱特征。因此, 空间近邻的像元在投影后应该尽量靠近其均值向量, 即像元在空间位置上的近邻结构也应该在低维特征空间保持不变。受 LDA 算法的类内散度矩阵 \mathbf{S}_w 启发, 定义空间近邻像元散度矩阵 \mathbf{F}_w 为

$$\mathbf{F}_w = \sum_{i=1}^{n_1} f_i = \sum_{i=1}^{n_1} \sum_{k=1}^{\omega_2} (\mathbf{x}_{ik} - \mathbf{m}^i) (\mathbf{x}_{ik} - \mathbf{m}^i)^T, \quad (7)$$

式中 \mathbf{m}^i 是以 \mathbf{x}_i 为中心的空间邻域 \mathbb{N}_i 内所有像元的均值向量, \mathbf{x}_{ik} 是 \mathbf{x}_i 的第 k 个空间近邻, 空间邻域大小为 ω_2 。空间近邻像元散度 f_i 表征像元 \mathbf{x}_i 的空间邻域 \mathbb{N}_i 内所有像元的离散程度。 \mathbf{F}_w 是标记样本集 \mathbf{X}_1 的 f_i 之和, 体现了 \mathbf{X}_1 所有样本的空间邻域像元的离散程度。 \mathbf{F}_w 越小, 意味着所有样本的空间邻域内像元的相似性和一致性越强。

定义 S³ELD 算法的目标函数为

$$\mathbf{a}_{\text{opt}} = \underset{\mathbf{a}}{\text{argmax}} \frac{\mathbf{a}^T (\mathbf{S}_b + \mathbf{X}_u \mathbf{X}_u^T) \mathbf{a}}{\mathbf{a}^T (\mathbf{S}_w + \mathbf{F}_w + \mathbf{X}_u \mathbf{M} \mathbf{X}_u^T) \mathbf{a}}, \quad (8)$$

在计算上式中局部流形嵌入的矩阵 \mathbf{M} 时,首先使用基于空谱距离的相似性度量算法来选择光谱近邻,再计算重构系数矩阵 \mathbf{S} ,最后得到矩阵 \mathbf{M} 。由(8)式可知, S^3 ELD 算法寻找一个最佳投影方向,使投影后的低维嵌入空间既能保存数据集在光谱域的可分性,又能保证高光谱图像特有的空间域的聚集性,并且在得到的局部流形结构中自动融入了空间信息。

对空间距离较远的两个光谱相似同类像元, S^3 ELD 算法通过类内散度矩阵 \mathbf{S}_w 极小化来保证它们之间的距离尽量小;对空间近邻像元,通过 \mathbf{F}_w 极小化使其在低维空间内更加聚集;同时,基于空谱距离的相似性度量增大了空间距离较近的同类像元被选为光谱近邻点的概率,可以更好地表征图像的局部几何特性。总之, S^3 ELD 算法提取的低维特征,可以更有效地区分分类地物,也更符合地物的空间分布特点,使高光谱图像数据集的非线性本质和局部几何特性得到更好的表征,有利于提高后续的地物分类效果。

在求解投影矩阵时,此问题可转化为广义特征值问题,即

$$(\mathbf{S}_b + \mathbf{X}_u \mathbf{X}_u^T) \mathbf{a} = \lambda (\mathbf{S}_w + \mathbf{F}_w + \mathbf{X}_u \mathbf{M} \mathbf{X}_u^T) \mathbf{a}, \quad (9)$$

其前 r 个最大特征值 $\lambda_1 > \lambda_2 > \dots > \lambda_r$ 对应的特征向量 $\mathbf{a}_1, \mathbf{a}_2, \dots, \mathbf{a}_r$ 组成最优投影矩阵 \mathbf{A} 。

2.4 SSNN 分类器

高光谱图像地物分类算法的另一个关键问题就是设计合适的分类器。最近邻分类器是最简单的分类器之一,它通过在训练样本中寻找最近邻的样本来判断测试样本的类别。利用基于空谱距离相似性度量,本研究提出 SSNN 分类器。SSNN 弥补了最近邻分类器没有考虑高光谱图像空间信息的缺陷,使选取的最近邻样本更符合高光谱数据集的本质。使用 SSNN 时,首先计算测试样本与训练样本的空谱距离,再根据最近邻训练样本的类别,判定测试样本的归类。

基于空谱距离的相似性度量,需要使用样本的空间邻域内的所有像元,当样本点处于不同地物边界时,空间邻域内包含有其他异类地物,虽然它们的权重较小、作用较弱,但对后续分类过程不利。故使用 SSNN 分类时,选取的训练样本应尽量避免靠近不同地物边界。同时,在不同地物边界附近,使用 SSNN 得到的分类结果,可能会丢失不同地物边界的细节信息。所以在全图所有像元分类等实际应用中,需要对此加以注意。

2.5 S^3 ELD-SSNN 算法步骤

S^3 ELD-SSNN 算法求解的具体步骤为:

输入:包含 N 个样本点的高光谱图像数据集 $\mathbf{X} \in \mathbb{R}^{I \times J \times m}$, $N = I \times J$, 标记样本集 $\mathbf{X}_1 \in \mathbb{R}^{d \times n_1}$, 无标记样本集 $\mathbf{X}_u \in \mathbb{R}^{d \times n_u}$, 类别数为 c , 嵌入维数为 r , 计算空谱距离的空间邻域大小 ω_1 和计算 \mathbf{F}_w 的空间邻域大小 ω_2 。

1) 求类内散度矩阵 \mathbf{S}_w 和类间散度矩阵 \mathbf{S}_b ;

2) 求空间近邻像元散度矩阵 \mathbf{F}_w ;

3) 求流形结构矩阵 \mathbf{M} ;

4) 求解广义特征值问题,得到特征向量 $\mathbf{a}_1, \mathbf{a}_2, \dots, \mathbf{a}_r$ 组成的最优投影矩阵 $\mathbf{A} \in \mathbb{R}^{d \times r}$, 低维数据为 $\mathbf{Y} = \mathbf{A}^T \mathbf{X}$;

5) 使用 SSNN 进行分类。

输出:分类精度。

3 实验结果及分析

3.1 实验数据

为评估 S^3 ELD-SSNN 算法对高光谱图像的分类性能,使用具有代表性的 PaviaU 和 Salinas 高光谱遥感数据集进行分类实验。

1) PaviaU 数据集。该数据集是 2002 年由反射光学系统成像光谱仪 (ROSIS) 传感器在意大利北部 Pavia 大学区域获取的航空高光谱遥感图像。图像大小为 610 pixel \times 340 pixel, 空间分辨率为 1.3 m; PaviaU 数据集包含了 430~860 nm 光谱范围内的 115 个波段, 光谱分辨率为 4~12 nm, 去除噪声影响严重的波段后, 剩余 103 个波段用于实验。该图像参考数据样本共计 42776 个, 含有 9 类地物信息。其假彩色图像和真实地物信息如图 1 所示。



图1 PaviaU 高光谱图像。(a)假彩色图;(b)真实地物图

Fig. 1 PaviaU hyperspectral image. (a) False-color image; (b) ground-truth map

2) Salinas 数据集。该数据集由机载可见光/红外成像光谱仪(AVIRIS)传感器拍摄于美国加利福尼亚南部 Salinas 山谷区域。图像大小为 512 pixel \times 217 pixel,空间分辨率为 3.7 m;Salinas 数据集包含了 400~2500 nm 光谱范围内的 224 个波段,光谱分辨率为 9.7~12 nm,去除噪声影响严重的波段后,剩余 204 个波段用于实验。该图像参考数据样本共计 54129 个,含有 16 类地物信息。其假彩色图像和真实地物信息如图 2 所示。

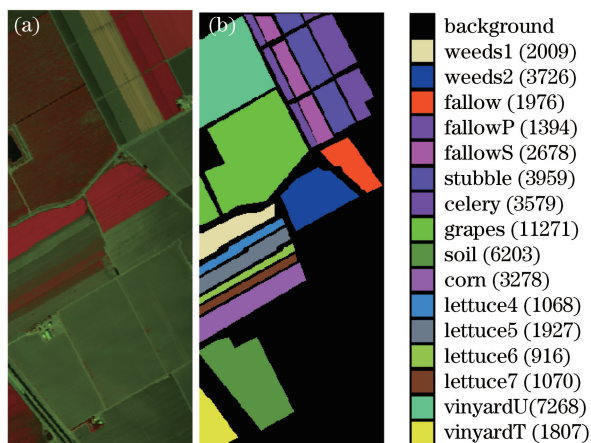


图2 Salinas 高光谱图像。(a)假彩色图;(b)真实地物图

Fig. 2 Salinas hyperspectral image. (a) False-color image; (b) ground-truth map

3.2 实验设置

实验中选取 SDA、SELF、SELDlpp、SELDnpe 等半监督算法与 S^3 ELD 算法进行对比,各算法的光谱近邻数 k 设置为 5。嵌入维数上界值除 SDA 算法设置为类别数减 1 外,其余算法都设置为 30。各算法均使用标记样本集 \mathbf{X}_1 和无标记样本集 \mathbf{X}_u 进行学习,得到投影矩阵,提取出低维判别特征。 \mathbf{X}_u 由每类地物随机选取的 300 个样本(不足 300 时取剩余所有样本)构成。在分类时,除 \mathbf{X}_1 之外,其余所有样本均作为测试样本。采用最近邻和 SSNN 进行分类,并用总体精度(OA)、平均精度(AA)和 Kappa 系数作为评价指标。为提高精确度和可靠性,实验重复运行 10 次,每次随机选取训练样本,对 10 次实验的分类精度求平均值。

3.3 参数的影响和各步骤的贡献

为探索相似性度量的空间邻域 ω_1 和空间近邻像元散度矩阵的空间邻域 ω_2 对 S^3 ELD-SSNN 算法的影响,分别从 PaviaU 和 Salinas 数据集每类地物选取 20 个标记样本进行实验。 ω_1 和 ω_2 的取值范围为 3,5,7,9,11,13,图 3 和图 4 分别是不同 ω_1 和 ω_2 时的分类精度。对于 PaviaU 数据集,当调节 ω_1 时, ω_2 设置为 5;当调节 ω_2 时, ω_1 设置为 5。在 Salinas 数据集上, ω_1 和 ω_2 的默认设置为 9 和 5。

以 PaviaU 数据集为例进行说明。在 PaviaU 图像中,除“meadows”和“bare soil”是大片均匀块状分布外,其余各类地物主要呈窄条带分布。对于空间邻域 ω_1 ,选取较小的空间邻域包含的空间信息较少,而较大的邻域又可能引入较多的异类地物,容易降低相似性度量的效果,导致分类精度稍微降低。由图 3 可知,当 ω_1 设置为 5 时两者达到平衡,分类精度最高;且当 ω_1 变化时,总体精度上下浮动在 2%之内。对于空间邻域 ω_2 ,由图 4 可知,随着 ω_2 的增加,PaviaU 分类精度先增加后逐渐减小,当 ω_2 为 5 时达到最高分类精度。这

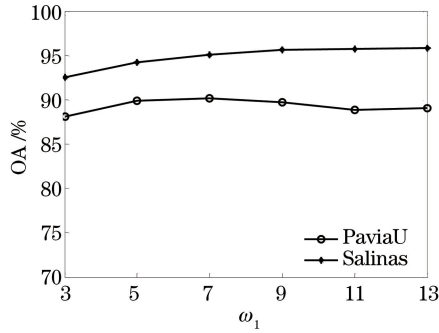


图 3 不同 ω_1 值下的分类精度

Fig. 3 Classification accuracies under different ω_1

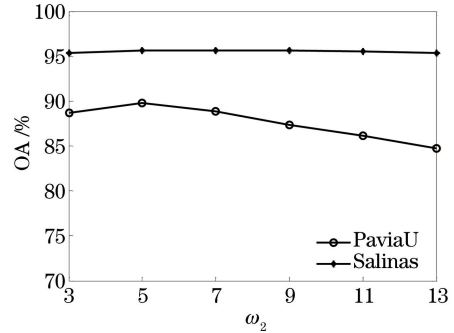


图 4 不同 ω_2 值下的分类精度

Fig. 4 Classification accuracies under different ω_2

是因为随着 ω_2 值的增加,空间邻域内的像元逐渐增加,其均值向量更能代表同类地物的典型特征,像元在降维后集中于均值向量附近,即空间聚集性较强;当邻域进一步增大时,与中心像元距离逐渐增大,属于同类地物的概率逐渐变小,而出现异类地物的概率逐渐增大,其均值向量偏离了同类地物的典型特征,使像元在投影后也偏离了同类地物,故分类精度不断降低。同理,相比于 PaviaU 图像,Salinas 数据集主要由块状分布的大片均匀同类地物构成,当 ω_1 选取为 9 时,既能达到较高的分类精度,也有较好的计算效率; ω_2 变化时,分类精度变化极小,故本文选 ω_2 为 5。

表 1 给出了算法各步骤对最终分类精度的贡献。表中除 S^3 ELD-SSNN 算法外,其余各算法的空间邻域均设置为 3。各算法中, S^3 ELD1 是只考虑空间近邻像元散度矩阵 F_w 贡献的结果, S^3 ELD2 是只考虑空谱距离相似性度量改善流形学习的结果, S^3 ELD-SSNN1 体现了 SSNN 分类器的作用。除 S^3 ELD-SSNN 和 S^3 ELD-SSNN1 外,其余均使用最近邻进行分类。

表 1 算法各步骤对最终分类精度的贡献

Table 1 Contributions of each algorithm step to final classification accuracy

Data sets	Baseline	SELDnpe	S^3 ELD1	S^3 ELD2	S^3 ELD	S^3 ELD-SSNN1	S^3 ELD-SSNN	%
PaviaU	66.74	74.18	77.71	75.31	77.98	86.36	90.05	
Salinas	82.51	86.88	88.13	87.56	88.25	92.02	95.60	

表 1 中比较了特征提取(Baseline 与 SELDnpe)、空间近邻结构保持(S^3 ELD1 与 SELDnpe)、空谱距离改善流形学习(S^3 ELD2 与 SELDnpe)、 S^3 ELD 算法(S^3 ELD 与 SELDnpe)、SSNN 分类器提升分类精度(S^3 ELD 与 S^3 ELD-SSNN1)和 S^3 ELD-SSNN 参数调节(S^3 ELD-SSNN1 与 S^3 ELD-SSNN)等步骤对分类精度的贡献。以 PaviaU 数据集的结果为例,与 SELDnpe 相比, S^3 ELD1 的分类精度提升了约 3%, S^3 ELD2 提升了 1%,分别说明了空间近邻结构保持和基于空谱距离的相似性度量改善流形学习的效果;两者结合后,分类精度提升了约 4%,体现 S^3 ELD 算法的优越性。与最近邻分类的结果对比,使用 SSNN 分类器后,分类精度又提升了 8%,体现了基于空谱距离的相似性度量在高光谱图像地物分类的优势。总体来看, S^3 ELD-SSNN 在两个数据集上的分类精度,比 SELDnpe 分别提升了 16%和 9%,这是因为 S^3 ELD 和 SSNN 都能有效地利用高光谱图像的空间信息,从光谱域的可分性、空间域的聚集性和基于空谱距离相似性度量等方面,改善了特征提取效果,提升了分类精度。Salinas 数据集的结果类似,不再赘述。

3.4 PaviaU 实验结果及分析

根据实验设置,每类地物取 10,20,30 个标记训练样本进行实验。图 5 为各算法在 PaviaU 数据集上不同标记样本、不同维数下的分类精度曲线,表 2 为对应的最大总体分类精度。

由图 5 可知,随着低维嵌入维数的增加,各算法的分类精度不断增加,并逐渐达到最大值,之后保持一定值或稍有降低。这是由于嵌入特征维数越高,嵌入特征包含的信息越丰富,分类精度也相应地变大;但是当有足够的特征用于分类时,特征维数增加对分类精度提升作用非常有限;保留 30 个低维嵌入特征已经达到最高分类精度。在表 2 中,各算法的分类精度随着标记样本数的增加而增加,这是因为标记样本越多,包含的标记信息越丰富,提取的低维特征的判别能力越强,其分类精度越好。

根据图 5 和表 2 可知,本研究所提出的 S^3 ELD 算法在分类性能上优于其他几种特征提取算法,其使用

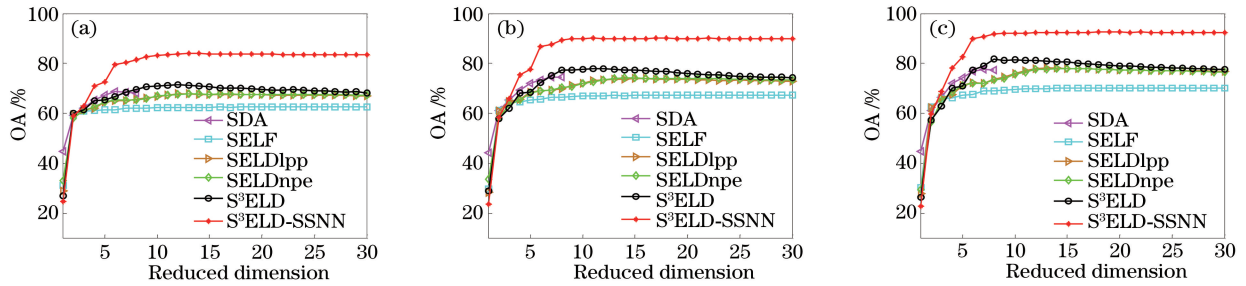


图 5 PaviaU 数据集采用不同算法在不同标记样本、不同维数下的分类精度。(a) 10 个标记样本；
(b) 20 个标记样本；(c) 30 个标记样本

Fig. 5 Classification accuracies of PaviaU data set with different algorithms under different dimensions and different labeled samples. (a) 10 labeled samples; (b) 20 labeled samples; (c) 30 labeled samples

最近邻分类时高出其他算法约 2%~9%，使用 SSNN 时高出约 9%~19%。这是由于 SDA、SELF、SELDlpp 和 SELDnpe 等算法都没有考虑高光谱图像特有的空间一致性，其提取的低维特征没有保存像元的空间近邻结构。S³ELD 算法同时利用了标记样本和无标记样本，自动融合了光谱信息和空间信息，不仅通过类内散度极小化保证光谱域的分类可分，还保存了图像在空间域的空间近邻结构，而且增强了空间位置较近的光谱近邻像元对流形结构的挖掘能力。这些都强化了同类像元和同一空间邻域像元的聚集性，改善了低维特征的判别能力，进而提高了分类精度。

表 2 PaviaU 数据集上分类精度随训练样本数量的变化(平均值±标准差)

Table 2 Classification accuracies varies with the number of labeled samples in PaviaU data set (mean±standard deviation)

Classifier	Number of labeled sample	SDA / %	SELF / %	SELDlpp / %	SELDnpe / %	S ³ ELD / %
NN	10	69.10±3.92	62.41±3.22	67.76±3.00	67.83±2.67	71.32±3.13
	20	74.88±2.04	67.24±2.51	73.84±1.49	74.18±1.76	77.98±1.04
	30	77.94±1.85	70.09±1.25	78.09±0.97	77.81±1.23	81.71±1.13
SSNN	10	74.13±2.66	65.39±2.80	73.20±3.12	74.73±2.46	83.87±3.10
	20	81.77±2.32	70.82±1.55	80.48±2.02	83.03±1.62	90.05±1.52
	30	87.51±1.02	75.45±1.88	86.19±1.61	88.47±1.69	92.51±1.26

使用 SSNN 分类时，除 S³ELD 外其余算法空间邻域均设置为 3。由表 2 可知，SSNN 的分类精度始终高于最近邻约 3%~12%，这是因为 SSNN 采用基于空谱距离的相似性度量，实质是利用空间邻域内所有像元来替代单一像元进行度量，有效克服了同类地物中差异性较大的孤立噪点的影响，增大了分类过程中正确归类的可能性。

表 3 是选取 30 个标记样本时不同地物的分类精度。S³ELD-SSNN 算法在大部分地物类别都具有较好的分类效果，尤其是对于“meadows”和“bare soil”的分类，并且 S³ELD-SSNN 算法的总体精度、精度和 Kappa 系数均高于其他算法。这是因为 S³ELD-SSNN 算法能够表征高光谱数据集的特有的空间一致性，获取更有效的判别特征，提升分类精度。图 6 为对应的分类图，可以看出 S³ELD-SSNN 算法获得了更多光滑区域。




图 6 不同算法下 PaviaU 图像的分类图。(a) SDA; (b) SELF; (c) SELDlpp; (d) SELDnpe; (e) S³ELD; (f) S³ELD-SSNN

Fig. 6 Classification maps for PaviaU images with different algorithms. (a) SDA; (b) SELF; (c) SELDlpp; (d) SELDnpe; (e) S³ELD; (f) S³ELD-SSNN

表 3 PaviaU 数据集各类地物在不同算法下的分类精度

Table 3 Classification accuracies of each surface feature in PaviaU data set with different algorithms

Class	Number of labeled sample	Test	SDA / %	SELF / %	SELDlpp / %	SELDnpe / %	S ³ ELD / %	S ³ ELD-SSNN / %
Asphalt	30	6601	72.65	68.24	71.39	67.12	69.34	89.73
Meadows	30	18619	75.31	65.31	77.27	78.85	82.59	92.49
Gravel	30	2069	71.59	62.26	70.79	68.02	71.18	89.16
Trees	30	3034	90.35	88.29	89.31	90.03	92.37	94.61
Metal sheets	30	1315	99.57	99.14	99.61	99.57	99.82	100.00
Bare soil	30	4099	78.80	65.26	78.09	80.06	92.63	98.40
Bitumen	30	1300	89.38	87.82	93.42	91.33	85.40	98.65
Bricks	30	3652	75.67	69.45	75.00	71.41	66.90	83.06
Shadows	30	917	99.96	99.95	99.97	99.86	99.93	99.75
OA			77.94	70.09	78.09	77.81	81.71	92.51
Kappa			71.86	62.30	72.43	72.15	76.28	90.21
AA			83.70	78.41	83.87	82.91	84.46	93.98

3.5 Salinas 实验结果及分析

根据实验设置,图 7 为各算法在 Salinas 数据集上不同维数下的分类精度曲线,表 4 为不同标记样本数下的最大总体分类精度。从图 7 和表 4 可以看出,其他几种算法的分类精度均稍低于 S³ELD 算法。这是因为 SDA、SELF、SELDlpp 和 SELDnpe 等算法虽然充分利用了标记样本的判别信息,保持了数据集的可分性,且通过较多的未标记样本挖掘数据集的局部流形结构或最大的方差信息,但都忽视了高光谱图像中不同地物的空间分布规律。而 S³ELD 算法不仅保持了同类数据的散度极小化,还能增强同一空间邻域像元的聚集性,同时在挖掘流形结构时自动融入了空间信息,使同类像元和空间近邻像元的相似性和聚集性在低维空间中保持不变,从而达到了较高的分类精度;使用 SSNN 分类器后,受益于基于空谱距离的相似性度量的良好效果,分类精度又有了进一步提高。




图 7 Salinas 数据集采用不同算法在不同标记样本、不同维数下的分类精度。(a) 10 个标记样本; (b) 20 个标记样本; (c) 30 个标记样本

Fig. 7 Classification accuracies of Salinas data set with different algorithms under different dimensions and different labeled samples. (a) 10 labeled samples; (b) 20 labeled samples; (c) 30 labeled samples

表 4 不同标记样本数目下的最大总体分类精度(平均值±标准差)

Table 4 Maximum overall classification accuracies varies with different numbers of labeled sample (mean±standard deviation)

Classifier	Number of labeled sample	SDA / %	SELF / %	SELDlpp / %	SELDnpe / %	S ³ ELD / %
NN	10	86.07±1.59	82.40±1.10	85.13±0.94	85.10±1.01	86.62±1.35
	20	87.68±1.08	83.57±1.05	86.60±0.99	86.88±0.84	88.25±0.97
	30	87.92±0.67	84.06±0.57	86.67±0.49	87.01±0.60	88.62±0.95
SSNN	10	89.37±1.77	85.37±0.77	88.51±1.12	88.90±1.07	92.68±1.06
	20	91.56±1.18	87.50±1.09	90.48±1.05	91.07±0.93	95.60±0.80
	30	92.33±0.65	87.76±0.74	91.04±0.65	91.74±0.72	96.29±0.49

3.6 时间复杂度分析

S^3 ELD 算法能有效地利用高光谱图像的空间信息,保存了像元的空间近邻结构和空间布局,算法复杂度可表示为 $O\{n_1d^2\omega^2 + 3n_u^2d + n_u[2d^2 + (k^3 + \omega_1^2)d]\}$, 主要受标记样本数 n_1 、未标记样本数 n_u 、波段数 d 、空间邻域 ω 和近邻点数 k 的影响。SDA 算法能保存数据集的局部几何特性,复杂度为 $O[(n_1 + c)d^2 + n_u d^2 + 2n_u^2d]$; SELDlpp 和 SELDnpe 算法集成了 LDA 的判别能力和 LPP、NPE 的流形结构保存能力,复杂度为 $O(n_1d^2 + 3n_u^2d + 2n_u d^2)$, SELDnpe 计算重构系数额外还需要 $O(n_u dk^3)$ 的算法复杂度; SELF 算法充分利用了样本的方差信息,复杂度为 $O(3n_1^2d + 2n_1d^2 + n_u d^2)$ 。由于 n_u 通常大于 n_1 ,故 S^3 ELD 与 SELDnpe 算法的复杂度差异较小。对于分类器来说,易知最近邻分类器的复杂度为 $O(Nrn_1)$, 而 SSNN 分类器的复杂度为 $O[Nr(n_1 + \omega_2^2)]$, 即二者的复杂度差别不大。

以选取 20 个标记样本为例,表 5 是不同特征提取算法的运行时间,实验硬件平台的 CPU 为 Intel(R) Core(TM) i7-2600 3.40 GHz,随机存取存储器(RAM)为 16.0 GB,软件版本为 Matlab 7.0。 S^3 ELD 提取特征算法的运行时间与 SELDnpe 差别较小,这与复杂度分析的结论一致。由于 Salinas 数据集的波段数是 PaviaU 的近 2 倍,且地物类别较多,每次选取的样本总数也较多,故 Salinas 数据集上各算法耗时比 PaviaU 数据集多。表 5 中 SELF 算法的运行时间最长,这主要是由于程序设计的原因。

表 5 各算法的运行时间

Table 5 Running time of different algorithms

Data set	SDA	SELF	SELDlpp	SELDnpe	S^3 ELD
PaviaU	0.56	2.36	0.47	0.89	0.93
Salinas	1.82	10.94	1.62	2.51	3.09

4 结 论

传统的基于特征提取的高光谱分类算法只对图像的光谱特征进行分析,忽略了高光谱数据集特有的丰富的空间信息,故分类效果较差。针对该问题,研究了基于 S^3 ELD 的特征提取和基于空谱距离相似性度量的 SSNN 分类器相结合的高光谱分类算法。结果发现在特征提取过程中加入空间信息约束,能更有效地表征高光谱图像特有的空间一致性和数据集的内在结构,提升低维嵌入特征的可分性;通过使用 SSNN 分类器,能进一步将空间邻域信息引入分类过程,实现了更好的相似性度量效果,从而得到了更高的分类准确率。在不同数据集和不同样本数下进行实验,本算法始终保持着较高的分类精度,验证了本算法的有效性。

参 考 文 献

- [1] Fauvel M, Tarabalka Y, Benediktsson A, *et al.* Advances in spectral-spatial classification of hyperspectral images[C]. Proceedings of the IEEE, 2013, 101(3): 652-675.
- [2] Liu Dawei, Han Ling, Han Xiaoyong. High spatial resolution remote sensing image classification based on deep learning[J]. Acta Optica Sinica, 2016, 36(4): 0428001.
刘大伟, 韩 玲, 韩晓勇. 基于深度学习的高分辨率遥感影像分类研究[J]. 光学学报, 2016, 36(4): 0428001.
- [3] Ye Zhen, Bai Lin, Nian Yongjian. Hyperspectral image classification algorithm based on Gabor feature and locality-perserving dimension reduction[J]. Acta Optica Sinica, 2016, 36(10): 1028003.
叶 珍, 白 璘, 粘永健. 基于 Gabor 特征与局部保护降维的高光谱图像分类算法[J]. 光学学报, 2016, 36(10): 1028003.
- [4] Li Zhimin, Zhang Jie, Huang Hong, *et al.* Semi-supervised Laplace discriminant embedding for hyperspectral image classification[J]. Journal of Electronics & Information Technology, 2015, 37(4): 995-1001.
李志敏, 张 杰, 黄 鸿, 等. 面向高光谱图像分类的半监督 Laplace 鉴别嵌入[J]. 电子信息学报, 2015, 37(4): 995-1001.
- [5] Bandos T, Bruzzone L, Camps-valls G. Classification of hyperspectral images with regularized linear discriminant analysis[J]. IEEE Transactions on Geoscience and Remote Sensing, 2009, 47(3): 862-873.
- [6] Roweis S, Saul L. Nonlinear dimensionality reduction by locally linear embedding[J]. Science, 2000, 290(5500): 2323-2326.

- [7] Belkin M, Niyogi P. Laplacian eigenmaps and spectral techniques for embedding and clustering[C]. Proceedings of the 14th International Conference on Neural Information Processing Systems: Natural and Synthetic, 2001, 14(6): 585-591.
- [8] He X F, Niyogi P. Locality preserving projections [C]. Proceedings of Advance in Neural Information Processing Systems, 2005, 16(1): 153-160.
- [9] He X F, Cai D, Yan S C, *et al.* Neighborhood preserving embedding[C]. Proceedings of the 10th IEEE International Conference on Computer Vision, 2005, 2(23): 1208-1213.
- [10] Cai D, He X F, Han J. Semi-supervised discriminant analysis [C]. Proceedings of the 11th IEEE International Conference on Computer Vision, 2008, 5: 1-7.
- [11] Sugiyama M, Ide T, Nakajima S, *et al.* Semi-supervised local Fisher discriminant analysis for dimensionality reduction [J]. Machine Learning, 2010, 78(1): 36-61.
- [12] Liao W, Pizurica A, Scheunders P, *et al.* Semisupervised local discriminant analysis for feature extraction in hyperspectral images[J]. IEEE Transactions on Geoscience and Remote Sensing, 2013, 51(1): 184-198.
- [13] Zhou Y C, Peng J T, Chen C L P. Dimension reduction using spatial and spectral regularized local discriminant embedding for hyperspectral image classification[J]. IEEE Transactions on Geoscience and Remote Sensing, 2015, 53(2): 1082-1095.
- [14] Li J, Marpu P R, Plaza A, *et al.* Generalized composite kernel framework for hyperspectral image classification[J]. IEEE Transactions on Geoscience and Remote Sensing, 2013, 51(9): 4816-4829.
- [15] Kang X, Li S, Benediktsson J A. Spectral-spatial hyperspectral image classification with edge-preserving filtering[J]. IEEE Transactions on Geoscience and Remote Sensing, 2014, 52(2): 2666-2677.
- [16] Li M, Ma A D, Cai J, *et al.* Graph-based semi-supervised learning for spectral-spatial hyperspectral image classification [J]. Pattern Recognition Letters, 2016, 83: 133-142.
- [17] Pu H Y, Chen Z, Wang B, *et al.* A novel spatial-spectral similarity measure for dimensionality reduction and classification of hyperspectral imagery[J]. IEEE Transactions on Geoscience and Remote Sensing, 2014, 52(11): 7008-7022.
- [18] Huang Hong, Zhen Xinlei, Luo Fulin, *et al.* Hyperspectral image classification with combination of weighted mean filter and manifold reconstruction preserving embedding[J]. Acta Photonica Sinica, 2016, 45(10): 1030001.
黄 鸿, 郑新磊, 罗甫林, 等. 融合加权均值滤波与流形重构保持嵌入的高光谱影像分类[J]. 光子学报, 2016, 45(10): 1030001.
- [19] Hsiuhan L Y, Melba M C. Spectral and spatial proximity-based manifold alignment for multitemporal hyperspectral image classification[J]. IEEE Transactions on Geoscience and Remote Sensing, 2016, 54(1): 51-64.
- [20] Dalton L, Saurabh P, Melba M C, *et al.* Manifold-learning based feature extraction for classification of hyperspectral data: a review of advances in manifold learning[J]. IEEE Signal Processing Magazine, 2014, 31(1): 55-66.